



UNIVERSIDAD DE VALLADOLID

FACULTAD DE MEDICINA  
ESCUELA DE INGENIERÍAS INDUSTRIALES

TRABAJO DE FIN DE GRADO  
GRADO EN INGENIERÍA BIOMÉDICA

**INVESTIGACIÓN DE LA DINÁMICA DE REDES  
CEREBRALES DURANTE LA TERAPIA DE  
OBSERVACIÓN DE ACCIONES MEDIANTE  
ALGORITMOS DE DETECCIÓN DE  
COMUNIDADES MULTICAPA**

Autora:  
**Elena Gómez Arranz**

Tutores:  
**Dr. D. Javier Gómez Pilar**

**D.<sup>a</sup> Martina Corda Tesi**

Valladolid, septiembre de 2025



---

TÍTULO:	<b>Investigación de la dinámica de redes cerebrales durante la terapia de observación de acciones mediante algoritmos de detección de comunidades multicapa</b>
AUTORA:	<b>D.<sup>a</sup> Elena Gómez Arranz</b>
TUTOR/A:	<b>D.<sup>a</sup> Martina Corda Tesi</b> <b>Dr. D. Javier Gómez Pilar</b>
DEPARTAMENTO:	<b>Teoría de la Señal y Comunicaciones e Ingeniería Telemática</b>

---

### **Tribunal**

---

PRESIDENTE:	<b>Dr. D. Jesús Poza Crespo</b>
SECRETARIO:	<b>Dr. D. Javier Gómez Pilar</b>
VOCAL:	<b>Dr. D. Carlos Gómez Peña</b>
SUPLENTE 1:	<b>Dr. D.<sup>a</sup> María García Gadañón</b>
SUPLENTE 2:	<b>Dr. D. Daniel Álvarez González</b>

---

---

FECHA:	<b>Septiembre de 2025</b>
CALIFICACIÓN:	

---



# Agradecimientos

Quisiera comenzar agradeciendo a mis tutores, Javier Gómez Pilar y Martina Corda Tesi, por brindarme siempre su ayuda y conocimientos, y por guiarme en cada paso de este trabajo. También quiero expresar mi gratitud a Anna Maria Bianchi por abrirme las puertas de su laboratorio en el Politécnico de Milán y darme la oportunidad de formar parte de su proyecto durante mi estancia Erasmus, una experiencia inolvidable que ha marcado tanto mi vida personal como académica.

A mi familia, porque sin ellos nunca me habría convertido en la mujer que soy hoy. Gracias por darme siempre la oportunidad de crecer desde el respeto, la libertad, el esfuerzo y el trabajo duro. Gracias también por hacer posible que viviera un año en Milán y aprendiera tanto, pudiendo plasmar aquí todo ese aprendizaje.

A mis abuelos, que siempre me han enseñado que la humildad es el camino que más lejos te lleva. Sé que siempre estaréis orgullosos de mí, como yo lo he estado de vosotros. Y a mi abuelo, que nunca deja de recordarme: “*Vete siempre con los ojos bien abridos*”.

A mis amigos de siempre, por haberme dejado crecer a vuestro lado. Un pedacito de mí siempre estará hecho de vosotros. A mis amigas de la carrera, porque sin vosotras no sé si hubiera sido capaz de llegar hasta aquí. Y, por último, a mis amigos del Erasmus, habéis sido un regalo inesperado y un gran descubrimiento.

Agradecerte a ti también, María. No sé muy bien lo que me deparará la vida, pero ojalá que tú estés en ella.

A todos, gracias.



# Resumen

La Terapia de Observación de la Acción (AOT) ha despertado en los últimos años un gran interés en el ámbito de la neurociencia y la neurorrehabilitación. Esta técnica se fundamenta en la activación del sistema de neuronas espejo, que se activa tanto al ejecutar un movimiento como al observarlo. Gracias a esta propiedad, la AOT permite estimular redes motoras sin necesidad de realizar un movimiento físico, lo que la convierte en una estrategia especialmente relevante en pacientes con limitaciones motoras. La literatura científica ha mostrado que la AOT favorece procesos de aprendizaje motor y plasticidad cerebral, planteándose como una estrategia complementaria a la fisioterapia convencional. Sin embargo, todavía existe una necesidad de comprender con mayor precisión cómo esta terapia modula la conectividad funcional del cerebro, especialmente desde una perspectiva dinámica y con medidas que vayan más allá de los análisis estáticos tradicionales.

El presente Trabajo de Fin de Grado tiene como hipótesis que la AOT induce reorganizaciones dinámicas en las redes cerebrales, que pueden observarse a través de cambios en su estructura modular a lo largo del tiempo. Por ello, el objetivo principal es caracterizar estas reorganizaciones mediante registros de electroencefalografía (EEG) de 46 sujetos sanos durante la observación de videos de diferentes acciones, analizados con métricas de conectividad y algoritmos de detección de comunidades. El EEG constituye una herramienta idónea debido a su alta resolución temporal, que permite capturar variaciones rápidas en la actividad cerebral, y a su facilidad de aplicación no invasiva.

La conectividad funcional se estimó mediante el índice *weighted Phase Lag Index* (wPLI), una métrica basada en el desfase de fase que reduce la influencia del volumen conductor y resulta adecuada para el análisis de señales EEG. A continuación, se aplicó un enfoque de ventanas deslizantes para construir matrices dinámicas de conectividad a lo largo del tiempo. Estas matrices se analizaron utilizando el algoritmo *GenLouvain* en un marco multicapa, lo que permitió detectar comunidades funcionales y estudiar su evolución. Se calcularon métricas como el número y la dimensión de las comunidades, la matriz de consenso y el índice *Normalized Mutual Information* (NMI) para evaluar la estabilidad y reorganización modular. Asimismo, se exploró la influencia de parámetros como el acoplamiento temporal ( $\omega$ ) en la detección de comunidades.

Los resultados obtenidos demuestran que la AOT induce reconfiguraciones modulares alrededor del inicio de los estímulos, con diferencias claras entre bandas de frecuencia. En la banda alfa, se observaron reorganizaciones iniciales seguidas de una tendencia a recuperar la estabilidad, lo que sugiere un mecanismo de ajuste funcional tras el estímulo. En la banda beta, en cambio, las redes mostraron una fragmentación más acusada y una dinámica más variable, lo que apunta a un mayor involucramiento de procesos motores y de control cognitivo. Además, se comprobó que la elección del parámetro  $\omega$  modula de forma significativa la estabilidad de las comunidades, confirmando la necesidad de una selección cuidadosa para interpretar la dinámica funcional.

En conjunto, este trabajo aporta evidencia de que la AOT genera reorganizaciones dinámicas en la conectividad cerebral que pueden captarse mediante EEG. Más allá de los análisis estáticos, el uso de métricas de modularidad multicapa ofrece una aproximación robusta para estudiar la evolución temporal de las redes cerebrales. Estos

hallazgos refuerzan la idea de que la AOT no solo activa las áreas motoras, sino que también reorganiza de manera dinámica la arquitectura funcional del cerebro, abriendo nuevas vías para su aplicación clínica en el ámbito de la neurorrehabilitación.

**Palabras clave:** Electroencefalografía (EEG), Terapia de Observación de la Acción (AOT), Conectividad funcional dinámica (dFC), modularidad, detección de comunidades, wPLI.

# Abstract

Action Observation Therapy (AOT) has gained increasing attention in recent years within the fields of neuroscience and neurorehabilitation. This technique is based on the activation of the mirror neuron system (MNS), which responds both during the execution of a movement and when observing it. Thanks to this property, AOT enables the stimulation of motor networks without the need to physically perform the movement, making it particularly relevant for patients with motor limitations. Scientific literature has shown that AOT promotes motor learning and brain plasticity and has been proposed as a complementary strategy to conventional physiotherapy. However, there is still a need to better understand how this therapy modulates brain functional connectivity, especially from a dynamic perspective and through measures that go beyond traditional static analyses.

The present Bachelor Thesis hypothesizes that AOT induces dynamic reorganizations in brain networks, which can be observed through changes in their modular structure over time. The main objective is therefore to characterize these reorganizations using EEG recordings from 46 healthy subjects during the observation of action videos, analyzed through connectivity metrics and community detection algorithms. EEG provides an ideal tool for this purpose due to its high temporal resolution, which captures rapid fluctuations in brain activity, and its non-invasive nature.

Functional connectivity was estimated using the weighted Phase Lag Index (wPLI), a phase-based metric that minimizes the influence of volume conduction and is well-suited for EEG analysis. A sliding window approach was then applied to build dynamic connectivity matrices over time. These matrices were processed with the GenLouvain algorithm in a multilayer framework, allowing the detection of functional communities and the study of their evolution. Metrics such as the number and size of communities, consensus matrices, and the Normalized Mutual Information (NMI) index were calculated to evaluate modular stability and reorganization. Additionally, the influence of parameters such as temporal coupling ( $\omega$ ) on community detection was explored.

The results show that AOT induces modular reconfigurations around the onset of stimuli, with clear differences between frequency bands. In the alpha band, initial reorganizations were followed by a trend towards stability, suggesting a functional adjustment mechanism after the stimulus. In contrast, beta-band networks exhibited stronger fragmentation and more variable dynamics, pointing to greater involvement of motor and cognitive control processes. Furthermore, the choice of the  $\omega$  parameter significantly modulated community stability, highlighting the need for careful selection when interpreting dynamic connectivity.

Overall, this work provides evidence that AOT generates dynamic reorganizations in brain connectivity that can be captured through EEG. Beyond static analyses, the use of multilayer modularity metrics offers a robust approach to studying the temporal evolution of brain networks. These findings reinforce the idea that AOT not only activates motor areas but also dynamically reorganizes the brain's functional architecture, opening new avenues for clinical applications in neurorehabilitation.

**Keywords:** Electroencephalography (EEG), Action Observation Therapy (AOT), Dynamic Functional Connectivity (dFC), modularity, community detection, wPLI.

# Índice general

<b>Capítulo 1. Introducción y marco teórico .....</b>	<b>17</b>
1.1. Introducción.....	17
1.2. Terapia de Observación de la Acción.....	18
1.3. Electroencefalografía.....	19
1.3.1. Ritmos de frecuencia.....	19
1.3.2. Limitaciones del EEG: ruido, artefactos .....	20
1.4. Conectividad cerebral .....	21
1.4.1. Tipos: estructural, funcional y efectiva.....	21
1.4.2. Dominios de análisis .....	22
1.4.3. Métricas de conectividad.....	24
1.4.4. Limitaciones en el análisis de conectividad .....	25
1.5. Conectividad funcional dinámica .....	25
1.5.1. Métodos de estimación: <i>sliding window</i> .....	26
1.5.2. Matrices de conectividad.....	27
1.6. Teoría de grafos .....	28
1.6.1. Algoritmo de detección de comunidades .....	29
1.7. Descripción del documento .....	31
<b>Capítulo 2. Revisión del estado del arte: Terapia de Observación de la Acción y Conectividad Funcional dinámica.....</b>	<b>33</b>
2.1. Estudios previos en AOT y conectividad cerebral .....	33
2.2. Limitaciones de la literatura existente .....	34
<b>Capítulo 3. Hipótesis y Objetivos .....</b>	<b>37</b>
3.1. Hipótesis .....	37
3.2. Objetivos del trabajo.....	37
<b>Capítulo 4. Materiales y métodos .....</b>	<b>39</b>
4.1. Base de datos y paradigma experimental.....	39
4.2. Preprocesado y análisis de datos.....	40
4.3. Estimación de la conectividad funcional .....	41
4.3.1. Índice wPLI .....	41
4.4. Detección de comunidades multicapa .....	44
4.4.1. Matriz de modularidad .....	44
4.4.2. Algoritmo <i>GenLouvain</i> .....	45
4.5. Métricas para el análisis dinámico de comunidades.....	46
4.5.1. Número de comunidades .....	46
4.5.2. Dimensión de comunidades.....	47
4.5.3. Matriz de consenso .....	47
4.5.4. NMI .....	48
4.6. Análisis estadístico .....	49
<b>Capítulo 5. Resultados.....</b>	<b>51</b>
5.1. Reconfiguración modular inducida por la AOT .....	51
5.2. Influencia del parámetro $\omega$ en la organización modular .....	57

5.3. Evaluación mediante métricas dinámicas .....	60
5.3.1. Número de comunidades .....	60
5.3.2. Dimensión de comunidades.....	65
5.3.3. Matriz de consenso y NMI .....	70
<b>Capítulo 6. Discusión .....</b>	<b>83</b>
6.1. Implicaciones de la reconfiguración modular observada .....	83
6.2. Interpretación de las métricas comunitarias .....	84
6.3. Limitaciones .....	87
<b>Capítulo 7. Conclusiones.....</b>	<b>89</b>
7.1. Líneas futuras.....	89
<b>Bibliografía .....</b>	<b>91</b>

# Índice de figuras

## CAPÍTULO 1: Introducción y marco teórico

---

<b>Figura 1.1</b> Representación de cuatro ritmos cerebrales típicos en condiciones normales, ordenados de mayor a menor frecuencia: beta, alfa, theta y delta. Imagen adaptada de (Sanei Saeid and Chambers J.A, 2007).....	20
<b>Figura 1.2</b> Clasificación de las principales métricas utilizadas para el análisis de conectividad cerebral, agrupadas según su dominio de aplicación (temporal, frecuencial o de información) y su naturaleza (dirigida o no dirigida). Imagen adaptada de (Chiaroni <i>et al.</i> , 2023).....	23
<b>Figura 1.3</b> Representación de una matriz de adyacencia simétrica (panel A) y una matriz de adyacencia asimétrica (panel B). Imagen adaptada de (Rubinov and Sporns, 2010).....	27

## CAPÍTULO 4: Materiales y métodos

---

<b>Figura 4.1</b> Secuencia de estimulación para las tareas de AO y MI. Imagen adaptada de (Coelli <i>et al.</i> , 2023).....	40
<b>Figura 4.2</b> Ejemplo de matrices de conectividad funcional obtenidas mediante el índice wPLI en la condición W1 (acción de recoger monedas) y en la banda alfa (8–13 Hz).....	43

## CAPÍTULO 5: Resultados

---

<b>Figura 5.1</b> Particiones modulares de los 55 nodos en cada sujeto (W1, banda alfa) a lo largo de 22 ventanas temporales.....	52
<b>Figura 5.2</b> Particiones modulares de los 55 nodos en cada sujeto (W1, banda beta) a lo largo de 22 ventanas temporales.....	53
<b>Figura 5.3</b> Particiones modulares de los 55 nodos en cada sujeto (W2, banda alfa) a lo largo de 22 ventanas temporales.....	54
<b>Figura 5.4</b> Particiones modulares de los 55 nodos en cada sujeto (W2, banda beta) a lo largo de 22 ventanas temporales.....	56
<b>Figura 5.5</b> Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 0.1$ ) .....	58
<b>Figura 5.6</b> Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 0.5$ ) .....	58
<b>Figura 5.7</b> Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 0.7$ ) .....	59
<b>Figura 5.8</b> Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 1$ ) .....	59
<b>Figura 5.9</b> Ejemplo del número promedio de comunidades en la condición W1, banda alfa, para distintos valores de $\omega$ .....	61
<b>Figura 5.10</b> Ejemplo del número promedio de comunidades en la condición W1, banda beta, para distintos valores de $\omega$ .....	62

<b>Figura 5.11</b> Ejemplo del número promedio de comunidades en la condición W2, banda alfa, para distintos valores de $\omega$ .....	64
<b>Figura 5.12</b> Ejemplo de la dimensión promedio de comunidades en la condición W1, banda alfa, para distintos valores de $\omega$ .....	66
<b>Figura 5.13</b> Ejemplo de la dimensión promedio de comunidades en la condición W1, banda beta, para distintos valores de $\omega$ .....	67
<b>Figura 5.14</b> Ejemplo de la dimensión promedio de comunidades en la condición W2, banda alfa, para distintos valores de $\omega$ .....	68
<b>Figura 5.15</b> Ejemplo de la dimensión promedio de comunidades en la condición W2, banda beta, para distintos valores de $\omega$ .....	69
<b>Figura 5.16</b> Representación de la matriz de consenso para la condición W1 en banda alfa con $\omega = 1$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.	71
<b>Figura 5.17</b> Representación de la matriz de consenso para la condición W1 en banda alfa con $\omega = 0.5$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.	72
<b>Figura 5.18</b> Evolución del índice NMI para la condición W1 en banda alfa con $\omega = 1$ .....	73
<b>Figura 5.19</b> Evolución del índice NMI para la condición W1 en banda alfa con $\omega = 0.5$ .....	73
<b>Figura 5.20</b> Representación de la matriz de consenso para la condición W1 en banda beta con $\omega = 1$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.	75
<b>Figura 5.21</b> Representación de la matriz de consenso para la condición W1 en banda beta con $\omega = 0.5$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.	76
<b>Figura 5.22</b> Evolución del índice NMI para la condición W1 en banda beta con $\omega = 1$ .....	77
<b>Figura 5.23</b> Evolución del índice NMI para la condición W1 en banda beta con $\omega = 0.5$ .....	77
<b>Figura 5.24</b> Representación de la matriz de consenso para la condición W3 en banda alfa con $\omega = 0.1$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.	79
<b>Figura 5.25</b> Representación de la matriz de consenso para la condición W3 en banda beta con $\omega = 0.1$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.	80
<b>Figura 5.26</b> Evolución del índice NMI para la condición W3 en banda alfa con $\omega = 0.1$ .....	81
<b>Figura 5.27</b> Evolución del índice NMI para la condición W3 en banda beta con $\omega = 0.1$ .....	81

## CAPÍTULO 6: Discusión

---

<b>Figura 6.1</b> Evolución del número de comunidades en función de la ventana temporal para distintos valores de $\omega$ (0.1, 0.5, 0.7 y 1) en la banda analizada, sin aplicar <i>thresholding</i> .....	86
<b>Figura 6.2</b> Evolución del número de comunidades en función de la ventana temporal para distintos valores de $\omega$ (0.1, 0.5, 0.7 y 1) en la misma banda, tras aplicar <i>thresholding</i> .....	86

# Índice de tablas

<b>Tabla 1</b> Resultados del test de Friedman aplicados al número de comunidades en la condición W1, banda alfa. Se muestran los <i>p</i> -valores obtenidos en cada una de las 22 ventanas temporales.	61
<b>Tabla 2</b> Resultados del test de Friedman aplicados al número de comunidades en la condición W1, banda beta. Se muestran los <i>p</i> -valores obtenidos en cada una de las 22 ventanas temporales.	63
<b>Tabla 3</b> Resultados del test de Friedman aplicados al número de comunidades en la condición W2, banda alfa. Se muestran los <i>p</i> -valores obtenidos en cada una de las 22 ventanas temporales.	64



# **Capítulo 1. Introducción y marco teórico**

## **1.1. Introducción**

El cerebro humano, caracterizado por su extrema complejidad, funciona gracias a dinámicas de actividad espontánea correlacionada entre distintas regiones cerebrales. Durante mucho tiempo, se consideró que la conectividad funcional era un fenómeno estacionario, asumiendo que las interacciones entre regiones cerebrales eran estáticas (Allen *et al.*, 2018). Sin embargo, investigaciones más recientes han demostrado que estas interacciones son, en realidad, dinámicas: fluctúan de forma continua, reflejando los cambios en los estados funcionales del cerebro y ocurriendo a diferentes escalas temporales (Allen *et al.*, 2018).

Una potente herramienta para estudiar esta conectividad funcional dinámica es la electroencefalografía (EEG), ya que permite observar la evolución temporal de dichas interacciones con alta resolución temporal. Esto brinda una oportunidad única para comprender cómo cambian estas conexiones a lo largo del tiempo y cómo pueden verse afectadas en diferentes contextos, incluyendo diversas enfermedades (O'Neill *et al.*, 2018).

Paralelamente, diversos estudios han demostrado que la observación de acciones puede facilitar tanto el aprendizaje como el rendimiento motor. En el ámbito clínico, esta estrategia ha dado lugar a la Terapia de Observación de Acciones (*Action Observation Therapy*, AOT), una técnica basada en la activación del sistema de neuronas espejo (*Mirror Neuron System*, MNS) (Ge *et al.*, 2023). Este sistema incluye un conjunto de regiones frontoparietales que se activan tanto al ejecutar una acción como al observar a otro realizarla, lo que permite al cerebro simular internamente los movimientos observados y, con ello, facilitar su aprendizaje (Ge *et al.*, 2023).

El estudio de los efectos de la AOT mediante métricas de conectividad funcional basadas en EEG constituye una vía prometedora para comprender la reorganización de las redes cerebrales durante la observación de acciones. Sin embargo, este enfoque plantea importantes desafíos técnicos: las señales EEG reflejan una actividad neuronal altamente variable, no lineal y distribuida en distintas bandas de frecuencia, lo que dificulta su interpretación directa. Además, la notable variabilidad entre sujetos añade un nivel adicional de dificultad a la hora de identificar patrones consistentes.

Para analizar esta dinámica cerebral se emplean técnicas capaces de identificar grupos de regiones cerebrales que comparten patrones de interacción a lo largo del tiempo. En el contexto de la AOT, este enfoque permite explorar cómo se organiza y reconfigura la conectividad funcional durante la observación de acciones, haciendo posible la identificación de patrones neuronales comunes pese a la variabilidad interindividual.

## 1.2. Terapia de Observación de la Acción

En pacientes con enfermedades neurológicas como el ictus, la enfermedad de Parkinson o la esclerosis múltiple, uno de los principales objetivos terapéuticos es la recuperación de la función motora. Tradicionalmente, las terapias de rehabilitación se han centrado en el entrenamiento físico temprano, con el fin de normalizar la actividad funcional y favorecer una recuperación integral. No obstante, numerosos estudios han demostrado que la práctica física directa no es la única vía eficaz para inducir mejoras motoras (Ge *et al.*, 2023; Meng *et al.*, 2023; Chen *et al.*, 2025). La observación de acciones, por ejemplo, se ha mostrado efectiva para activar el sistema motor y estimular la plasticidad cerebral, incluso en ausencia de movimiento real (Gatti *et al.*, 2013; Kim and Cho, 2016).

Este efecto se explica a través del funcionamiento del MNS, una red cerebral que se activa tanto durante la ejecución de una acción como al observar a otra persona realizarla. Esta capacidad de simular internamente los movimientos observados permite al cerebro construir representaciones motoras que facilitan el aprendizaje y la recuperación funcional. Aunque este mecanismo fue descubierto inicialmente en la corteza premotora, investigaciones posteriores han identificado su participación en otras áreas como la insula, la corteza cingulada y la corteza parietal posterior (Temporiti *et al.*, 2023). En un principio se pensaba que el sistema se activaba solo frente a acciones simples y dirigidas a un objetivo, como empujar, agarrar o arrastrar, pero estudios más recientes han demostrado que también responde a acciones complejas, como escalar, manipular objetos o utilizar herramientas (Rizzolatti *et al.*, 2021).

La AOT se basa en el funcionamiento de este sistema. Consiste en estimular el sistema sensoriomotor mediante la visualización de vídeos que muestran acciones específicas (Ge *et al.*, 2023). Su objetivo es activar indirectamente las redes motoras del paciente y facilitar el reaprendizaje de habilidades funcionales, especialmente en casos en los que el movimiento físico está limitado. Por ejemplo, en pacientes con espasticidad, rigidez muscular o pérdida de control motor (Kim and Cho, 2016).

Se ha comprobado que los beneficios de la AOT pueden potenciarse al combinarla con la imaginería motora (*motor imagery*, MI). Es decir, la representación mental de la acción observada. Diversos estudios han evidenciado que la combinación de AOT + MI produce una mayor activación en áreas motoras cerebrales que cualquiera de las dos estrategias por separado, ya que existe un solapamiento funcional en la activación cerebral durante la observación y la imaginación de acciones motoras (Gatti *et al.*, 2013; Kim, Frank and Schack, 2017; Emerson *et al.*, 2018). Además, la observación motora se ha planteado como una herramienta especialmente útil para contrarrestar el fenómeno del “no uso aprendido”, una forma de plasticidad desadaptativa en la que el paciente evita utilizar el lado afectado del cuerpo tras una lesión neurológica (Kim and Cho, 2016).

## **1.3. Electroencefalografía**

Para el estudio del control motor, se han desarrollado diversas técnicas, entre las cuales la electroencefalografía (EEG) destaca por su portabilidad, su alta resolución temporal y su capacidad para registrar la actividad cerebral en distintas bandas de frecuencia durante la ejecución de movimientos.

La EEG es una técnica no invasiva que mide la actividad cerebral eléctrica mediante electrodos colocados sobre el cuero cabelludo. Gracias a su seguridad y facilidad de aplicación, puede utilizarse en personas de cualquier edad y es ampliamente empleada tanto en investigación como en el ámbito clínico, especialmente en el diagnóstico de trastornos neurológicos como tumores, epilepsias o hemorragias(Teplan and Teplan, 2002).

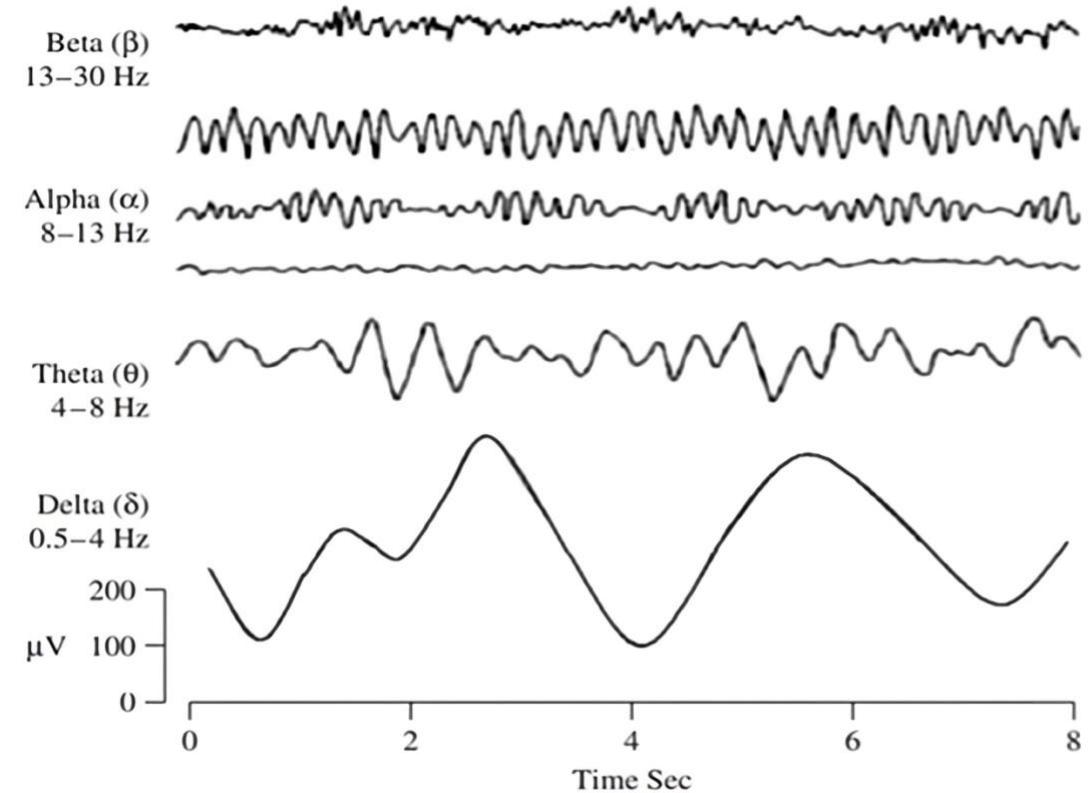
La señal que recoge el EEG refleja la suma de los potenciales postsinápticos generados por grandes grupos de neuronas, en particular las neuronas piramidales de la corteza cerebral. Estas neuronas forman dipolos eléctricos entre el cuerpo celular y las dendritas apicales, cuyas corrientes sinápticas sincronizadas pueden detectarse desde la superficie del cuero cabelludo (Teplan and Teplan, 2002).

Dado que el presente trabajo se centra en el estudio de la reorganización de las redes cerebrales a partir de datos de EEG, este apartado se dedica a describir los fundamentos de esta técnica, incluyendo las principales bandas de frecuencia en las que se clasifica la actividad cerebral, así como sus principales limitaciones. Entender cómo se estructuran los ritmos neuronales permite interpretar mejor los patrones de conectividad funcional, mientras que identificar las fuentes de ruido y artefactos resulta esencial para garantizar la fiabilidad del análisis.

### **1.3.1. Ritmos de frecuencia**

En términos funcionales, la actividad cerebral registrada por el EEG se clasifica en cinco bandas o ritmos de frecuencia (véase la Figura 1.1), cada una asociada a diferentes procesos cognitivos y estados mentales (Chaddad *et al.*, 2023):

- Banda delta (1 – 4 Hz): las ondas son oscilaciones de gran amplitud, están relacionadas con la actividad cerebral de ondas lentas y el sueño profundo.
- Banda theta (4 – 8 Hz): las ondas se observan comúnmente durante períodos de relajación y meditación.
- Banda alfa (8 – 13 Hz): las ondas son más evidentes durante estados de relajación, con los ojos cerrados y sin atención dirigida.
- Banda beta (13 – 30 Hz): las ondas se asocian con el procesamiento cognitivo activo y pueden detectarse durante tareas que requieren una atención significativa.



**Figura 1.1** Representación de cuatro ritmos cerebrales típicos en condiciones normales, ordenados de mayor a menor frecuencia: beta, alfa, theta y delta. Imagen adaptada de (Sanei Saeid and Chambers J.A, 2007)

- Banda gamma (30 – 100 Hz): las ondas están vinculadas al procesamiento cognitivo avanzado y a la integración de información sensorial.

### 1.3.2. Limitaciones del EEG: ruido, artefactos

Aunque el EEG ofrece una alta resolución temporal y constituye una herramienta accesible y no invasiva, presenta limitaciones importantes que deben considerarse. Una de ellas es su baja resolución espacial: las señales registradas en el cuero cabelludo reflejan principalmente la actividad postsináptica de las células piramidales corticales, organizadas en las capas externas de la corteza. Esto implica que la información obtenida procede casi exclusivamente de regiones corticales superficiales, mientras que la actividad de estructuras profundas no puede registrarse con precisión mediante esta técnica (Chiarion *et al.*, 2023). Para suplir estas carencias se emplean habitualmente métodos complementarios, como la fMRI, que proporciona una excelente resolución espacial, pero cuya resolución temporal es muy baja (del orden de segundos), lo que le impide captar fenómenos en escalas temporales rápidas (He *et al.*, 2019).

Además, la adquisición de señales EEG se ve afectada por la presencia de ruido no deseado, lo que dificulta su análisis. Esto se debe a la naturaleza inherente del EEG, que capta no solo la actividad neuronal de interés, sino también otras señales externas (o de otras partes del cuerpo) no relacionadas. Esto da lugar a la aparición de lo que se conoce como artefactos.

Estos artefactos pueden originarse tanto por el instrumental de medición como por factores ambientales o fisiológicos. En el primer caso, encontramos problemas como electrodos defectuosos, alta impedancia, o ruido de red eléctrica, que pueden minimizarse mediante sistemas de registro más precisos y un protocolo de adquisición riguroso. Sin embargo, los artefactos fisiológicos, como los movimientos oculares, los parpadeos, la actividad muscular o cardíaca, resultan mucho más difíciles de eliminar, ya que están intrínsecamente ligados al propio sujeto (Jiang, Bian and Tian, 2019).

La presencia de estos artefactos puede distorsionar significativamente la señal EEG, interfiriendo con las verdaderas conexiones neuronales y generando interpretaciones erróneas (Jiang, Bian and Tian, 2019).

## 1.4. Conectividad cerebral

El cerebro es un sistema altamente complejo, caracterizado por múltiples niveles de interconexión e interacción que abarcan desde la escala microscópica, como las células y sinapsis, hasta la macroscópica, donde distintas regiones y sistemas cerebrales interactúan entre sí. El estudio de las redes cerebrales permite representar las áreas del cerebro como nodos interconectados, mientras que las interacciones entre ellas se modelan como conexiones dentro de una red dinámica. Este enfoque permite describir y analizar cómo se comunican las distintas partes del cerebro en reposo o durante la realización de tareas específicas (Zamani Esfahlani *et al.*, 2021).

La conectividad cerebral se centra precisamente en describir estos patrones de interacción, tanto dentro de cada región cerebral como entre diferentes regiones (Chiarioti *et al.*, 2023). A lo largo de este apartado, se presenta una visión general sobre los principales tipos de conectividad cerebral, los distintos enfoques para su análisis, los índices más utilizados para caracterizar estas complejas redes de interacción, así como los principales desafíos metodológicos asociados a su estudio.

### 1.4.1. Tipos: estructural, funcional y efectiva

La conectividad cerebral se puede dividir fundamentalmente en tres tipos: estructural, funcional y efectiva. La conectividad estructural (SC) hace referencia a las conexiones anatómicas entre neuronas o regiones cerebrales, representando la arquitectura física del sistema nervioso. La conectividad funcional (FC), en cambio, se basa en la relación temporal de la actividad neuronal entre distintas áreas, sin implicar necesariamente una conexión física directa. Finalmente, la conectividad efectiva (EC) permite identificar influencias causales, proporcionando información sobre qué regiones ejercen control sobre otras y en qué dirección fluye la actividad cerebral (Rubinov and Sporns, 2010; Ge *et al.*, 2023).

La conectividad funcional no implica una dirección concreta ni una organización anatómica determinada en el cerebro. Se entiende más bien como la probabilidad de que las respuestas neuronales registradas en distintas áreas estén relacionadas entre sí. Por tanto, no permite inferir la naturaleza de dicha relación, sino únicamente constatar si existe o no una dependencia estadística. Este tipo de conectividad se evalúa mediante métricas simétricas, como la correlación, la coherencia o la información mutua, que permiten cuantificar la sincronización de regiones cerebrales, pero sin establecer si una influye sobre la otra (Chiarion *et al.*, 2023).

Por su parte, la conectividad efectiva busca determinar si la actividad de una región cerebral precede y predice la de otra, lo que sugiere una relación de causa-efecto. Entre las métricas más utilizadas para este análisis se encuentran la causalidad de Granger, la coherencia dirigida, la coherencia parcial dirigida y la entropía de transferencia. Todas ellas permiten captar la dirección del flujo de información entre distintas áreas cerebrales (Rubinov and Sporns, 2010; Chiarion *et al.*, 2023)

#### **1.4.2. Dominios de análisis**

La elección de la métrica de conectividad más adecuada depende tanto del tipo de fenómeno fisiológico que se desea estudiar como de las características específicas de las señales registradas. Para ello, se han desarrollado múltiples enfoques metodológicos que permiten analizar la conectividad funcional desde distintas perspectivas o dominios (véase la Figura 1.2) (Chiarion *et al.*, 2023).

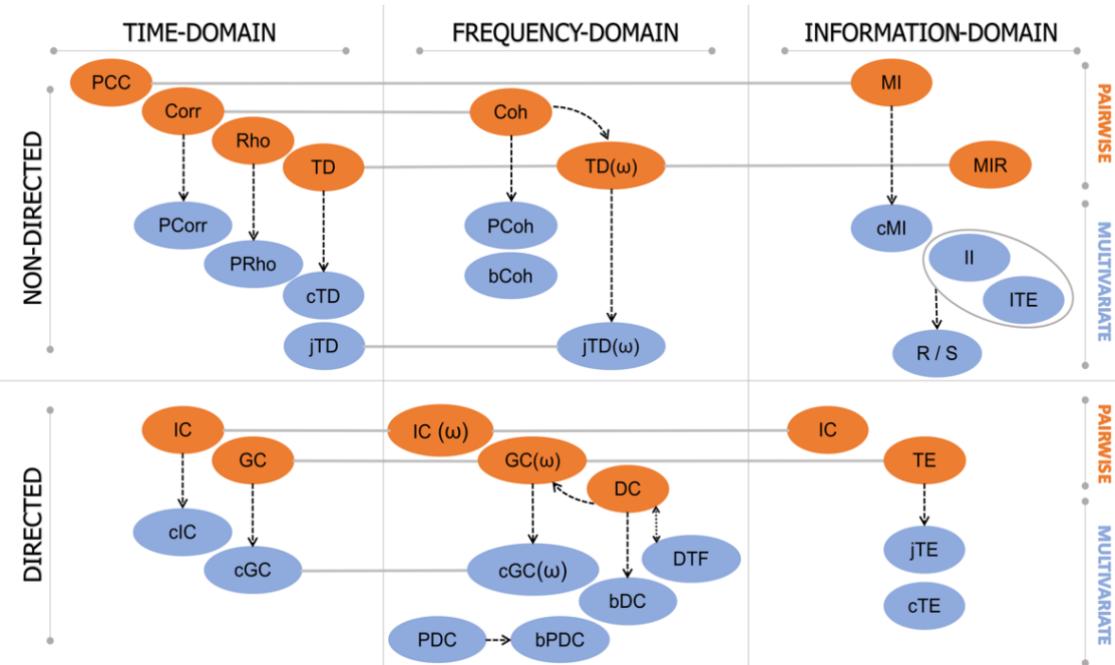
Algunos métodos se basan en modelos lineales, como los modelos autorregresivos, que permiten representar las interacciones cerebrales mediante ecuaciones matemáticas bien definidas. Otros enfoques, en cambio, son no lineales o no requieren un modelo previo (*model-free*), lo que los hace especialmente útiles para captar relaciones complejas y no evidentes entre las señales neuronales (Pereda, Quiroga and Bhattacharya, 2005).

Estos métodos también se pueden clasificar en función del dominio de análisis en el que operan. En el dominio temporal, se estudia la evolución de las señales a lo largo del tiempo. En el dominio frecuencial, se analizan las componentes oscilatorias de la señal, que abarcan desde las bandas de baja frecuencia (delta y theta) hasta las de frecuencia media y alta (alfa, beta y gamma), y su grado de sincronización entre distintas regiones cerebrales. Por otro lado, el dominio de la teoría de la información permite medir cuánta información comparten diferentes áreas del cerebro, proporcionando una perspectiva complementaria sobre las interacciones funcionales (Chiarion *et al.*, 2023).

Además, el análisis de conectividad puede abordarse desde una perspectiva estática o dinámica. En un enfoque estático, se asume que las relaciones entre regiones se mantienen constantes durante todo el periodo de observación. En cambio, el enfoque dinámico permite capturar cómo varían estas conexiones a lo largo del tiempo, lo cual resulta especialmente útil en tareas cognitivas o situaciones clínicas donde la actividad cerebral no es estacionaria, como en la observación de acciones (Chiarion *et al.*, 2023).

Por este motivo, en el presente trabajo se ha adoptado un enfoque dinámico para estudiar la conectividad funcional mediante EEG, como se describe en el apartado 1.5.

Finalmente, los análisis pueden realizarse de forma bivariada, evaluando las relaciones entre pares de señales, o de forma multivariada, considerando múltiples regiones de forma simultánea. Esta última opción permite obtener una representación más global y realista de las complejas redes de interacción cerebral (Cohen and Mike X, 2014).



**Figura 1.2** Clasificación de las principales métricas utilizadas para el análisis de conectividad cerebral, agrupadas según su dominio de aplicación (temporal, frecuencial o de información) y su naturaleza (dirigida o no dirigida). Imagen adaptada de (Chiarion *et al.*, 2023).

### 1.4.3. Métricas de conectividad

Los índices de conectividad pueden agruparse en cinco categorías diferentes: Medidas Clásicas, Índices de Sincronización Generalizada (*Generalized Synchronization Indexes*, GS), Índices basados en Causalidad de Granger, Medidas basadas en Teoría de la Información e Índices de Sincronización de Fase (*Phase Synchronization Indexes*, PS). Cada una de estas categorías investiga diferentes aspectos de la conectividad cerebral y se caracteriza por presentar ventajas y limitaciones específicas (Niso *et al.*, 2013).

Las medidas clásicas incluyen técnicas lineales como el coeficiente de correlación de Pearson (COR), la función de correlación cruzada (XCOR), la coherencia (COH) y la correlación de la envolvente de amplitud (*Amplitude Envelope Correlation*, AEC). Esta última estima la correlación entre las envolventes de amplitud de dos series temporales. Para su cálculo, se aplica la transformada de Hilbert para extraer dichas envolventes y, posteriormente, se computa la correlación de Pearson sobre ellas. Es importante señalar que la AEC debe aplicarse sobre señales previamente ortogonalizadas, con el fin de minimizar los efectos espurios de la conducción de volumen (Brookes *et al.*, 2014; O'Neill *et al.*, 2018). Estos métodos se emplean ampliamente debido a su simplicidad y eficiencia computacional; sin embargo, su principal limitación es que solo pueden detectar dependencias lineales entre variables (Niso *et al.*, 2013).

Los GS se basan en el concepto de sincronización generalizada, que se da cuando los estados de un subsistema dinámico (Y) están influenciados por los estados de otro subsistema (X), lo cual se expresa como  $Y = F(X)$ .

Los índices basados en la causalidad de Granger están relacionados con la teoría de Wiener y evalúan la causalidad entre dos señales medidas simultáneamente,  $x(t)$  e  $y(t)$ , analizando si la inclusión de valores pasados de una señal mejora la predicción de la otra.

Las medidas basadas en la teoría de la información se fundamentan principalmente en una métrica que cuantifica la información de una variable aleatoria discreta X: su entropía de Shannon.

Por último, los PS se basan en el concepto de sincronización de fase, que hace referencia a una situación en la que las fases de dos osciladores acoplados se sincronizan, aunque sus amplitudes puedan permanecer no correlacionadas. Cuentan con algunas métricas como el *Phase Locking Value* (PLV), el *Phase Lag Index* (PLI) y el *Phase Slope Index* (PSI) (Niso *et al.*, 2013).

El PLV se basa únicamente en la diferencia de fase relativa entre señales y evalúa cómo se distribuye esta diferencia alrededor del círculo unitario. Cuando existe una fuerte sincronización de fase entre dos señales (por ejemplo, X e Y), la fase relativa se concentra en una pequeña región del círculo, y el PLV se aproxima a 1. En cambio, si no hay sincronización, la fase relativa se dispersa por todo el círculo, dando lugar a valores bajos de PLV.

El PLI mide la consistencia del desfase de fase entre dos señales, descartando aquellas diferencias centradas en cero, lo que lo hace menos sensible a artefactos causados por el *volume conduction*. A partir de este índice surge el *weighted Phase Lag Index* (wPLI), una variante ponderada que mejora la detección de cambios en la sincronización de fase al reducir la influencia del ruido no correlacionado y aumentar el poder estadístico. A diferencia de otros índices de fase, el wPLI incorpora información tanto de fase como de amplitud, lo que proporciona una estimación más robusta de la conectividad funcional (Niso et al., 2013).

En el presente trabajo se ha seleccionado el wPLI como métrica principal para calcular la conectividad funcional a partir de señales EEG, debido a sus múltiples ventajas: permite identificar interacciones con desfase temporal (aportando una noción de direccionalidad), se adapta al análisis en el dominio frecuencial y es especialmente resistente a los efectos del *volume conduction*, lo que lo convierte en una herramienta fiable para estudios sobre conectividad cerebral.

#### 1.4.4. Limitaciones en el análisis de conectividad

Como ya se ha mencionado anteriormente, una de las limitaciones más relevantes es el *volume conduction*. Este fenómeno ocurre cuando la actividad eléctrica generada en una región del cerebro es registrada simultáneamente por varios electrodos, lo que produce una autocorrelación espacial a nivel del sensor. Como consecuencia, puede parecer que existe una conexión funcional entre dos electrodos, cuando en realidad ambos están captando la misma fuente de señal cerebral.

Este efecto puede dar lugar a conectividad espuria, es decir, relaciones aparentes entre regiones cerebrales que en realidad no están interactuando. El *volume conduction* es un fenómeno inevitable, ya que forma parte del proceso físico de propagación de la señal eléctrica desde el interior del cerebro hasta la superficie del cuero cabelludo (He et al., 2019).

Para mitigar este problema se han propuesto diferentes estrategias. Una primera aproximación consiste en utilizar métricas de conectividad menos sensibles al *volume conduction*. Por ejemplo, índices basados en el desfase de fase como el PSI o el wPLI permiten detectar interacciones con cierto retraso temporal, ignorando las correlaciones instantáneas que suelen ser producto de este efecto (Niso et al., 2013). Otra alternativa, empleada en otros estudios, es el uso de técnicas de análisis de fuentes (*source imaging*), que permiten estimar la actividad neuronal en el espacio fuente a partir de las señales registradas en el cuero cabelludo (espacio sensor), reduciendo así la probabilidad de detectar conectividad espuria debida a la propagación de volumen (Jiang, Bian and Tian, 2019; Chiarion et al., 2023). En el presente trabajo se optó únicamente por la primera estrategia, sin aplicar procedimientos de *source imaging*.

### 1.5. Conectividad funcional dinámica

El cerebro debe integrar, coordinar y responder de forma dinámica a estímulos internos y externos a través de múltiples escalas temporales. Por ello, las interacciones cerebrales no son estáticas, sino que las relaciones funcionales entre diferentes regiones cerebrales cambian a lo largo del tiempo (Hutchison et al., 2013).

Para estimar la conectividad funcional dinámica (*dynamic functional connectivity*, dFC), es necesario aplicar métodos que permitan observar cómo varían las conexiones entre regiones cerebrales en el tiempo. Todos estos métodos requieren un número suficiente de puntos temporales para obtener resultados fiables.

En las siguientes secciones se describen los métodos empleados para estimar la dFC y la construcción de matrices de conectividad que permiten representar de manera estructurada dichas interacciones.

### 1.5.1. Métodos de estimación: *sliding window*

Una de las formas más sencillas y ampliamente utilizadas para estimar la dFC es el enfoque de ventanas deslizantes (*sliding window*). Este método consiste en dividir la serie temporal de la señal EEG en ventanas de duración fija (Ge *et al.*, 2023). A continuación, la ventana se desplaza a lo largo del tiempo por un número determinado de puntos, también conocido como paso (*step size*), lo cual define el grado de solapamiento entre ventanas consecutivas (Hutchison *et al.*, 2013). En cada ventana, se calcula una métrica de conectividad funcional, como la correlación, la coherencia o algún índice de sincronización de fase. De esta manera, se obtiene una secuencia de matrices que reflejan cómo evolucionan las interacciones funcionales entre regiones cerebrales a lo largo del tiempo (Ge *et al.*, 2023).

Una de las principales ventajas de este enfoque es su compatibilidad con una amplia variedad de métricas de conectividad estática, lo que lo convierte en una herramienta flexible y accesible (O'Neill *et al.*, 2018). Sin embargo, presenta algunas limitaciones como la selección de la longitud de la ventana: si es demasiado corta, puede introducir ruido o inestabilidad en la estimación; si es demasiado larga, puede suavizar en exceso las transiciones rápidas entre estados cerebrales. Además, diferentes métricas requieren duraciones mínimas distintas para generar resultados fiables. Por ejemplo, se ha observado que las métricas basadas en fase requieren más datos que las basadas en amplitud para alcanzar consistencia (O'Neill *et al.*, 2018).

En este trabajo se ha aplicado este enfoque de ventanas deslizantes para estimar la conectividad funcional dinámica a partir de los registros EEG obtenidos durante la AOT. Este método permite observar cómo varían las interacciones entre regiones cerebrales a lo largo de las distintas fases del vídeo de la AOT, facilitando el análisis de posibles reconfiguraciones funcionales inducidas por el estímulo. Su uso resulta especialmente adecuado en este contexto, ya que ofrece una resolución temporal suficiente para captar cambios relevantes durante la tarea, al tiempo que se mantiene una implementación metodológica robusta y compatible con métricas como el PLI.

Cabe destacar que también existen métodos alternativos, conocidos como métodos instantáneos, que no requieren segmentar la señal en ventanas temporales. Técnicas como la transformada de Hilbert o la transformada wavelet continua permiten estimar la fase y potencia instantáneas en cada momento del tiempo, lo que puede resultar útil en tareas muy rápidas o con transiciones abruptas. No obstante, estos métodos son más sensibles al ruido y exigen señales con oscilaciones bien definidas para ofrecer resultados fiables (Ge *et al.*, 2023).

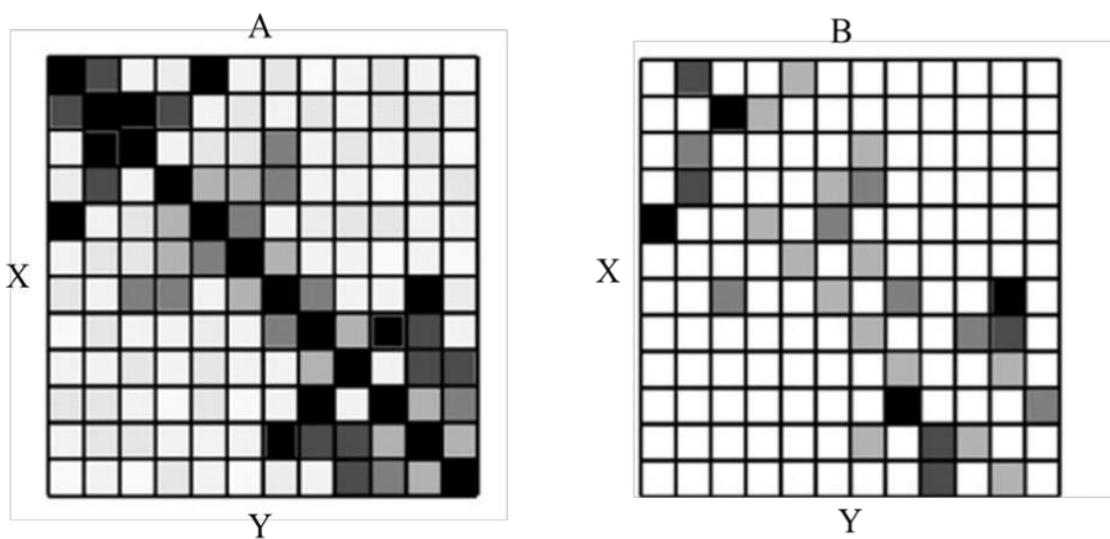
## 1.5.2. Matrices de conectividad

Una red es una representación matemática de un sistema complejo del mundo real, y se define como un conjunto de nodos (o vértices) y enlaces (o aristas) que conectan pares de nodos. En las redes cerebrales los nodos corresponden a electrodos, y las aristas a alguna medida de conectividad entre pares de estos (Rubinov and Sporns, 2010).

Todas las redes pueden representarse mediante matrices de conectividad (también denominadas matrices de adyacencia). Las filas y columnas de estas matrices representan los nodos, mientras que cada entrada ( $X, Y$ ) representa el valor de conectividad entre los electrodos  $X$  e  $Y$ . Así, dado un conjunto de  $N$  electrodos, se obtiene una matriz cuadrada de tamaño  $N \times N$ , en la que se codifica la conectividad entre todos los pares posibles.

La conectividad puede calcularse en distintos dominios, como el temporal o el frecuencial, lo que implica que cada matriz 2D representa la conectividad en un punto específico del espacio tiempo-frecuencia (Rubinov and Sporns, 2010).

Según el tipo de medida utilizada, la matriz de conectividad puede presentar diferentes propiedades estructurales (véase la Figura 1.3). Si el valor en la posición  $(X, Y)$  es idéntico al de  $(Y, X)$ , se trata de una matriz simétrica, como suele ocurrir en la conectividad funcional. En este caso, los triángulos superior e inferior respecto a la diagonal principal contienen información redundante. Por el contrario, una matriz asimétrica refleja relaciones direccionales o diferentes medidas en cada sentido, como por ejemplo si el triángulo inferior representa la conectividad de  $X$  a  $Y$ , mientras que el superior la de  $Y$  a  $X$  (Rubinov and Sporns, 2010).



**Figura 1.3** Representación de una matriz de adyacencia simétrica (panel A) y una matriz de adyacencia asimétrica (panel B). Imagen adaptada de (Rubinov and Sporns, 2010).

La naturaleza ruidosa de las medidas de conectividad funcional, junto con la presencia de múltiples conexiones espurias o débiles, puede dificultar notablemente la interpretación de los resultados. Esta dificultad se incrementa especialmente cuando se trabaja con un elevado número de electrodos. Por ello, los métodos de umbralización (*thresholding*) resultan útiles para obtener una visualización y comprensión más clara y simplificada de la red cerebral, permitiendo centrarse únicamente en las conexiones más relevantes (Cohen and Mike X, 2014).

Existen distintas estrategias para aplicar umbrales. Una de las más comunes es la umbralización absoluta, que consiste en establecer en cero todas las medidas de conectividad que estén por debajo de un determinado valor de corte. Este valor puede definirse de forma arbitraria (por ejemplo, un determinado percentil o un número de desviaciones estándar por encima del valor medio de conectividad) (Cohen and Mike X, 2014).

Otras estrategias comunes de umbralización consisten en especificar el número de conexiones que se desean conservar, y fijar a cero el resto. El valor del umbral puede mantenerse constante para toda la población o adaptarse a cada paciente en particular (Rubinov and Sporns, 2010; Cohen and Mike X, 2014).

En este caso, se utiliza una umbralización basada en un número específico de conexiones conservadas. De esta manera, una vez calculados los valores de conectividad mediante el índice wPLI y construidas las matrices de conectividad en cada una de las ventanas deslizantes, se aplica un umbral sobre ellas. Así, las matrices umbralizadas se podrán representar de forma más interpretable mediante grafos o comunidades.

Aunque existen múltiples formas de analizar estas matrices, en este trabajo nos centraremos en la detección de comunidades, como se detallará en el siguiente apartado.

## 1.6. Teoría de grafos

Estudiar cómo se organiza el cerebro durante una tarea o estado mental concreto es esencial, ya que tanto los cambios como los patrones estables en la red neuronal pueden tener implicaciones fisiológicas relevantes (Puxeddu, Petti and Astolfi, 2021). Para abordar esta cuestión, una herramienta muy utilizada es la teoría de grafos, una rama de las matemáticas que se encarga de analizar redes formadas por un conjunto de nodos y aristas que representan los elementos de un sistema y sus interrelaciones (Bassett and Sporns, 2017). En este enfoque, las matrices de conectividad de tamaño  $N \times N$  se transforman en grafos, donde  $N$  indica el número de nodos. A partir de estos grafos, es posible aplicar técnicas de análisis que permiten describir su estructura topológica (Rubinov and Sporns, 2010).

Este tipo de análisis permite extraer métricas que reflejan aspectos tanto locales como globales de la red. Entre las más relevantes se encuentran aquellas relacionadas con tres grandes bloques: segregación funcional, integración funcional y centralidad (Rubinov and Sporns, 2010).

La integración funcional se refiere a la capacidad del cerebro para combinar información procedente de áreas dispersas entre sí. Para cuantificarla, se analiza cómo de fácil es la comunicación entre nodos distantes. Este análisis se basa en el concepto de camino, entendido como la secuencia de enlaces que conecta dos nodos. En particular, la longitud del camino más corto representa el número mínimo de enlaces necesarios para conectar un par de nodos. Una de las métricas más comunes es la eficiencia global (*global efficiency*, GE), que se calcula como el inverso del promedio de las distancias más cortas entre todos los pares de nodos (Rubinov and Sporns, 2010; Cohen and Mike X, 2014).

Las medidas de centralidad permiten identificar los nodos centrales o "hubs" dentro de las redes cerebrales. Por ejemplo, el grado (*degree*, D) contabiliza el número de conexiones de un nodo, mientras que su versión ponderada, llamada fuerza (*strength*), suma los pesos de esas conexiones. La centralidad de intermediación (*betweenness centrality*, BC), por otro lado, muestra cuántos caminos más cortos de la red pasan por un nodo determinado (Rubinov and Sporns, 2010).

La segregación funcional del cerebro hace referencia a su capacidad para llevar a cabo procesos especializados dentro de grupos de regiones altamente interconectadas, conocidas como clústeres o módulos. Una de las métricas más potentes en este sentido es la modularidad (Q), que evalúa en qué medida una red puede dividirse en subconjuntos o comunidades claramente diferenciadas, con muchas conexiones internas y pocas conexiones externas (Rubinov and Sporns, 2010).

Para estimar esta métrica en redes cerebrales reales, especialmente aquellas derivadas de datos EEG, es necesario aplicar algoritmos específicos que permitan identificar dichas comunidades de forma automática. A continuación, se describe el enfoque de detección de comunidades, que constituye la base metodológica empleada en este trabajo.

### **1.6.1. Algoritmo de detección de comunidades**

El análisis de la estructura modular resulta especialmente útil en el contexto del EEG, ya que esta técnica ofrece una excelente resolución temporal. Aplicar enfoques de detección de comunidades sobre redes derivadas del EEG permite observar cómo se agrupan dinámicamente las regiones cerebrales durante una tarea, siendo útil en campos como la epilepsia, la percepción visual o los procesos cognitivos (Puxeddu, Petti and Astolfi, 2021).

Los algoritmos de detección de comunidades permiten descomponer una red en grupos densos de nodos llamados “módulos” o más comúnmente “comunidades” (Bassett *et al.*, 2013). De forma general, una comunidad es un conjunto de nodos que están “más densamente” conectados entre sí que con nodos de otras comunidades. En las particiones más comunes, cada nodo pertenece a una única comunidad, lo que se conoce como partición rígida (Bazzi *et al.*, 2017).

Para identificar dichas comunidades dentro de la red, se suele recurrir a la optimización de una función de calidad, siendo la modularidad (Q) la métrica más empleada. Esta medida evalúa hasta qué punto una partición presenta más conexiones dentro de las comunidades de lo que cabría esperar por azar, comparándola con un modelo nulo aleatorio (Bassett *et al.*, 2013). Cuanto mayor sea la modularidad, mayor será la cohesión interna de las comunidades encontradas frente a su conexión con el resto de la red.

Debido a que la búsqueda de la partición óptima es un problema computacionalmente complejo, se utilizan algoritmos heurísticos como el de *Louvain*, ampliamente utilizado por su eficiencia para encontrar máximos locales de la función de modularidad (Bassett *et al.*, 2013).

Los dos enfoques más habituales a la hora de detectar comunidades son el análisis en una sola capa (*single-layer community detection*) y el enfoque multicapa (*multi-layer community detection*). En el análisis monocapa, el algoritmo de *Louvain* clásico se aplica de manera independiente a cada matriz de conectividad correspondiente a una ventana temporal. Esto implica que las comunidades detectadas en una ventana pueden diferir completamente de las de la siguiente, dificultando el seguimiento de la evolución temporal de la organización funcional del cerebro (Puxeddu, Petti and Astolfi, 2021).

En cambio, el enfoque multicapa, basado en el algoritmo *GenLouvain*, generaliza la maximización clásica de la modularidad incorporando un término adicional que tiene en cuenta el acoplamiento de los nodos entre capas temporales consecutivas. De esta manera, se puede capturar de forma más precisa la evolución temporal de las comunidades, observando cómo se mantienen, se reorganizan o desaparecen a lo largo de la tarea (Puxeddu, Petti and Astolfi, 2021).

El algoritmo de *Louvain*, tanto en su versión clásica como multicapa, se desarrolla en dos fases iterativas. Partiendo de una partición inicial, se consideran los nodos uno por uno (en algún orden) y se asigna cada nodo a la comunidad que produzca el mayor aumento de modularidad. Si ningún cambio mejora la puntuación, el nodo conserva su asignación actual. Esta primera fase se repite hasta alcanzar un máximo local (Bazzi *et al.*, 2020).

En la segunda fase, se construye una nueva matriz de modularidad agregando los conjuntos de nodos obtenidos tras la convergencia de la primera fase. Luego, se vuelve a aplicar la primera fase sobre esta nueva matriz, repitiendo ambas fases hasta que se converge a un máximo local (Bazzi *et al.*, 2020).

Esta función de modularidad está influida por dos parámetros clave: gamma ( $\gamma$ ) y omega ( $\omega$ ). Gamma es el parámetro de resolución estructural y ajusta la granularidad con la que se detectan comunidades. Cuando gamma es bajo, se tiende a identificar comunidades más grandes; en cambio, valores altos favorecen comunidades más pequeñas y específicas (Zamani Esfahlani *et al.*, 2021).

Por su parte, el parámetro omega determina la fuerza del acoplamiento entre capas temporales. Un omega bajo implica que las comunidades se detectan casi de forma independiente en cada capa, generando una mayor fragmentación. En cambio, un omega alto promueve la estabilidad de las comunidades a lo largo del tiempo, favoreciendo que los nodos mantengan su asignación comunitaria en ventanas sucesivas (Rizkallah *et al.*, 2018)

En este trabajo se ha aplicado el algoritmo de detección de comunidades multicapa *GenLouvain*, con el objetivo de estudiar cómo se reconfiguran las redes cerebrales en función del tiempo durante la AOT.

## 1.7. Descripción del documento

Este apartado se centra en la estructura de este Trabajo de Fin de Grado (TFG), el cual está dividido en varios capítulos. A continuación, se enumeran dichos capítulos junto con una breve explicación de lo que contiene cada uno de ellos.

- **Capítulo 1. Introducción y marco teórico.** Este capítulo se estructura en cinco secciones. En primer lugar, se introduce la AOT, abordando sus bases neurofisiológicas y su relevancia en el ámbito de la rehabilitación. A continuación, se profundiza en los principios fundamentales de la EEG, junto con sus ritmos de frecuencia característicos y las principales limitaciones asociadas a la adquisición de señales. La tercera sección está dedicada a la conectividad cerebral, incluyendo sus distintos tipos, dominios de análisis y métricas empleadas para su evaluación. En la cuarta sección se describen los fundamentos de la teoría de grafos y su aplicación al análisis de redes cerebrales, con especial énfasis en los algoritmos de detección de comunidades. Finalmente, se presentan las hipótesis y objetivos del estudio, que guían el análisis desarrollado en los capítulos siguientes.
- **Capítulo 2. Revisión del estado del arte: Terapia de Observación de la Acción y Conectividad Funcional Dinámica.** En este capítulo se realiza una revisión de los principales estudios existentes que relacionan la AOT con la conectividad cerebral, prestando especial atención a aquellos que utilizan EEG y métricas como el wPLI, así como técnicas de conectividad dinámica. También se incluyen estudios con fMRI que permiten una comprensión complementaria del fenómeno. Por último, se destacan las limitaciones asociadas a la literatura existente.
- **Capítulo 3. Hipótesis y objetivos.** Se formula la hipótesis central del trabajo y se detallan los objetivos generales y específicos que guían la investigación.
- **Capítulo 4. Materiales y métodos.** En este capítulo se describe el conjunto de datos utilizado, el diseño experimental, las etapas de preprocessamiento del EEG y la metodología de análisis de conectividad dinámica aplicada, incluyendo el cálculo del índice wPLI, el enfoque *sliding window* y el algoritmo *GenLouvain*.
- **Capítulo 5. Resultados.** Se presentan los hallazgos derivados del análisis, combinando resultados cuantitativos y representaciones visuales. Se muestran las variaciones en el número y dimensión de comunidades, las particiones grupales derivadas de la matriz de consenso y los valores del índice NMI como medida de estabilidad. Además, se incluyen comparaciones entre bandas de frecuencia (alfa y beta), condiciones experimentales y fases del estímulo, resaltando ejemplos de reorganización modular y patrones de transición o fragmentación en las redes. Finalmente, se analiza la influencia de los parámetros  $\gamma$  y  $\omega$  en la detección de comunidades y en la interpretación de la dinámica funcional.
- **Capítulo 6. Discusión.** En este capítulo se interpretan los resultados obtenidos a la luz de la literatura revisada, destacando las implicaciones de los hallazgos para la comprensión de la reorganización cerebral inducida por la AOT. Se analizan las diferencias observadas entre bandas de frecuencia, se discute la relevancia del

uso de métricas de modularidad multicapa y se valoran las limitaciones metodológicas del estudio.

- **Capítulo 7. Conclusiones.** En esta sección se sintetizan los principales resultados del trabajo, subrayando la evidencia de que la AOT genera reorganizaciones dinámicas en la conectividad cerebral captables mediante EEG y análisis multicapa. Asimismo, se plantean posibles aplicaciones clínicas en el ámbito de la neurorrehabilitación y se proponen líneas de investigación futuras que podrían profundizar en la validación de estos hallazgos y en su transferencia a contextos clínicos.

# **Capítulo 2. Revisión del estado del arte: Terapia de Observación de la Acción y Conectividad Funcional dinámica**

La AOT y el estudio de la dFC han mostrado un notable potencial para comprender la reorganización de las redes cerebrales. En este capítulo se revisan los principales hallazgos en este campo y las limitaciones que motivan el presente trabajo.

## **2.1. Estudios previos en AOT y conectividad cerebral**

En los últimos años, la AOT se ha consolidado como una terapia prometedora en el campo de la neurorrehabilitación. A través de la observación de acciones, se promueve el aprendizaje motor y se inducen cambios positivos en la plasticidad neuromotora, incluso sin necesidad de ejecutar físicamente los movimientos. Por este motivo, la AOT se ha planteado como una alternativa o complemento eficaz a la terapia física convencional (Kim and Cho, 2016).

Diversos estudios han demostrado que la AOT puede inducir cambios significativos en la conectividad funcional cerebral, favoreciendo procesos de reorganización y plasticidad (Buccino *et al.*, 2001; Rizzolatti *et al.*, 2021). Sin embargo, el enfoque metodológico ha variado considerablemente entre estudios, especialmente en cuanto a la técnica de registro utilizada. Las dos herramientas más utilizadas han sido la EEG y la resonancia magnética funcional (fMRI).

En el caso del EEG, varios estudios se han centrado en el análisis de la desincronización y resincronización relacionada con eventos (ERD/ERS) para caracterizar la actividad cortical durante AOT (Muthukumaraswamy and Singh, 2008; Gonzalez-Rosa *et al.*, 2015). En particular, Kim y colegas (2016) observaron una clara desincronización del ritmo mu en las regiones centrales (C3 y C4), caracterizando una activación de la corteza motora. Asimismo, la banda alfa demostró reducciones significativas en las regiones frontal, central, parietal y occipital. Por el contrario, la actividad de la banda beta aumentó significativamente en las regiones central y occipital, con una mayor coherencia en las áreas frontocentrales. Estos resultados respaldan la hipótesis de una reactivación de las áreas motoras inducida por la observación (Kim and Cho, 2016).

Por su parte, Adham *et al.* (2024) estudiaron las respuestas corticales durante tareas de observación (O), imaginación (OI) y ejecución motora (OM) de miembros inferiores. Observaron una desincronización de la banda alfa en las regiones centroparietales durante la ejecución motora, así como una modulación progresiva del ritmo beta dependiendo del tipo de tarea. Además, el análisis del rebote beta pone de manifiesto la necesidad de añadir intención motora a la observación de la acción para activar los mecanismos de validación motora. (Adham *et al.*, 2024).

Desde un enfoque de conectividad funcional, Zhang y colegas (2018) utilizaron EEG y el índice wPLI para explorar la interacción entre la *Action Observation Network* (AON) y la *Mentalizing Network* (MZN) durante la AOT. Encontraron que las acciones familiares activaban predominantemente la AON, mientras que las ambiguas o sin intención clara

movilizaban la MZN. A nivel de red, se observó una reconfiguración dinámica con cambios en la GE y en la centralidad de ciertos nodos, destacando una transición funcional relevante durante la observación de acciones (Zhang et al., 2018).

En el ámbito de los estudios basados en fMRI, la evidencia también respalda la capacidad de la AOT para modificar los patrones de conectividad funcional cerebral. Un ejemplo destacado es el estudio de Meng et al. (2023), quienes compararon la eficacia de una intervención de AOT basada en movimientos de Tai Chi (TC-AOT) con la de una terapia física convencional, aplicada en pacientes con enfermedad de Parkinson en fases tempranas. Ambos enfoques terapéuticos resultaron efectivos, mostrando mejoras significativas en la función motora, el equilibrio y la calidad de vida. Sin embargo, únicamente el grupo que recibió TC-AOT mostró un incremento en la conectividad funcional entre múltiples regiones cerebrales, lo cual sugiere que esta modalidad de AOT podría inducir una reorganización más eficiente de los circuitos motores y cognitivos que la terapia tradicional (Meng et al., 2023).

Por último, Cordani y colegas (2021) analizaron la dFC en sujetos sanos durante y después de la observación de vídeos de acciones. Observaron una disminución progresiva de la dFC tras la tarea, lo que sugiere un proceso de adaptación y reorganización funcional posiblemente vinculado a mecanismos de consolidación o automatización motora (Cordani et al., 2021).

En conjunto, la literatura apoya la idea de que la AOT no solo activa el sistema motor durante la observación pasiva de acciones, sino que también promueve una reorganización dinámica de las redes cerebrales. Estos efectos se han medido tanto en escalas temporales rápidas (EEG) como espaciales (fMRI), y parecen modulados por factores como la perspectiva del observador, la familiaridad de la acción y la complejidad de la tarea. Sin embargo, los resultados disponibles son todavía heterogéneos y en muchos casos dependen de la metodología empleada, lo que dificulta extraer conclusiones consistentes.

## 2.2. Limitaciones de la literatura existente

A pesar de los avances descritos, los estudios previos presentan limitaciones importantes. En primer lugar, aunque la fMRI ha permitido identificar con gran detalle las regiones cerebrales implicadas en la AOT, su baja resolución temporal limita la posibilidad de captar interacciones rápidas y dinámicas, que resultan fundamentales para comprender cómo se coordinan las redes cerebrales durante la observación de acciones. Por su parte, el EEG ofrece la ventaja de registrar la actividad neuronal en escalas de milisegundos, pero la mayoría de las investigaciones se han centrado en analizar ritmos relacionados con eventos (ERD/ERS), sin profundizar en métricas de conectividad capaces de describir con mayor precisión las interacciones entre áreas cerebrales.

Asimismo, los estudios que han abordado la conectividad funcional dinámica durante la AOT son todavía escasos y, en general, no han empleado indicadores de modularidad que permitan caracterizar cómo se reorganizan las comunidades funcionales a lo largo de la tarea. A ello se suma una notable heterogeneidad metodológica, tanto en los paradigmas experimentales como en las poblaciones analizadas y en las métricas utilizadas, lo que dificulta la comparación de resultados y la obtención de conclusiones generalizables.

En este contexto, se hace necesario un estudio que integre el registro EEG con medidas de conectividad funcional y análisis de modularidad, con el fin de caracterizar de manera más precisa los cambios dinámicos que la AOT puede inducir en la organización cerebral.



# Capítulo 3. Hipótesis y Objetivos

En este capítulo se presenta la hipótesis central y los objetivos que orientan el presente TFG.

## 3.1. Hipótesis

El presente TFG plantea la hipótesis de que *la aplicación de la AOT induce una reorganización dinámica de las redes cerebrales, que puede observarse mediante cambios en la estructura modular a lo largo del tiempo*. En particular, se espera que durante la observación de acciones se produzcan patrones de modularidad específicos que reflejen el papel del sistema de neuronas espejo en el aprendizaje motor y la simulación de movimientos. A partir del análisis de señales EEG y mediante la aplicación del algoritmo de detección de comunidades multicapa, se prevé identificar patrones de conectividad que reflejen la formación, estabilidad o disolución de comunidades funcionales durante la tarea. Esta reconfiguración dinámica aportaría evidencia sobre cómo se organiza el cerebro ante estímulos visomotores, y contribuiría a una mejor comprensión del papel de la modularidad en el aprendizaje motor y la simulación de acciones observadas.

## 3.2. Objetivos del trabajo

El objetivo principal de este TFG es **identificar los patrones de la reorganización dinámica de la conectividad funcional del cerebro durante la AOT en sujetos sanos, a partir de registros EEG**. Para ello, se estudia la evolución temporal de la arquitectura modular de las redes cerebrales, aplicando técnicas de detección de comunidades multicapa sobre las matrices de conectividad.

Específicamente, los objetivos son:

- I. Obtener los patrones de conectividad funcional a partir de las señales EEG mediante el índice de fase wPLI, que permite estimar la conectividad funcional minimizando el efecto del volumen conductor.
- II. Desarrollar y aplicar un enfoque de conectividad funcional dinámica mediante ventanas deslizantes para capturar cómo varía la interacción entre regiones cerebrales a lo largo del tiempo durante la observación de acciones.
- III. Identificar la organización modular de dichas redes utilizando el algoritmo *GenLouvain* para detectar comunidades cerebrales y estudiar su estabilidad y evolución temporal.
- IV. Evaluar el impacto de diferentes parámetros (como gamma y omega) en la detección de comunidades y evaluar cómo se reorganizan funcionalmente las redes cerebrales durante la AOT.



# Capítulo 4. Materiales y métodos

En esta sección se presentan los materiales y métodos empleados en este TFG para alcanzar los objetivos propuestos. Se describe el conjunto de datos utilizado, el diseño experimental y las distintas herramientas empleadas. Todos los análisis se llevaron a cabo en el entorno de MATLAB.

## 4.1. Base de datos y paradigma experimental

El conjunto de datos empleado en este estudio procede de un trabajo previo realizado en el mismo laboratorio (Coelli *et al.*, 2023), en el que se registraron señales de EEG durante tareas de observación de la acción (AO) y MI. En el presente trabajo, únicamente se han analizado los ensayos correspondientes a la condición de AO, sin incluir los datos de MI.

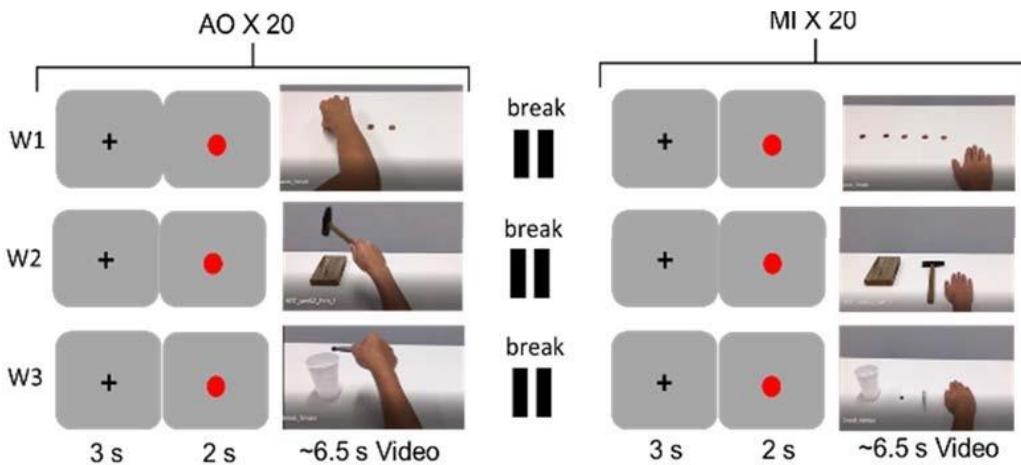
Las señales se registraron en 46 participantes sanos y todos ellos diestros. El conjunto lo conforman 22 mujeres y 24 hombres, con edades comprendidas entre los 20 y los 30 años. La adquisición de las señales se realizó con un casco de 61 canales y el sistema de registro poligráfico *SD LTM 64 Express* (Micromed, Mogliano Veneto, Italia). Las señales se muestraron a una frecuencia de 1024 Hz y las impedancias se mantuvieron por debajo de 20 KOhm mediante el uso de un hidrogel conductor (Coelli *et al.*, 2023).

El protocolo de AO y MI fue aprobado por el Comité Ético Interno del *Istituto Clinico Humanitas* (Rozzano, Italia). Todos los sujetos firmaron un consentimiento informado antes de los registros.

En la tarea de AO, los sujetos observaban un vídeo de 6.5 segundos en el que se mostraba un movimiento de la extremidad superior desde una perspectiva en primera persona. La acción era realizada por un actor del mismo sexo que el participante, y solo era visible el miembro superior en movimiento. La duración total de cada estímulo alcanzaba los 11.5 segundos, ya que el vídeo iba precedido por un periodo de reposo de 3 segundos (fijación en una cruz) y un periodo de preparación de 2 segundos (presentación de un círculo rojo). La secuencia completa se repitió en 20 ensayos (Coelli *et al.*, 2023).

La tarea de MI siguió exactamente la misma estructura temporal. Sin embargo, en este caso se presentaba únicamente el primer fotograma del vídeo durante los 6.5 segundos, e inmediatamente después se pedía a los participantes que imaginaran estar ejecutando el movimiento ellos mismos. También en esta condición se realizaron 20 ensayos. Cabe señalar que esta tarea no incluía retroalimentación en tiempo real, por lo que no se trataba de un paradigma de interfaz cerebro-computador (BCI), sino de un ejercicio de imaginación motora sin *feedback* externo.

En total, cada participante completó tres bloques de estimulación (W1, W2 y W3), separados por periodos de descanso durante los cuales podían moverse libremente. Cada bloque presentaba un tipo distinto de movimiento transitivo y se diferenciaba por el grado de interacción con un objeto (véase Figura 3.1). W1 consistía en recoger cinco monedas pequeñas, W2 presentaba el uso de un martillo para clavar un clavo y W3 mostraba la interacción con unas pinzas para mover un objeto pequeño a un vaso de plástico. El orden de presentación de los vídeos se determinó de forma aleatoria para cada participante (Coelli *et al.*, 2023).



**Figura 4.1** Secuencia de estimulación para las tareas de AO y MI. Imagen adaptada de (Coelli *et al.*, 2023).

## 4.2. Preprocesado y análisis de datos

Los datos empleados en este trabajo fueron proporcionados ya preprocesados por el grupo de investigación responsable de la recogida. El preprocesamiento de las señales de EEG se realizó utilizando el *toolbox* EEGLAB junto con otros scripts personalizados adaptados a los objetivos del estudio. En primer lugar, se aplicó un filtro *Finite Impulse Response* (FIR) paso banda, de fase cero, con un rango de frecuencia entre 1 y 45 Hz, con el fin de eliminar artefactos de baja frecuencia y ruido eléctrico de alta frecuencia. Posteriormente, las señales se remuestrearon a 256 Hz aplicando un filtro *antialiasing*, y se realizó una inspección visual para identificar y eliminar los canales con mala calidad de señal (Coelli *et al.*, 2023).

Las señales se segmentaron en ensayos comprendidos entre -5 y +6.5 segundos con respecto al inicio de la presentación del estímulo principal (vídeo). Después, se aplicó un análisis de componentes independientes (ICA) mediante el algoritmo *Extended Infomax* sobre los ensayos concatenados, con el objetivo de identificar y eliminar fuentes de artefactos no cerebrales, como parpadeos o actividad muscular. Los ensayos con artefactos residuales se revisaron manualmente y se descartaron (Coelli *et al.*, 2023).

Para cada participante y tipo de vídeo se seleccionaron 18 ensayos (*trials*) limpios, correspondientes al intervalo comprendido entre el inicio del estímulo y el final de la fase de observación. De esta manera, el conjunto de datos utilizado se estructuró en matrices de 55 electrodos x 2944 muestras x 18 ensayos diferentes. Aunque la adquisición original se realizó con un casco de 61 electrodos (Coelli *et al.*, 2023), tras el preprocesado se restringió el análisis a 55 canales, descartando aquellos que presentaban peor calidad de señal o cuya localización periférica resultaba menos relevante para el estudio de la dinámica sensoriomotora.

Cabe señalar que, debido a la calidad variable de los registros, el número de sujetos incluidos en cada análisis no fue el mismo para todas las condiciones. En W1 se excluyeron los sujetos 16 y 38, mientras que en W2, los sujetos 13, 14, 15, 16, 26 y 38. Finalmente, en W3 se dispuso de datos completos para todos los participantes.

Asimismo, el análisis se restringió a las bandas alfa (8–13 Hz) y beta (13–30 Hz), por ser las más estrechamente vinculadas a la actividad sensorimotora y a los procesos de observación de la acción. Tal como se expone en la revisión de la literatura (sección 2), estas bandas muestran patrones consistentes de ERD/ERS en estudios previos de AOT (Kim and Cho, 2016), lo que facilita la comparabilidad con trabajos anteriores y, al mismo tiempo, reduce la complejidad analítica frente al uso de un rango más amplio de frecuencias.

## 4.3. Estimación de la conectividad funcional

En esta sección se detallan el índice y los parámetros empleados para realizar el análisis de conectividad, que constituye el objetivo principal de este trabajo.

### 4.3.1. Índice wPLI

Para cuantificar la conectividad funcional entre regiones cerebrales, se empleó el wPLI (Detti *et al.*, 2019). Este índice mide la consistencia del desfase de fase entre pares de señales EEG a lo largo del tiempo, proporcionando una estimación robusta de la interacción neuronal y reduciendo la influencia de artefactos como el *volume conduction* (Stam, Nolte and Daffertshofer, 2007).

El PLI es una métrica que descarta las diferencias de fase próximas a cero, ya que estas suelen deberse a fuentes comunes o referencias activas. Para descartar estas diferencias, el PLI se basa en calcular un índice de asimetría que mide la probabilidad de que la diferencia de fase  $\Delta\phi$  entre dos señales se encuentre dentro del intervalo  $(-\pi, \pi)$  (Detti *et al.*, 2019).

En este contexto,  $PLI = 0$  indica ausencia de acoplamiento o un acoplamiento con diferencia de fase centrada en 0 (mod  $\pi$ ), mientras que  $PLI = 1$  refleja un acoplamiento de fase perfecto con un valor de  $\Delta\phi$  distinto de 0 (mod  $\pi$ ). Cuanto más fuerte sea este acoplamiento de fase distinto de cero, mayor será el valor del PLI (Detti *et al.*, 2019).

El wPLI constituye una extensión del PLI. La mejora clave de este índice es que pondera cada diferencia de fase por la magnitud de la componente imaginaria del espectro cruzado. Esto atenúa el impacto de ruidos no correlacionados y aumenta la capacidad para detectar variaciones reales en la sincronización de fase (Vinck *et al.*, 2011).

El wPLI se define mediante la siguiente ecuación:

$$wPLI_{h,k,\Delta t} = \frac{\left| \frac{1}{N} \sum_{p=1}^N \sin(\phi_h(p) - \phi_k(p)) \right|}{\frac{1}{N} \sum_{p=1}^N |\sin(\phi_h(p) - \phi_k(p))|} \quad (1)$$

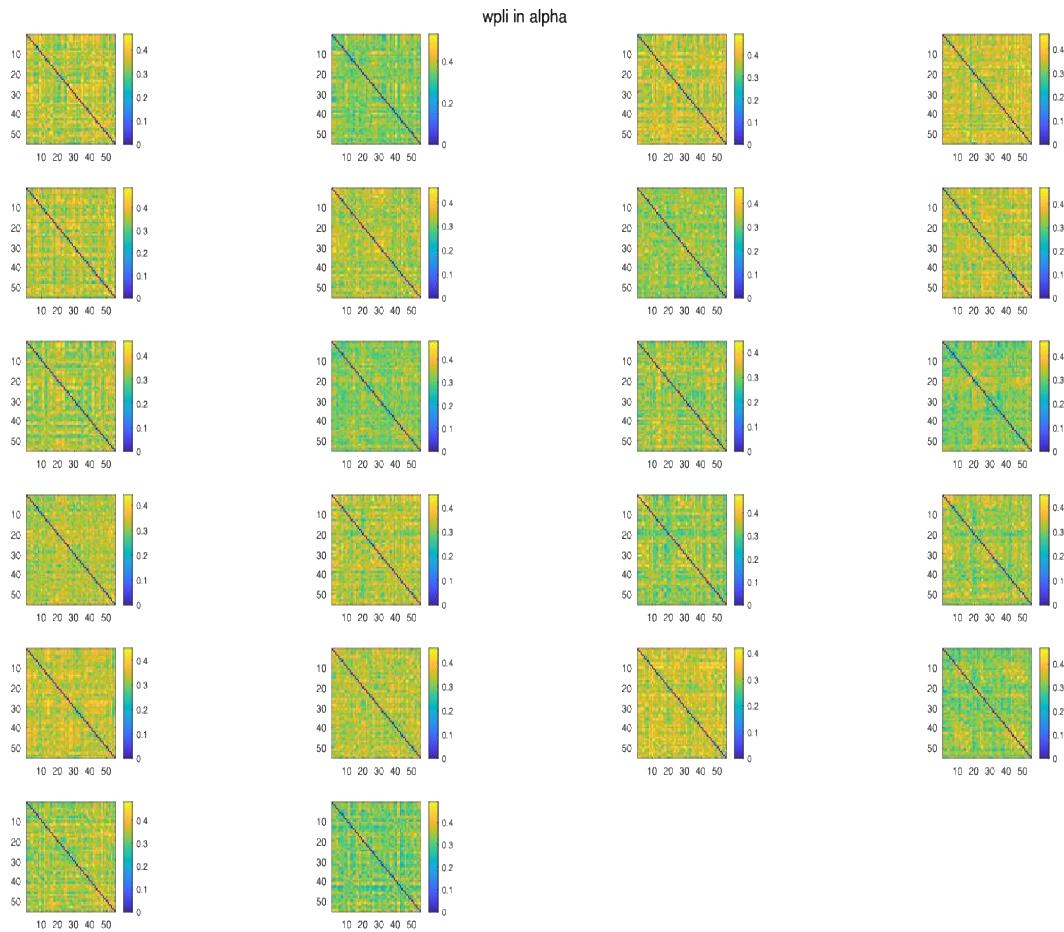
donde  $h$  y  $k$  se definen como el par de canales o electrodos cuya conectividad se está midiendo, y  $\Delta t$  corresponde a una ventana temporal con  $N$  muestras o instantes de tiempo. Las fases  $\phi_h(p)$  y  $\phi_k(p)$  son las de las señales en el instante  $p$  para los canales  $h$  y  $k$ , respectivamente (Detti *et al.*, 2019).

El índice wPLI también toma valores entre 0 y 1. Las diferencias de fase cercanas a cero apenas contribuyen al valor final, lo que disminuye la probabilidad de detectar conectividad espuria causada por *volume conduction* y mejora la capacidad para identificar sincronización genuina (Detti *et al.*, 2019).

Con el objetivo de implementar este índice en el presente estudio, las fases de las señales EEG se obtuvieron siguiendo el enfoque propuesto por Cohen, basado en la convolución de *wavelets* de Morlet con la señal previamente filtrada (Cohen and Mike X, 2014). Para cada canal, se calculó la Transformada Rápida de Fourier (FFT) de la señal, y, posteriormente, para cada frecuencia, se multiplicó punto a punto por la FFT de la *wavelet* correspondiente. La transformada inversa (IFFT) proporcionó una señal compleja de la cual se extrajo la fase instantánea en cada punto temporal.

El análisis se realizó en un conjunto de 25 frecuencias equiespaciadas entre 2 y 40 Hz, con especial atención a las bandas alfa (8–13 Hz) y beta (14–30 Hz). A partir de las fases instantáneas, se calculó el índice wPLI empleando ventanas de 1 segundo (256 muestras) con un solapamiento del 50% (128 muestras). Dado que cada ensayo tenía una duración aproximada de 11.5 segundos (desde -5 hasta +6.5 s respecto al inicio del estímulo), este procedimiento generó un total de 22 ventanas consecutivas.

Finalmente, el cálculo del wPLI entre todos los pares de electrodos en cada ventana temporal permitió construir matrices de conectividad funcional para cada vídeo experimental (W1, W2 y W3), cada banda de frecuencia (alfa y beta) y cada sujeto. Las matrices resultantes tuvieron dimensiones 55 x 55 x 22, correspondientes a los 55 electrodos y las 22 ventanas temporales analizadas.



**Figura 4.2** Ejemplo de matrices de conectividad funcional obtenidas mediante el índice wPLI en la condición W1 (acción de recoger monedas) y en la banda alfa (8–13 Hz).

Finalmente, las matrices de conectividad fueron umbralizadas. Dado que los valores de umbral suelen determinarse de manera arbitraria, lo más adecuado es caracterizar las redes a lo largo de un rango amplio de densidades con el fin de obtener una descripción más robusta y fiable de su organización topológica (Rubinov and Sporns, 2010). Por esta razón, manteniendo el parámetro  $\omega = 1$ , se evaluaron diferentes valores de densidad (10%, 20% y 30%). En este contexto, se fijó un límite inferior del 10%, ya que densidades más bajas tienden a generar una fragmentación excesiva de la red, y un límite superior del 30%, dado que valores mayores incrementan la probabilidad de incluir conexiones espurias y de enmascarar la estructura modular (Fornito, Zalesky and Bullmore, 2010). Los resultados mostraron que, a medida que se incrementa el umbral, se observa una tendencia decreciente en el número de comunidades detectadas, lo cual concuerda con la mayor restricción impuesta a la red al conservar únicamente las interacciones más fuertes. De esta manera, se consideró el 30% como un compromiso adecuado entre la reducción de la fragmentación, la minimización de las conexiones espurias, y la alta variabilidad intersujeto (Calcagno *et al.*, 2024), garantizando una caracterización más estable de la dinámica modular.

## 4.4. Detección de comunidades multicapa

En esta sección se presenta el procedimiento de detección de comunidades multicapa aplicado a las matrices de conectividad obtenidas, con el fin de analizar su organización modular y su evolución temporal en función de las condiciones experimentales.

### 4.4.1. Matriz de modularidad

Una vez obtenidas las matrices de conectividad para cada sujeto, tipo de video y banda de frecuencia (alfa y beta), y a lo largo de 22 ventanas temporales, se reorganizó su estructura en un arreglo de celdas donde cada elemento correspondía a la matriz de conectividad de una ventana específica. Este formato es necesario, ya que la función de cálculo de modularidad empleada requiere una celda como entrada.

La matriz  $B$  representa los valores de modularidad que posteriormente se utilizan en el algoritmo de detección de comunidades. Se trata de una matriz dispersa de dimensiones  $[N \times T] \times [N \times T]$ , donde  $N$  es el número de nodos y  $T$  el número de capas o ventanas de la red. Esta matriz indica en qué medida cada conexión contribuye a la calidad de la partición en comunidades. Un valor positivo significa que los nodos están más conectados de lo que estarían si no existieran comunidades, mientras que un valor negativo indica lo contrario (Mucha *et al.*, 2010).

La matriz de modularidad multicapa  $B$  se calculó de la siguiente manera:

$$B = (A_{ijl} - \gamma_l P_{ijl})\delta_{lr} + \delta_{ij}\omega_{jlr} \quad (2)$$

donde  $A_{ijl}$  es la matriz de conectividad entre los nodos  $i$  y  $j$  en la capa  $l$  (calculada mediante el índice wPLI),  $P_{ijl}$  es el valor esperado de conectividad según el modelo nulo,  $\delta_{lr}$  y  $\delta_{ij}$  son deltas de Kronecker que activan respectivamente las conexiones intracapa e intercapa,  $\omega_{jlr}$  es el parámetro de acoplamiento entre capas, mientras que  $\gamma_l$  es el parámetro de resolución estructural (Mucha *et al.*, 2010).

El parámetro  $\gamma$  controla las conexiones *intralayer* (dentro de una misma capa) comparando la conectividad real entre dos nodos con la conectividad esperada según un modelo nulo. Actúa como un peso sobre dicho modelo: si la diferencia es positiva, los nodos tienden a permanecer en la misma comunidad, mientras que, si es negativa, tienden a separarse. Determina el tamaño de los módulos dentro de cada capa. Valores altos producen comunidades más pequeñas y numerosas; valores bajos generan comunidades más grandes y en menor número (Farahani *et al.*, 2024).

Por su parte,  $\omega$  regula las conexiones *interlayer* (entre diferentes capas), determinando la fuerza con la que un mismo nodo se conecta a lo largo de las distintas ventanas temporales. Si es alto, favorece que el nodo permanezca en la misma comunidad a lo largo del tiempo, lo que reduce el número de comunidades y aumenta su tamaño. En cambio, un valor bajo facilita que el nodo cambie de comunidad entre ventanas, generando más comunidades y de menor tamaño (Mucha *et al.*, 2010).

En este trabajo se mantuvo gamma fija en 1, ya que su influencia requiere un estudio más profundo. Por otro lado, se modificaron los valores de omega con  $\omega \in [0.1, 0.5, 0.7, 1]$  porque el objetivo principal era analizar la dinámica del cambio de comunidades a lo largo del tiempo, comparando la organización modular antes y después de la observación del vídeo.

#### 4.4.2. Algoritmo *GenLouvain*

Una vez definida  $B$ , se utilizó como entrada para el algoritmo de detección de comunidades *GenLouvain*, que busca grupos de nodos (comunidades) fuertemente conectados entre sí. El algoritmo comienza asignando cada nodo a su propia comunidad y, de forma iterativa y en orden aleatorio, evalúa si mover un nodo a otra comunidad mejora la modularidad  $Q$ . Si es así, realiza el cambio. Cuando no es posible mejorar más, agrupa los nodos que han quedado en la misma comunidad y los trata como un único “mega-nodo”, repitiendo el proceso hasta que la modularidad no aumenta (Zamani Esfahlani *et al.*, 2021).

La función de modularidad se define mediante la siguiente ecuación:

$$Q = \frac{1}{2\mu} \sum_{ijlr} \{(A_{ijl} - \gamma_l P_{ijl})\delta_{lr} + \delta_{ij}\omega_{jlr}\} \delta(g_{il}, g_{jr}) \quad (3)$$

donde  $g_{il}$  indica la asignación de comunidad del nodo  $i$  en la capa  $l$ , y  $g_{jr}$  la asignación del nodo  $j$  en la capa  $r$ . Además,  $\delta(g_{il}, g_{jr}) = 1$  si los dos nodos están asignados a la misma comunidad y 0 en caso contrario (Mucha *et al.*, 2010).

La modularidad de la red multicapa se estimó 100 veces en cada caso, ya que el valor de  $Q$  puede presentar variaciones entre ejecuciones debido al carácter heurístico del algoritmo (Bassett *et al.*, 2013; Rizkallah *et al.*, 2018). A partir de estas repeticiones se construyó una matriz de consenso, cuyos elementos representan la proporción de veces en la que cada par de nodos fue asignado a la misma comunidad.

De manera similar, para cada ventana temporal se generó un modelo nulo aleatorio mediante la estrategia de randomización de redes (*Network randomization*) implementada en el *Brain Connectivity toolbox* (BTC). Este enfoque genera redes aleatorias que preservan la distribución de grados de la red original, mientras redistribuyen las conexiones entre nodos (Rubinov and Sporns, 2010). Este procedimiento también se repitió 100 veces, obteniendo en cada repetición una partición modular y, a partir de todas ellas, una matriz de consenso correspondiente al modelo nulo (Bassett *et al.*, 2013; Rizkallah *et al.*, 2018).

El proceso de umbralización final consistió en conservar únicamente aquellas asociaciones de la matriz de consenso real que aparecían con mayor frecuencia que en el modelo nulo. Finalmente, sobre la matriz de consenso umbralizada se aplicó el algoritmo de *GenLouvain* para obtener la partición modular definitiva (Rizkallah *et al.*, 2018).

De esta manera, obtuvimos finalmente una matriz de particiones  $S$ , en la cual cada nodo recibía una etiqueta de comunidad. El tamaño de esta matriz fue de  $55 \times 22$ , correspondiente al número de nodos y de ventanas temporales, respectivamente. Este procedimiento se repitió de forma independiente para cada banda de frecuencia, cada sujeto, cada condición de vídeo y para los distintos valores de  $\omega \in [0.1, 0.5, 0.7, 1]$ .

## 4.5. Métricas para el análisis dinámico de comunidades

Con el fin de evaluar el comportamiento dinámico de la red cerebral durante la AOT, se calcularon varias métricas derivadas de la detección de comunidades. Estas medidas permiten caracterizar cómo evoluciona la organización modular a lo largo de las ventanas temporales y analizar si dicha organización varía en función de las condiciones experimentales (vídeos), de la banda de frecuencia considerada y de los diferentes valores del parámetro de acoplamiento temporal. De este modo, no solo se estudia la configuración modular en un instante concreto, sino también su reconfiguración en el tiempo.

### 4.5.1. Número de comunidades

A partir de la matriz de particiones  $S$  generada por el algoritmo de detección multicapa, se contabilizó el número de comunidades distintas presentes en cada ventana temporal. Esta métrica se interpreta como un indicador del grado de segregación funcional de la red en cada instante. En la literatura se han empleado enfoques similares para extraer métricas dinámicas a partir de la evolución temporal de las comunidades (Designed Research; D, Performed Research; D and Pnas, 2011; Rizkallah *et al.*, 2018; Puxeddu, Petti and Astolfi, 2021)

El cálculo se realizó en las 22 ventanas temporales definidas, para cada banda ( $\alpha$  y  $\beta$ ) y condición experimental, considerando únicamente los sujetos con datos disponibles para cada vídeo ( $N = 46$  menos los descartados). El procedimiento se repitió para distintos valores del parámetro de acoplamiento temporal  $\omega$ , con el objetivo de analizar cómo influye en la partición modular obtenida.

Para ello, se analizaron los distintos valores de  $\omega$  y, para cada uno, se procesaron todos los sujetos válidos. En cada ventana temporal se identificaron las comunidades presentes y se contabilizó cuántas distintas aparecían. Los resultados se almacenaron en una matriz de dimensiones *sujetos x ventanas* y posteriormente en una estructura tipo celda que guarda, para cada  $\omega$ , la distribución completa del número de comunidades en todos los sujetos y ventanas.

Finalmente, se calculó la media del número de comunidades por ventana, promediando entre todos los sujetos, para obtener la evolución temporal media de la segregación modular bajo cada condición, banda y valor de omega.

## 4.5.2. Dimensión de comunidades

La dimensión de comunidad se define como el número de nodos que componen cada módulo en una ventana temporal determinada. Su análisis permite estudiar cómo varía el tamaño de las comunidades a lo largo del tiempo y entre condiciones experimentales. Esta métrica se ha utilizado en estudios previos para caracterizar la estructura modular de redes cerebrales y su evolución dinámica (Bassett *et al.*, 2011; Puxeddu, Petti and Astolfi, 2021).

Se trata de una medida complementaria al número de comunidades, ya que en lugar de contabilizar cuántas comunidades existen en una partición, describe su tamaño medio. De esta manera, ambas aportan información relacionada: cuando la red se fragmenta muchas comunidades, cada módulo tiende a ser más pequeño, mientras que una red menos fragmentada concentra los nodos en comunidades más grandes.

En redes cerebrales, los tamaños de comunidad no son homogéneos y pueden presentar una amplia variabilidad, coexistiendo muchas comunidades pequeñas con unas pocas de gran tamaño (Lancichinetti, Fortunato and Radicchi, 2008).

Su cálculo se realizó de manera análoga al del número de comunidades: para cada combinación de  $\omega$ , sujeto y ventana, se identificaron las comunidades presentes y se contaron cuántos nodos integraban cada una de ellas. Los resultados se almacenaron en una estructura que organiza los tamaños de comunidad por  $\omega$ , sujeto y ventana, lo que permite posteriormente obtener la dimensión media por ventana promediando entre todos los sujetos válidos, y así describir la evolución temporal del tamaño de los módulos bajo cada condición, banda y valor de omega.

## 4.5.3. Matriz de consenso

Con el objetivo de obtener una representación grupal que integrase la información de todos los sujetos en cada condición experimental, banda de frecuencia y valor de  $\omega$ , se construyó una matriz de consenso en cada una de las 22 ventanas temporales. Este enfoque se ha utilizado en análisis de redes cerebrales para derivar estructuras modulares representativas a nivel de grupo (Jeub, Sporns and Fortunato, 2018) y permite facilitar la comparación entre condiciones a partir de una partición común.

En la práctica, para cada valor de  $\omega$  y ventana temporal se recopilaron las particiones de comunidades de todos los sujetos en una matriz de dimensiones  $55 \times N_{\text{sujetos}}$ , donde las filas corresponden a los nodos y cada columna indica la etiqueta de comunidad de un sujeto en esa ventana. A partir de estas matrices se calculó una matriz de consenso de  $55 \times 55$ , en la que cada elemento representa la proporción de veces que dos nodos fueron asignados a la misma comunidad en esa ventana.

Posteriormente, sobre cada matriz de consenso se calculó la modularidad y se aplicó el algoritmo *GenLouvain*, obteniendo una partición grupal única de los nodos para esa ventana. Repitiendo este procedimiento en las 22 ventanas, las particiones obtenidas se organizaron en una matriz final de dimensiones  $55 \times 22$ , donde las filas representan los nodos y las columnas las ventanas temporales.

De esta manera, cada nodo queda etiquetado en comunidades a lo largo de todas las ventanas, proporcionando una representación dinámica y grupal de la organización modular de la red. Este proceso, repetido para cada valor de  $\omega$ , permite analizar y comparar la evolución temporal de la modularidad entre vídeos y bandas de frecuencia.

#### 4.5.4. NMI

Para evaluar la estabilidad temporal de la organización modular a nivel grupal se utilizó el índice *Normalized Mutual Information* (NMI). Este índice permite estimar cuánta información de una partición puede explicarse a partir de otra. Es decir, en qué medida conocer una partición aporta información sobre la otra únicamente a partir de la estructura de la red (Danon, Diaz-Guilera and Arenas, 2006).

Sean  $X$  e  $Y$  las variables aleatorias que describen las asignaciones de comunidad de dos particiones distintas, la información mutua  $I(X, Y)$  mide la dependencia estadística entre ambas, es decir, cuánta información del etiquetado  $X$  se puede conocer a partir de  $Y$ , y viceversa. Sin embargo, dado que  $I(X, Y)$  no tiene un límite superior definido, se utiliza una versión normalizada que permite acotar los valores entre 0 y 1, facilitando la interpretación y la comparación entre casos (Strehl and Ghosh, 2002).

En este trabajo se emplea la normalización basada en la media geométrica de las entropías de las dos particiones, propuesta en (Strehl and Ghosh, 2002), por su analogía con un producto escalar normalizado. La expresión final es:

$$NMI(X, Y) = \frac{I(X, Y)}{\sqrt{H(X) \cdot H(Y)}} \quad (4)$$

donde  $H(X)$  y  $H(Y)$  representan las entropías de las particiones  $X$  e  $Y$ . De esta forma, el NMI toma el valor 1 cuando ambas particiones son idénticas, y 0 cuando son completamente independientes. (Danon, Diaz-Guilera and Arenas, 2006).

En nuestro caso, las particiones comparadas corresponden a las obtenidas tras aplicar el algoritmo *GenLouvain* sobre las matrices de consenso en ventanas temporales consecutivas. Dichas particiones se organizaron en una matriz grupal de 55 x 22, donde cada columna representa la asignación de comunidades de los 55 nodos en una ventana. A partir de esta representación, se calculó el NMI entre las particiones de las ventanas 1–2, 2–3, y así sucesivamente hasta la pareja 21–22, obteniendo un total de 21 valores por cada combinación de condición experimental, banda de frecuencia y valor de  $\omega$ .

Este procedimiento se repitió para distintos valores del parámetro omega y para todos los vídeos, lo que permitió evaluar cómo influye en la estabilidad de la partición modular. Un valor medio de NMI cercano a 1 indica que la red mantiene una organización modular estable entre ventanas consecutivas, mientras que valores más bajos reflejan una reconfiguración modular más frecuente a lo largo del tiempo.

## 4.6. Análisis estadístico

Para evaluar la significancia de las diferencias observadas en la métrica de número de comunidades se aplicó el test de Friedman. Dado que los datos no mostraron ser normales y homocedásticos, este procedimiento no paramétrico es adecuado para diseños de medidas repetidas (Zippo *et al.*, 2018). Este test se considera la alternativa al ANOVA de un factor cuando los datos no cumplen los supuestos de normalidad y se utiliza para comparar  $k$  condiciones medidas sobre los mismos sujetos (diseño intrasujeto). La hipótesis nula ( $H_0$ ) establece que las distribuciones son iguales a lo largo de las medidas repetidas, mientras que la hipótesis alternativa ( $H_1$ ) plantea que existen diferencias entre condiciones (Kim, 2014).

El procedimiento consiste en transformar los valores en rangos dentro de cada sujeto y calcular las sumas de rangos por condición. A continuación, se evalúa si estas difieren significativamente entre sí mediante un estadístico con distribución aproximada chi-cuadrado. La fórmula empleada es:

$$X_r^2 = \frac{12}{N \cdot k(k+1)} \sum_{j=1}^k R_j^2 - 3N \cdot (k+1) \quad (5)$$

donde  $k$  es el número de condiciones,  $N$  es el número de sujetos y  $R_j$  es la suma de los rangos en la condición  $j$ .

En este trabajo, el test de Friedman se aplicó de manera independiente en cada una de las 22 ventanas temporales. Para ello, se consideraron todos los sujetos válidos y los cuatro valores del parámetro de acoplamiento  $\omega$  (0.1, 0.5, 0.7 y 1). De esta forma, en cada ventana se disponía de cuatro vectores de datos correspondientes al número de comunidades obtenido por cada sujeto en cada valor de  $\omega$ . Sobre estos vectores se aplicó el test, obteniendo un  $p$ -valor por ventana. Se estableció un nivel de significación de  $\alpha = 0.05$ , de modo que, cuando el valor resultaba significativo ( $p < 0.05$ ), se rechazaba la hipótesis nula y se concluía que la distribución difería entre los distintos valores de  $\omega$ . En total se obtuvieron 22  $p$ -valores, uno por cada ventana temporal, lo que permitió evaluar si la dinámica modular mostraba diferencias significativas entre valores de  $\omega$  en el tiempo.

Cabe señalar que el test se aplicó únicamente a la métrica de número de comunidades. Dado que la dimensión de comunidades constituye una medida complementaria y directamente relacionada, su análisis estadístico habría arrojado resultados equivalentes.



# Capítulo 5. Resultados

Una vez descrita la metodología empleada, en este capítulo se presentan los resultados obtenidos. En primer lugar, se muestran los resultados con los parámetros por defecto, es decir, fijando  $\gamma = 1$  y  $\omega = 1$ . A continuación, se presentan los resultados obtenidos al modificar los valores del parámetro  $\omega \in [0.1, 0.5, 0.7, 1]$ , con el fin de analizar su influencia en la dinámica modular. Las métricas consideradas (número de comunidades, dimensión de comunidades, matriz de consenso y NMI) se muestran tanto para los valores por defecto como para los valores modificados de omega, permitiendo así una comparación directa entre condiciones experimentales, bandas de frecuencia y configuraciones del modelo.

## 5.1. Reconfiguración modular inducida por la AOT

En primer lugar, se analizó la dinámica modular con los parámetros por defecto ( $\gamma = 1$  y  $\omega = 1$ ). En este caso, se representan las particiones de los 55 nodos en comunidades a lo largo de las 22 ventanas temporales, donde cada color corresponde a una comunidad distinta. En las figuras, cada recuadro corresponde a un sujeto. El eje X representa las ventanas temporales y el eje Y los nodos. Así, las líneas horizontales muestran la pertenencia de cada nodo a una comunidad a lo largo del tiempo: cuando el color permanece estable, el nodo sigue en la misma comunidad, mientras que los cambios de color indican transiciones comunitarias. Además, cuando dos nodos presentan el mismo color en una ventana determinada, significa que en ese instante pertenecen a la misma comunidad.

Se observa que, en todos los casos, los nodos no permanecen estáticos, sino que presentan una clara reconfiguración a lo largo del tiempo. Este efecto es especialmente evidente en torno a los momentos marcados por las dos líneas rojas discontinuas: la primera indica el inicio del proceso de preparación (señalado experimentalmente por un círculo rojo) y la segunda corresponde al inicio del video. Estos puntos temporales actúan como hitos que desencadenan reorganizaciones significativas en la estructura modular de la red cerebral.

En la Figura 5.1 (condición W1, banda alfa) se aprecia que la dinámica modular cambia notablemente tras el inicio del video, momento en el que las comunidades muestran una mayor fragmentación. Además, se observa una marcada variabilidad entre sujetos: algunos presentan transiciones frecuentes en la asignación de comunidades, mientras que otros mantienen patrones más estables. Por ejemplo, en los sujetos 6 y 23 muchas filas cambian repetidamente de color a lo largo de las ventanas, reflejando una alta reconfiguración modular. En contraste, en los sujetos 8 y 16 la mayoría de las filas mantienen un color homogéneo y continuo, lo que indica una mayor estabilidad comunitaria en el tiempo.

En la Figura 5.2 (condición W1, banda beta) se aprecia una mayor fragmentación modular en comparación con la banda alfa, reflejada en un incremento de los cambios de color a lo largo de las ventanas. Esto indica que la dinámica en beta es más inestable y presenta transiciones más frecuentes entre comunidades. A diferencia de lo observado en alfa, apenas se encuentran sujetos con franjas homogéneas y continuas, lo que revela una menor estabilidad comunitaria. En prácticamente todos los sujetos se aprecia una clara reorganización, siendo especialmente evidente en el sujeto 31.

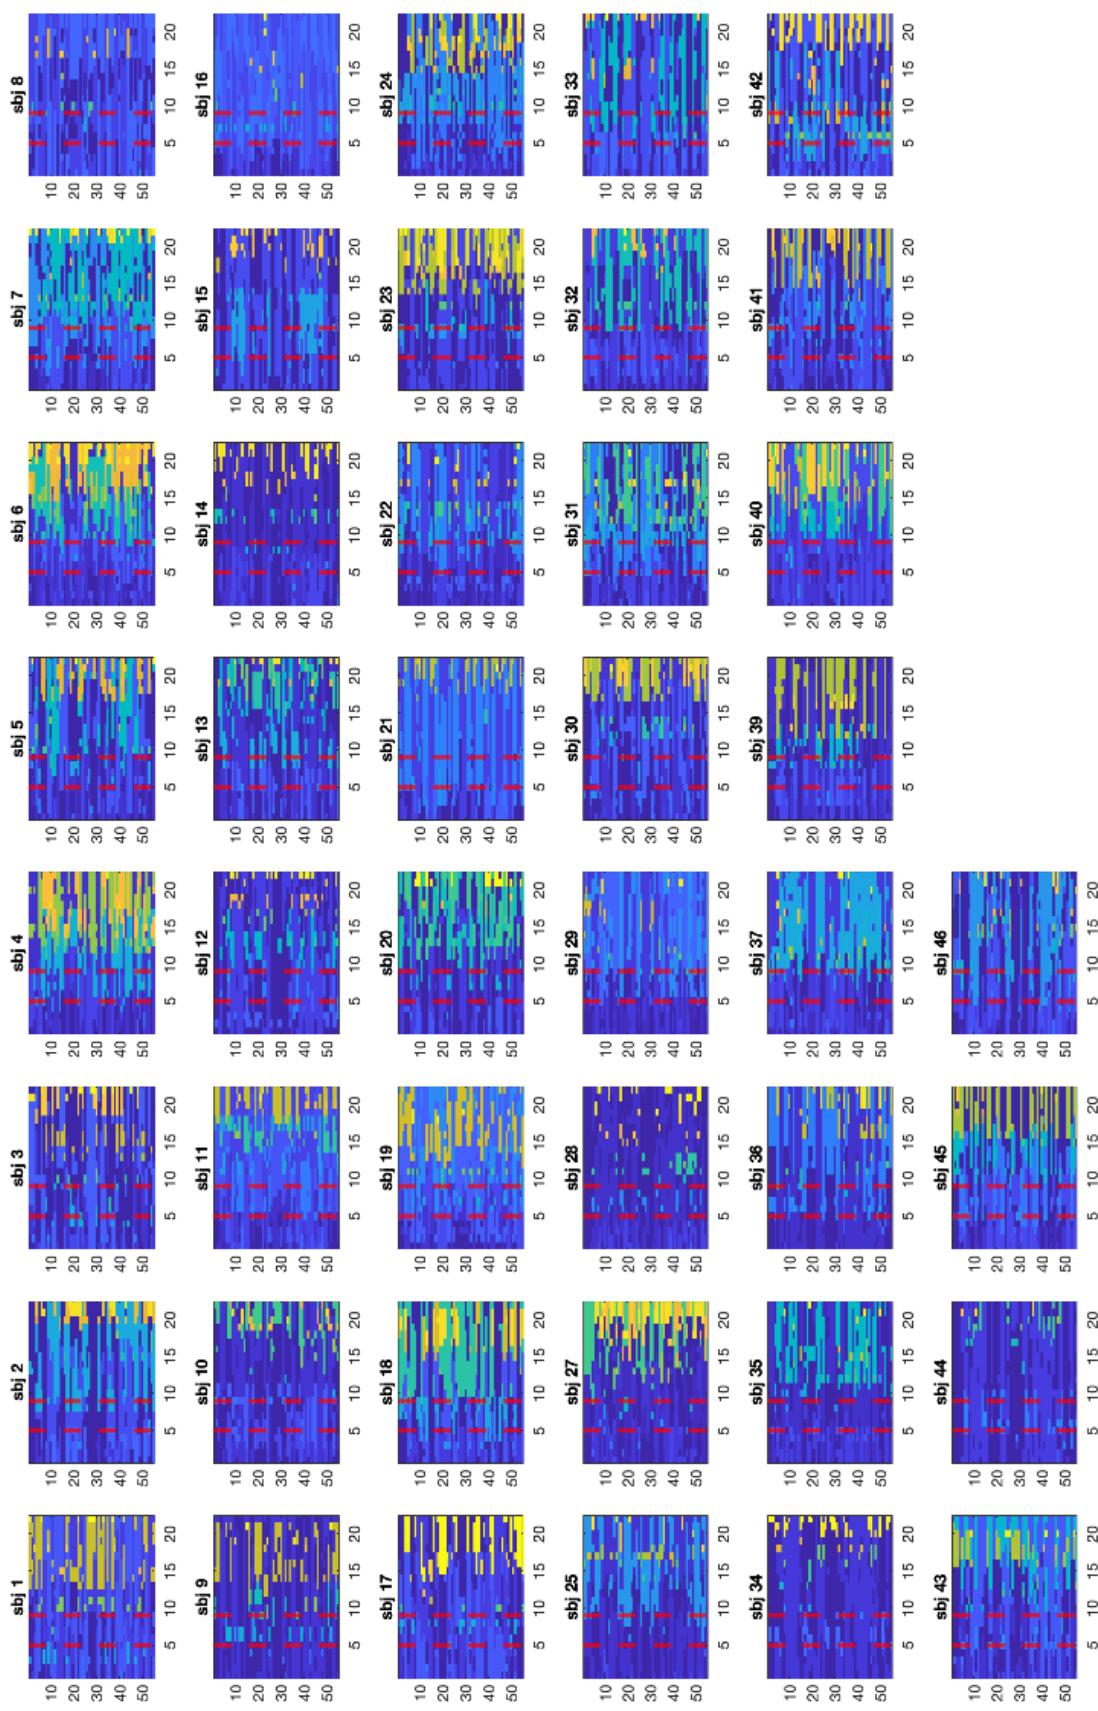
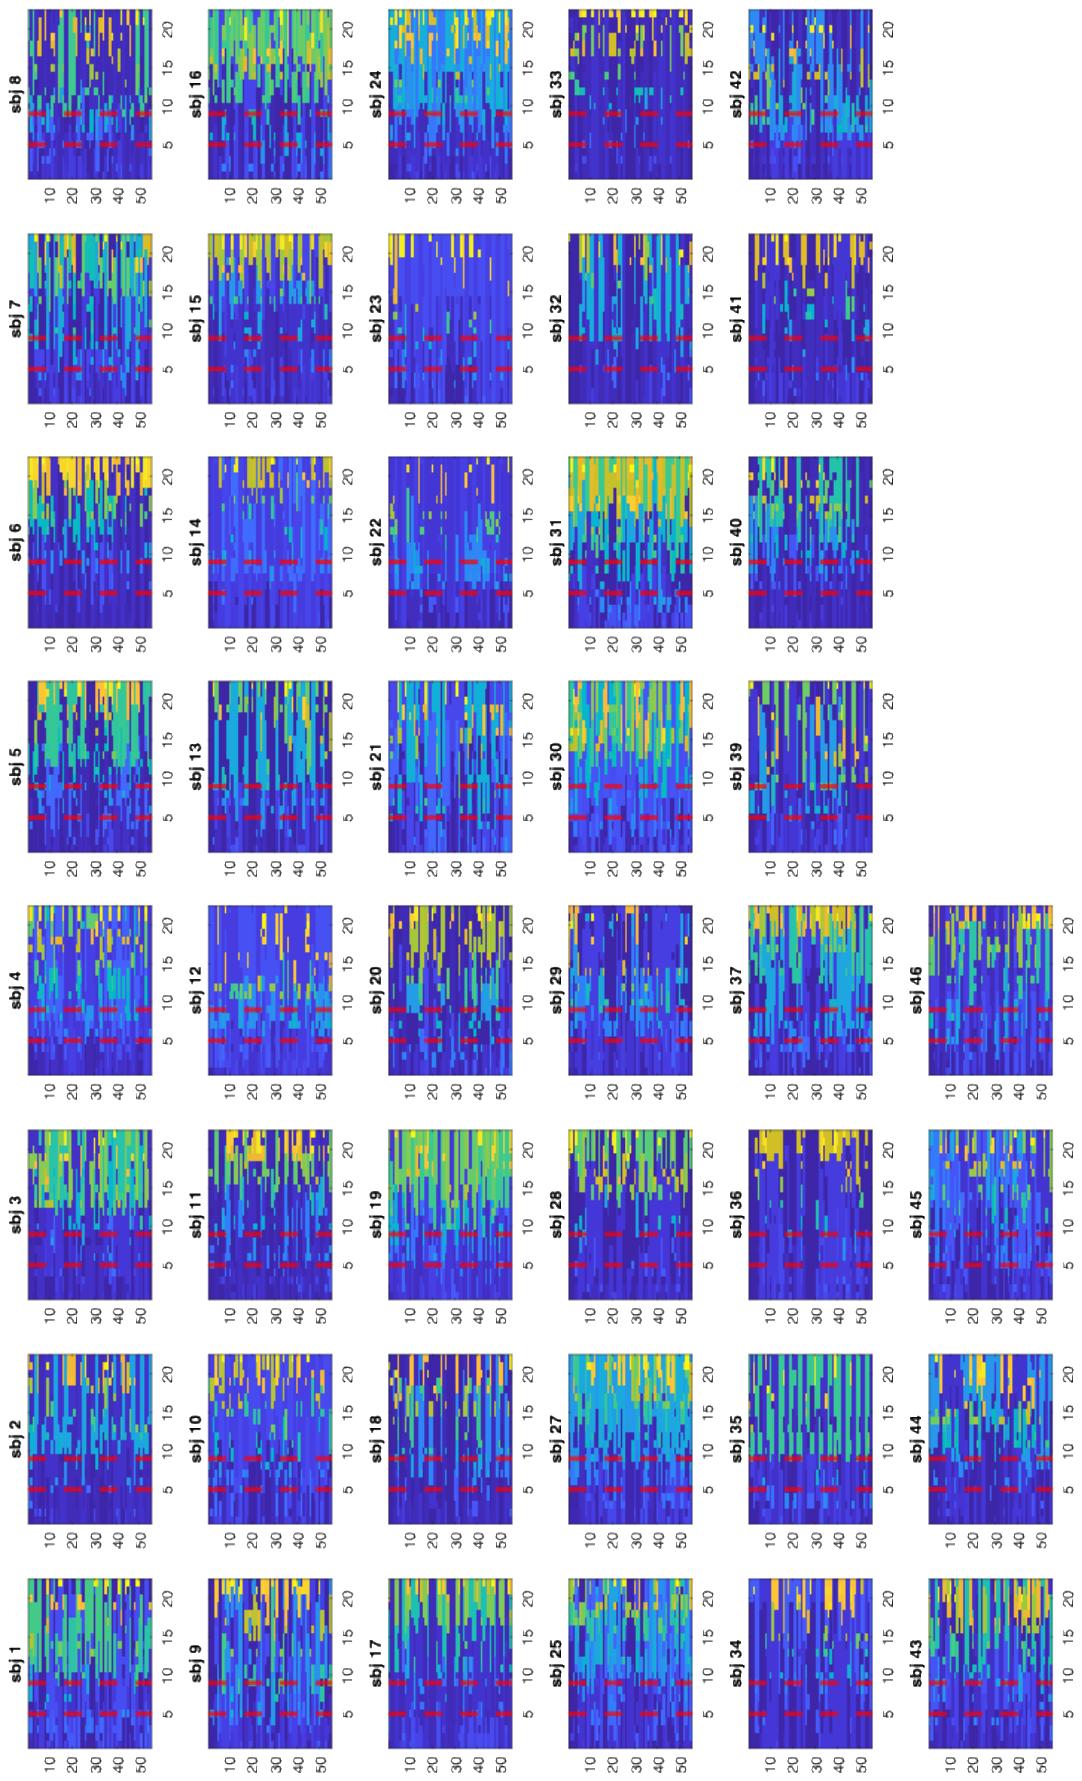
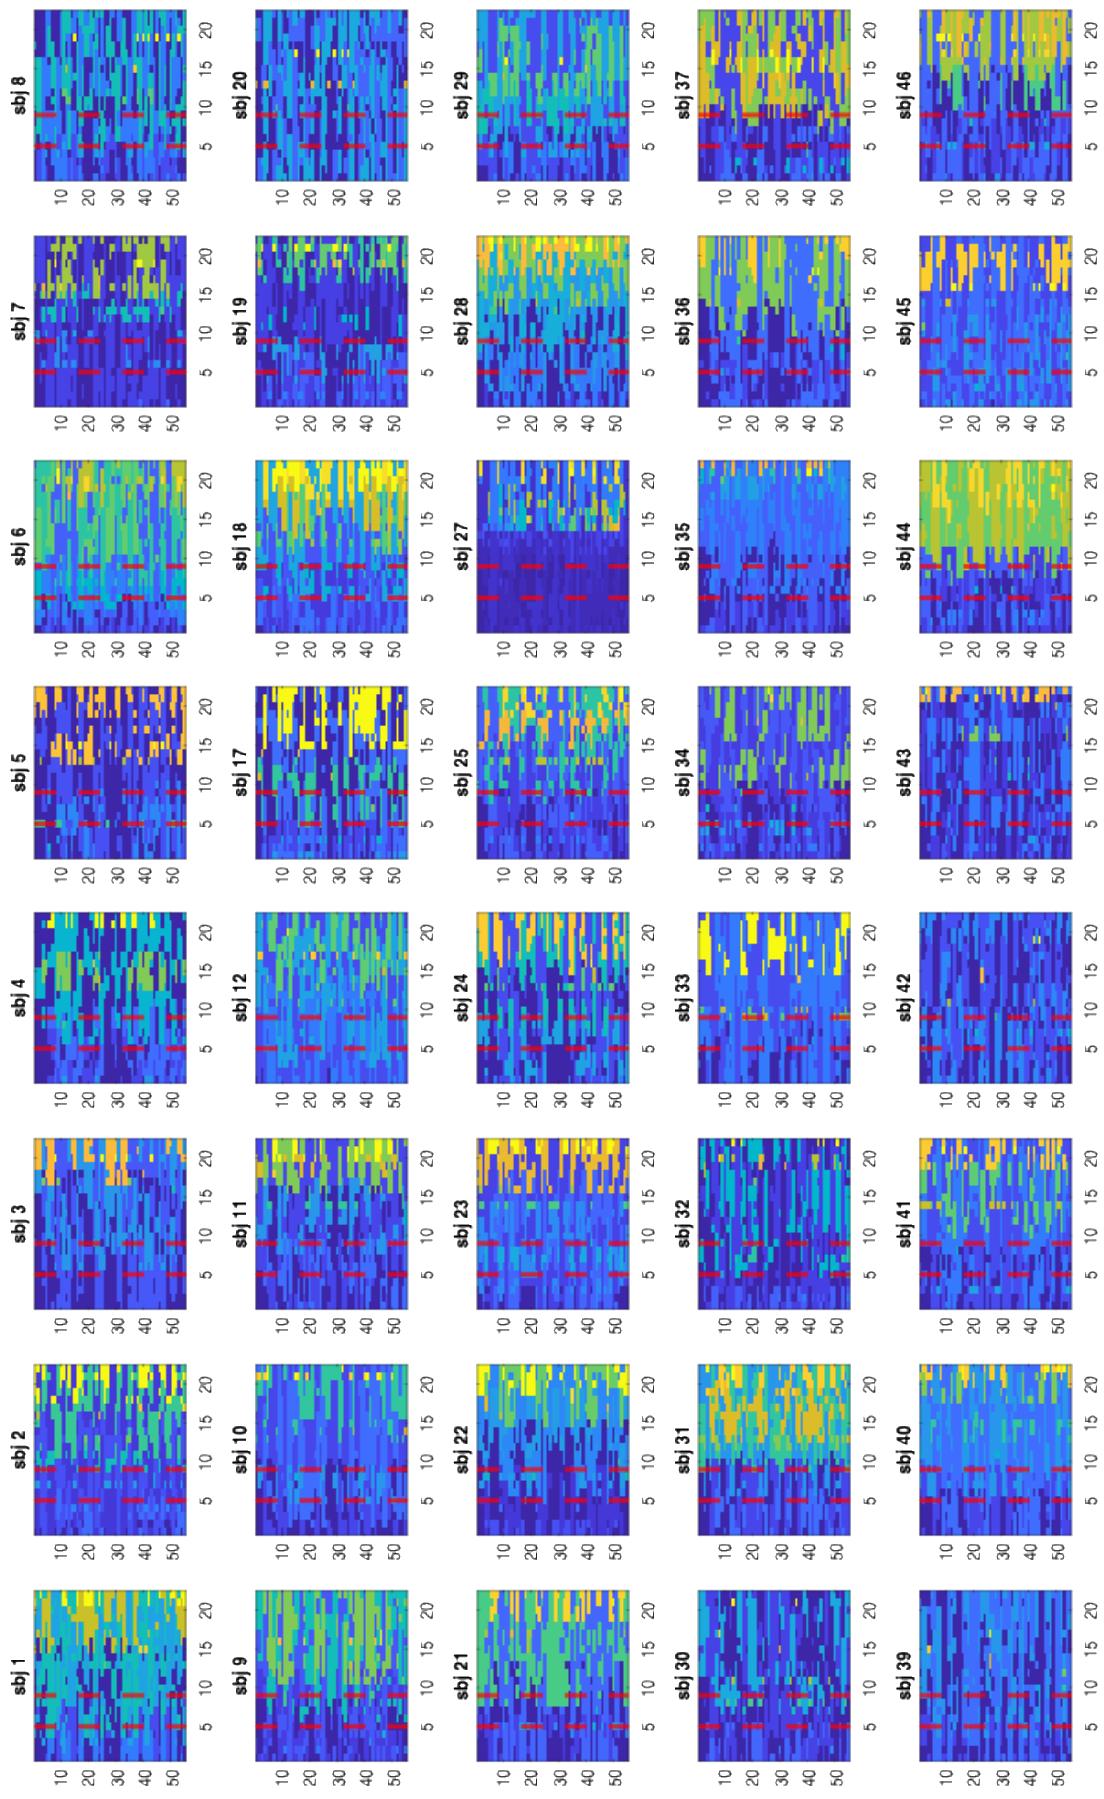


Figura 5.1 Particiones modulares de los 55 nodos en cada sujeto (W1, banda alfa) a lo largo de 22 ventanas temporales.



**Figura 5.2** Particiones modulares de los 55 nodos en cada sujeto ( $W_1$ , banda beta) a lo largo de 22 ventanas temporales.



**Figura 5.3** Particiones modulares de los 55 nodos en cada sujeto (W2, banda alfa) a lo largo de 22 ventanas temporales.

En la Figura 5.3 (condición W2, banda alfa) se aprecia que, aunque se mantiene el mismo patrón general observado en la banda alfa de W1, la dinámica cambia en función del vídeo. Sujetos como el 6 o el 23, que en W1 presentaban una fuerte fragmentación, muestran en W2 un comportamiento más estable, mientras que otros, que en la primera condición mantenían comunidades más homogéneas, en W2 evidencian una mayor variabilidad.

En la Figura 5.4 (condición W2, banda beta) se observa una dinámica más fragmentada que en la banda alfa de la misma condición, con la mayoría de los sujetos mostrando transiciones frecuentes entre comunidades a lo largo de las ventanas. A diferencia de W1 beta, donde casi todos los sujetos presentaban una reorganización constante, en W2 beta se aprecian algunos casos con mayor estabilidad relativa. Por ejemplo, el sujeto 42 mantiene franjas más homogéneas, mientras que en otros como el 12 o el 20 predomina la reconfiguración modular continua.

En este apartado se muestran únicamente los resultados de las condiciones W1 y W2, ya que representan los casos más contrastados y permiten ilustrar de forma clara las diferencias en la dinámica modular. La condición W3 presenta un comportamiento intermedio entre ambas, con patrones de reorganización que no alcanzan la marcada fragmentación de W1 ni la variabilidad de W2, por lo que se ha considerado menos representativa a efectos de exposición.

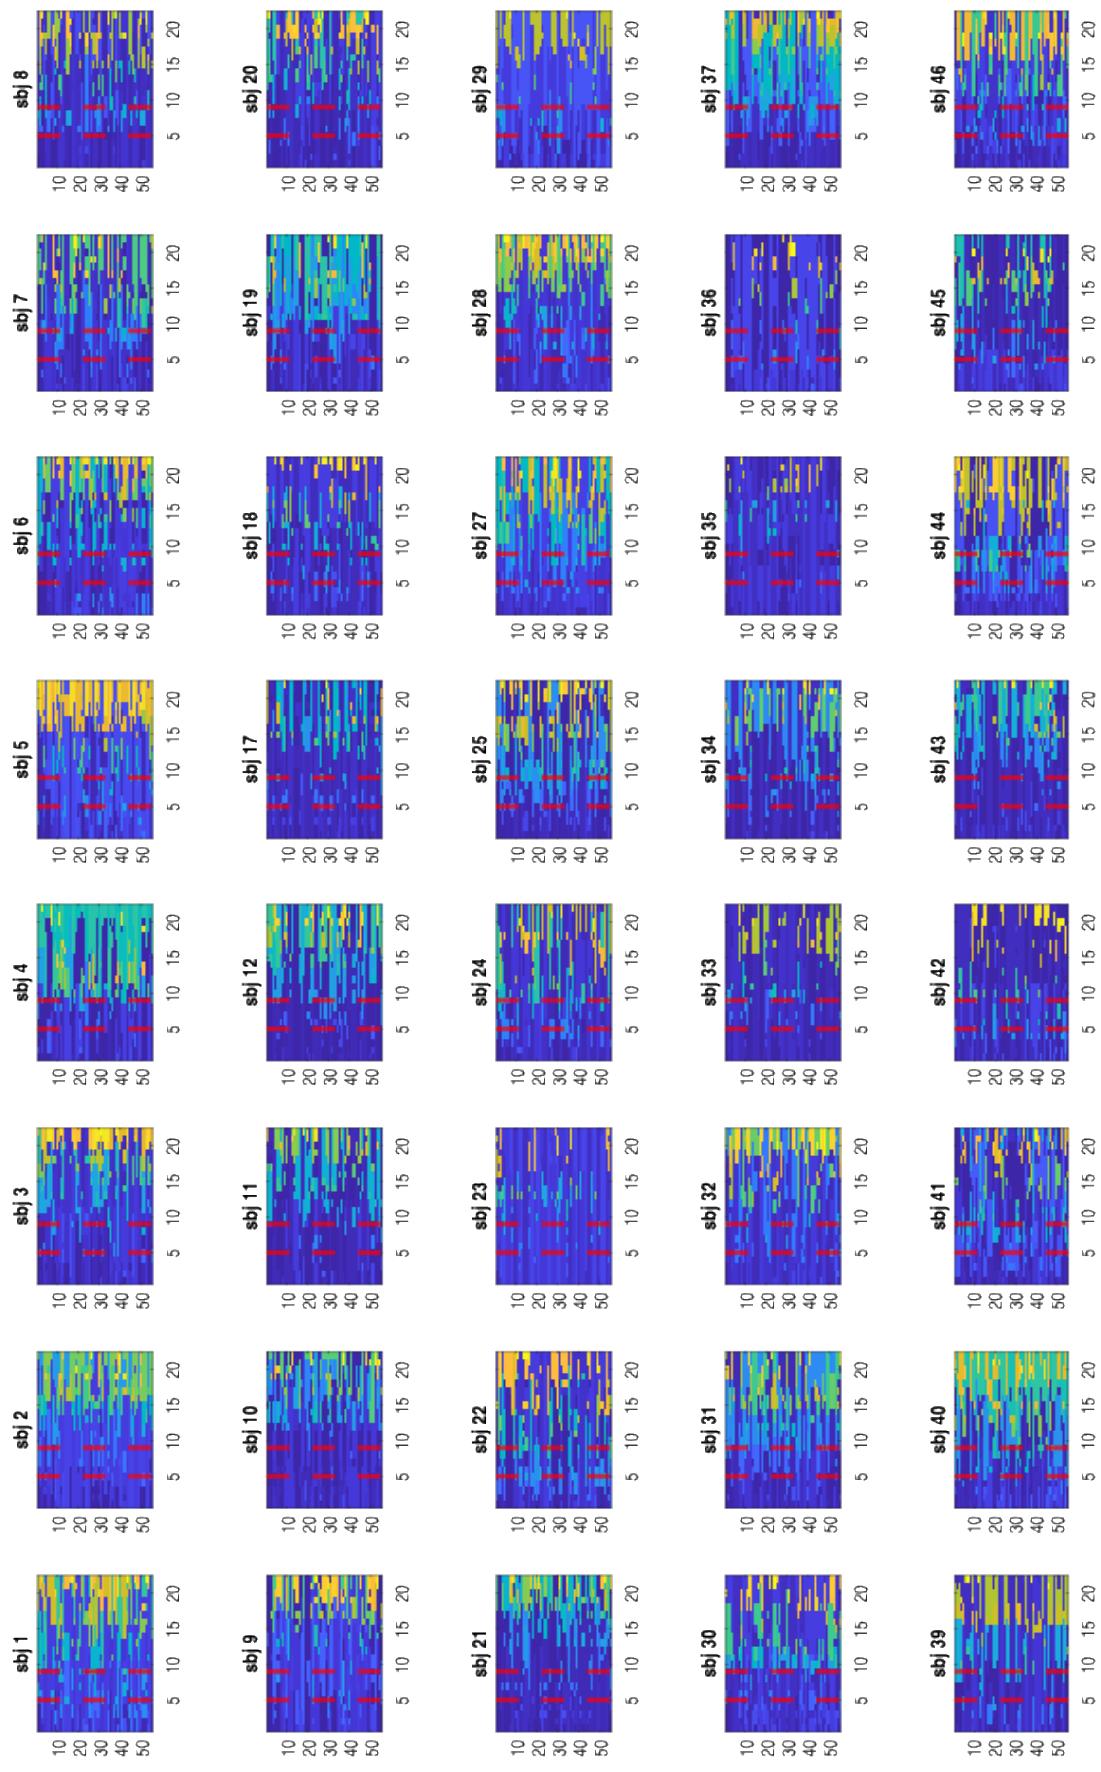


Figura 5.4 Particiones modulares de los 55 nodos en cada sujeto (W2, banda beta) a lo largo de 22 ventanas temporales.

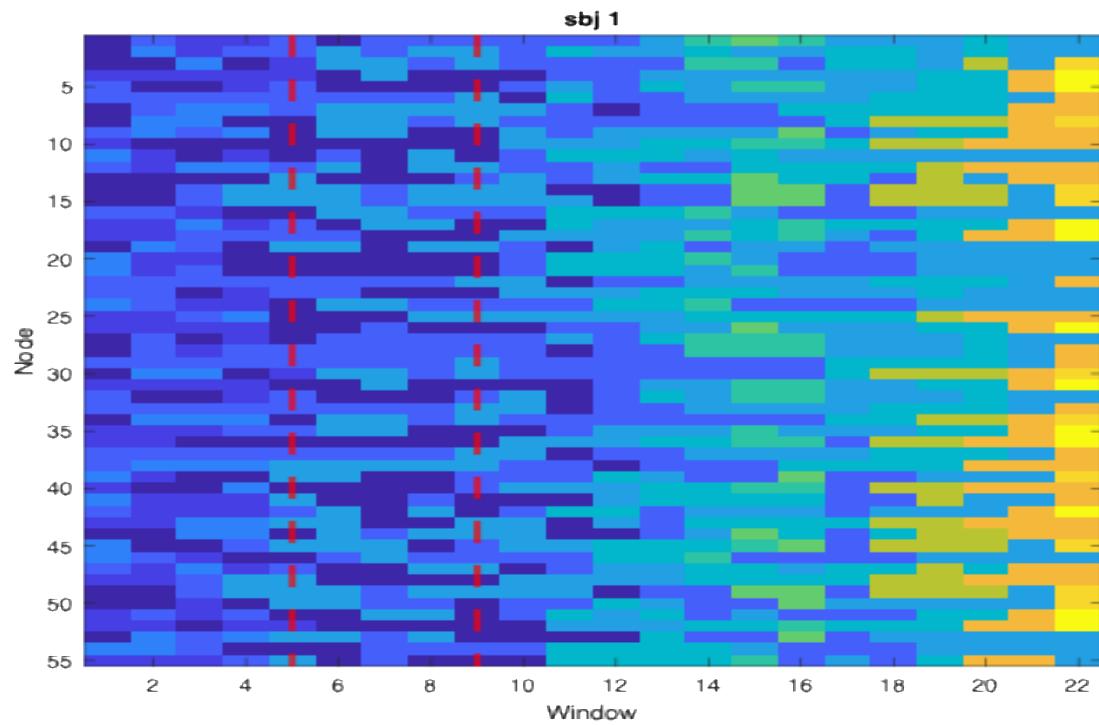
## 5.2. Influencia del parámetro $\omega$ en la organización modular

Tras el análisis inicial con  $\gamma = 1$  y  $\omega = 1$ , se exploró cómo la modificación de  $\omega$ , parámetro que regula el grado de acoplamiento temporal entre ventanas, afecta a la organización modular. A modo ilustrativo, en las Figuras 5.5 – 5.8 se muestran los resultados del sujeto 1 en la condición W1 - banda alfa para distintos valores de  $\omega \in [0.1, 0.5, 0.7, 1]$ .

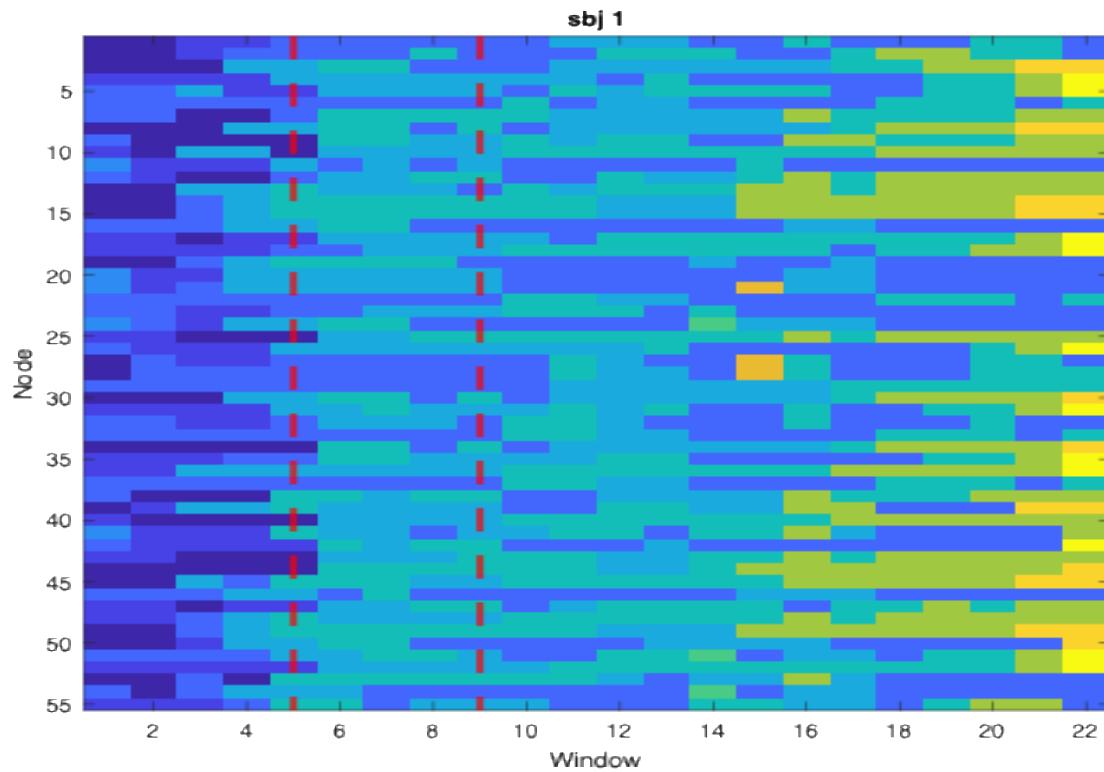
Cuando  $\omega = 0.1$  (Figura 5.5), se observa una fuerte variabilidad: los nodos cambian frecuentemente de comunidad, lo que refleja una red con alta flexibilidad temporal. A medida que se incrementa el valor de  $\omega$ , el acoplamiento entre ventanas se hace más fuerte y las particiones resultantes tienden a ser más consistentes. Por ejemplo, con  $\omega = 0.5$  (Figura 5.6) ya se aprecia una reducción de los cambios bruscos entre ventanas, y con  $\omega = 0.7$  (Figura 5.7) esta tendencia se acentúa, con comunidades más regulares a lo largo del tiempo. Finalmente, con  $\omega = 1$  (Figura 5.8) los nodos permanecen en gran medida dentro de las mismas comunidades durante todo el periodo, lo que implica una partición mucho más homogénea y con menos fragmentación que en valores bajos de  $\omega$ .

Este ejemplo individual muestra cómo el parámetro  $\omega$  actúa como un factor de acoplamiento temporal, forzando en mayor medida a los nodos a mantener su asignación comunitaria entre ventanas consecutivas. Con valores bajos de  $\omega$  se capturan mejor las fluctuaciones dinámicas de la red, mientras que con valores altos las particiones tienden a ser más uniformes a lo largo del tiempo.

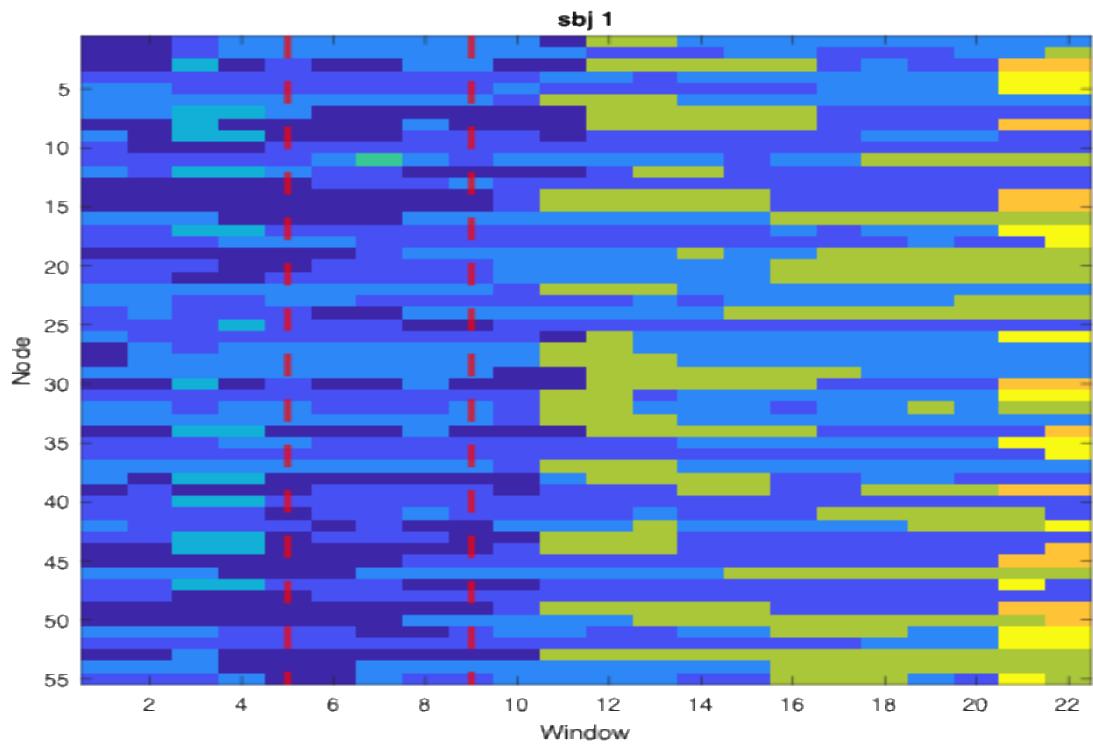
No obstante, estas observaciones son solo cualitativas. En los siguientes apartados se cuantificarán de manera sistemática mediante diferentes métricas (número de comunidades, dimensión de comunidades, NMI y matrices de consenso), lo que permitirá evaluar con mayor precisión cómo la elección de  $\omega$  modula la dinámica de las comunidades entre condiciones y sujetos.



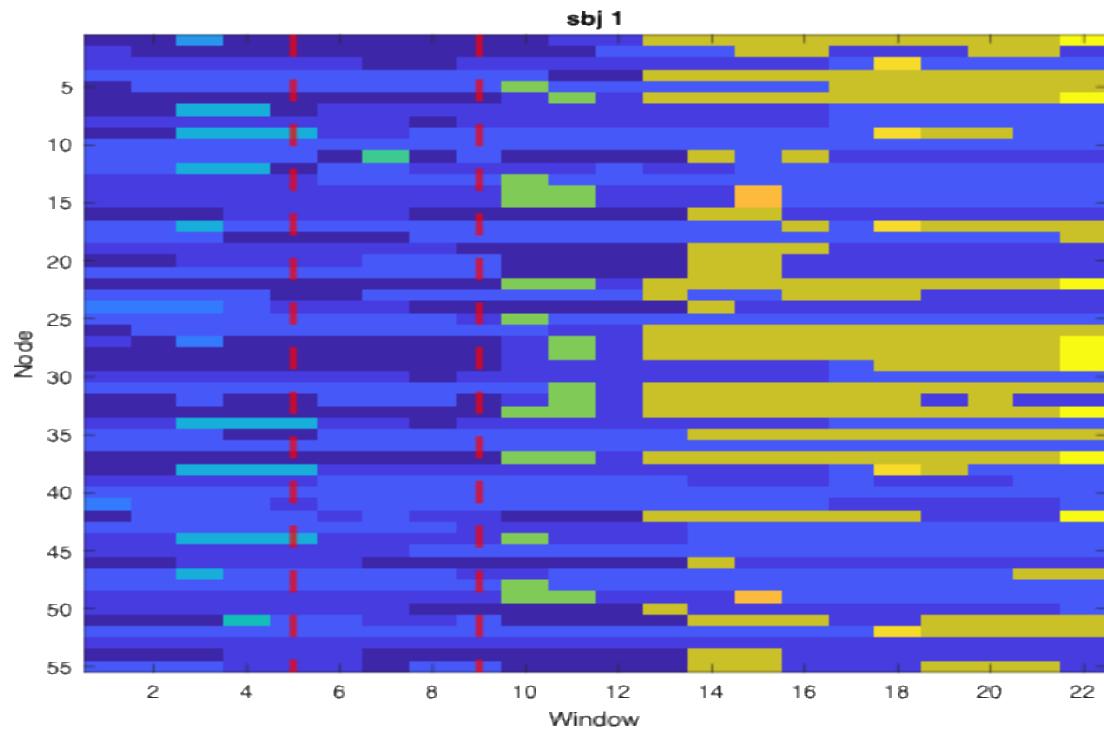
**Figura 5.5** Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 0.1$ ).



**Figura 5.6** Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 0.5$ ).



**Figura 5.7** Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 0.7$ ).



**Figura 5.8** Ejemplo ilustrativo de las particiones en comunidades del sujeto 1 en la condición W1-alfa ( $\omega = 1$ ).

## 5.3. Evaluación mediante métricas dinámicas

Para caracterizar la dinámica modular se calcularon distintas métricas complementarias: el número de comunidades, la dimensión de las comunidades y la combinación de matriz de consenso con NMI. Estas medidas permiten evaluar la fragmentación, el tamaño y la estabilidad de la organización modular a lo largo del tiempo.

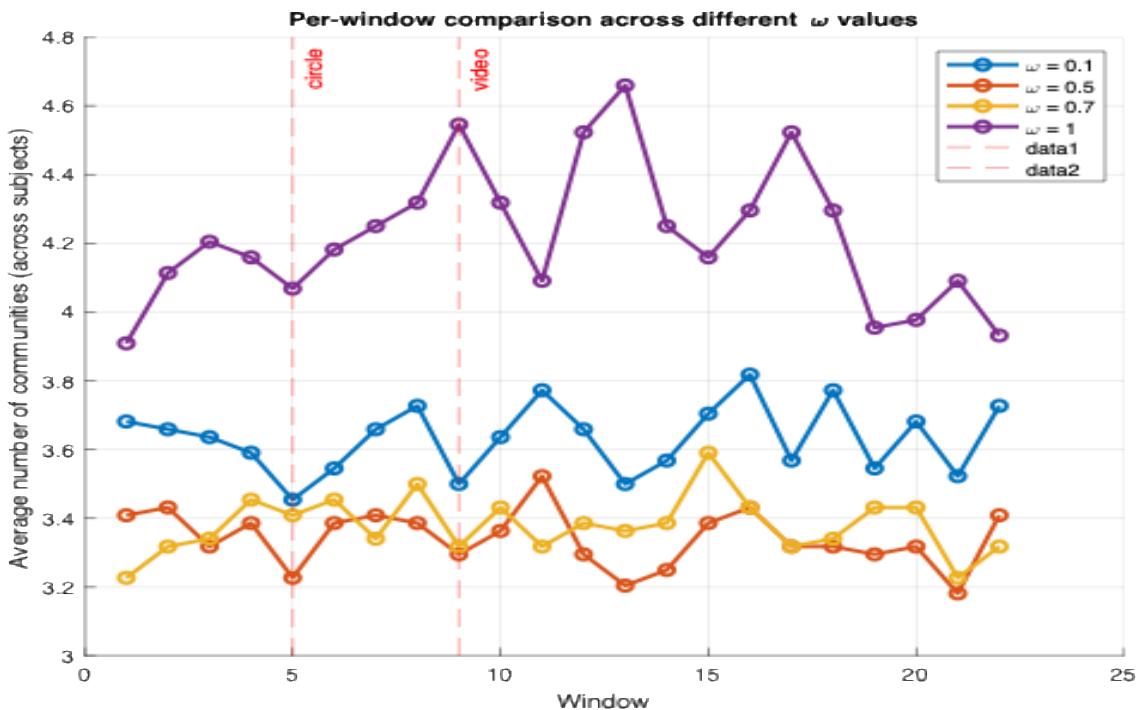
### 5.3.1. Número de comunidades

Con el objetivo de analizar cómo varía la fragmentación de la red en función del acoplamiento temporal, se calculó el número de comunidades en cada ventana para cada sujeto, condición experimental, banda de frecuencia y valor de  $\omega$ . Posteriormente, se promedió este número de comunidades entre todos los sujetos en cada ventana, obteniendo así una medida grupal que permite comparar de manera más directa la dinámica modular entre diferentes valores de  $\omega$ .

En este apartado se han mostrado ejemplos representativos (W1 y W2) para ilustrar con más detalle las dinámicas observadas. No obstante, los mismos patrones generales se reproducen en el resto de las condiciones.

En la Figura 5.9 (condición W1, banda alfa) se observa cómo el número de comunidades varía en función del parámetro  $\omega$ . Para  $\omega = 0.1$ , el promedio se mantiene en torno a 3-4 comunidades, con ligeras oscilaciones entre ventanas. Con  $\omega = 0.5$  y  $\omega = 0.7$  el valor medio se estabiliza alrededor de 3, mientras que con  $\omega = 1$  se alcanzan los valores más altos, cercanos a 4-5 comunidades. Este resultado indica que el mayor acoplamiento temporal no reduce el número de comunidades, como cabría esperar según lo descrito en la literatura donde valores altos de  $\omega$  suelen favorecer particiones más estables y menos fragmentadas, sino que incrementa la fragmentación modular de la red en esta condición. Esta discrepancia se abordará en el capítulo de Discusión, donde se analizarán posibles explicaciones.

El análisis estadístico mediante el test de Friedman confirmó la existencia de diferencias significativas entre los cuatro valores de  $\omega$ . En todas las ventanas temporales de la condición W1, banda alfa, se obtuvieron  $p$ -valores inferiores a 0.05 (Tabla 1), lo que indica que el número de comunidades varía de manera consistente en función del parámetro omega.



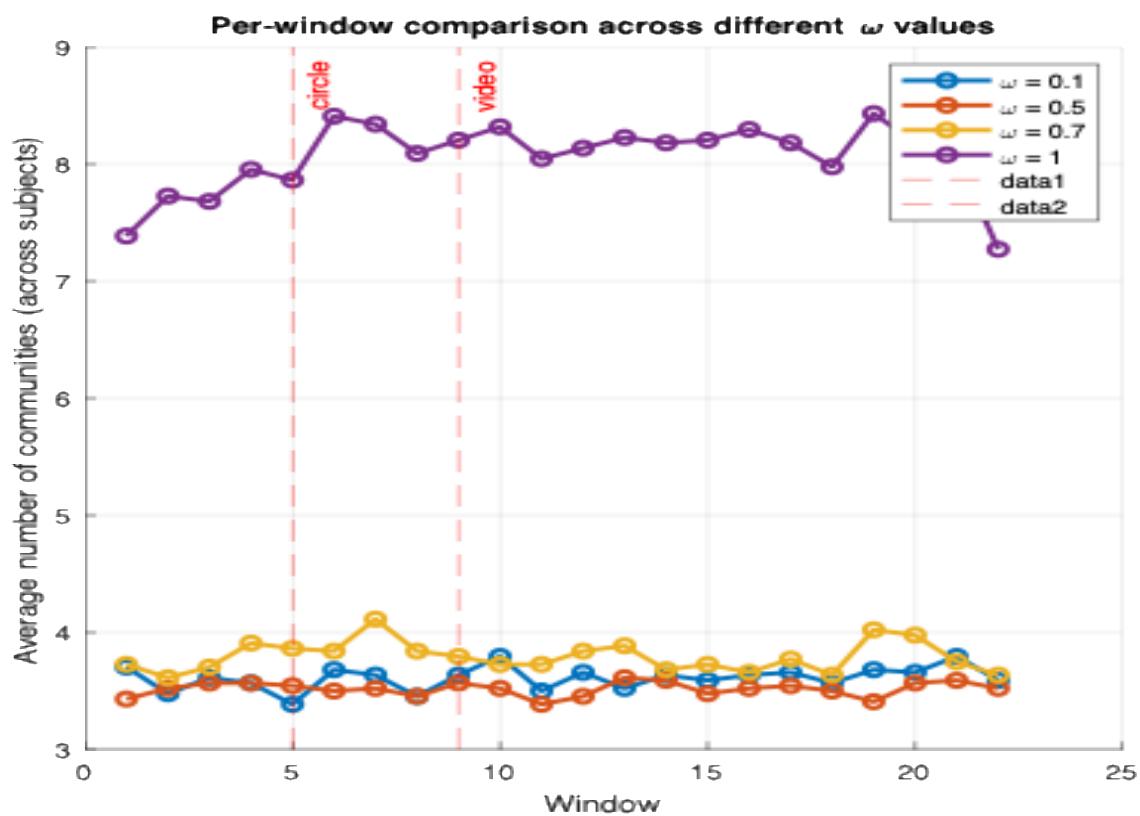
**Figura 5.9** Ejemplo del número promedio de comunidades en la condición W1, banda alfa, para distintos valores de  $\omega$ .

Ventana	p-valor	Significativa ( $p < 0.05$ )
1	0.000465	Sí
2	1.095e-05	Sí
3	9.837e-09	Sí
4	8.374e-07	Sí
5	4.192e-06	Sí
6	8.78e-06	Sí
7	3.657e-07	Sí
8	5.515e-06	Sí
9	3.927e-08	Sí
10	5.047e-06	Sí
11	0.001881	Sí
12	1.716e-07	Sí
13	2.287e-12	Sí
14	2.859e-06	Sí
15	0.00369	Sí
16	4.974e-07	Sí
17	1.196e-09	Sí
18	2.504e-09	Sí
19	0.0006261	Sí
20	0.0004677	Sí
21	2.206e-05	Sí
22	0.0004623	Sí

**Tabla 1** Resultados del test de Friedman aplicados al número de comunidades en la condición W1, banda alfa. Se muestran los  $p$ -valores obtenidos en cada una de las 22 ventanas temporales.

En la Figura 5.10 (condición W1, banda beta) se aprecia un contraste más marcado entre los distintos valores de  $\omega$  que en la banda alfa. Para  $\omega = 0.1$  y  $\omega = 0.5$  el número de comunidades se mantiene estable en torno a 3, mientras que con  $\omega = 0.7$  asciende ligeramente hasta valores cercanos a 4. En cambio, con  $\omega = 1$  se alcanza un número claramente superior, entre 7 y 9 comunidades, que además se mantiene relativamente constante a lo largo del tiempo. Este resultado refuerza la influencia directa de  $\omega$  sobre la fragmentación modular de la red, mostrando en la banda beta un efecto aún más pronunciado que en la alfa.

El análisis estadístico mediante el test de Friedman confirmó esta observación: en las 22 ventanas se obtuvieron  $p$ -valores altamente significativos (Tabla 2), en muchos casos del orden de  $10^{-20}$  incluso más pequeños que en la condición W1 alfa. Este resultado concuerda con lo observado en la Figura 5.10, donde la línea morada correspondiente a  $\omega = 1$  aparece claramente más separada del resto de curvas, reflejando que las diferencias entre los valores de  $\omega$  son todavía más pronunciadas.



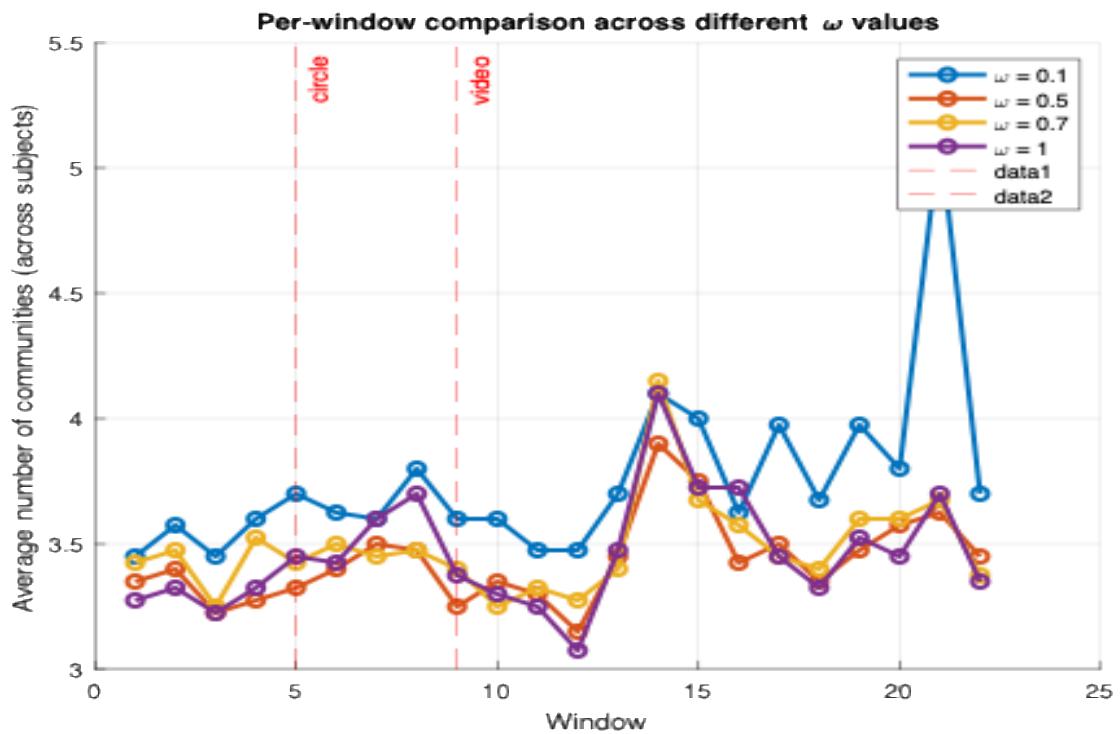
**Figura 5.10** Ejemplo del número promedio de comunidades en la condición W1, banda beta, para distintos valores de  $\omega$ .

Ventana	<i>p</i> -valor	Significativa ( <i>p</i> < 0.05)
1	1.818e-19	Sí
2	2.457e-19	Sí
3	5.827e-20	Sí
4	1.543e-20	Sí
5	4.829e-20	Sí
6	9.777e-20	Sí
7	1.584e-19	Sí
8	1.373e-19	Sí
9	8.376e-20	Sí
10	7.329e-20	Sí
11	7.138e-20	Sí
12	4.661e-21	Sí
13	3.734e-21	Sí
14	3.367e-20	Sí
15	2.946e-21	Sí
16	1.476e-20	Sí
17	8.179e-20	Sí
18	1.764e-19	Sí
19	2.889e-21	Sí
20	9.786e-21	Sí
21	5.329e-18	Sí
22	2.140e-16	Sí

**Tabla 2** Resultados del test de Friedman aplicados al número de comunidades en la condición W1, banda beta. Se muestran los *p*-valores obtenidos en cada una de las 22 ventanas temporales.

En la Figura 5.11 (condición W2, banda alfa) se observa que el número de comunidades depende del valor de  $\omega$ , aunque con diferencias más sutiles que en W1. Para  $\omega = 0.1$  la curva muestra mayores fluctuaciones, con picos aislados como en la ventana 22 donde se superan las 5 comunidades. En cambio, para  $\omega = 0.5, 0.7$  y  $1$  las curvas se mantienen más estables en torno a 3-4 comunidades, especialmente a partir de la ventana 10, coincidiendo con el inicio del vídeo. Esto refleja una dinámica más coherente y menos ruidosa que en la banda beta, donde la fragmentación resultaba más acusada.

El análisis estadístico mediante el test de Friedman refleja este comportamiento: aunque en varias ventanas se encontraron diferencias significativas entre los valores de  $\omega$  ( $p < 0.05$  en las ventanas 3–5, 8–10, 12 y 17–20), en muchas otras no se alcanzó la significación (Tabla 3). En conjunto, aproximadamente la mitad de las ventanas resultaron significativas, lo que concuerda con la menor separación visual de las líneas en la Figura 5.11 y confirma que en esta condición la influencia de  $\omega$  sobre el número de comunidades es más limitada y dependiente del intervalo temporal analizado.



**Figura 5.11** Ejemplo del número promedio de comunidades en la condición W2, banda alfa, para distintos valores de  $\omega$ .

Ventana	p-valor	Significativa ( $p < 0.05$ )
1	0.467	No
2	0.06536	No
3	0.04785	Sí
4	0.02157	Sí
5	0.004124	Sí
6	0.1679	No
7	0.308	No
8	0.04337	Sí
9	0.0188	Sí
10	0.01575	Sí
11	0.4582	No
12	0.0004714	Sí
13	0.3729	No
14	0.1356	No
15	0.6291	No
16	0.2921	No
17	0.006407	Sí
18	0.001966	Sí
19	0.01188	Sí
20	0.02183	Sí
21	0.3326	No
22	0.003768	Sí

**Tabla 3** Resultados del test de Friedman aplicados al número de comunidades en la condición W2, banda alfa. Se muestran los  $p$ -valores obtenidos en cada una de las 22 ventanas temporales.

El patrón general se mantiene a lo largo de todas las condiciones experimentales (W1–W3, en bandas alfa y beta), aunque con diferencias en la magnitud del efecto. En particular, en W1 se observa el incremento más acusado en el número de comunidades al aumentar  $\omega$ , mientras que en W2 el efecto es más moderado y en W3 aparece como una situación intermedia, con un aumento presente pero menos marcado.

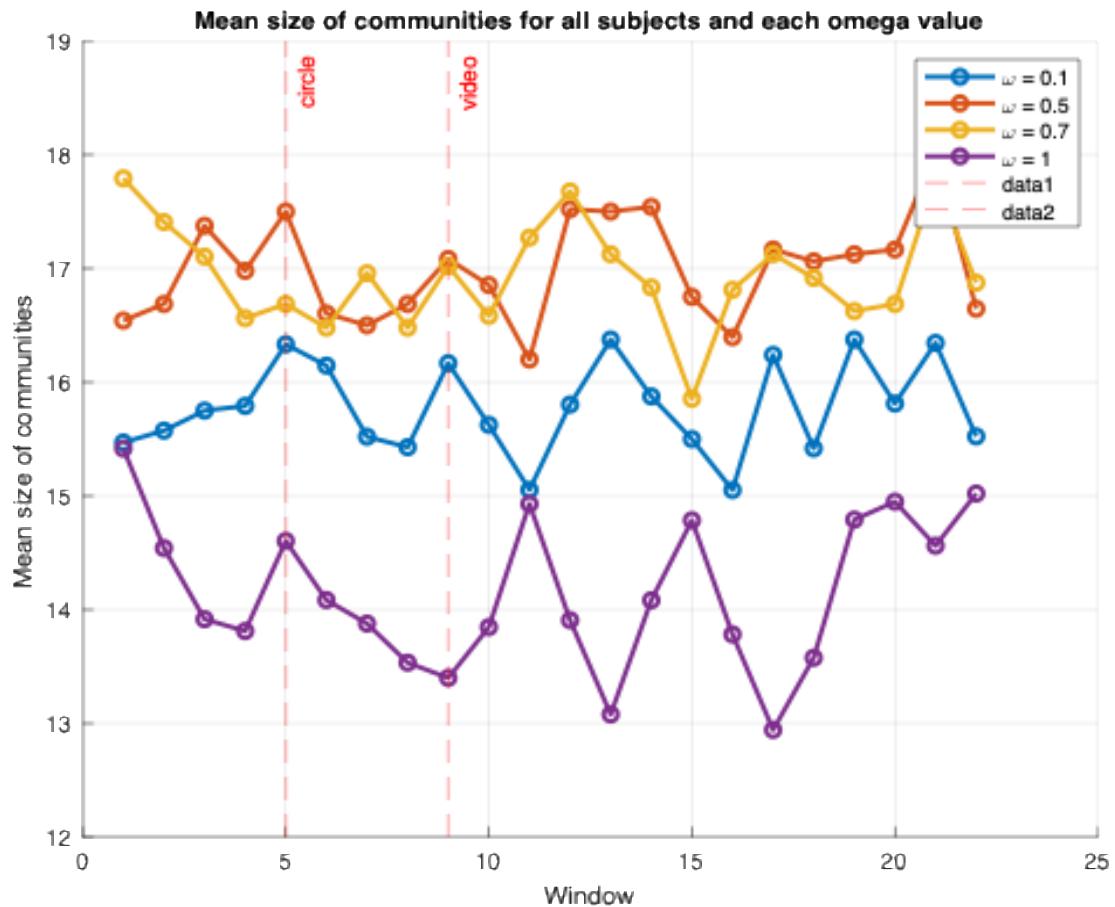
De forma global, se aprecia que, antes del inicio del vídeo, el número de comunidades suele ser menor, mientras que tras el comienzo de la tarea de observación se produce un aumento progresivo, reflejando la reorganización dinámica de la red cerebral inducida por el estímulo. Este efecto se amplifica especialmente para  $\omega = 1$ , alcanzando en la banda beta valores máximos cercanos a 10 comunidades, mientras que en la banda alfa se mantiene alrededor de 5.

### 5.3.2. Dimensión de comunidades

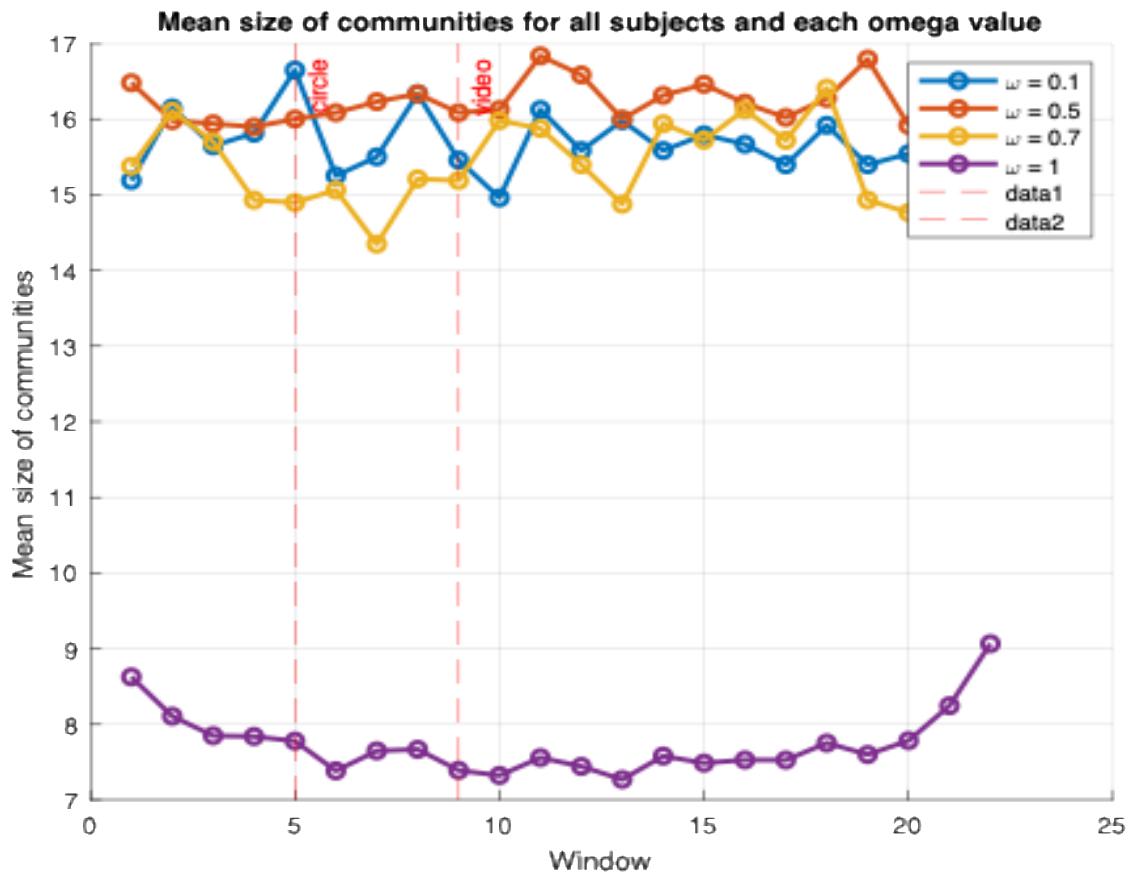
Además del número de comunidades, se analizó la dimensión media de las mismas a lo largo de las ventanas temporales para los diferentes valores del parámetro  $\omega$ . Según la literatura, cabría esperar que un mayor acoplamiento entre capas ( $\omega$  más altos) se asociara con un menor tamaño medio de las comunidades, ya que la red tiende a fragmentarse en grupos más pequeños y estables. Sin embargo, los resultados muestran un patrón más complejo y no siempre consistente con esta hipótesis.

En la condición W1, banda alfa (Figura 5.12), se observa que para  $\omega = 1$  el tamaño medio de las comunidades es claramente inferior al de otros valores, situándose entre 13 y 15 nodos. Para  $\omega = 0.1$  este valor asciende ligeramente hasta 15–16 nodos, mientras que para  $\omega = 0.5–0.7$  se mantiene más estable en torno a 16–18 nodos.

En la condición W1, banda beta (Figura 5.13), la diferencia es aún más marcada. Con  $\omega = 1$  el tamaño medio desciende de forma pronunciada, alcanzando valores de apenas 7–9 nodos, mientras que para el resto de los valores (0.1–0.7) las comunidades se mantienen considerablemente más grandes, en torno a 15–17 nodos.

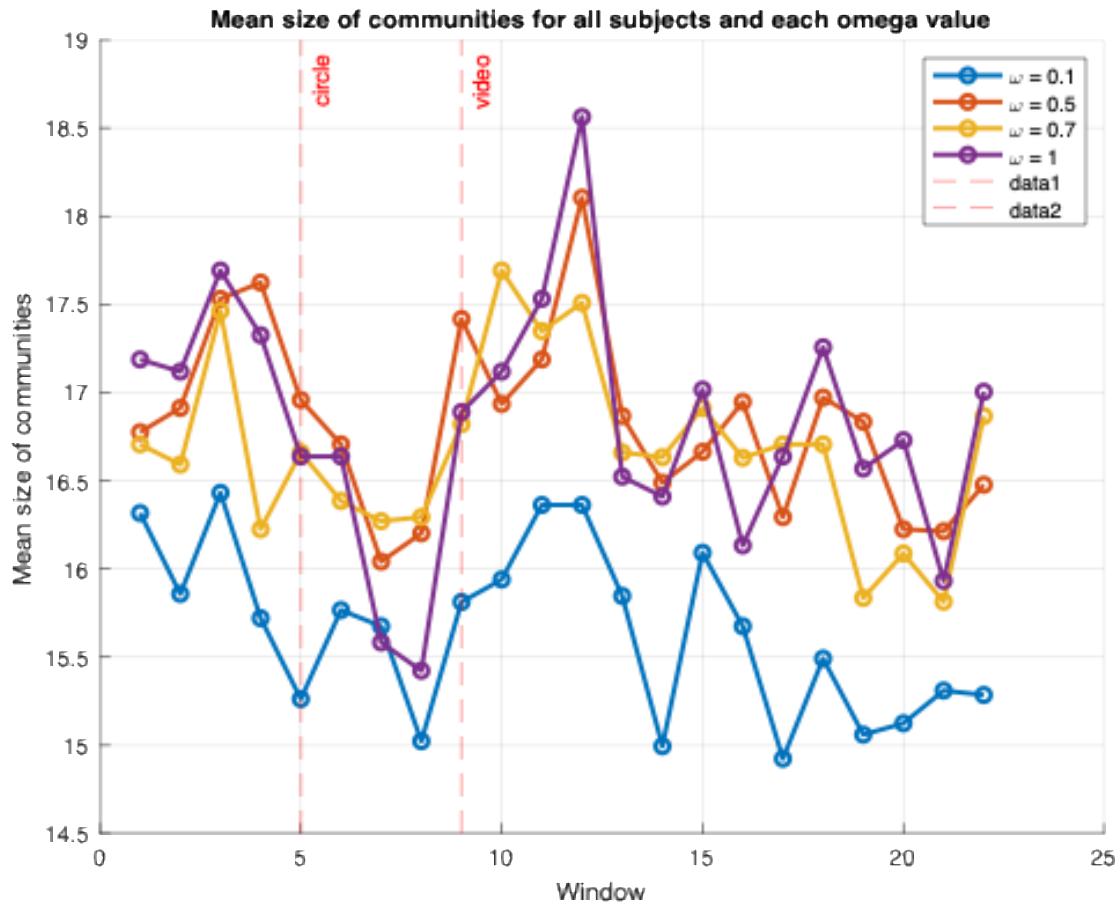


**Figura 5.12** Ejemplo de la dimensión promedio de comunidades en la condición W1, banda alfa, para distintos valores de  $\omega$ .



**Figura 5.13** Ejemplo de la dimensión promedio de comunidades en la condición W1, banda beta, para distintos valores de  $\omega$ .

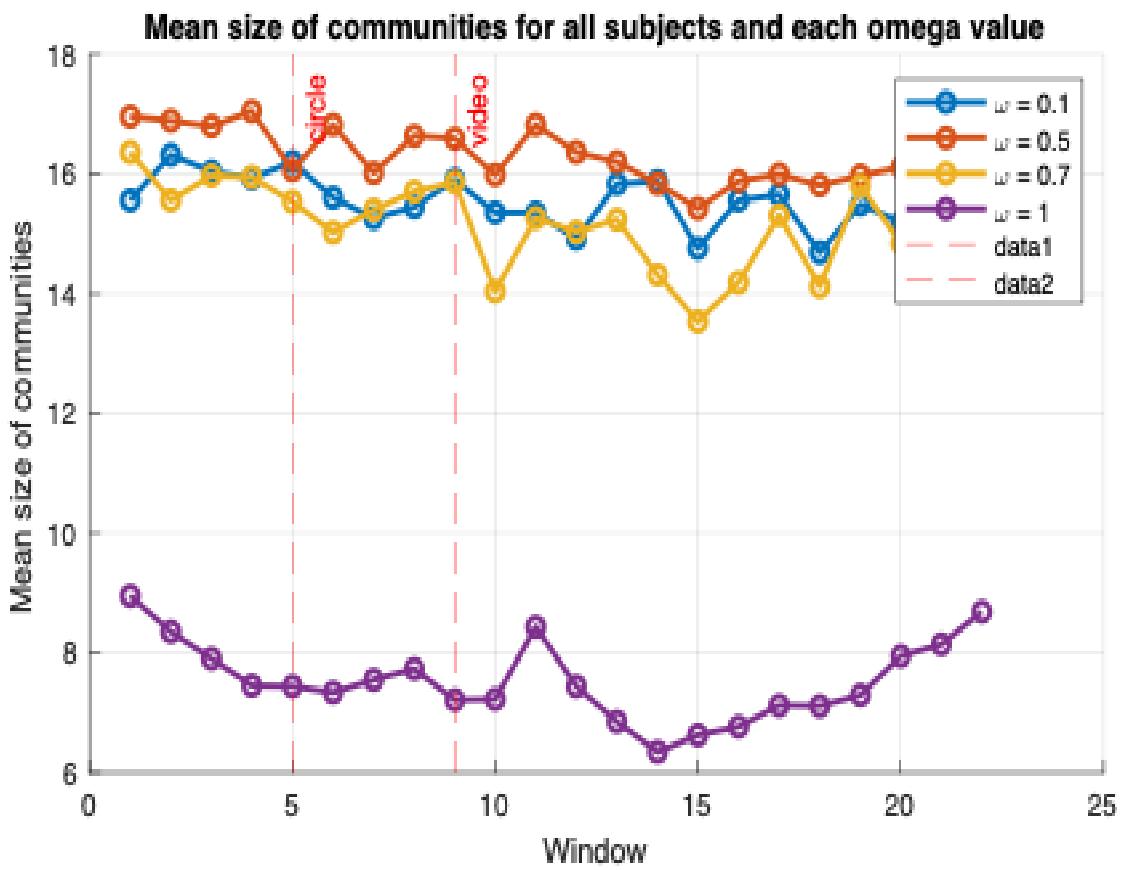
En la condición W2, banda alfa (Figura 5.14) se observa un patrón distinto al esperado según la literatura. A diferencia de W1, aquí el tamaño medio de las comunidades no disminuye de forma marcada con  $\omega = 1$ ; por el contrario, los valores son comparables a los obtenidos con  $\omega$  intermedios (0.5–0.7) e incluso en algunos momentos superiores. En cambio, para  $\omega = 0.1$  los tamaños son notablemente más bajos. Además, se aprecia una mayor fluctuación a lo largo de las ventanas, con variaciones constantes y la aparición de picos puntuales donde el número de nodos por comunidad aumenta de manera abrupta.



**Figura 5.14** Ejemplo de la dimensión promedio de comunidades en la condición W2, banda alfa, para distintos valores de  $\omega$ .

En la condición W2, banda beta (Figura 5.15), el comportamiento se asemeja más al observado en W1. Para  $\omega = 1$  el tamaño medio de las comunidades se reduce claramente respecto a los demás valores, situándose en torno a 7–9 nodos, mientras que para  $\omega$  bajos (0.1–0.7) se mantiene alrededor de 15–17 nodos. Este resultado sí coincide con lo descrito en la literatura, donde un mayor acoplamiento entre capas tiende a fragmentar la red en comunidades más pequeñas y estables.

En el caso de W3-alfa y W3-beta, el patrón general se conserva, con comunidades más reducidas para  $\omega = 1$  y mayores dimensiones para  $\omega$  bajos. No obstante, en W3-beta las diferencias entre condiciones se atenúan en comparación con W1 y W2.



**Figura 5.15** Ejemplo de la dimensión promedio de comunidades en la condición W2, banda beta, para distintos valores de  $\omega$ .

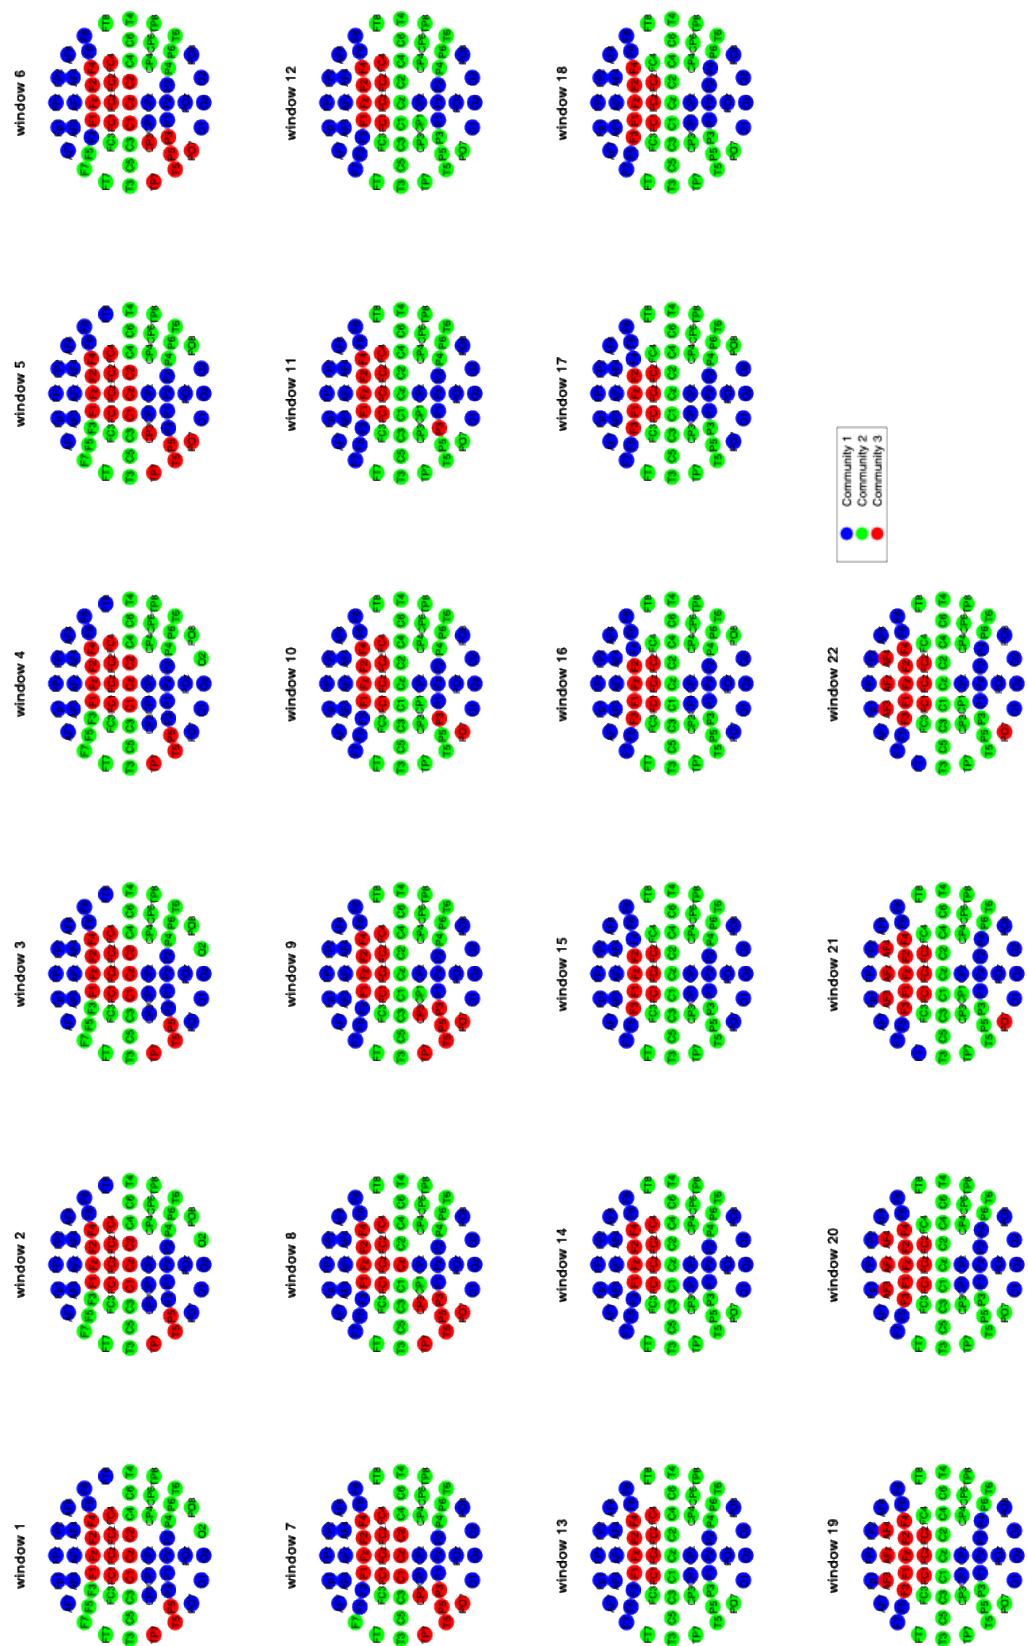
En resumen, los resultados muestran que la dimensión de las comunidades varía de manera significativa en función del parámetro de acoplamiento temporal  $\omega$ , con un descenso más marcado en la banda beta que en alfa. Además, se aprecian diferencias entre condiciones experimentales: mientras que en W1 el efecto de  $\omega$  es más claro y consistente, en W2 se observan mayores fluctuaciones y patrones menos definidos. Estos hallazgos ponen de manifiesto la influencia conjunta del valor de  $\omega$ , la banda de frecuencia y el tipo de estímulo sobre la dinámica comunitaria de la red cerebral.

### 5.3.3. Matriz de consenso y NMI

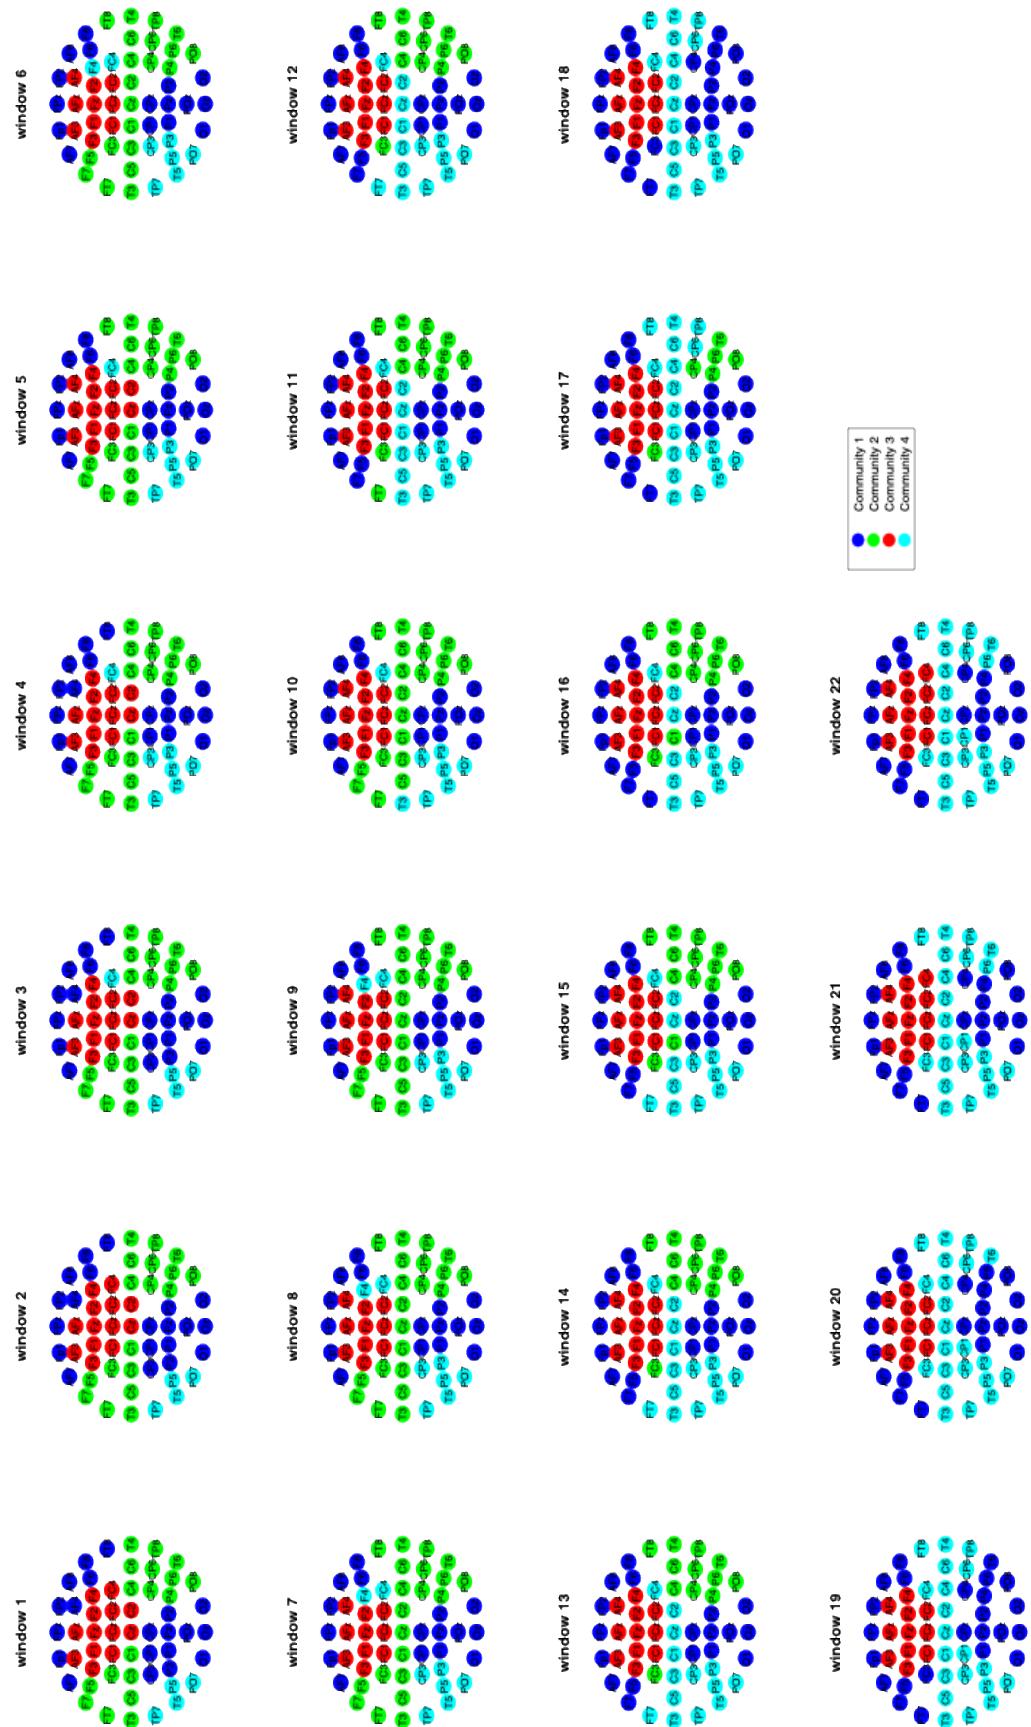
La combinación de la matriz de consenso y la métrica NMI aportan una visión complementaria al análisis de comunidades. Mientras que la matriz de consenso permite obtener una partición grupal representativa a partir de las soluciones individuales, el NMI cuantifica la estabilidad de dichas particiones entre ventanas temporales consecutivas (Lancichinetti and Fortunato, 2012). De este modo, es posible evaluar tanto la organización modular promedio del grupo como su evolución dinámica a lo largo del tiempo. Dado el volumen de resultados (diferentes condiciones, bandas y valores de  $\omega$ ), en este apartado se incluyen únicamente ejemplos ilustrativos seleccionados por su relevancia, ya que no es posible mostrar todos los casos. En particular, la condición W2 no se presenta en detalle al haber resultado la más variable y menos representativa, lo que dificultaría la extracción de conclusiones generales.

En la condición W1, banda alfa con  $\omega = 1$  (Figura 5.16), la matriz de consenso revela comunidades bien definidas y relativamente homogéneas. El NMI (Figura 5.18) muestra un patrón muy estable antes de los estímulos, con valores cercanos a 1, pero tras el inicio del vídeo aparecen oscilaciones y caídas puntuales, lo que refleja una reorganización dinámica de la red inducida por la tarea de observación.

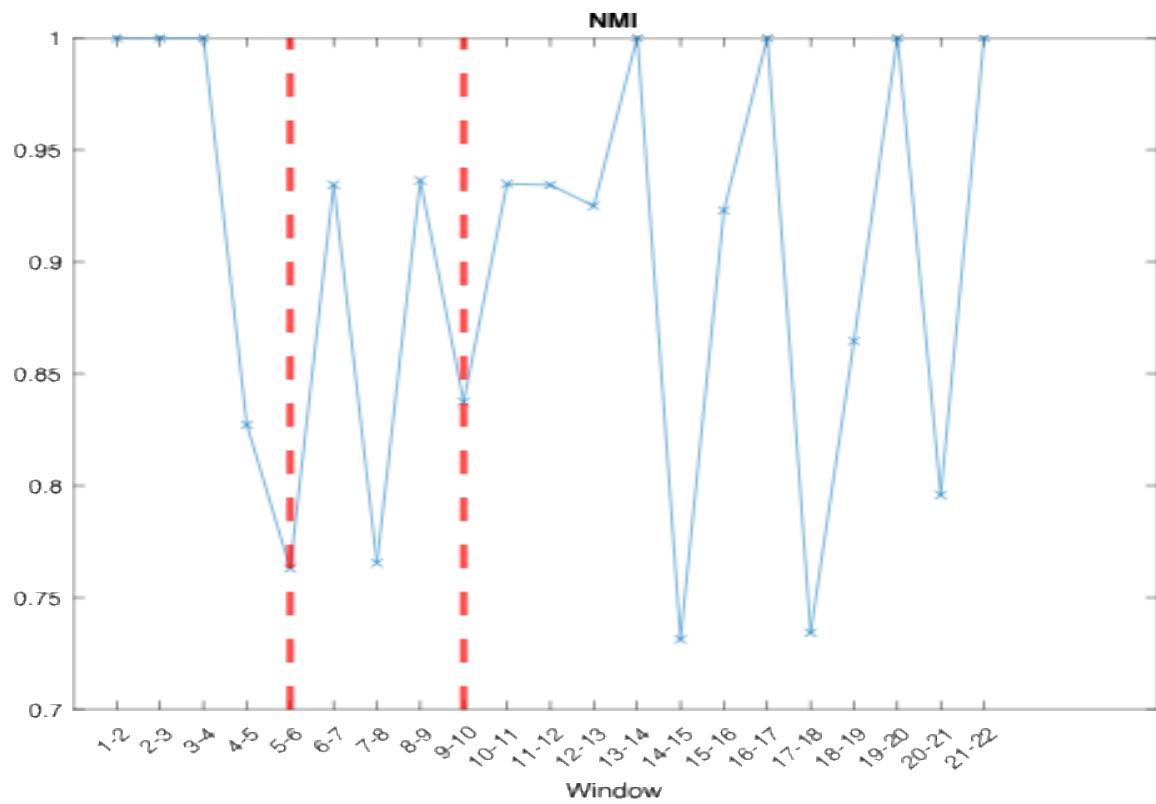
En la condición W1-alfa con  $\omega = 0.5$  (Figura 5.17) la matriz de consenso muestra comunidades más homogéneas que con  $\omega = 1$ , con una estructura que se mantiene relativamente estable a lo largo de las ventanas. El índice NMI (Figura 5.19), confirma esta tendencia: antes de los estímulos los valores son cercanos a 1, y aunque tras el inicio del vídeo aparecen caídas puntuales, la recuperación es rápida y se mantiene un nivel alto de estabilidad. Esto indica que con un acoplamiento intermedio la red conserva parte de su flexibilidad sin perder consistencia en la asignación comunitaria.



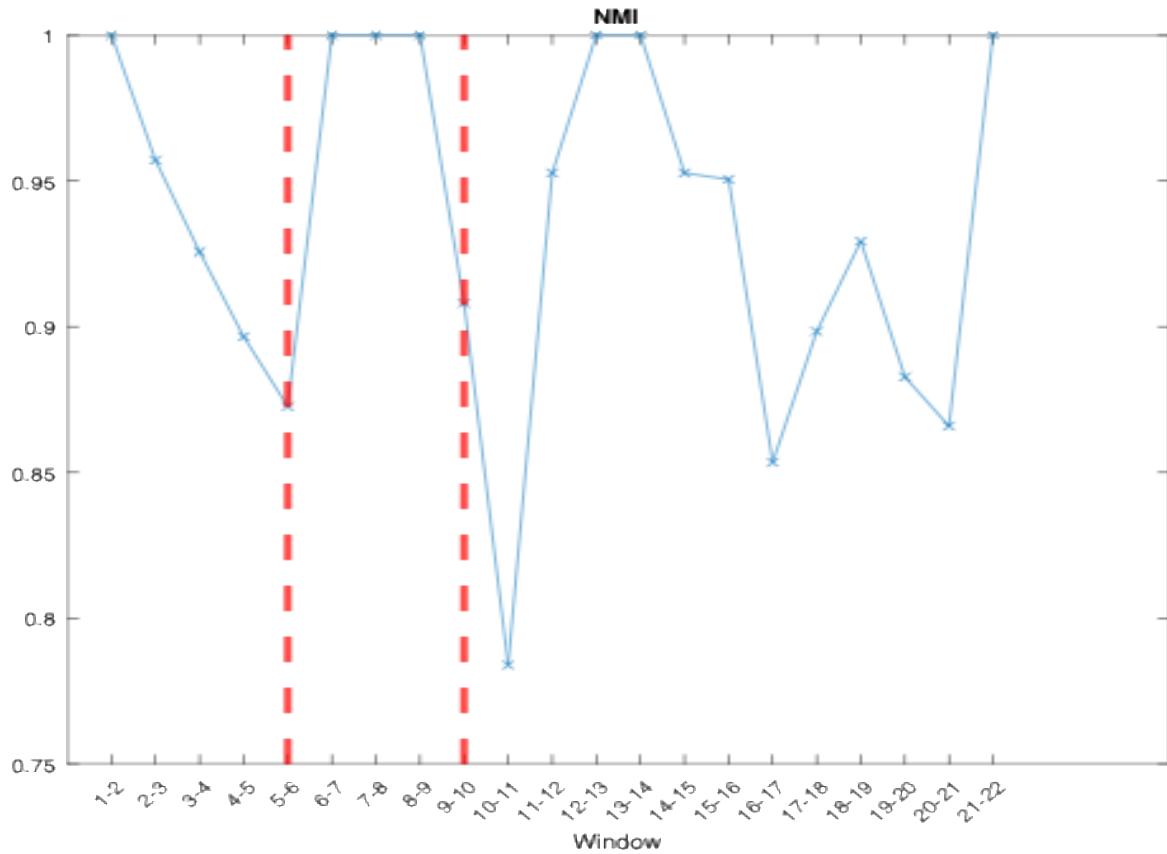
**Figura 5.16** Representación de la matriz de consenso para la condición W1 en banda alfa con  $\omega = 1$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.



**Figura 5.17** Representación de la matriz de consenso para la condición W1 en banda alfa con  $\omega = 0.5$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.



**Figura 5.18** Evolución del índice NMI para la condición W1 en banda alfa con  $\omega = 1$ .

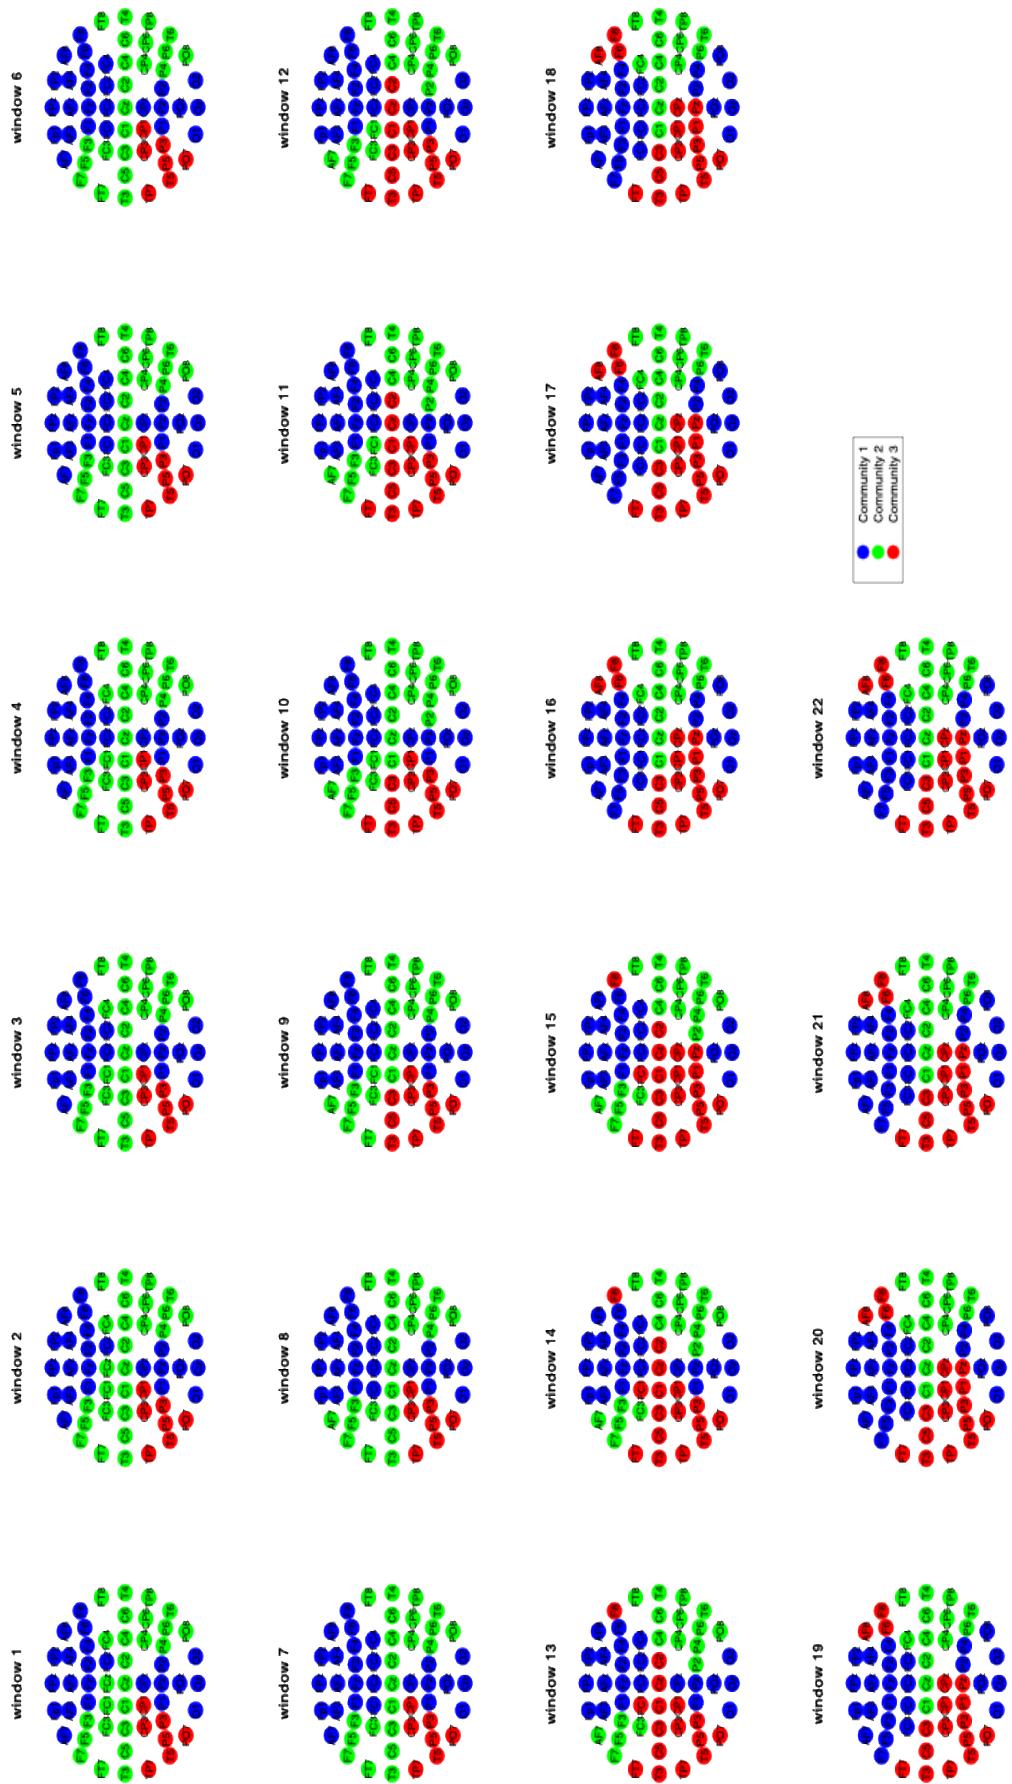


**Figura 5.19** Evolución del índice NMI para la condición W1 en banda alfa con  $\omega = 0.5$ .

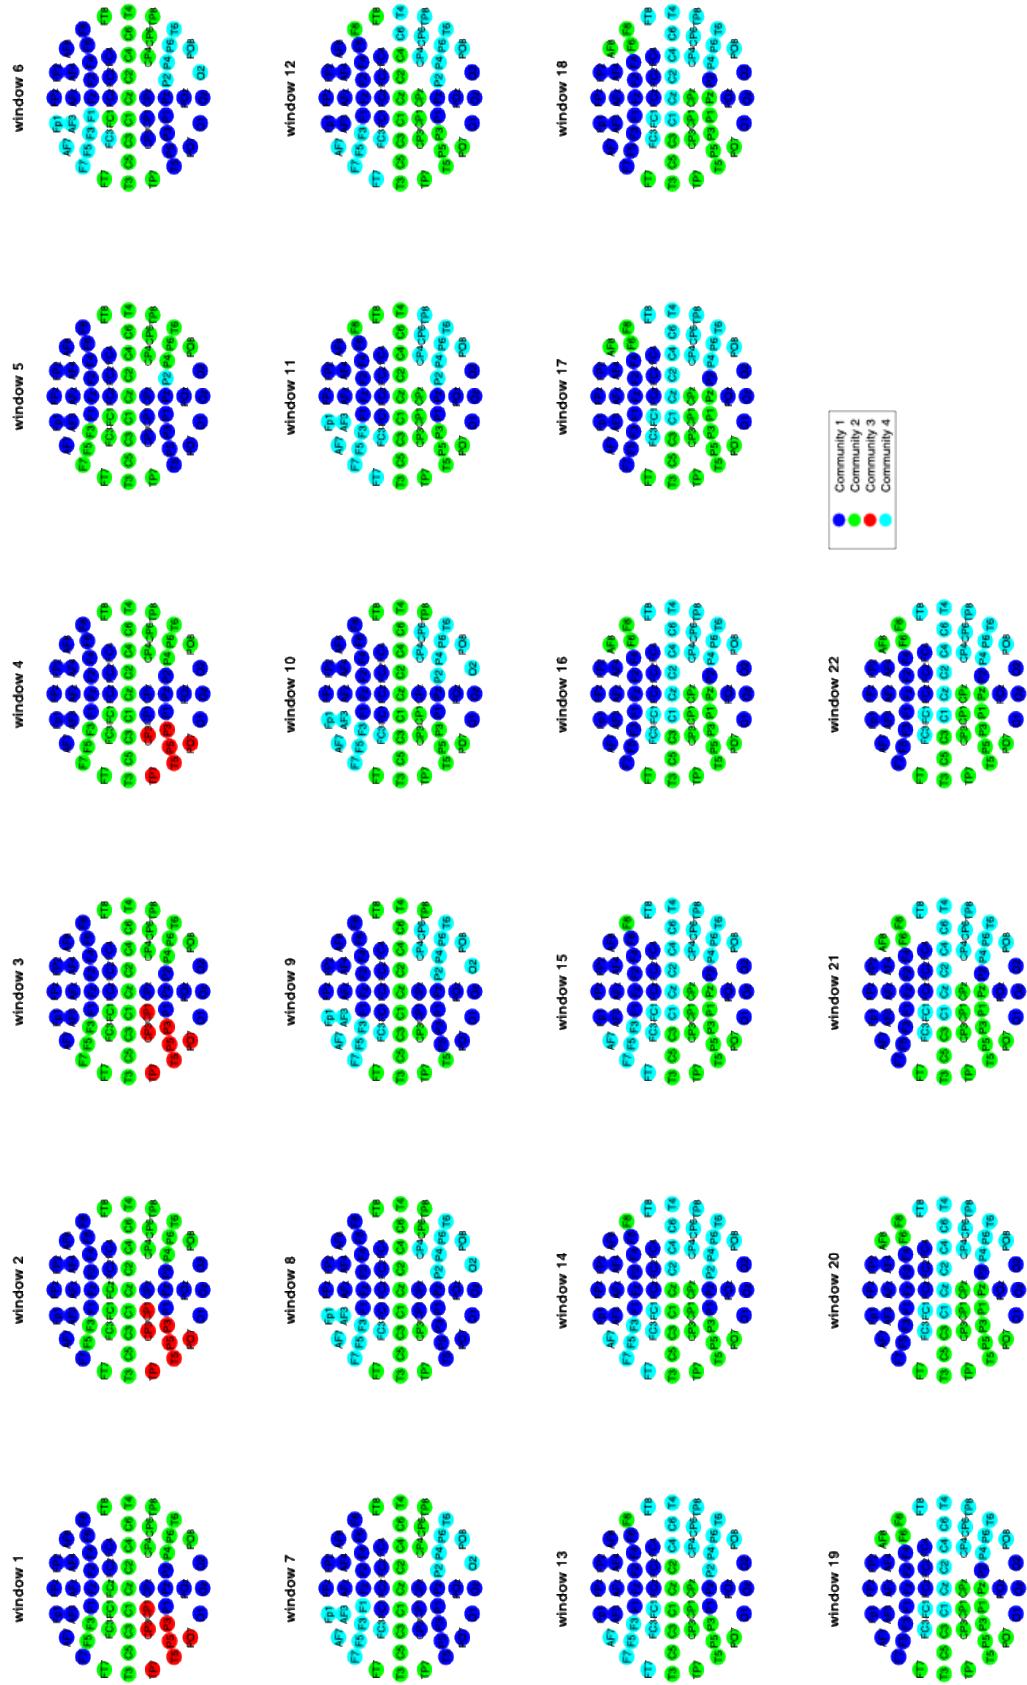
En cambio, en la condición W1, banda beta con  $\omega = 1$  (Figura 5.20), el patrón es distinto: aunque la matriz de consenso indica una mayor fragmentación inicial, el NMI (Figura 5.22) resulta menos variable que en alfa. Si bien presenta inestabilidad en los primeros instantes, tras el estímulo alcanza un nivel de consistencia elevado, estabilizándose cerca de 1 a partir de la ventana 15. Esto sugiere que, en banda beta, el mayor acoplamiento temporal favorece una partición más estable en fases tardías de la tarea.

Por su parte, con  $\omega = 0.5$  (Figura 5.21) la matriz de consenso refleja una organización más fragmentada desde el inicio, con comunidades menos compactas y más cambios en la asignación. El NMI (Figura 5.23), es más variable en comparación con alfa, mostrando caídas repetidas que evidencian transiciones frecuentes entre particiones. No obstante, hacia las últimas ventanas la estabilidad tiende a recuperarse, alcanzando valores cercanos a 1.

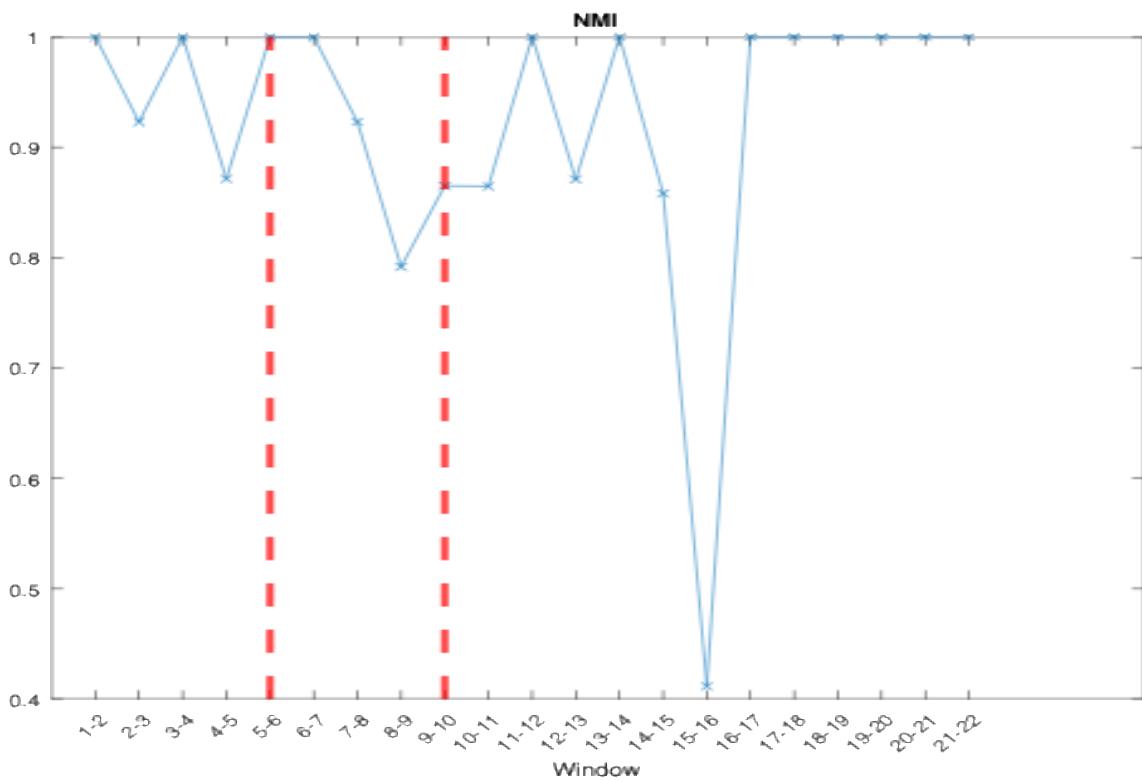
En conjunto, los resultados muestran que en alfa la estabilidad inicial se rompe con reorganizaciones puntuales inducidas por el estímulo, mientras que en beta predomina la variabilidad desde el principio y el estímulo genera una disrupción más clara seguida de una estabilización posterior.



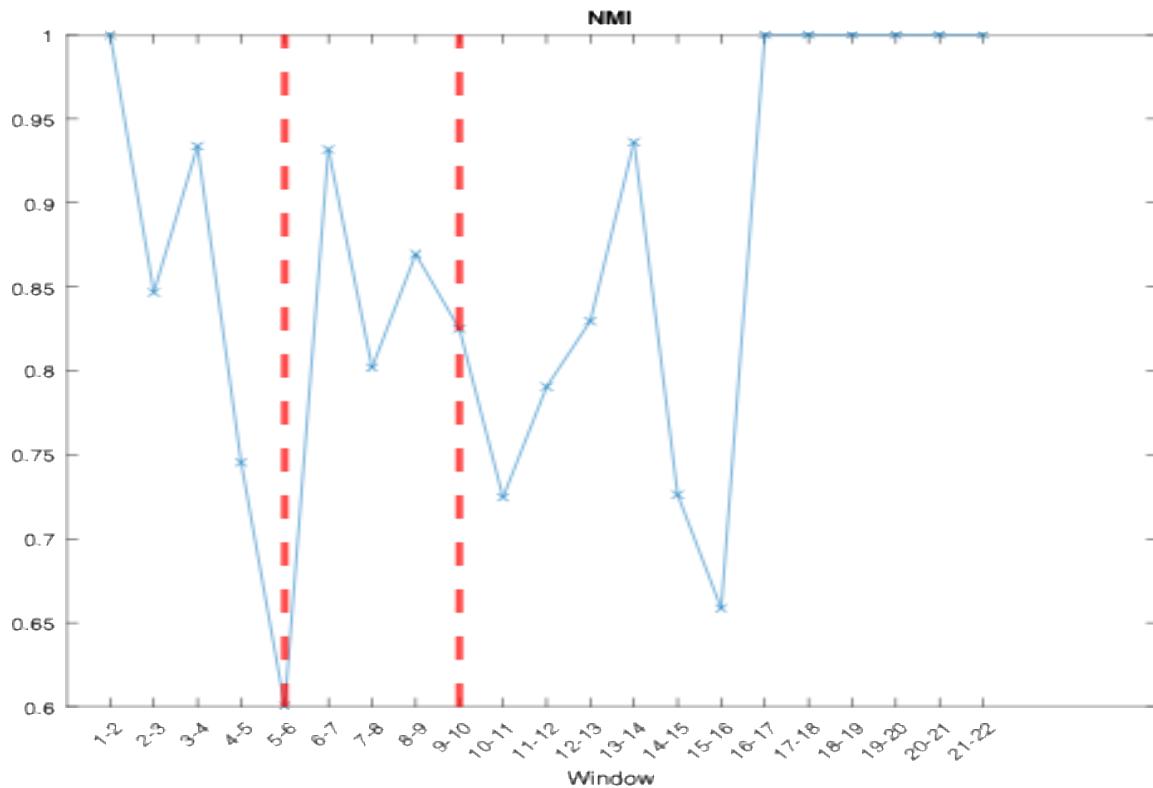
**Figura 5.20** Representación de la matriz de consenso para la condición W1 en banda beta con  $\alpha = 1$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.



**Figura 5.21** Representación de la matriz de consenso para la condición W1 en banda beta con  $\omega = 0.5$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.



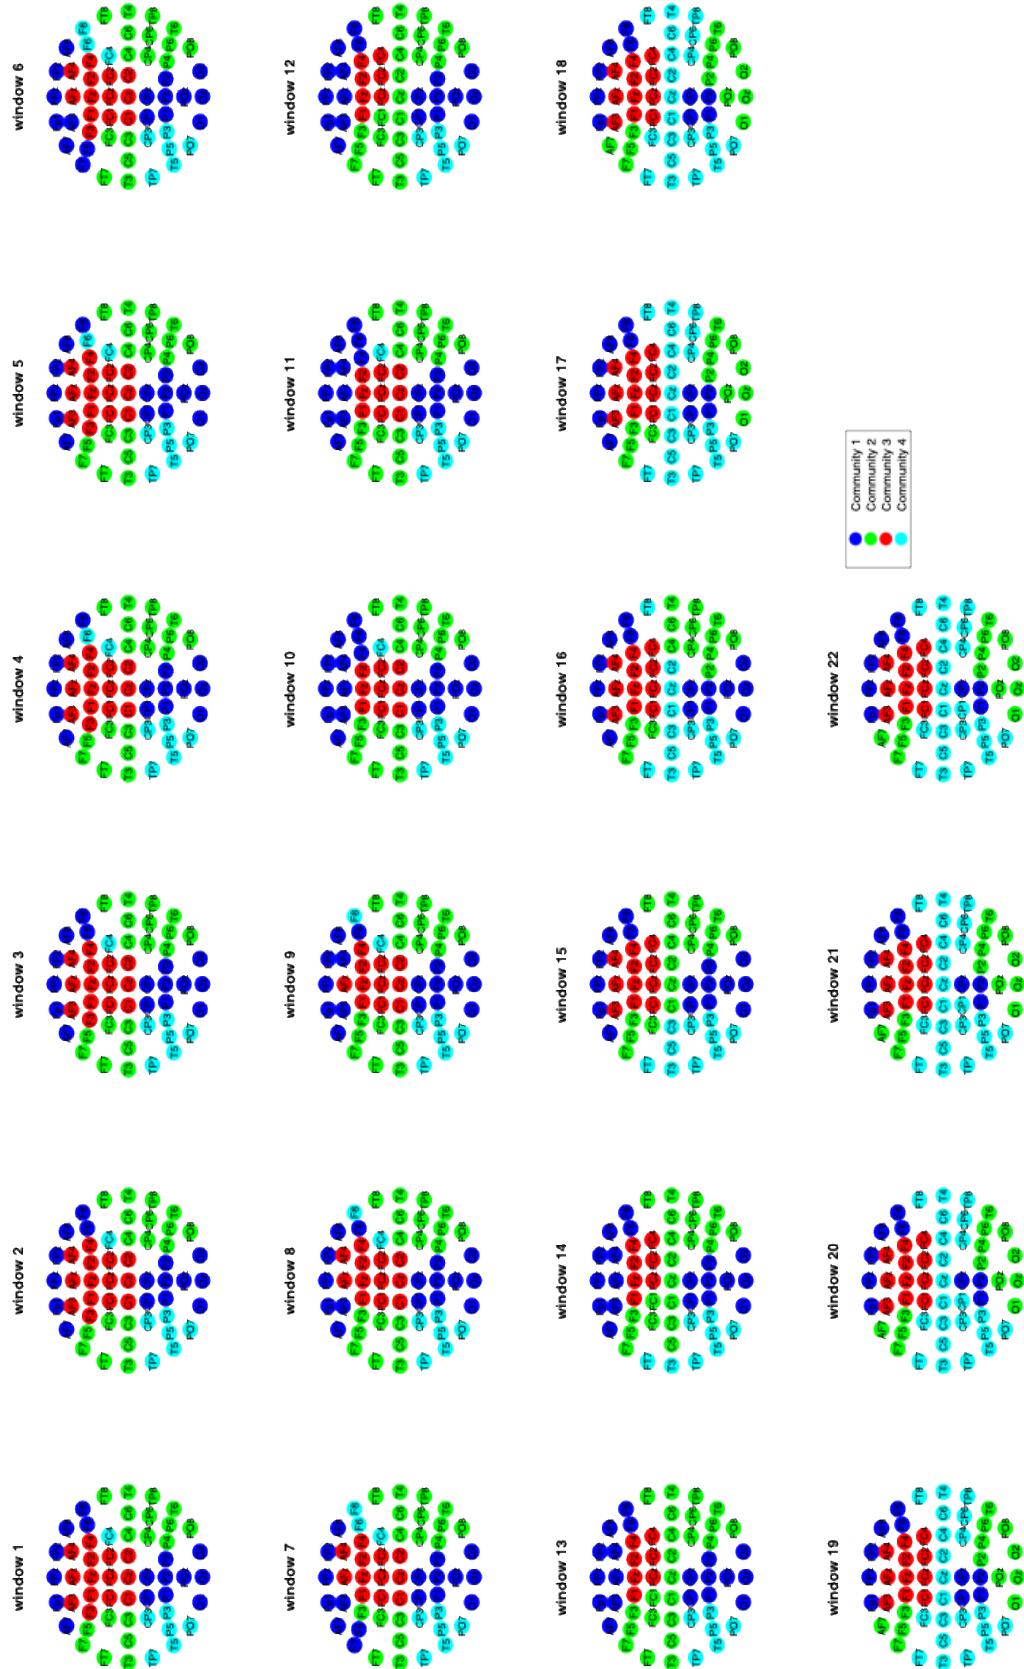
**Figura 5.22** Evolución del índice NMI para la condición W1 en banda beta con  $\omega = 1$ .

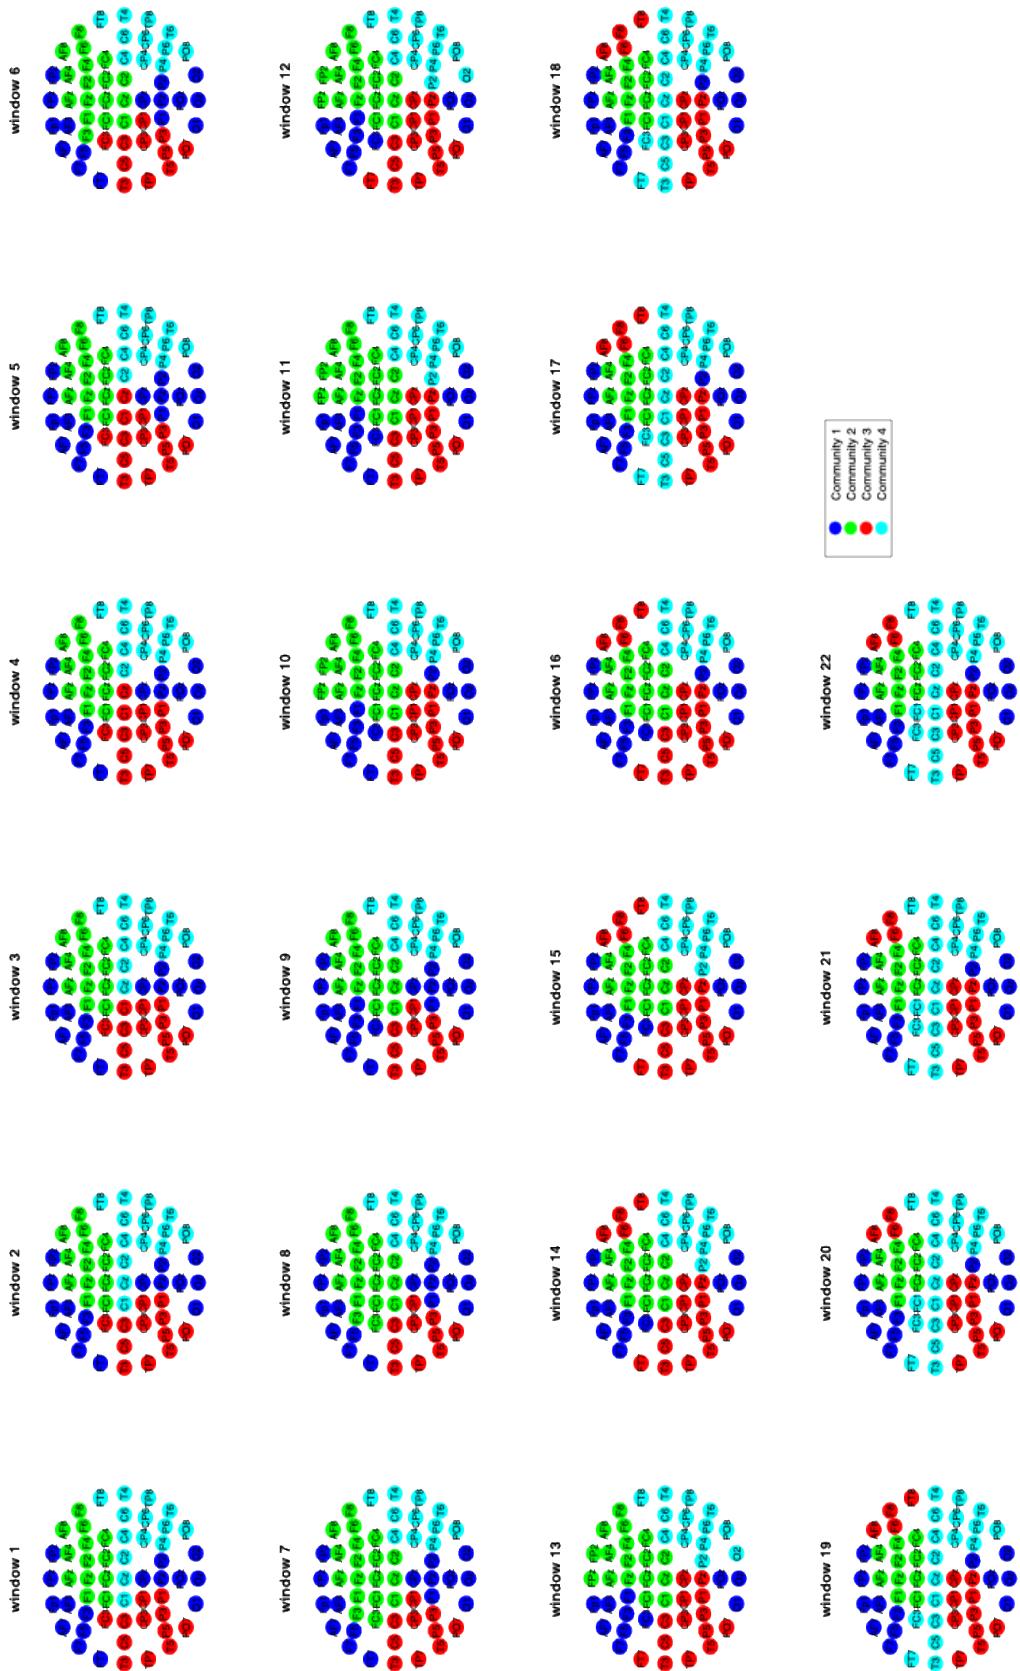


**Figura 5.23** Evolución del índice NMI para la condición W1 en banda beta con  $\omega = 0.5$ .

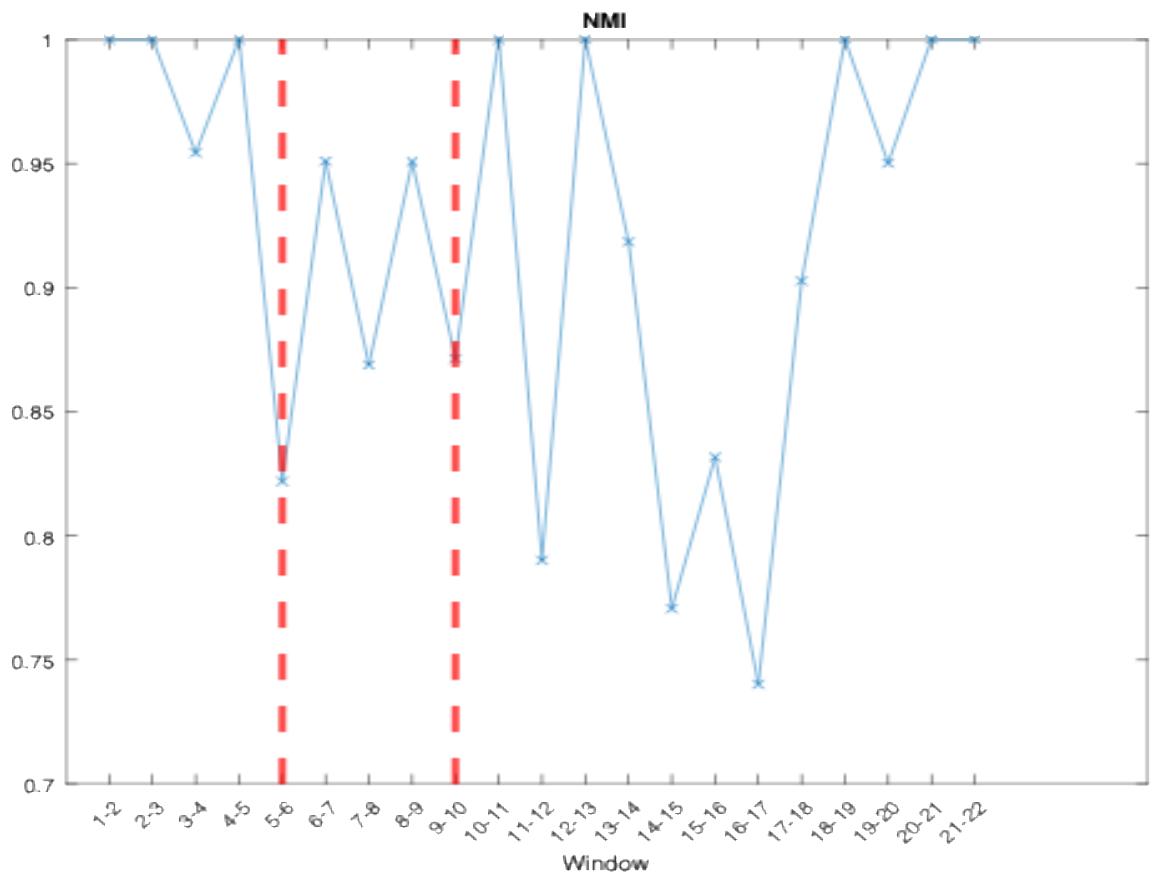
En la condición W3, banda alfa con  $\omega = 0.1$  (Figura 5.24), la matriz de consenso muestra una organización poco homogénea, con comunidades que se reorganizan con relativa frecuencia entre ventanas. El índice NMI (Figura 5.26) refleja esta dinámica: aunque antes del estímulo los valores se mantienen altos y cercanos a 1, tras el inicio del video aparecen caídas pronunciadas y oscilaciones recurrentes, lo que evidencia una reorganización más variable y menos estable.

En la condición W3, banda beta (Figura 5.25), este efecto se intensifica. La matriz de consenso revela una fragmentación más acusada y cambios más frecuentes en la asignación comunitaria. El NMI (Figura 5.27) confirma esta inestabilidad, mostrando caídas más profundas y sostenidas a lo largo de las ventanas, en especial después del inicio del video. Aunque hacia el final se aprecia cierta recuperación de la estabilidad, el comportamiento general es más fluctuante que en alfa, indicando que en esta banda la red responde con mayor variabilidad a la tarea de observación.

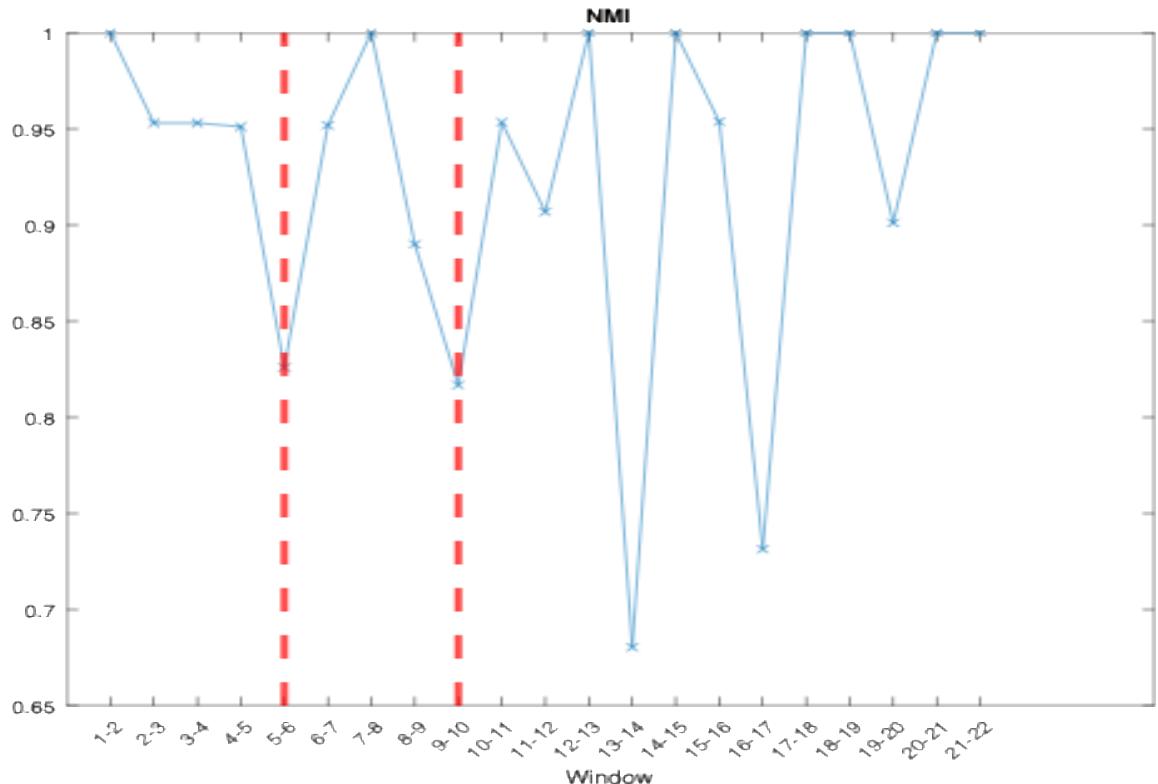




**Figura 5.25** Representación de la matriz de consenso para la condición W3 en banda beta con  $\omega = 0.1$ . Cada nodo corresponde a un electrodo, y su color indica la comunidad a la que pertenece.



**Figura 5.26** Evolución del índice NMI para la condición W3 en banda alfa con  $\omega = 0.1$ .



**Figura 5.27** Evolución del índice NMI para la condición W3 en banda beta con  $\omega = 0.1$



# **Capítulo 6. Discusión**

El estudio de la dinámica funcional del cerebro ha cobrado un interés creciente en los últimos años, especialmente en el ámbito de la neurorrehabilitación, donde técnicas como la AOT se han consolidado como herramientas prometedoras para la recuperación motora en pacientes con daño neurológico (Kim and Cho, 2016; Cordani *et al.*, 2021). La base de estas intervenciones reside en la activación del MNS y en la reorganización dinámica de redes cerebrales durante la observación de acciones, lo cual puede evaluarse a través de índices derivados de la conectividad funcional obtenida con EEG (Bassett and Sporns, 2017; Rizkallah *et al.*, 2018).

En este contexto, el presente TFG ha planteado como objetivo caracterizar la reorganización modular del cerebro durante la observación de distintas acciones, comparando las bandas alfa y beta y evaluando la influencia del parámetro de acoplamiento temporal en la detección de comunidades multicapa. Se emplearon diferentes métricas con el fin de cuantificar tanto la fragmentación como la estabilidad temporal de la organización modular.

En la primera sección de esta discusión se analizará el efecto de la AOT sobre la dinámica modular, considerando tanto las diferencias entre bandas como entre las tres condiciones experimentales. En la segunda sección se abordará el papel del parámetro  $\omega$  y sus implicaciones metodológicas. Posteriormente, se integrarán los hallazgos derivados de las métricas empleadas, discutiendo su coherencia y discrepancias con estudios previos de dinámica funcional. Finalmente, se discutirán las limitaciones del estudio, destacando aquellos aspectos que condicionan la interpretación y generalización de los resultados.

## **6.1. Implicaciones de la reconfiguración modular observada**

Los resultados obtenidos muestran que la AOT induce una reorganización modular dinámica del cerebro, caracterizada por cambios significativos en torno a los hitos experimentales, especialmente en la fase de preparación y en el inicio del vídeo. Esta reorganización refleja que la red cerebral no mantiene una configuración estática, sino que ajusta de manera continua su estructura comunitaria en función de las demandas de la tarea (Ge *et al.*, 2023).

Con los parámetros por defecto ( $\gamma = 1$ ,  $\omega = 1$ ) se evidenció un patrón diferenciado entre las bandas alfa y beta. En la banda alfa se observó un comportamiento heterogéneo entre sujetos: algunos mostraron comunidades relativamente estables, mientras que otros presentaron transiciones frecuentes. En la banda beta, en cambio, predominó una reorganización más fragmentada y con menor estabilidad comunitaria, lo que sugiere una mayor sensibilidad de esta frecuencia a la tarea. Esta variabilidad interindividual respalda la idea de que los patrones de modularidad cerebral evolucionan en el tiempo en función de las condiciones del sujeto, la naturaleza de la tarea y el intervalo de frecuencia considerado (Puxeddu, Petti and Astolfi, 2021).

Estos hallazgos se alinean con lo descrito por Kim y Cho (2016), quienes observaron que, durante la AOT, la banda alfa muestra una supresión significativa de potencia y una reducción de la coherencia en redes frontocentrales y parieto-occipitales, fenómeno interpretado como desincronización alfa (ERD) vinculada a la activación cortical y a procesos de atención. Por el contrario, la banda beta presentó incrementos tanto en potencia como en coherencia, especialmente en regiones motoras y sensoriales, lo que refleja una mayor sensibilidad a la tarea y a la reorganización funcional (Kim and Cho, 2016).

Asimismo, las condiciones experimentales modulaban de forma específica estos patrones. En W1 se evidenció una clara diferenciación entre sujetos con mayor estabilidad y otros con fuerte reconfiguración, lo que apunta a un efecto heterogéneo de la tarea. En W2, algunos sujetos que en W1 mostraban fragmentación pasaron a exhibir mayor estabilidad, mientras que en otros ocurrió lo contrario, lo cual indica que el tipo de acción observada influye de forma directa en la organización modular. Finalmente, W3 se situó en un punto intermedio: la mayoría de los sujetos presentó reorganizaciones dinámicas, pero sin alcanzar la inestabilidad marcada de la banda beta ni la homogeneidad observada en algunos casos de alfa.

Estas diferencias pueden entenderse en función de la naturaleza de los movimientos observados. La tarea de W1 (recoger monedas) implicaba una motricidad fina, repetitiva y rápida, que demanda un control visomotor detallado y una mayor atención sostenida, lo que podría explicar la fragmentación modular observada en varios sujetos. En cambio, W2 (uso de un martillo) representaba un gesto más global, rítmico y automático, asociado probablemente a una menor carga atencional y a patrones de organización más estables en algunos participantes. Por su parte, W3 (uso de pinzas) requería precisión manual y planificación, situándose en un punto intermedio al combinar elementos de control fino y secuencias motoras más amplias.

En conjunto, estos resultados respaldan la hipótesis de que la AOT genera reconfiguraciones rápidas y específicas de la red cerebral, moduladas tanto por la frecuencia analizada como por el tipo de acción observada. La alta variabilidad interindividual observada refuerza la idea de que los efectos de la AOT no son uniformes, sino que dependen del perfil dinámico de cada sujeto. Lejos de ser una limitación, esta variabilidad constituye un aspecto central para entender cómo la observación de acciones puede adaptarse a distintos contextos y perfiles clínicos, abriendo la puerta a personalizar protocolos de rehabilitación basados en AOT.

## 6.2. Interpretación de las métricas comunitarias

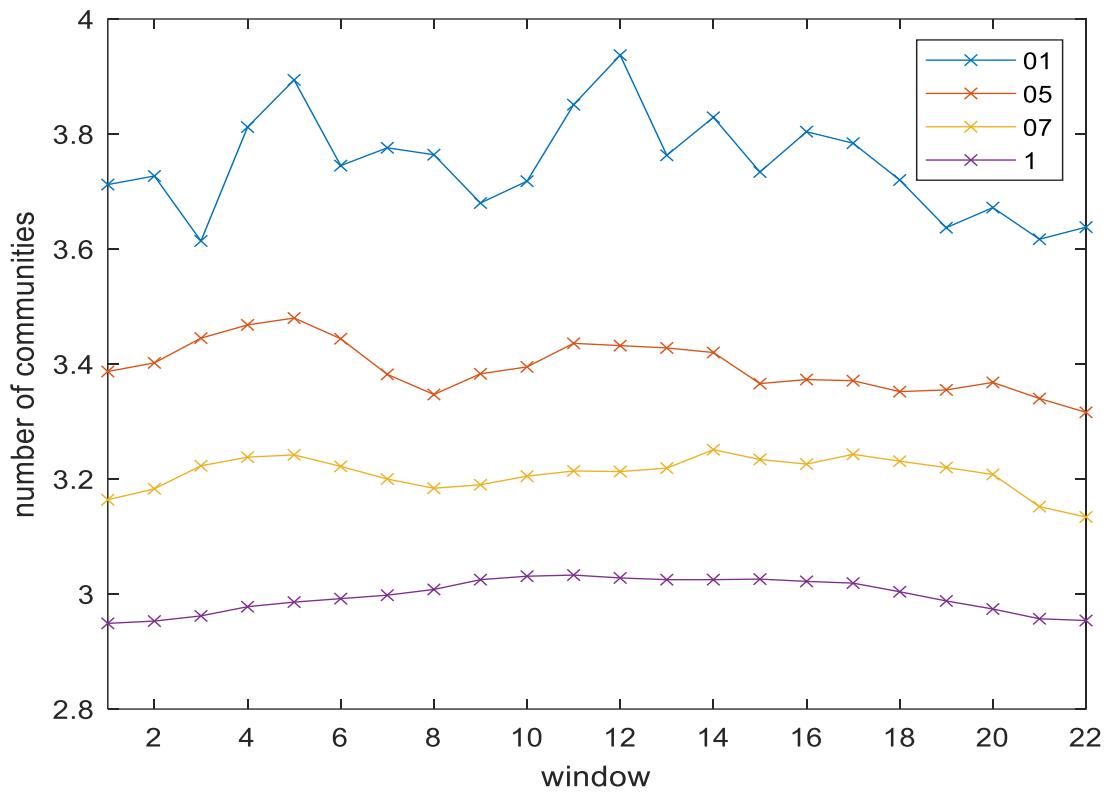
En la literatura se han empleado múltiples aproximaciones para caracterizar comunidades en redes cerebrales. Por ejemplo, Puxedu et al. (2020) revisan trabajos donde el número de comunidades se fija de antemano, se varía su tamaño o densidad, o se evalúa el rendimiento de los algoritmos en función de métricas como la dimensión o la densidad media (Puxeddu et al., 2020). Por su parte, Rizkallah y colegas (2018) aplicaron algoritmos de modularidad *multislice* a una tarea de reconocimiento visual y mostraron que, además de contabilizar el número de comunidades, es posible describir la dinámica modular con indicadores como la integración entre módulos o la ocurrencia (Rizkallah *et al.*, 2018).

En este contexto, el trabajo de Puxeddu y colegas (2021) mostró que el rendimiento de algoritmos como *genLouvain* y *FacetNet* depende fuertemente de los valores de sus parámetros,  $\omega$  y  $\gamma$ . Al probar distintos rangos y condiciones, los autores concluyeron que no existe un valor universal óptimo, sino que la elección de estos parámetros debe ajustarse a las características específicas de cada red, como su estabilidad, nivel de ruido o número de capas (Puxeddu, Petti and Astolfi, 2021).

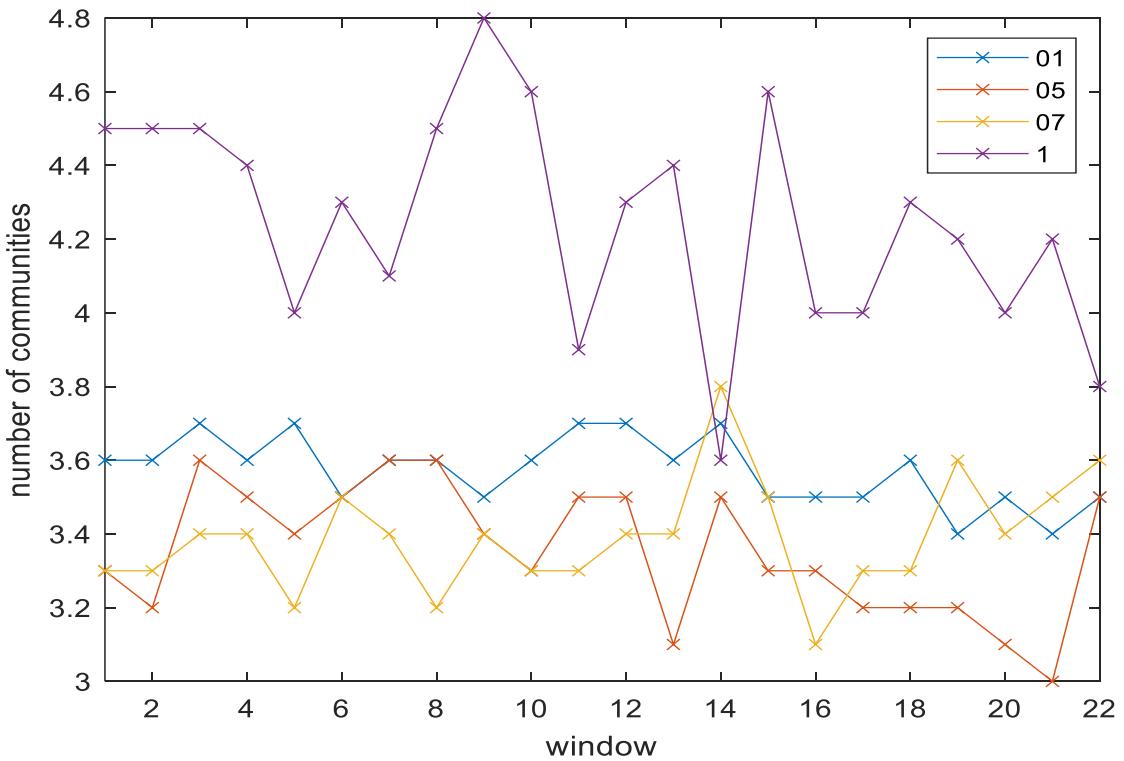
En nuestro caso, un análisis cualitativo inicial (sujeto 1, condición W1–alfa) mostró un comportamiento coherente con la teoría: valores bajos de omega generaron una red muy flexible con cambios frecuentes, mientras que valores altos favorecieron particiones más consistentes y estables en el tiempo (Mucha *et al.*, 2010; Puxeddu, Petti and Astolfi, 2021). Sin embargo, cuando se pasó al análisis cuantitativo mediante métricas, los resultados fueron más complejos y en ocasiones contrarios a lo descrito en la literatura.

En relación con el número de comunidades, en la mayoría de las condiciones, los valores promediados se situaron entre 3 y 5, un rango coherente con lo reportado en la literatura (Bassett *et al.*, 2011; Designed Research; D, Performed Research; D and Pnas, 2011; M.G Puxeddu *et al.*, 2017). Sin embargo, este patrón se rompe al aplicar  $\omega = 1$ , tanto en la banda beta como en algunas condiciones de alfa, donde el número de comunidades aumenta de forma notable y se desvía de lo esperado. Teóricamente, se esperaría un comportamiento opuesto: valores más bajos de  $\omega$  deberían favorecer más comunidades y valores altos menos. No obstante, en nuestros resultados ocurre lo contrario. Tal como destacan (Puxeddu, Petti and Astolfi, 2021), estas discrepancias pueden depender de las propiedades específicas del dataset y del preprocesamiento aplicado.

Una posible explicación metodológica es el proceso de umbralización aplicado a las matrices de conectividad. Al umbralizar con un enfoque de densidad fija (30%), se eliminan conexiones débiles y se altera de forma sustancial la distribución de grados. En la práctica, esto implica que el algoritmo recibe otro input de matriz, lo cual puede cambiar de manera significativa el número de comunidades detectadas. De hecho, al comparar los análisis sin (Figura 6.1) y con *thresholding* (Figura 6.2) se observa que los valores previos a la umbralización tienden a ser más consistentes con lo descrito en la literatura, mientras que tras el *thresholding* emergen más fragmentaciones.



**Figura 6.1** Evolución del número de comunidades en función de la ventana temporal para distintos valores de  $\omega$  (0.1, 0.5, 0.7 y 1) en la banda analizada, sin aplicar *thresholding*.



**Figura 6.2** Evolución del número de comunidades en función de la ventana temporal para distintos valores de  $\omega$  (0.1, 0.5, 0.7 y 1) en la misma banda, tras aplicar *thresholding*.

En cuanto a la dimensión media de las comunidades, los resultados fueron más consistentes con lo esperado, aunque no de forma uniforme. En varias condiciones, especialmente en beta, un mayor acoplamiento sí se tradujo en comunidades más pequeñas y estables, en línea con la literatura (Danon, Diaz-Guilera and Arenas, 2006; Lancichinetti, Fortunato and Radicchi, 2008; Designed Research; D, Performed Research; D and Pnas, 2011). Sin embargo, en condiciones como W2–alfa este patrón no se mantuvo, ya que  $\omega$  altos no redujeron el tamaño medio de manera clara e incluso aparecieron picos de crecimiento inesperados. Esto apunta a que la relación entre  $\omega$  y el tamaño de las comunidades depende no solo del parámetro en sí, sino también de la banda de frecuencia y del tipo de estímulo.

El uso de matrices de consenso se justifica por la elevada heterogeneidad intersujeto observada en los datos. Cada participante presenta patrones de conectividad propios, lo que dificulta la comparación directa y complica la integración de la información en un único análisis (Puxeddu, Petti and Astolfi, 2021). El consenso ofrece una solución robusta al calcular la coocurrencia de nodos en las mismas comunidades a lo largo de sujetos y ventanas, generando así una partición modular representativa del grupo (Jeub, Sporns and Fortunato, 2018). De este modo, es posible obtener una única partición por ventana que sintetiza la dinámica global de la muestra y facilita la comparación entre bandas de frecuencia y condiciones experimentales sin perder la información conjunta.

La combinación del consenso con el índice NMI permite además evaluar la estabilidad de las comunidades de manera cuantitativa. Mientras que el consenso refleja visualmente la robustez de la partición, el NMI mide la similitud entre particiones de distintas repeticiones y ventanas, proporcionando un indicador numérico de estabilidad (Lancichinetti and Fortunato, 2012). En la banda alfa, se observó un patrón relativamente estable antes del inicio del estímulo, con descensos puntuales del NMI en las primeras ventanas tras la aparición del video, seguidos de una recuperación rápida. En la banda beta, en cambio, predominó la variabilidad desde el inicio, y el estímulo intensificó la fragmentación, prolongando las caídas de NMI antes de que apareciera una estabilización en fases más tardías. Estos resultados concuerdan con la mayor sensibilidad de la beta a reorganizaciones rápidas y a procesos motores.

Cabe destacar que, aunque en general valores altos de  $\omega$  favorecen una mayor estabilidad, con el NMI más cercano a 1, no siempre representan la condición óptima. En algunos casos, valores intermedios de  $\omega$  ofrecieron perfiles de NMI más consistentes a lo largo de las ventanas temporales.

### 6.3. Limitaciones

El presente trabajo presenta varias limitaciones metodológicas y experimentales que deben tenerse en cuenta a la hora de interpretar los resultados. En primer lugar, la señal EEG, aunque aporta una excelente resolución temporal, tiene limitaciones espaciales y está sujeta a artefactos fisiológicos y de registro que pueden afectar a la estimación de la conectividad. A pesar de aplicar preprocesado exhaustivo y métricas robustas como el wPLI, no es posible eliminar completamente estos efectos.

En segundo lugar, el tamaño muestral, aunque razonable en el contexto de estudios con EEG, no es muy elevado, lo que reduce la potencia estadística y limita la generalización de los resultados.

También debe señalarse es la elevada variabilidad intersujeto, que constituye un desafío para la obtención de patrones consistentes. Aunque se emplearon matrices de consenso para integrar los resultados a nivel grupal, este procedimiento puede enmascarar diferencias individuales relevantes.

A ello se suma que buena parte de las conclusiones se apoyan en una interpretación visual de las métricas y figuras, lo que reduce la solidez cuantitativa del análisis. Aunque se aplicó un análisis estadístico mediante el test no paramétrico de Friedman, este se limitó al número de comunidades, sin extenderse a otras métricas, de modo que sus resultados deben interpretarse con cautela.

Asimismo, no se realizó un análisis de fuentes (*source imaging*), lo que habría permitido mitigar de forma más directa los efectos de la conducción de volumen y obtener una mejor localización cortical de las interacciones. La ausencia de este paso limita la interpretación espacial de los hallazgos y deja abierta la posibilidad de que algunas conexiones observadas estén influidas por efectos espurios derivados del registro en superficie.

Otra limitación es la dependencia de los resultados respecto a parámetros como el valor de  $\omega$ , cuya elección no cuenta con un criterio universal y puede inducir resultados divergentes según la condición y la banda de frecuencia. Por último, el enfoque de *thresholding* aplicado a las matrices de conectividad, necesario para reducir el impacto de conexiones espurias, también modifica la topología de la red y puede influir en el número y tamaño de comunidades detectadas.

# **Capítulo 7. Conclusiones**

Este trabajo constituye un estudio piloto sobre la reorganización modular del cerebro durante la AOT a partir de registros EEG y análisis de comunidades multicapa. Los resultados muestran que la AOT induce reconfiguraciones dinámicas de la red cerebral, especialmente en torno al inicio de los estímulos, con un comportamiento diferenciado entre bandas: la alfa tiende a recuperar la estabilidad tras una reorganización inicial, mientras que la beta mantiene una mayor variabilidad a lo largo del tiempo. El parámetro de acoplamiento temporal ( $\omega$ ) se confirma como un modulador clave de la estabilidad comunitaria: valores altos promueven particiones más estables, aunque en algunos casos intermedios se observó mayor coherencia temporal, en línea con lo descrito en la literatura. Pese a la complejidad de los resultados y a la heterogeneidad interindividual, el uso combinado de matrices de consenso y del índice NMI permitió obtener una caracterización robusta de la dinámica modular. En conjunto, este trabajo aporta evidencia preliminar de que la AOT genera reorganizaciones funcionales medibles mediante EEG, abriendo el camino hacia estudios más amplios que validen estos hallazgos y exploren su aplicabilidad en entornos clínicos de neurorrehabilitación.

## **7.1. Líneas futuras**

De cara a investigaciones futuras, sería recomendable ampliar el número de sujetos y explorar condiciones experimentales más diversas para aumentar la generalización de los hallazgos. Asimismo, la combinación de EEG con otras modalidades como fMRI o MEG podría enriquecer el análisis multimodal, compensando las limitaciones espaciales del EEG. Otra línea prometedora consiste en explorar métricas adicionales de dinámica modular, como la flexibilidad o la persistencia de los nodos, que aportarían una visión más completa de los patrones de reorganización. Igualmente, convendría analizar la interacción entre bandas de frecuencia desde un enfoque de redes multiplex, lo que permitiría caracterizar cómo se coordinan las oscilaciones alfa, beta y gamma durante la AOT. Por último, en el ámbito clínico, futuras investigaciones podrían evaluar estos mismos análisis en pacientes con patologías neurológicas, con el fin de determinar si la dinámica modular puede servir como biomarcador del efecto de la AOT y guiar protocolos personalizados de rehabilitación.



# Bibliografía

- Adham, A. *et al.* (2024) ‘Neural basis of lower-limb visual feedback therapy: an EEG study in healthy subjects’, *Journal of NeuroEngineering and Rehabilitation*, 21(1). <https://doi.org/10.1186/s12984-024-01408-8>.
- Allen, E.A. *et al.* (2018) ‘EEG Signatures of Dynamic Functional Network Connectivity States’, *Brain Topography*, 31(1), pp. 101–116. <https://doi.org/10.1007/s10548-017-0546-2>.
- Bassett, D.S. *et al.* (2011) *Supplementary Material for Dynamic reconfiguration of human brain networks during learning*.
- Bassett, D.S. *et al.* (2013) ‘Robust detection of dynamic community structure in networks’, *Chaos*, 23(1). <https://doi.org/10.1063/1.4790830>.
- Bassett, D.S. and Sporns, O. (2017) ‘Network neuroscience’, *Nature Neuroscience*. Nature Publishing Group, pp. 353–364. <https://doi.org/10.1038/nn.4502>.
- Bazzi, M. *et al.* (2017) ‘Community detection in temporal multilayer networks, with an application to correlation networks’. <http://arxiv.org/abs/1501.00040>.
- Bazzi, M. *et al.* (2020) ‘A framework for the construction of generative models for mesoscale structure in multilayer networks’. <https://doi.org/10.5281/zenodo>.
- Brookes, M.J. *et al.* (2014) ‘Measuring temporal, spectral and spatial changes in electrophysiological brain network connectivity’, *NeuroImage*, 91, pp. 282–299. <https://doi.org/10.1016/j.neuroimage.2013.12.066>.
- Buccino, G. *et al.* (2001) *SHORT COMMUNICATION Action observation activates premotor and parietal areas in a somatotopic manner: an fMRI study*.
- Calcagno, A. *et al.* (2024) ‘EEG connectivity in functional brain networks supporting visuomotor integration processes in dominant and non-dominant hand movements’, *Journal of Neural Engineering*, 21(3). <https://doi.org/10.1088/1741-2552/ad4f17>.
- Chaddad, A. *et al.* (2023) ‘Electroencephalography Signal Processing: A Comprehensive Review and Analysis of Methods and Techniques’, *Sensors*. Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/s23146434>.
- Chen, X. *et al.* (2025) ‘Exploring the Effects of Action Observation Therapy on Swallowing Disorders in Stroke: A Functional Connectivity-Based fMRI Study’, *Neural Plasticity*, 2025(1). <https://doi.org/10.1155/np/8176431>.
- Chiaroni, G. *et al.* (2023) ‘Connectivity Analysis in EEG Data: A Tutorial Review of the State of the Art and Emerging Trends’, *Bioengineering*. MDPI. <https://doi.org/10.3390/bioengineering10030372>.

Coelli, S. *et al.* (2023) ‘Event-Related Desynchronization Analysis During Action Observation and Motor Imagery of Transitive Movements’, in. Scitepress, pp. 86–93. <https://doi.org/10.5220/0011740600003414>.

Cohen and Mike X (2014) ‘364151992-Cohen-Analizing-Neural-Time-Series-pdf’. Cordani, C. *et al.* (2021) ‘Action observation training promotes motor improvement and modulates functional network dynamic connectivity in multiple sclerosis’, *Multiple Sclerosis Journal*, 27(1), pp. 139–146. <https://doi.org/10.1177/1352458519887332>.

Danon, L., Diaz-Guilera, A. and Arenas, A. (2006) *Effect of size heterogeneity on community identification in complex networks*.

Designed Research; D, S.T.G.S.B., Performed Research; D, N.F.W.S.B. and Pnas, J. (2011) ‘Dynamic reconfiguration of human brain networks during learning’, 108(18), pp. 7641–7646. <https://doi.org/10.1073/pnas.1018985108/-DCSupplemental>.

Detti, P. *et al.* (2019) ‘A Patient-Specific Approach for Short-Term Epileptic Seizures Prediction Through the Analysis of EEG Synchronization’, *IEEE Transactions on Biomedical Engineering*, 66(6), pp. 1494–1504. <https://doi.org/10.1109/TBME.2018.2874716>.

Emerson, J.R. *et al.* (2018) ‘Combined action observation and motor imagery therapy: A novel method for post-stroke motor rehabilitation’, *AIMS Neuroscience*, 5(4), pp. 236–252. <https://doi.org/10.3934/NEUROSCIENCE.2018.4.236>.

Farahani, F. V. *et al.* (2024) ‘Brain Network Alterations in Chronic Spinal Cord Injury: Multilayer Community Detection Approach’, *Neurotrauma Reports*, 5(1), pp. 1048–1059. <https://doi.org/10.1089/neur.2024.0098>.

Fornito, A., Zalesky, A. and Bullmore, E.T. (2010) ‘Network scaling effects in graph analytic studies of human resting-state fMRI data’, *Frontiers in Systems Neuroscience*, 4. <https://doi.org/10.3389/fnsys.2010.00022>.

Gatti, R. *et al.* (2013) ‘Action observation versus motor imagery in learning a complex motor task: A short review of literature and a kinematics study’, *Neuroscience Letters*, pp. 37–42. <https://doi.org/10.1016/j.neulet.2012.11.039>.

Ge, S. *et al.* (2023) ‘Effective Connectivity Analysis and Classification of Action Observation from Different Perspectives: An fMRI Study’, *IEEE Transactions on Biomedical Engineering*, 70(2), pp. 723–734. <https://doi.org/10.1109/TBME.2022.3201547>.

Gonzalez-Rosa, J.J. *et al.* (2015) ‘Action observation and motor imagery in performance of complex movements: Evidence from EEG and kinematics analysis’, *Behavioural Brain Research*, 281, pp. 290–300. <https://doi.org/10.1016/j.bbr.2014.12.016>.

He, B. *et al.* (2019) ‘Electrophysiological Brain Connectivity: Theory and Implementation’, *IEEE Transactions on Biomedical Engineering*, 66(7), pp. 2115–2137. <https://doi.org/10.1109/TBME.2019.2913928>.

Hutchison, R.M. *et al.* (2013) ‘Dynamic functional connectivity: Promise, issues, and interpretations’, *NeuroImage*, 80, pp. 360–378. <https://doi.org/10.1016/J.NEUROIMAGE.2013.05.079>.

Jeub, L.G.S., Sporns, O. and Fortunato, S. (2018) ‘Multiresolution Consensus Clustering in Networks’, *Scientific Reports*, 8(1). <https://doi.org/10.1038/s41598-018-21352-7>.

Jiang, X., Bian, G. Bin and Tian, Z. (2019) ‘Removal of artifacts from EEG signals: A review’, *Sensors (Switzerland)*. MDPI AG. <https://doi.org/10.3390/s19050987>.

Kim, H.-Y. (2014) ‘Statistical notes for clinical researchers: Nonparametric statistical methods: 2. Nonparametric methods for comparing three or more groups and repeated measures’, *Restorative Dentistry & Endodontics*, 39(4), p. 329. <https://doi.org/10.5395/rde.2014.39.4.329>.

Kim, S.-H. and Cho, J.-S. (2016) ‘Action Observation and Cortical Connectivity: Evidence from EEG Analysis’, *The Journal of Korean Physical Therapy*, 28(6), pp. 398–407. <https://doi.org/10.18857/jkpt.2016.28.6.398>.

Kim, T., Frank, C. and Schack, T. (2017) ‘A systematic investigation of the effect of action observation training and motor imagery training on the development of mental representation structure and skill performance’, *Frontiers in Human Neuroscience*, 11. <https://doi.org/10.3389/fnhum.2017.00499>.

Lancichinetti, A. and Fortunato, S. (2012) ‘Consensus clustering in complex networks’, *Scientific Reports*, 2. <https://doi.org/10.1038/srep00336>.

Lancichinetti, A., Fortunato, S. and Radicchi, F. (2008) ‘Benchmark graphs for testing community detection algorithms’, *Physical Review E - Statistical, Nonlinear, and Soft Matter Physics*, 78(4). <https://doi.org/10.1103/PhysRevE.78.046110>.

Meng, L. *et al.* (2023) ‘Enhanced brain functional connectivity and activation after 12-week Tai Chi-based action observation training in patients with Parkinson’s disease’, *Frontiers in Aging Neuroscience*, 15. <https://doi.org/10.3389/fnagi.2023.1252610>.

M.G Puxeddu *et al.* (2017) ‘embc puxeddu et al. (tuning of the omega parameter)’. Mucha, P.J. *et al.* (2010) ‘Community Structure in Time-Dependent, Multiscale, and Multiplex Networks’. <https://doi.org/10.1126/science.1184819>.

Muthukumaraswamy, S.D. and Singh, K.D. (2008) ‘Modulation of the human mirror neuron system during cognitive activity’, *Psychophysiology*, 45(6), pp. 896–905. <https://doi.org/10.1111/j.1469-8986.2008.00711.x>.

Niso, G. *et al.* (2013) ‘HERMES: Towards an integrated toolbox to characterize functional and effective brain connectivity’, *Neuroinformatics*, 11(4), pp. 405–434. <https://doi.org/10.1007/s12021-013-9186-1>.

O’Neill, G.C. *et al.* (2018) ‘Dynamics of large-scale electrophysiological networks: A technical review’, *NeuroImage*. Academic Press Inc., pp. 559–576. <https://doi.org/10.1016/j.neuroimage.2017.10.003>.

Pereda, E., Quiroga, R.Q. and Bhattacharya, J. (2005) ‘Nonlinear multivariate analysis of neurophysiological signals’, *Progress in Neurobiology*, pp. 1–37. <https://doi.org/10.1016/j.pneurobio.2005.10.003>.

Puxeddu, M.G., Petti, M. and Astolfi, L. (2021) ‘A Comprehensive Analysis of Multilayer Community Detection Algorithms for Application to EEG-Based Brain Networks’, *Frontiers in Systems Neuroscience*, 15. <https://doi.org/10.3389/fnsys.2021.624183>.

Rizkallah, J. *et al.* (2018) ‘Dynamic reshaping of functional brain networks during visual object recognition’, *Journal of Neural Engineering*, 15(5). <https://doi.org/10.1088/1741-2552/aad7b1>.

Rizzolatti, G. *et al.* (2021) ‘The role of mirror mechanism in the recovery, maintenance, and acquisition of motor abilities’, *Neuroscience & Biobehavioral Reviews*, 127, pp. 404–423. <https://doi.org/10.1016/J.NEUBIOREV.2021.04.024>.

Rubinov, M. and Sporns, O. (2010) ‘Complex network measures of brain connectivity: Uses and interpretations’, *NeuroImage*, 52(3), pp. 1059–1069. <https://doi.org/10.1016/j.neuroimage.2009.10.003>.

Sanei Saeid and Chambers J.A (2007) *EEG SIGNAL PROCESSING*.

Stam, C.J., Nolte, G. and Daffertshofer, A. (2007) ‘Phase lag index: Assessment of functional connectivity from multi channel EEG and MEG with diminished bias from common sources’, *Human Brain Mapping*, 28(11), pp. 1178–1193. <https://doi.org/10.1002/hbm.20346>.

Strehl, A. and Ghosh, J. (2002) *Cluster Ensembles-A Knowledge Reuse Framework for Combining Multiple Partitions*, *Journal of Machine Learning Research*.

Temporiti, F. *et al.* (2023) ‘Early sleep after action observation and motor imagery training boosts improvements in manual dexterity’, *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-29820-5>.

Teplan, Michal and Teplan, M (2002) *Fundamental of EEG Measurement FUNDAMENTALS OF EEG MEASUREMENT, MEASUREMENT SCIENCE REVIEW*. <https://www.researchgate.net/publication/228599963>.

Vinck, M. *et al.* (2011) ‘An improved index of phase-synchronization for electrophysiological data in the presence of volume-conduction, noise and sample-size bias’, *NeuroImage*, 55(4), pp. 1548–1565. <https://doi.org/10.1016/j.neuroimage.2011.01.055>.

Zamani Esfahlani, F. *et al.* (2021) ‘Modularity maximization as a flexible and generic framework for brain network exploratory analysis’, *NeuroImage*. Academic Press Inc. <https://doi.org/10.1016/j.neuroimage.2021.118607>.

Zhang, L. *et al.* (2018) ‘Spatiotemporal Phase Synchronization in Adaptive Reconfiguration from Action Observation Network to Mentalizing Network for Understanding Other’s Action Intention’, *Brain Topography*, 31(3), pp. 447–467. <https://doi.org/10.1007/s10548-017-0614-7>.

Zippo, A.G. *et al.* (2018) ‘Alternating Dynamics of Segregation and Integration in Human EEG Functional Networks During Working-memory Task’, *Neuroscience*, 371, pp. 191–206. <https://doi.org/10.1016/j.neuroscience.2017.12.004>.