

Universidad Nacional
de Educación a Distancia

Escuela Técnica Superior de
Ingeniería Informática



Universidad
Complutense de Madrid

Facultad de
Informática

Reducción de artefactos en EEG utilizando técnicas de descomposición modal empírica

Lozano Pérez, David

Director/a: Dormido Canto, Raquel
Co-director/a: Duro Carralero, Natividad

Trabajo de Fin de Máster

Máster Universitario
en Ingeniería de Sistemas y de Control

Junio 2025

Máster Universitario
en Ingeniería de Sistemas y de Control

Reducción de artefactos en EEG utilizando técnicas de descomposición modal empírica

Autor/a:	Lozano Pérez, David
Director/a:	Dormido Canto, Raquel
Co-director/a:	Duro Carralero, Natividad

Trabajo de Fin de Máster
Proyecto tipo A

Junio 2025



Universidad Nacional
de Educación a Distancia

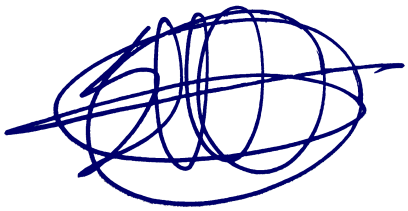


Universidad
Complutense de Madrid

Autorización

Autorizamos a la Universidad Complutense y a la UNED a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a sus autores, tanto la memoria de este Trabajo Fin de Máster, como el código, la documentación y/o el prototipo desarrollado.

Firma: Lozano Pérez, David



Agradecimientos

A Raquel y Natividad, por su ayuda y cercanía, por entender que no siempre dispuse del tiempo que me hubiera gustado.

A mis padres y a mi hermana, por su apoyo incondicional y fomentar en mi la curiosidad.

A Alba, mi compañera, por estar siempre ahí, con su infinita paciencia.

Resumen

El electroencefalograma es una técnica no invasiva utilizada para monitorizar la actividad cerebral del paciente. Como norma general, la señal EEG está contaminada por distintos tipos de artefactos que dificultan su correcto análisis. En este trabajo se ha realizado una comparativa entre tres métodos de reducción de artefactos basados en descomposición adaptativa: el método EMD, su extensión multicanal MEMD y una versión híbrida MEMD+FastICA. Estos tres métodos han sido evaluados inicialmente sobre señales sintéticas para evaluar su desempeño. Finalmente, el último método, que ha demostrado el mejor rendimiento, se ha aplicado a un conjunto de señales EEG reales de larga duración previamente segmentadas mediante un extractor de artefactos basado en una SVM entrenada.

Palabras clave: Electroencefalograma, Empirical mode descomposition, Independent component analysis, Intrinsic mode function,

Abstract

Electroencephalogram is a non-invasive technique used to monitor a patient's brain activity. Typically, the raw EEG signal is contaminated by different types of artefacts that hinder its correct analysis. In this work, a comparison has been made between three methods of artefact reduction based on adaptive decomposition: the EMD method, its multichannel extension MEMD and a hybrid version MEMD+FastICA. These three methods have been initially evaluated on synthetic signals to assess their performance. Finally, the last method, which has shown the best performance, has been applied to a set of real EEG signals of long duration previously segmented by means of an artefact extractor based on a trained SVM.

Keywords: Electroencephalogram, Empirical mode descomposition, Independent component analysis, Intrinsic mode function,

Índice general

Lista de Acrónimos **xxi**

1. Introducción **1**

1.1. Motivación 1

1.2. Propuesta, objetivos y metodología 2

1.3. Estructura del documento 3

2. Señales Biomédicas **5**

2.1. Contexto General 5

2.2. Señales EEG 6

2.3. Artefactos en EEG 10

2.4. Técnicas de eliminación de artefactos 12

2.4.1. Métodos de regresión lineal 12

2.4.2. Métodos de filtrado 13

2.4.3. Métodos de separación ciega de fuentes. 13

2.4.4. Métodos de descomposición de fuente 14

2.4.5. Métodos híbridos 14

3. Marco Teórico **15**

3.1. Empirical Mode Descomposition ó EMD 15

3.2. Multivariate Empirical Mode Descomposition 19

3.3. Multivariate Empirical Mode Descomposition con FastICA 21

4. Implementación y resultados del proyecto **23**

4.1. Solución abordada 23
4.2. Escenario con Señales sintéticas 27
4.2.1. Generación de Señales sintéticas 28
4.2.2. Eliminación artefacto mediante EMD 30
4.2.3. Eliminación artefacto mediante MEMD 37
4.2.4. Eliminación artefacto mediante MEMD-FastICA 42
4.3. Escenario con Señales reales 48
4.3.1. DETECT Toolbox 48
4.3.2. Procesamiento de canales 50
4.3.3. MEMD + FastICA sobre señales reales 52
4.4. Discusión 57

5. Conclusiones y futuras lineas de trabajo **59**

A. Anexo **61**

Índice de figuras

2.1. Esquema del cerebro y disposición de lóbulos [1] 6

2.2. Esquema de una neurona 7

2.3. Muestra de un Encefalograma (EEG) 8

2.4. Posición de los electrodos acorde al Sistema Internacional 10-20. [2] 9

2.5. Muestra de diferentes artefactos en un EEG 11

2.6. Porcentaje de Métodos en publicaciones 2013-2018 12

3.1. Representación gráfica del proceso completo de descomposición EMD con dos iteraciones del proceso de *Sifting*. 18

3.2. Representación gráfica del proceso completo de descomposición MEMD. . . . 20

3.3. Representación gráfica del proceso completo de descomposición MEMD+FastICA. 22

4.1. Esquema Algoritmo General 23

4.2. Respuesta filtro Notch 60Hz 24

4.3. Diagrama de flujo para proceso con señales sintéticas 28

4.4. Señal Sintética Artefacto Eye Blink 29

4.5. Señal Sintética Eyebrow Movement 29

4.6. Señal Sintética Jaw Clench 30

4.7. Señal Sintética EEG simulando un Eye Blink 31

4.8. Descomposición EMD para señal sintética Eye Blink 31

4.9. Características normalizadas para EyeBlink sintético 32

4.10. HeatMap de Energia Relativa para señal sintética Eye Blink mediante EMD 33

4.11. Descomposición EMD para señal sintética Eye Blink con IMFs eliminadas . . 33

4.12. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto EyeBlink mediante el método EMD. 34

4.13. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método EMD sobre artefacto EyeBlink. 34

4.14. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método EMD aplicado al artefacto EyeBlink. . 35

4.15. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto EyeBrow Movement mediante el método EMD. . . 35

4.16. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método EMD sobre artefacto EyeBrow Movement. 35

4.17. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método EMD aplicado al artefacto EyeBrow Movement. 36

4.18. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto JawClench mediante el método EMD. 36

4.19. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método EMD sobre artefacto JawClench. 36

4.20. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método EMD aplicado al artefacto JawClench. 37

4.21. Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink) 37

4.22. Análisis de métricas normalizadas por canal tras descomposición MEMD asociado al artefacto de parpadeo ocular (Eye Blink) 38

4.23. Mapa de calor de la energía relativa por canal EEG para la detección del artefacto de Eye Blink y Mapa de calor de los modos positivos seleccionados por canal para el filtrado del artefacto. 38

4.24. Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink) tras etapa de filtrado. 39

4.25. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de parpadeo ocular (Eye Blink) mediante el método MEMD. 39

4.26. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD sobre artefacto de parpadeo ocular (Eye Blink). 40

4.27. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD aplicado al artefacto de parpadeo ocular (Eye Blink). 40

4.28. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de movimiento de ceja (Eye Brow Movement) mediante el método MEMD. 40

4.29. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD sobre artefacto de movimiento de ceja (Eye Brow). 41

4.30. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD aplicado al artefacto de movimiento de ceja (Eye Brow). 41

4.31. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de apretamiento mandibular (Jaw Clench) mediante el método MEMD. 41

4.32. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD sobre artefacto de apretamiento mandibular (Jaw Clench). . 42

4.33. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD aplicado al artefacto de apretamiento mandibular (Jaw Clench). 42

4.34. Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink) 43

4.35. Suma de la energía relativa de cada modo, con selección de las IMFs elegidas para ser procesadas mediante el algoritmo FastICA en el contexto del artefacto producido por el parpadeo ocular (Eye Blink) 43

4.36. Reordenamiento de IMFs para FMEMD parpadeo ocular (Eye Blink) 44

4.37. Componentes Independientes extraídas por IMF seleccionada mediante FastICA 44

4.38. Reducción de energía en las reconstrucciones según la CI eliminada para cada colección de IMFs 45

4.39. Reordenamiento de IMFs para FMEMD tras filtrado con FastICA en parpadeo ocular (Eye Blink) 45

4.42. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método FICA MEMD sobre artefacto de movimiento de ceja (Eye Brow). . . 45

4.40. Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink) tras el filtrado con FastICA 46

4.43. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método FICA MEMD aplicado al artefacto de movimiento de ceja (Eye Brow). 46

4.41. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto ocular mediante el método MEMD+FICA. 47

4.44. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de movimiento de ceja mediante el método MEMD+FICA. 47

4.45. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD+FICA sobre artefacto de movimiento de ceja (Eye Brow). . 48

4.46. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD+FICA aplicado al artefacto de movimiento de ceja (Eye Brow). 48

4.47. Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de apretamiento mandibular mediante el método MEMD+FICA. 49

4.48. Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD+FICA sobre artefacto de un apretamiento mandibular (Jaw Clench). 49

4.49. Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD+FICA aplicado al artefacto de un apretamiento mandibular (Jaw Clench). 50

4.50. Comparativa métricas de los metodos EMD, MEMD y MEMD+FastICA . . 50

4.51. Diagrama de flujo para proceso con señales reales. 51

4.52. Señal EEG con artefacto Eye Blick Real 52

4.53. Indice de Brusquedad para el artefacto Eye Blick Real 53

4.54. Comparativa de señal EEG Original real y Procesada con MEMD+FastICA de un Eye Blink 53

4.55. Errrores NMSE y RRMSE para el caso de Eye Blink real 54

4.56. Señal EEG con artefacto Eye Blick Real tratado con MEMD+FastICA . . . 54

4.57. Comparativa de señal EEG Original real y Procesada con MEMD+FastICA para el caso Eye Movement 55

4.58. Errrores NMSE y RRMSE para el caso de Eye Movement real 55

4.59. Comparativa de señal EEG Original real y Procesada con MEMD+FastICA para el caso Jaw Movement 56
4.60. Errrores NMSE y RRMSE para el caso de Jaw Movement real 56

Índice de tablas

A.1. Comparación de algoritmos para diferentes señales y canales. 61

Lista de Acrónimos

ADN Ácido Desoxirribonucleico.

BCI Brain Computer Interface.

BSS Blind Source Separation.

CEEMD Complete Ensemble Empirical Mode Decomposition.

EEG Electroencefalograma.

EEMD Ensemble Empirical Mode Decomposition.

EMD Empirical Mode Descomposition.

EMG Electromiograma.

EOG Electrooculograma.

FastICA Fast Independent Component Analysis.

HHT Hilbert-Huang Transform.

HSA Hilbert Spectrum Analysis.

ICA Independent Component Analysis.

IMF Intrinsic Mode Function.

MEMD Multivariate Empirical Mode Descomposition.

MEMD+FastICA Método híbrido de MEMD+FastICA.

MOR Movimientos Oculares Rápidos.

PCA Principal Component Analysis.

SVM Support Vector Machine.

WT Wavelet Transform.

Capítulo 1

Introducción

1.1. Motivación

El avance en la tecnología ha transformado profundamente el mundo de la medicina, permitiendo el desarrollo de herramientas cada vez más precisas para el diagnóstico y monitoreo de pacientes. Una de las líneas principales de investigación en ingeniería biomédica se centra en el análisis y procesamiento de señales e imágenes biomédicas, utilizadas para extraer información clínicamente relevante de un paciente y ayudar a su diagnóstico.

En el campo de la neurología, el encefalograma es una herramienta clave para evaluar la actividad eléctrica del cerebro, con aplicaciones que van desde el diagnóstico de transtornos neurológicos (como epilepsia, Alzheimer o transtornos del sueño) hasta interfaces cerebro computadora o en ingles Brain Computer Interface (BCI). Sin embargo, dada la alta sensibilidad de la técnica, las señales EEG están frecuentemente contaminadas por artefactos y es crucial realizar un procesamiento adecuado de éstas para mitigar, en la medida de lo posible, todas las componentes que pueden perturbar la señal original, enmascarando la actividad cerebral real. Estos artefactos dificultan el análisis de la EEG e impiden la correcta interpretación de los resultados, limitando de esta manera su utilidad clínica.

La separación entre señal real EEG y las componentes artefactuales representa uno de los principales desafíos en el procesamiento de señales biomédicas. Métodos tradicionales como el filtrado lineal, la regresión [3] o el análisis de componentes independientes [4] han demostrado limitaciones en escenarios donde los artefactos presentan solapamiento espectral o estacionariedad. Por ello, existe una necesidad creciente de explorar técnicas avanzadas de descomposición de señales que permitan una eliminación más efectiva y adaptativa de estos artefactos.

1.2. Propuesta, objetivos y metodología

En este trabajo se propone utilizar la descomposición empírica de modos o Empirical Mode Descomposition (EMD) como una alternativa prometedora a los métodos tradicionales debido a su capacidad para manejar señales no lineales y no estacionarias, adaptándose automáticamente a las características intrínsecas de la señal EEG. A diferencia de métodos basados en transformaciones fijas como Fourier o Wavelets, la EMD descompone la señal en modos intrínsecos que facilitan la identificación y eliminación selectiva de artefactos sin afectar significativamente la información neural subyacente.

El objetivo principal del trabajo es analizar y comparar diferentes técnicas de descomposición adaptativa basadas en EMD para la reducción de artefactos en señales EEG. Para ello, se plantean los siguientes objetivos específicos:

1. Revisión y estudio teórico de las técnicas actuales de eliminación de artefactos en EEG, con especial énfasis en métodos basados en descomposición modal empírica (EMD, MEMD) y enfoques híbridos (MEMD + FastICA).
2. Implementación y evaluación de los algoritmos EMD, MEMD y MEMD+FastICA en señales EEG sintéticas, con el fin de determinar cuál ofrece el mejor rendimiento.
3. Validación en señales EEG reales mediante la aplicación del método más efectivo sobre registros de larga duración, utilizando un clasificador basado en Máquinas de Vectores Soporte (SVM) para la detección automática de segmentos artefactuados.

La metodología que se ha seguido para lograr los objetivos planteados se puede resumir en los siguientes pasos generales que se irán detallando a lo largo del texto:

1. Generación de señales sintéticas y preprocesamiento inicial.
2. Implementación de los algoritmos: EMD estándar, MEMD y MEMD + FastICA.
3. Aplicación de los algoritmos a las señales sintéticas, evaluación comparativa del desempeño y selección del método más eficaz.
4. Adquisición y preprocesamiento de señales reales de larga duración.
5. Clasificación de artefactos en señales reales mediante SVM y aplicación del método seleccionado.
6. Evaluación final de los resultados obtenidos.

1.3. Estructura del documento

A continuación se resumirá brevemente el contenido de cada uno de los apartados.

En el Capítulo 1 se realizará una breve introducción donde se establecerá la motivación bajo la cual se ha desarrollado el presente trabajo y la propuesta del mismo con los objetivos previamente definidos.

En el Capítulo 2 se hará un recorrido teórico sobre la importancia de las señales biomédicas en general y las EEG en específico, así como un estudio del arte de las técnicas actuales de eliminación de artefactos en señales EEG.

En el Capítulo 3 se realizará un estudio del marco teórico de los métodos utilizados en la realización del presente trabajo. Se trabajarán los fundamento de EMD, MEMD y FastICA

En el Capítulo 4 se procederá a realizar una documentación exhaustiva de las diferentes pruebas realizadas. En primer lugar se expondrá la solución general abordada para seguir con un desarrollo de las pruebas en un escenario con señales sintéticas. En último lugar se realizará un estudio del escenario con señales reales y el uso del mejor método obtenido.

En el Capítulo 5 se realizará un análisis de las conclusiones obtenidas y un estudio general sobre las líneas futuras de trabajo que se presentan.

Capítulo 2

Señales Biomédicas

2.1. Contexto General

El cerebro es la estructura principal responsable de la coordinación y del control del organismo del ser humano. Se trata de una masa de tejido blando protegida por los huesos del cráneo y las meninges que están compuestas por tres membranas de tejido conectivo que cubren todo el sistema nervioso central. A través de las meninges discurre el líquido cefalorraquídeo que actúa como amortiguador mecánico además de tener otras muchas funciones fisiológicas. Se trata de una estructura compleja, pues procesa y almacena información de manera continua, integrando funciones cognitivas superiores como la memoria o la inteligencia, y en la percepción sensorial y regulación autónoma como la frecuencia cardíaca o la respiración.

El cerebro se divide en dos hemisferios, conectados por el cuerpo calloso, cuya superficie, denominada corteza cerebral, está formada por sustancia gris. Cada hemisferio cerebral está subdividido en lóbulos cuya superficie se encuentra marcada por surcos cerebrales que delimitan circunvoluciones como se puede apreciar en la Fig.2.1.

- El **lóbulo Frontal** participa en funciones ejecutivas como toma de decisiones o razonamiento. Participa en la regulación emocional, el control del habla y en movimientos voluntarios.
- El **lóbulo Parietal** controla las sensaciones táctiles, el dolor o la temperatura.
- El **lóbulo Temporal** es el encargado de la memoria, el oído y otras partes del habla.
- El **lóbulo Occipital** es el encargado de la visión y responsable de procesar las imágenes.

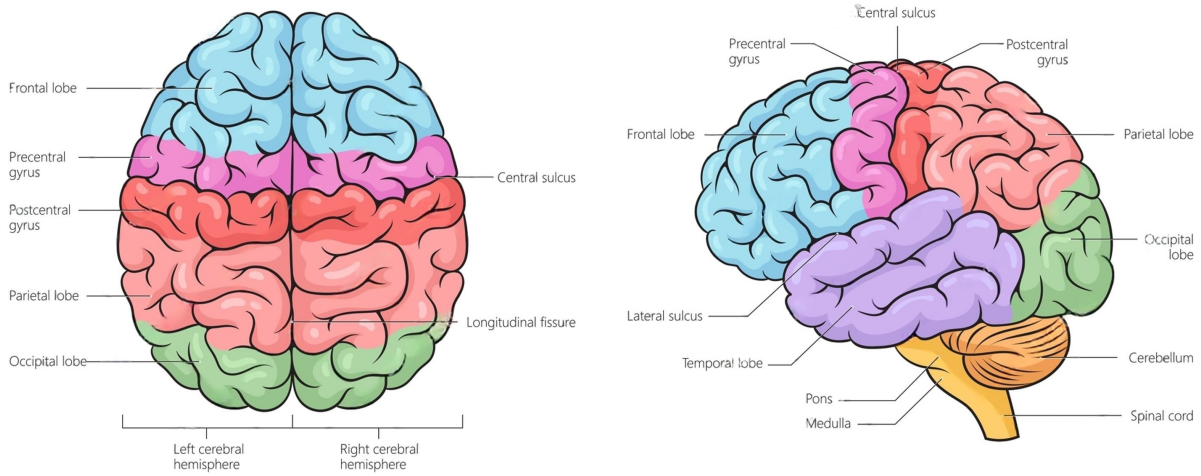


Figura 2.1: Esquema del cerebro y disposición de lóbulos [1]

- El **Cerebelo** es la parte trasera del cerebro y es responsable de la coordinación y el equilibrio .

Las neuronas o células nerviosas Fig. 2.2, son las unidades fundamentales del sistema nervioso central. Se caracterizan por la excitabilidad eléctrica de su membrana plasmática siendo así las responsables de la recepción de estímulos sensoriales y de enviar órdenes a diferentes partes del cuerpo. Se componen de tres partes fundamentales:

- El **cuerpo celular**, que contiene el núcleo, donde se encuentra el ADN.
- El **Axón** que es la parte alargada encargada de transportar los mensajes electro químicos.
- Las **dendritas** o ramificaciones nerviosas, que son las ramificaciones que establecen conexiones con otras células. Estas reciben los mensajes a través de neurotransmisores liberados por los axones de neuronas próximas.

2.2. Señales EEG

Las transmisiones eléctricas producidas por las neuronas se originan como consecuencia de un cambio transitorio de la permeabilidad en la membrana plasmática. Su propagación ocurre debido a la existencia de una diferencia de potencial entre la parte interna y externa de la célula, denominado potencial de membrana, y que está alrededor de -70 mV. La carga de una célula inactiva se mantiene en valores negativos y varía dentro de unos estrechos márgenes. Cuando el potencial de membrana de una célula excitable se despolariza más allá

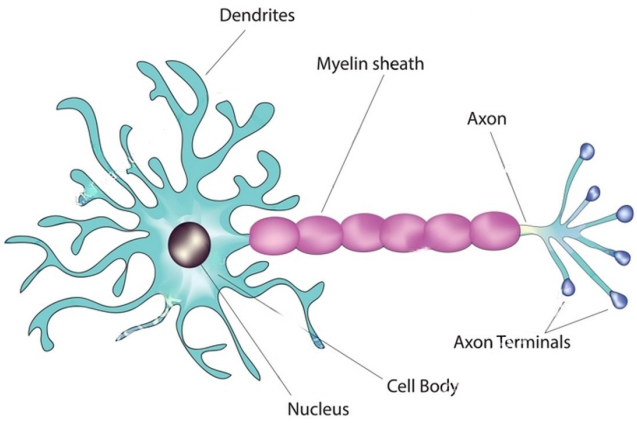


Figura 2.2: Esquema de una neurona

de un cierto umbral (de 65 mV a 55 mV) la célula genera un potencial de acción, que es un cambio muy rápido en la polaridad de la membrana de negativo a positivo y vuelta a negativo. Este ciclo dura únicamente unos milisegundos.

El estudio de actividad cerebral anteriormente descrita, es una de las principales líneas de investigación en la ciencia moderna, la cual está relacionada con muchos campos de estudio como la neurofisiología, las matemáticas o la biofísica.

Una de las principales fuentes de información proviene de una técnica denominada **electroencefalograma** (EEG) descubierta en 1929 por *Hans Berger*, un neurólogo alemán. El EEG es una técnica de exploración funcional del sistema nervioso central, de gran ayuda para el diagnóstico de algunas patologías como la epilepsia, encefalopatías o las alteraciones del estado de la consciencia. Mediante esta técnica se obtiene un registro de tiempo real de la actividad eléctrica cerebral. Por lo general, se trata de una técnica no invasiva, ya que únicamente consiste en la colocación de electrodos sobre el cuero cabelludo.

Las fluctuaciones de voltaje medidas en los electrodos permiten evaluar la actividad cerebral normal. Estas señales vienen en un rango de de 5-200 μV, lo que las hace especialmente sensibles a la distorsión, estas se convierten en una señal eléctrica que el equipo EEG transforma en un trazado visual Fig.2.3.

La frecuencia de muestreo representa la cantidad de veces que se toma el valor de la señal por unidad de tiempo. En la investigación de neuroimagen, una frecuencia de muestreo mínima de 256Hz suele ser aceptable, misma frecuencia que se utiliza de muestreo estándar para neurociencia en tiempo real.

Las señales EEG contienen información relevante en un rango de frecuencias entre los 0.5Hz y 80Hz. Este ancho de banda se descompone en diferentes bandas frecuenciales, identificadas con letras griegas [5].

- **Delta (0.5-4Hz):** Presenta un voltaje muy alto de 100 a 200 μV. Es el ritmo

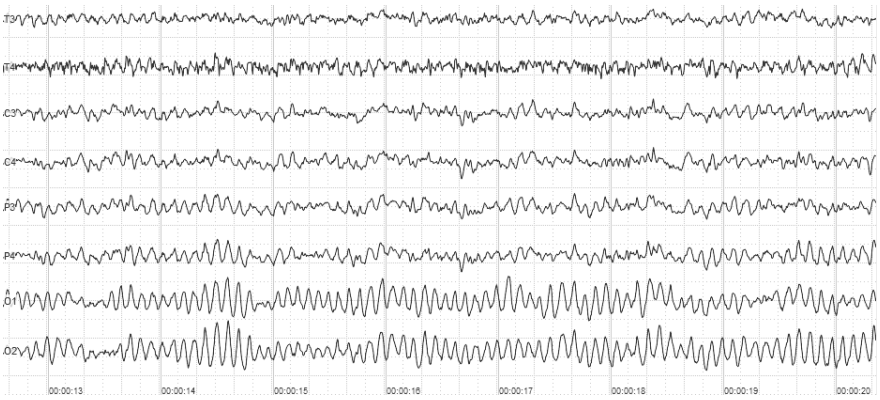


Figura 2.3: Muestra de un Encefalograma (EEG)

dominante en las etapas 3 y 4 del sueño, pero no se observa en el adulto consciente. Tiende a tener la mayor amplitud de todas las ondas. Su aparición en estados de vigilia suele indicar una patología.

- **Theta (4-8Hz):** Con amplitudes inferiores a 30 μV, se registra en sujetos durante el sueño, principalmente en la etapa de movimientos oculares rapidos (MOR). Este ritmo no está presente en adultos despiertos, pero es normal en niños despiertos hasta la adolescencia.

- **Alpha (8-16Hz):** Con amplitudes medias entre 30 y 50 μV, se observa cuando el sujeto está relajado en estado de vigilia y con los ojos cerrados. La banda es bloqueada o atenuada por la apertura de ojos o el esfuerzo mental.

- **Beta(16-24HZ):** Con amplitudes inferiores a 20 μV, predomina en individuos despiertos y con los ojos abiertos, especialmente durante la actividad mental.

- **Gamma (24-80HZ):** Con amplitudes entre los 5 y los 10 μVs y predomina en procesos mentales superiores.

La colocación de los electrodos para la realización de un electroencefalograma sigue, por lo general, un patrón estandarizado denominado sistema *10-20*, desarrollado por *Herbert Jasper* en 1958. Este método se basa en mediciones específicas del cráneo, realizadas desde el nasion, parte superior de la nariz, hasta el inión, protuberancia ósea en la parte posterior del cráneo, y entre los puntos preauriculares A1 y A2, ubicados frente a cada oído.

El nombre *'10-20'* hace referencia a los porcentajes de distancia entre los electrodos adyacentes, que representan el 10 % o el 20 % de la distancia total entre puntos anatómicos de referencia. A partir de esta lógica, han surgido diferentes sistemas según el grado de resolución:

- **Sistema 10-20:** Utiliza 21 electrodos, distribuidos con distancias del 10 %

y 20 % sobre las curvas de referencia sagital y coronal. Se puede apreciar su distribución en Fig.2.4.

- **Sistema 10-10:** Amplía el número de electrodos a 81, utilizando distancias del 10 % entre todos los puntos.
- **Sistema 10-5:** Aún más preciso, con aproximadamente 320 electrodos, usando una separación del 5 % entre cada uno.

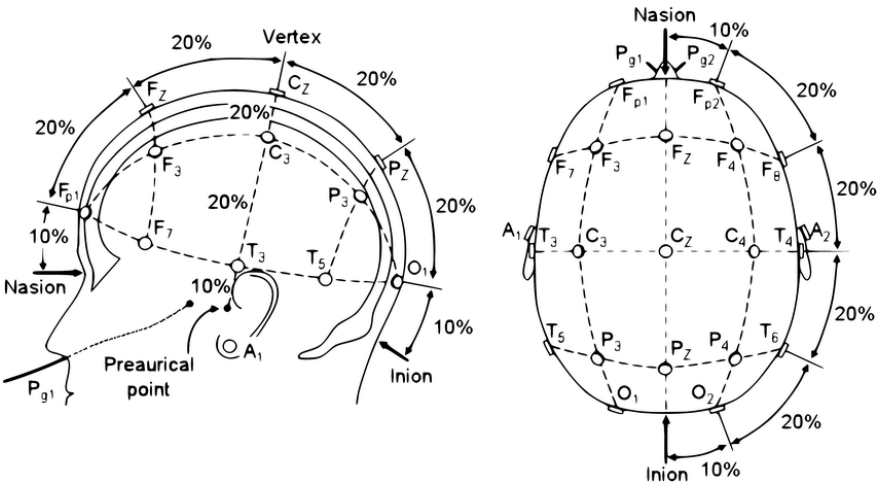


Figura 2.4: Posición de los electrodos acorde al Sistema Internacional 10-20. [2]

Cada punto de colocación de los electrodos recibe una letra que indica la región cerebral desde la cual se realiza la lectura. Las principales letras utilizadas son **Fp** para la región prefrontal, **F** para la frontal, **T** para la temporal, **P** para la parietal, **O** para la occipital y **C** para la central.

Además, la letra **Z**, que representa "zero", se utiliza para identificar los electrodos ubicados sobre la línea media sagital del cráneo, es decir, la línea que divide el cerebro en dos hemisferios. [1]

En cuanto a la numeración, los electrodos que llevan números impares (1, 3, 5, 7, 9) se colocan en el hemisferio izquierdo, mientras que los que llevan números pares (2, 4, 6, 8, 10) se sitúan en el hemisferio derecho. Esta convención permite una localización precisa y estandarizada de cada electrodo sobre el cuero cabelludo.

Con respecto a la naturaleza de los electrodos, se pueden subdividir en varios tipos según sus características, como pueden ser la morfología o el tipo de adhesión al cuero cabelludo.

- Los **electrodos adheridos**, que son pequeños discos metálicos de unos 5mm de diámetro y que se adhieren con pasta conductora y se fijan con colodión

[1] Algunos ejemplos de estos puntos son **Fpz, Fz, Cz y Oz,** los cuales suelen emplearse como referencias centrales o puntos de simetría.

que es aislante. Estos electrodos con una aplicación correcta dan resistencias de contacto muy bajas entorno a $1\,\mathrm{k}\,\Omega$.

- Los **electrodos de contacto**, que consisten en pequeños tubos de plata clorurada roscados a unos soportes de plástico. Se sujetan al cráneo mediante unas bandas elásticas, y su colocación es muy sencilla y rápida. Tienen el inconveniente que son incómodos para el paciente, lo que imposibilitan bastante su uso en registros de larga duración.

- Los **electrodos integrados** en casco de malla, son la última novedad en electrodos y estos están incluidos en una especie de casco elástico y se sujetan con unas cintas a una banda torácica. Su diseño facilita su colocación y son cómodos para el paciente, permitiendo la toma de registros de larga duración. Otra de sus ventajas es la precisión en su ubicación minimizando significativamente los artefactos producidos por ruidos fisiológicos y ambientales.

La señal registrada mediante los electrodos en un EEG, también conocida como señal cruda o *raw*, es una gráfica que representa el voltaje en μV para el eje de ordenadas, y tiempo en el eje de abscisas. La gráfica resultante Fig.2.3 representa el cambio en el tiempo de la diferencia de actividad eléctrica entre dos puntos del cuero cabelludo.

2.3. Artefactos en EEG

Los datos recogidos en un EEG generalmente están recogidos a través de múltiples canales, cada uno de estos canales corresponde a un electrodo colocado en el cuero cabelludo que registra la actividad eléctrica cortical. El análisis de estos datos suele verse afectado por algunos patrones oscilatorios parásitos conocidos como ruido o artefactos, los cuales no proceden de la corteza cerebral de forma explícita. Estos artefactos pueden subdividirse en dos amplios grupos que se explican a continuación.

Los denominados **artefactos externos** o del entorno, son las componentes de ruido en la señal EEG que pueden deberse a algunas fuentes externas de cargas y señales eléctricas, como la carga estática, el mal blindaje de los electrodos de registro, la red eléctrica industrial, llamadas telefónicas o el mal contacto de los electrodos. Estos tipos de artefactos no dependen del paciente y puede reducirse considerablemente si se proporcionan condiciones experimentales adecuadas, como un correcto blindaje de los dispositivos de registro.

Los **artefactos fisiológicos** en cambio, están relacionados con procesos que tienen lugar en el organismo del sujeto y que generan alguna carga eléctrica parasitaria. Existen diferentes tipos y orígenes para este tipo de artefacto, algunos de los cuales se muestran en Fig.2.5.

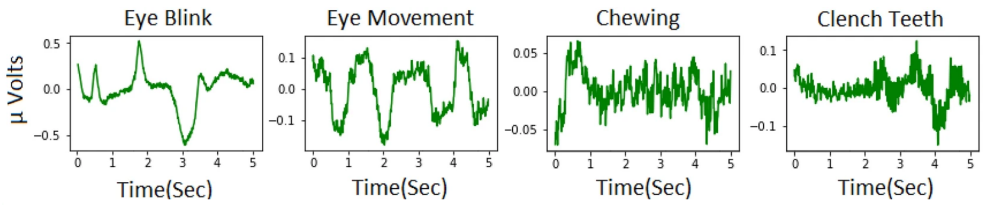


Figura 2.5: Muestra de diferentes artefactos en un EEG

- Los **Movimientos oculares y parpadeos** son unos de los principales artefactos que se pueden encontrar en un EEG. Los movimientos oculares pueden ser voluntarios o involuntarios, siendo estos últimos presentes en pacientes con un cuadro clínico mas crítico.

- Los artefactos **electromiográficos** son los producidos por la actividad eléctrica de los músculos, especialmente los de la cara, cuello y cuero cabelludo, donde intervienen músculos del cuero cabelludo, frontal facial y masetero.

- Los artefactos **glosocinéticos** son los producidos por los movimientos de la lengua. Estos artefactos no son tan frecuentes como los anteriores, pero pueden interferir significativamente en la señal. También podríamos incluir aquí los artefactos derivados del movimiento del musculo gloso-faríngeo al tragar.

- Los artefactos **cardiogénicos** son comunes, pues el potencial de acción que se produce en el movimiento de latido del corazón puede transmitirse hasta los electrodos, dando picos rítmicos claramente visibles. [2]

- El artefacto por **sudoración** es un artefacto producido por el cambio de la resistencia eléctrica de la piel al estar mojada, cambiando así también el valor de la señal. Puede incluir pequeños movimientos de los electrodos que también serán visibles en el EEG.

La identificación de artefactos en un EEG puede ser un gran desafío debido a múltiples razones. No se encuentran localizados en un punto específico de la señal, sino que pueden presentarse de forma difusa o dispersa a lo largo del registro. Se encuentran mezclados con las señales cerebrales importantes y pueden poseer características parecidas a actividad cerebral real, llegando a confundirse con patologías como una crisis epiléptica.

La eliminación y reducción de artefactos se ha convertido en uno de los aspectos más relevantes en la investigación y en la práctica clínica debido a los beneficios que aporta. La presencia de artefactos complica la interpretación de la señal, ya que enmascaran y distorsionan la actividad cerebral real. Al aplicar técnicas de eliminación de artefactos, se

[2]El artefacto cardiogénico es el derivado de los latidos del corazón, pueden ser reconocidos al solapar la información EEG con un Electrocardiograma (ECG).

facilita el trabajo del neurofisiólogo, permitiendo la revisión de registros de larga duración de forma más rápida. También mejora la fidelidad de la señal, puesto que ayuda a diferenciar entre actividad cerebral legítima y artefacto, reduciendo así los falsos positivos.

2.4. Técnicas de eliminación de artefactos

Existen numerosas técnicas y algoritmos desarrollados específicamente para la detección y eliminación de artefactos en señales EEG. Estos métodos o algoritmos permiten mejorar la calidad de la señal de las muestras tomadas.

Desde enfoques clásicos como el filtrado por bandas o la interpolación de canales contaminados, hasta técnicas más avanzadas como la descomposición en componentes independientes o los métodos basados en inteligencia artificial y aprendizaje automático, el abanico de posibilidades es amplio y sigue en constante evolución [6]. En este apartado se presentará una revisión general sobre las técnicas empleadas más utilizadas y novedosas. En Fig. 2.6 se puede apreciar el porcentaje de referencias publicadas entre el 2013 y 2018 basadas en algoritmos de descontamincación de artefactos en EEG [7].

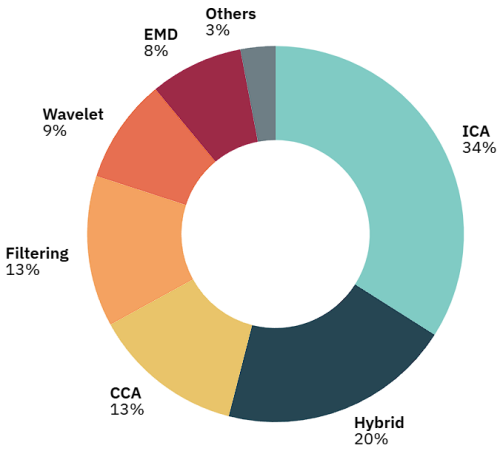


Figura 2.6: Porcentaje de Métodos en publicaciones 2013-2018

2.4.1. Métodos de regresión lineal

Son los métodos más clásicos y simples y con poco coste computacional. Cuando se dispone de uno o más canales de referencia, siempre y cuando estos representen de forma fidedigna la señal de la onda de interferencia, los artefactos pueden corregirse restando una parte proporcional de cada canal de referencia de la señal EEG contaminada de origen [8]. Esta regresión puede hacerse tanto en el dominio del tiempo como de la frecuencia.

Los métodos de regresión han sido reemplazados por algoritmos más sofisticados principalmente debido a su dependencia de señales de referencia y su limitada capacidad para

corregir unicamente artefactos oculares con electrooculograma (EOM) y artefactos musculares con electromiograma(EMG).

2.4.2. Métodos de filtrado

La técnica del filtrado ha sido ampliamente utilizada para la cancelación de artefactos en EEG. Su aplicación se basa en el principio de atenuar aquellas frecuencias o componentes no deseadas de la señal, preservando la información relevante. Entre los algoritmos mas utilizados se encuentran el filtro adaptativo, capaz de ajustarse dinámicamente a las variaciones de la señal.

El filtro *Wiener* [9], por su parte, actúa en el dominio de la frecuencia buscando separa la señal nueronal y la interferencia. Ambos filtros trabajan con la intención de reducir el error cuadrático medio.

2.4.3. Métodos de separación ciega de fuentes.

La separación ciega de fuentes o **Blind Source Separation** (BSS), permite estimar componentes independientes directamente desde las señales observadas sin necesidad de contar con una forma de onda de referencia ni para la señal deseada ni para los artefactos no deseados.

La efectividad de las técnicas BSS está sujeta a que se cumplan diversas suposiciones como la falta de correlación o la no gaussianidad. El éxito depende, por tanto, de una buena separación de las fuentes y de la correcta identificación de los componentes como señales cerebrales o como artefactos [10]. A continuación se describirán los dos métodos más estudiados:

- El análisis de componentes principales o **Principal Component Analysis** (PCA) es una de las técnicas BSS más simples y ampliamente utilizadas, cuyo algoritmo principal está basado en la matriz de covarianza de vectores propios o eigenvalues.

- El análisis de componentes independientes o **Independent Component Analysis** (ICA) es otra técnica muy utilizada y que asume que las señales fuente son combinaciones lineales de señales cerebrales y artefactos. Basado en esto, se puede descomponer la señal componentes independientes, y de ahí extraer la señal limpia y el artefacto.

2.4.4. Métodos de descomposición de fuente

El problema de encontrar la componente de artefacto puede realizarse mediante la descomposición de las señales registradas de forma individual y en base a buscar una forma de onda que representen tanto la señal como el artefacto. Dentro de este conjunto de técnicas destacan principalmente la transformada Wavelet y la descomposición empírica de modos.

- La Trasformada Wavelet (WT) es ampliamente utilizada dada su versatilidad y adaptabilidad a una gran cantidad de señales [11]. Este método descompone la señal en una serie de coeficientes, que representan la similitud de la señal con el wavelet elegida. La idea principal es aplicar la transformada wavelet elegida, y una vez creada la estructura de coeficientes y detalles, realizar un filtrado mediante un umbral, para posteriormente reconstruir la señal mediante la transformada inversa.

- La Descomposición empírica de modos o EMD es una técnica que se basa en descomponer la señal en funciones base denominadas funciones de modo intrínseco. La técnica es aceptada para procesar señales no lineales y no estacionarias, abriendo la posibilidad de aplicarse a señales que otros métodos deben abandonar. Una vez descompuesta la señal en sus funciones de modo intrínseco, se identifican y procesan las señales portadoras de artefactos y procesarlas, para posteriormente realizar la reconstrucción. Existen algunas variantes que ayudan a mejorar el desempeño del método como por ejemplo el Ensamble Empirical Mode Descomposition (EEMD) [12] o el Complete Ensamble Empirical Mode Descomposition (CEEMD) [13].

2.4.5. Métodos híbridos

Los métodos híbridos son métodos que combinan diferentes técnicas o algoritmos para mejorar la eficacia en la limpieza de artefactos. En la literatura científica hay gran variedad de publicaciones basadas en modelos híbridos como puede ser WT+ICA [14], EMD+ICA [15], Filtering+PCA [16], etc.

Capítulo 3

Marco Teórico

Antes de analizar los experimentos y los resultados obtenidos, este capítulo desarrolla los fundamentos teóricos que sustentan este trabajo. Su objetivo es establecer un marco conceptual completo de los algoritmos utilizados basados en la descomposición adaptativa.

Se comenzará revisando los fundamentos del **Empirical Mode Decomposition** (EMD), un algoritmo que permite descomponer una señal en componentes denominados modos intrínsecos de forma completamente adaptativa.

Posteriormente, se analizará el algoritmo multicanal conocido como **Multivariate Empirical Mode Decomposition** (MEMD), basado en EMD pero para señales multicanal, pues tiene en cuenta la coherencia entre los distintos canales,

En último lugar, se presenta una hibridación de MEMD con técnicas de separación ciega de fuentes. En el caso presentado se ha escogido el algoritmo **Fast Independent Component Analysis** (FastICA).

Todas estas técnicas se describirán en el contexto de su aplicación al análisis de señales biomédicas, con énfasis en el tratamiento y mejora de la interpretación de registros EEG multicanal.

3.1. Empirical Mode Descomposition ó EMD

El método EMD fue desarrollado en 1996 por *N.E. Huang* et al. [17] como parte de su trabajo en la denominada **Transformada de Hilbert-Huang** (HHT)[1] [18].

Como se expone en [19], [20] y [21], el algoritmo EMD está diseñado para analizar

[1] La *transformada de Hilber-Huang* o HHT es un análisis que se basa en aplicar la descomposición EMD, para posteriormente aplicar la transformada de Hilbert y obtener la frecuencia instantánea permitiendo aplicar HSA.

señales no lineales y no estacionarias. Se basa en descomponer la señal en un número finito de componentes oscilatorias de amplitud y frecuencia variable denominadas **Intrinsic Mode Functions** (IMFs). Estas IMFs poseen propiedades que las hacen especialmente adecuadas para su posterior análisis mediante la transformada de Hilbert. Para ser considerada una IMF, el modo debe satisfacer dos condiciones:

(i) La cantidad de puntos extremos (máximos y mínimos) y la cantidad de cruces por cero deben ser iguales o diferir a lo sumo en uno.
(ii) La media local, definida como el valor medio de las envolventes superior e inferior, debe ser nula para todo punto.

El modo de obtener las diferentes IMF es creando dos envolventes de la señal original mediante interpolación [2] y calculando su componente de baja frecuencia o promedio local. Este proceso se realiza de forma iterativa a través de un proceso denominado *Sifting* el cual se describe en el Algoritmo. 1.

Algoritmo 1: Empirical Mode Decomposition (EMD)

Paso 1: Encontrar tanto los *máximos locales* como los *mínimos locales* de $x(t)$.

Paso 2: Interpolar los máximos locales para construir la envolvente superior $e_{max}(t)$.

Paso 3: Interpolar los mínimos locales para construir la envolvente inferior $e_{min}(t)$.

Paso 4: Realizar el cálculo de la media local $m(t)$ de las dos envolventes.

$$m(t) = \frac{e_{\max}(t) - e_{\min}(t)}{2}$$

Paso 5: Quitar la media de la señal original.

$$h(t) = x(t) - m(t)$$

Paso 6: Evaluar si $h(t)$ satisface las condiciones para ser una IMF:

- Si $h(t)$ NO es una IMF se redefine la función y se salta al **Step 1**

$$x(t) = h(t)$$

- Si $h(t)$ es una IMF, se extrae la IMF y se define el residuo:

$$r(t) = x(t) - h(t)$$

Paso 7: Repetir el proceso hasta cumplir el *Stopping Criteria* según:

$$x(t) = r(t)$$

El proceso de *Sifting* se realiza iterativamente hasta que el *Stopping Criteria* se cumpla. Existen varios criterios de parada según su naturaleza:

(i) Con el criterio de *Cauchy*, el proceso se detiene cuando la diferencia entre dos iteraciones consecutivas es menor que un umbral definido ϵ.
(ii) Según el criterio de cruce por cero mínimo, el proceso se detiene cuando la señal

[2] La interpolación debe realizarse mediante splines cúbicos, donde cada tramo de la función es un polinomio cúbico definido entre dos puntos consecutivos del conjunto de datos.

residual unicamente tiene un solo cruce por cero.

(iii) Según el criterio de numero fijo de IMFs, el proceso de *Sifting* se detiene cuando el numero de IMFs deseadas se ha alcanzado.

El algoritmo EMD destaca por su excelente capacidad de reconstrucción y proporciona pocas perdidas en el proceso. El algoritmo de reconstrucción es muy sencillo y basta con sumar todas las IMF obtenidas junto con el residuo, se puede ver en el Algoritmo. 2.

Algoritmo 2: Reconstrucción de señal EMD

Step 1: Suma de todos los IMF calculados y el residuo.

$$\hat{x}(t) \;=\; \sum_{k=1}^{K} \mathrm{IMF}_k(t) \;+\; r_K(t)$$

La descomposición EMD no requiere una base predeterminada y es altamente adaptativa, pero tiene ciertas limitaciones. La primera de ella es el *mode mixing* [22] y [23], que es un problema que ocurre cuando en una IMF existen componentes de diferentes frecuencias. Esto sucede cuando los datos contienen intermitencias o ruido y esto crea una perdida de significado físico en las IMF.

Existen diferentes técnicas para reducir los problemas de *mode mixing* como la EEMD[3] o el uso de señales de enmascaramiento, pero quedan fuera del alcance de este trabajo.

El otro problema es el denominado *boundary effect* [24], que sucede al segmentar la señal original en ventanas. Al aplicar EMD y por consiguiente construir las envolventes superior e inferior con splines cúbicos naturales, las condiciones de frontera distorsionan la curva en los extremos de la ventana. Estos errores pueden mitigarse utilizando técnicas como el *mirror-padding*, que se encarga de coger un tramos antes y después de la señal para reducir los errores de las *spiline*.

Por último, en la Fig.3.1 se muestra un ejemplo ilustrativo del funcionamiento del algoritmo EMD y de la construcción de sus envolventes. Para ello se ha generado una señal artificial compuesta por la suma de dos señales sinusoidales, y se aplica el proceso de descomposición EMD hasta extraer las segunda IMF.

En la figura superior izquierda se presentan las dos señales en azul, que han sido utilizadas para generar la señal sintética de prueba. En la gráfica superior derecha e inferior izquierda, se presentan las dos iteraciones del *Sifting*, con la construcción de las envolventes marcadas en rojo, y la curva de media local en verde.

Tambíen podremos apreciar en la gráfica de abajo derecha, la comparativa de la señal original y la señal reconstruida, y por último un análisis de su error de reconstrucción. Se

[3]El *Ensemble Empirical Mode Decomposition* es una extensión de EMD al que se le añade ruido blanco de baja potencia para mejorar la descomposición y evitar el *mode mixing*.

puede apreciar la correcta descomposición de las dos frecuencias y la correcta reconstrucción con un error muy bajo.

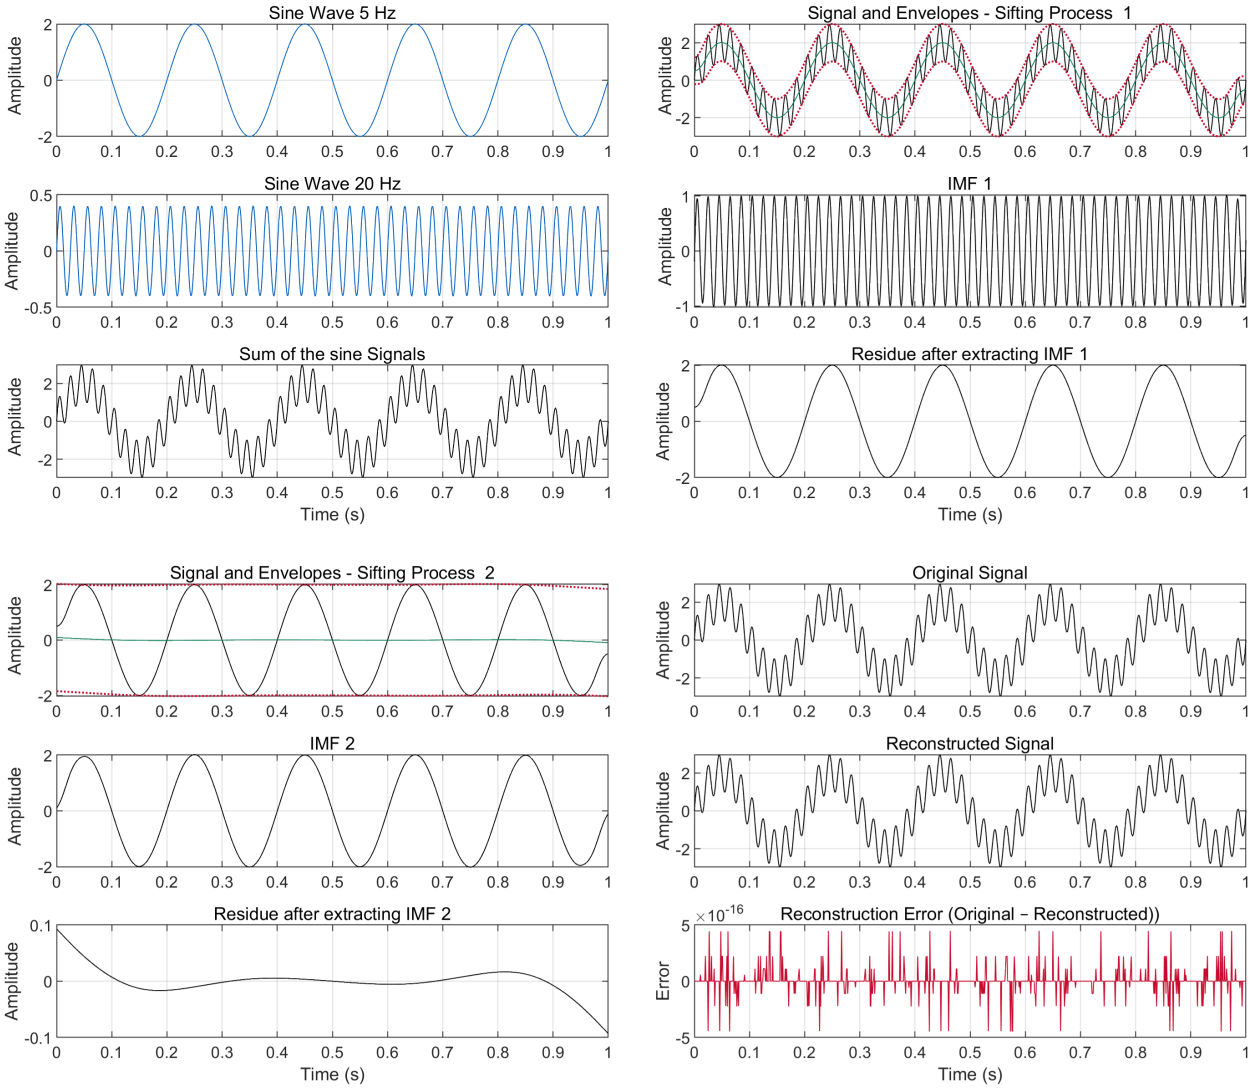


Figura 3.1: Representación gráfica del proceso completo de descomposición EMD con dos iteraciones del proceso de *Sifting*.

El método EMD ha demostrado ser potente y extremadamente útil para descomponer ciertas señales no estacionarias en sus modos intrínsecos, con aplicación directa como en [25] y [26]. Sin embargo, presenta ciertas limitaciones a la hora de tratar señales multicanal o señales con alto contenido de ruido. Para mejorar estas limitaciones y algunas otras, se han ido desarrollando extensiones basadas en EMD que mejoran partes del algoritmo o modelos híbridos de trabajo con diferentes algoritmos.

3.2. Multivariate Empirical Mode Descomposition

Los recientes avances en ciencia e ingeniería han planteado nuevos retos asociados al procesamiento de datos multicanal con dinámicas complejas. Para abordar estos desafíos, se propone la extensión del método estándar EMD a su versión multivariante, capaz de procesar señales multicanal de forma simultánea y coherente.

En 2010, *Rehman y Mandic* [27] presentaron la generalización n-variante de EMD, denominada **Multivariate Empirical Mode Decomposition** (MEMD). Aunque existen extensiones bivariantes [28] y trivariantes [29], MEMD es la primera formulación que admite un número arbitrario de variables.

MEMD conserva la filosofía de EMD, pero redefine los conceptos de extremos locales y envolventes en espacios de dimensión n. Dado que en señales multicanal los máximos y mínimos no se identifican directamente, el método proyecta el vector multicanal en múltiples direcciones definidas sobre la esfera unidad $\mathbb{S}^{n-1}$. En cada proyección se construyen envolventes n-dimensionales y, tras generar un conjunto uniforme de direcciones (vía muestreo sobre la esfera), se promedian esas envolventes para obtener la media local.

La selección de los vectores direccionales es clave: un muestreo uniforme sobre $\mathbb{S}^{n-1}$ garantiza que todas las orientaciones del espacio queden equitativamente representadas. Así, al aplicar MEMD obtenemos IMFs simultáneas que:

(i) Mantienen coherencia entre canales, reduciendo el *mode misalignment*[4].
(ii) Preservan la consistencia temporal y espectral en cada componente.

Con ello, MEMD facilita el análisis de señales multicanal interrelacionadas, abriendo la puerta a gran variedad de aplicaciones como el estudio de EEG multicanal.

A modo de conclusión, se muestra un ejemplo de la descomposición mediante MEMD de una señal multicanal de 3 canales generados sintéticamente. Cada canal se ha construido como combinación lineal de tres funciones sinusoidales diferentes. En la Fig. 3.2 se ilustra la composición de estos tres canales según la Eq. 3.1:

$$\begin{aligned} x_1(t) &= 4\,\sin\big(2\pi\cdot 50\,t\big) + 4\,\sin\big(2\pi\cdot 20\,t\big), \\ x_2(t) &= 5\,\sin\big(2\pi\cdot 50\,t\big) + 5\,\sin\big(2\pi\cdot 5\,t\big), \\ x_3(t) &= 3\,\sin\big(2\pi\cdot 50\,t\big) + 3\,\sin\big(2\pi\cdot 20\,t\big) + 3\,\sin\big(2\pi\cdot 5\,t\big). \end{aligned} \tag{3.1}$$

Análogamente, se ilustran las tres descomposiciones resultantes para cada canal, donde se puede apreciar como la frencuencia de una IMF disminuye al incrementar su índice, por lo que los modos van calculándose según su frecuencia, siendo el de mayor frecuencia el primero

[4]El *mode misaligment* o desaliniamiento de modos surge cuando el mismo número de modo de la descomposición multicanal no representa la misma frecuencia en todos los canales.

en calcularse. Además, las IMF de los tres canales están alineadas en frecuencia, dado que en la IMF 1 recoge la frecuencia de 50Hz, en la IMF 2 la frecuencia de 20Hz y en la IMF 3 aparece la frecuencia de los 5Hz, para los tres canales.

Tal como se hizo en la Sec. 3.1 con el ejemplo de EMD, en la última fila de la figura se incluyen las señales originales, las señales reconstruidas y el gráfico del error de reconstrucción, lo que permite evaluar numéricamente el rendimiento del algoritmo de reconstrucción.

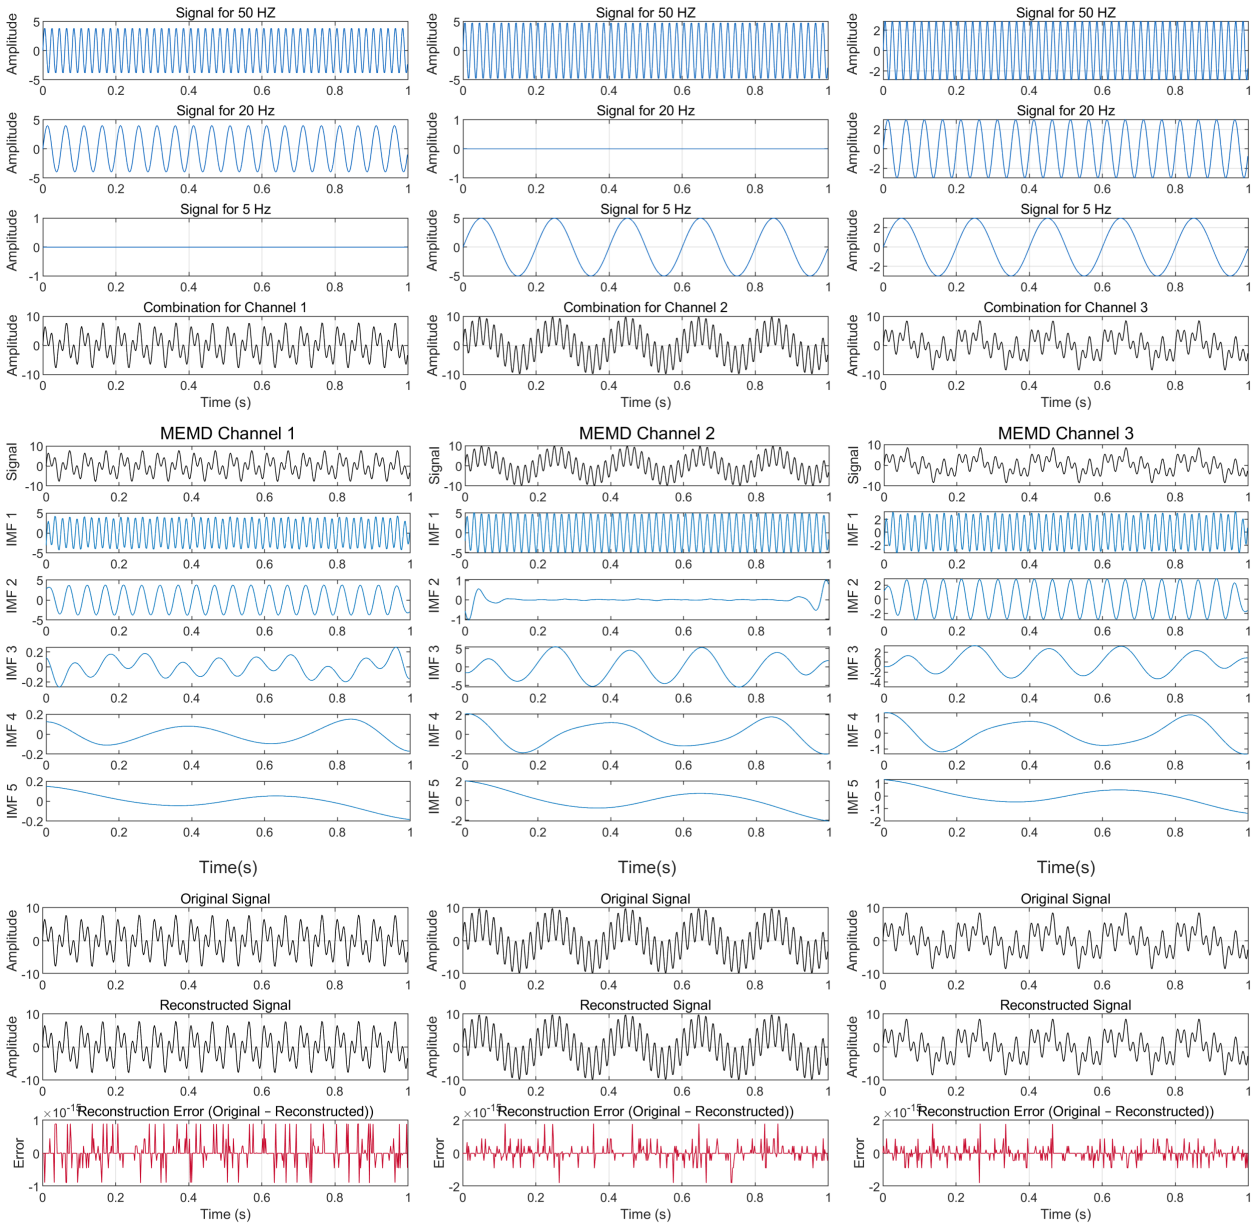


Figura 3.2: Representación gráfica del proceso completo de descomposición MEMD.

3.3. Multivariate Empirical Mode Descomposition con FastICA

La hibridación del método MEMD con un algoritmo de separación ciega de fuentes es una vertiente ampliamente estudiada [30], [31], [32] y surge con el objetivo de separar fuentes independientes en señales mezcladas tras realizar la descomposición MEMD. En el caso propuesto, se estudiará el caso particular de FastICA.

El algoritmo denominado **Independent Component Analysis** (ICA) es una propuesta realizada en 1994 por *P.Comon* [4] y está enmarcado en las diferentes propuestas para resolver el problema de separación ciega de fuentes o *Blind Source Separation*[5].

El objetivo del algoritmo consiste en representar un conjunto de m variables observadas $x_1, x_2, \ldots, x_m$ como combinaciones lineales de n componentes estadísticamente independientes $s_1, s_2, \ldots, s_n$. Estas variables observadas se modelan como mezclas lineales de fuentes desconocidas, donde se asume que las fuentes son mutuamente independientes y presentan media cero.

Agrupando las mezclas observadas en el vector $X = (x_1, x_2, \ldots, x_m)^T$ y las fuentes independientes en el vector $S = (s_1, s_2, \ldots, s_n)^T$, la relación lineal vendrá dada por la ecuación.

$$\mathbf{X} = \mathbf{A} \cdot \mathbf{S} \tag{3.2}$$

donde A es una matriz desconocida de dimensiones $m \times n$, denominada matriz de mezcla.

A partir de la Eq. 3.2, el objetivo del algoritmo ICA es estimar tanto la matriz de mezcla A como las fuentes independientes S, partiendo únicamente de las observaciones X, sin conocimiento previo ni de A ni de S. Para ello se emplea una matriz de separación W mediante la Eq. 3.3:

$$\mathbf{Y} = \mathbf{W} \cdot \mathbf{X} \tag{3.3}$$

donde Y representa una estimación de las fuentes independientes S. El reto consiste en encontrar un W tal que los componentes de Y sean lo más estadísticamente independientes posible.

Para estimar W existen diferentes estrategias que buscan la independencia estadística como la maximización de la no gaussianidad mediante kurtosis[6] o negentropía[7]. Este es el

[5]La separación ciega de fuentes es la separación de un conjunto de señales origen de un conjunto de señales mezcladas sin ningún tipo de información de las fuentes de las señales ni del proceso de mezcla.

[6]La kurtosis es una medida del grado de cuántos valores atípicos hay. Para una distribución normal, el valor del estadístico de kurtosis es 0.

[7]La negentropía es una medida de la distancia de normalidad de una distribución de probabilidad.

caso del algoritmo de FastICA que fue desarrollado en 1997 por *A.Hyvärinen* en [33].

El algoritmo **Fast Independent Component Analysis** (FastICA) es una de las implementaciónes más eficientes del método ICA, reduciendo las iteraciones necesarias frente a otros métodos, reduciendo así también el coste computacional.

El método de hibridación propuesto en la Fig. 3.3 se basa en la aplicación de la descomposición MEMD habitual sobre una señal multicanal, con la que obtendremos los modos intrínsecos fundamentales IMF de forma sincronizada entre canales, preservando la coherencia temporal y frecuencial de los modos.

Una vez realizada la descomposición, se analizarán las IMF de cada canal para identificar características que indiquen la presencia de mezclas con fuentes. Posteriormente, se aplicará el algoritmo FastICA a las IMF correspondientes al mismo nivel de descomposición, con el objetivo de detectar componentes estadísticamente dependientes. Estas componentes identificadas serán eliminadas mediante la anulación de su contribución en el espacio proyectado.

Finalmente se realizará la reconstrucción del proceso de FastICA restableciendo nuevamente las IMF de cada canal sin la aportación de la componente eliminada. Posteriormente, se volverá a reconstruir la señal de cada canal realizando la suma de sus IMF según el algoritmo descrito para el método.

Con este proceso se aprovecha las ventajas adaptativas del método MEMD y la independencia estadística que aporta FastICA, permitiendo realizar una limpieza precisa de las señales manteniendo su estructura multicanal.

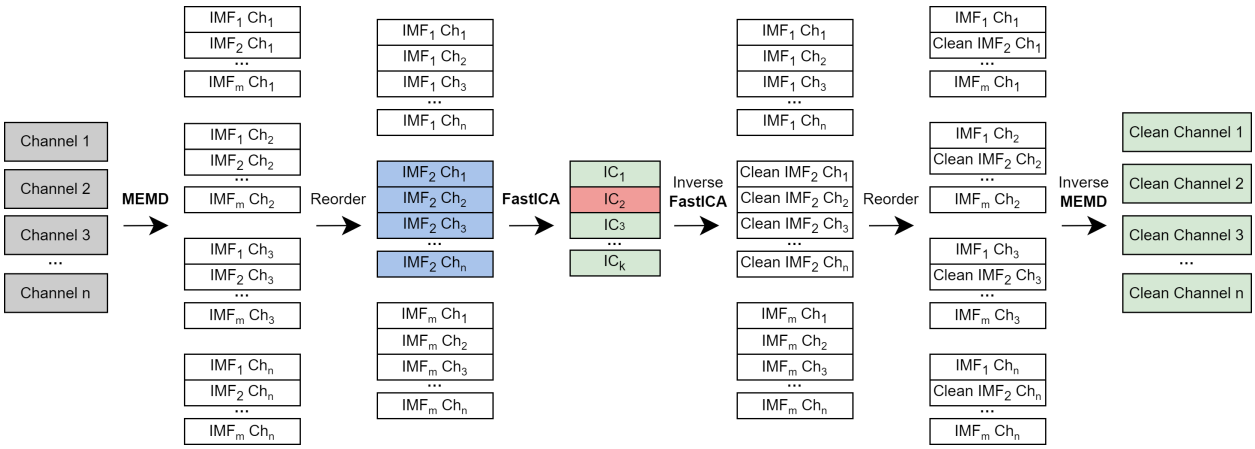


Figura 3.3: Representación gráfica del proceso completo de descomposición MEMD+FastICA.

Capítulo 4

Implementación y resultados del proyecto

4.1. Solución abordada

Se han considerado dos tipos de pruebas para la evaluación y comparación de algoritmos. La primera fase se utiliza una colección de 3 tipos de señales EEG generadas de forma sintética y que corresponden a 3 patrones muy comunes de artefactos. La segunda fase de pruebas se ha realizado sobre una colección de datos reales.

Tanto en las pruebas realizadas con señales sintéticas como las realizadas con señales originales provenientes de análisis EEG, se ha seguido la misma base de análisis, cuyo esquema se puede observar en la Fig.4.1

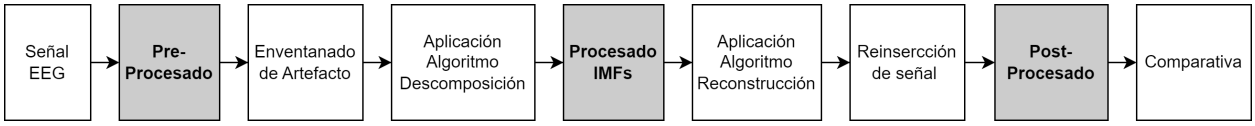


Figura 4.1: Algoritmo General

En la etapa de *Pre-Procesado*, se busca adecuar la señal de manera conveniente para las necesidades de los algoritmos basados en EMD aplicados a EEG. En primer lugar, se aplicará un **Filtro Notch** [34] y [35], un tipo específico de filtro que rechaza señales de frecuencias especificas sin afectar demasiado al resto del espectro de potencia cuya respuesta es la Fig. 4.2 . Este tipo de filtros permiten rechazar frecuencias definidas en rangos muy estrechos, en el caso de estudio con datos reales, dado que las muestras han sido obtenidas del *Research Resource for Complex Physiologic Signals* y proceden de ensayos realizados en los Estados Unidos, se rechazará la componente de 60Hz, que corresponde a la frecuencia de la red eléctrica en dicho país.

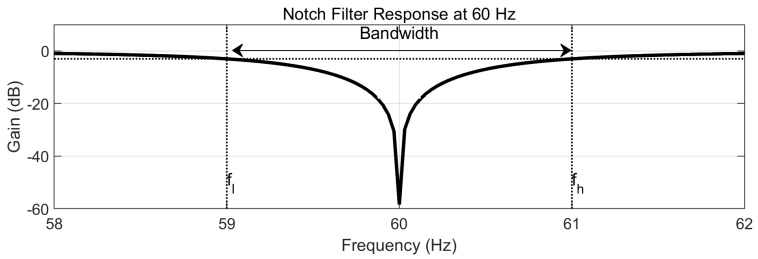


Figura 4.2: Respuesta Filtro Notch 60Hz

En esta etapa, también se ha procedido a extraer la componente media de la señal para centrar los datos alrededor del cero y a eliminar la tendencia de la señal, lo que permite suprimir componentes de muy baja frecuencias que podrían perturbar los resultados. Este es un proceso habitual en el estudio y tratamiento de señales EEG.

Todos los datos eliminados son almacenados para poder recuperarlos y recomponer la señal lo más fidedignamente posible. Tras la etapa de *Pre-Procesamiento* de la señal, se ha llevado a cabo una etapa de segmentación por ventanas, seleccionando únicamente los segmentos de señal donde se presenta el artefacto. Esta metodología es análoga a la que se aplicará en el procesamiento de las señales EEG originales y permite ejecutar el algoritmo exclusivamente en el segmento afectado por el artefacto.

Una vez se disponga de una señal enventanada y previamente tratada tenemos todos los requisitos para aplicar un algoritmo basado en EMD, el cual descompondrá la señal en un conjunto de señales fundamentales denominadas IMFs y con las cuales se trabajará exhaustivamente en busca de signos artefactuales.

El objetivo es identificar los IMFs que contienen características del artefacto para poder tratarlos y así reducir su influencia en la señal original, Para ello, se ha realizado un estudio en profundidad sobre diferentes características e índices estadísticos de cada IMF, con el fin de encontrar información específica que respalde la selección. Así pues, de cada IMF, se han calculado los siguientes parámetros:

1. **Amplitud RMS.** (A_{RMS}) Es una medida de la magnitud de una señal que representa su valor eficaz. Esta se puede calcular mediante

$$A_{\text{RMS}} = \sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2} \tag{4.1}$$

donde N es el número de muestras y x_i son los valores de la señal.

2. **Amplitud Peak to Peak.** (A_{P2P}) Es una medida que se calcula mediante

la diferencia entre el valor máximo y mínimo de la señal. Se calcula como

$$A_{\mathrm{P2P}} = x_{\max} - x_{\min} \tag{4.2}$$

donde $x_{\max}$ es el valor máximo y $x_{\min}$ es el valor mínimo de la señal.

3. **Entropia de Shannon Normalizada.** (H_{ShN}) Es una medida de incertidumbre o aleatoriedad en una señal, donde si una señal tiene poca variabilidad su entropía será baja (0.5 – 2) y si en cambio es muy caótica, su entropía será alta (2 -4). La entropía de Shannon se calcula como

$$H_{ShN} = -\sum_{i=1}^{N} P(x_i) \log_2 P(x_i) \tag{4.3}$$

4. **Kurtosis.** (K) Es una medida que nos da información sobre la forma de la distribución de los datos y se define como

$$K = \frac{\frac{1}{N}\sum_{i=1}^{N}(x_i - \bar{x})^4}{\left(\frac{1}{N}\sum_{i=1}^{N}(x_i - \bar{x})^2\right)^2} \tag{4.4}$$

lo que permite analizar la forma de la distribución. Una kurtosis alta >3 o leptocúrtica indica picos pronunciados. Una kurtosis baja <3 o platicúrtica indica señales mas suavizadas.

5. **Coeficiente de correlación de Pearson.** (r_p) Es una medida de dependencia lineal entre dos series temporales. Se intenta buscar la correlación entre la señal original y la señal IMF. Un valor de r_p cercano a 1 indica una fuerte correlación positiva, un valor cercano a -1 indica una fuerte correlación negativa, y cercano a 0 sugiere que no hay una correlación lineal significativa.

6. **Energía relativa.** (E_{Rel}) Es una medida de como se distribuye la energía de la señal original a través de todas las IMF de las descomposición. Se calcula mediante

$$E_{Rel} = \frac{E_i}{E_{total}} = \frac{\sum_{k=1}^{M} x_i^2(k)}{\sum_{j=1}^{N}\sum_{k=1}^{M} x_j^2(k)} \tag{4.5}$$

Una vez calculadas las características de cada una de las IMF para cada canal, dado que estos valores están en diferentes escalas, se ha realizado dos normalizaciones diferentes para poder comparar características en una escala similar. Estas son:

1. **Normalización Min Max** Se trata de un sistema de reescalado de datos para acomodar los valores a un rango [0,1]. La normalización *min-max* se define como:
$$x_{\text{norm}} = \frac{x - \text{mín}(x)}{\text{máx}(x) - \text{mín}(x)} \tag{4.6}$$

2. **Normalización Z-Scale** Se trata de un sistema de normalización cuyo objetivo es que los valores tengan media 0 y desviación estandar 1. La normalización *z-scale* se expresa como:
$$x_{\text{norm}} = \frac{x - \mu}{\sigma} \tag{4.7}$$

En función del rendimiento de estos parámetros calculados, se realizará una selección de uno o varios IMF candidatos a ser tratados para eliminar su componente artefactual. Existen multitud de formas de realizar el tratamiento de estos IMF seleccionados, pero en el presente trabajo se utilizará siempre su eliminación completa, asegurando una supresión definitiva de los componentes seleccionados.

Con los IMF tratados, se reconstruirá completamente la señal enventanada mediante la suma de todos los IMFs componente a componente incluyendo el residuo final obtenido del proceso de descomposición, siguiendo el algoritmo de reconstrucción establecido por el método. Con este proceso se obtiene una primera versión de la señal reconstruida, la cual conservará toda la información relevante de la señal de origen.

Esta primera versión necesita de una fase de *Post-Procesado* para restaurar completamente las características de la señal original. En esta fase se añade la tendencia y la media que previamente se había eliminado en la etapa de Pre-Procesado, obteniendo así la señal final reconstruida.

Se han empleado 4 métricas para evaluar el rendimiento de los diferentes métodos para eliminar artefactos. Estas métricas se han seleccionado de forma muy cuidadosa para no depender de información del artefacto ni de información de la señal limpia EEG, lo que permite así su aplicación directa en señales originales donde dichos datos no están disponibles. Las métricas son las siguiente:

1. **Pearson Correlation**.(r) Evalúa la relación lineal entre dos variables. En este caso se tomará la correlación que existe entre la señal pura y la señal contaminada. Se calculará analogamente la correlación existente entre la señal pura y la señal procesada para poder hacer una comparativa.

2. **Root Mean Square Error**. ($RMSE$) Es una métrica que mide el error promedio entre los valores predichos y los valores reales. Como en el caso anterior se calculará el RMSE entre la señal pura y la señal contaminada y

el RMSE entre la señal pura y la señal procesada para poder realizar una comparación.

3. **Relative Root Mean Square Error**. ($RRMSE$) Es una versión normalizada del RMSE y es definida como

$$RRMSE = \frac{RMS(X_{EEG} - \hat{X}_{EEG})}{RMS(X_{EEG})} \tag{4.8}$$

donde X_{EEG} es la señal original y $\hat{X}_{EEG}$ es la señal reconstruida tras el proceso.

4. **Normalized Mean Square Error**. ($NMSE$) Es una métrica utilizada para medir la diferencia entre una señal original y su versión estimada o reconstruida y queda definida mediante

$$NMSE = \frac{\sum(X_{EEG} - \hat{X}_{EEG})^2}{\sum X_{EEG}^2} \tag{4.9}$$

donde X_{EEG} es la señal original y $\hat{X}_{EEG}$ es la señal reconstruida tras el proceso.

4.2. Escenario con Señales sintéticas

El uso de señales sintéticas a la hora de probar los diferentes algoritmos tiene una serie de ventajas frente a las señales reales. En primer lugar, se tiene un control total sobre la propia señal, pudiendo definir tanto la duración o la longitud de la serie temporal, como añadir artefactos en el momento que deseado y con la potencia necesaria.

El uso de señales auto generadas también brinda la posibilidad de realizar una evaluación objetiva de los diferentes algoritmos, pues se dispone de la señal limpia, del artefacto puro introducido, y de la señal contaminada. Esto es de gran importancia a la hora de realizar una comparación única y exclusiva con señales sintéticas.

También es necesario realizar estos tipos de test con señales sintéticas para realizar una validación previa de los algoritmos y procesos antes de realizar las pruebas en señales con EEG reales, dado que estas son mucho mas complejas, ruidosas y extensas en el tiempo. Además incorporan un alto número de canales, lo que complica su análisis.

En la Fig.4.3 aparece un esquema completo del proceso que se emplea para realizar el estudio de estas señales bajo algoritmos basados en EMD. Este proceso, es el que se seguirá para todos los tipos de algoritmos que se estudiarán.

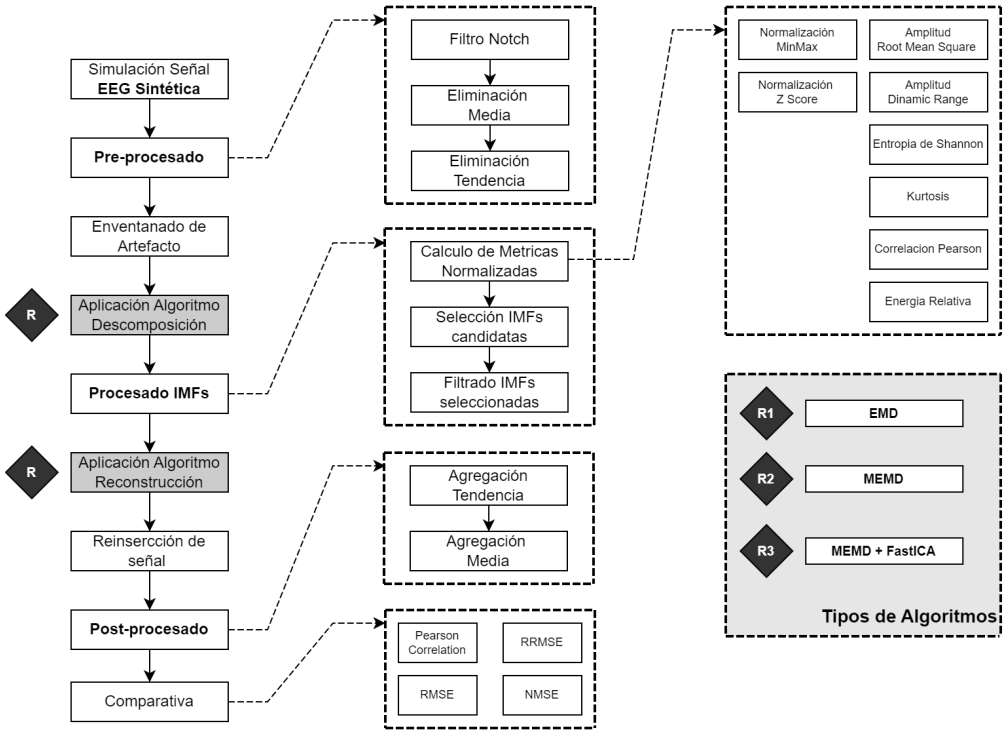


Figura 4.3: Diagrama de flujo para proceso con señales sintéticas.

4.2.1. Generación de Señales sintéticas

Para realizar pruebas se han creado tres señales multicanal sintéticas que simulan una señal EEG. Estas señales tienen de una base completamente libre de ruido que luego es contaminada con diferentes artefactos simulados para evaluar su efecto.

Cada señal consta de tres canales base, a los que se les aplicará el mismo artefacto pero con intensidades diferentes, simulando la contaminación que produce un estimulo artefactuado a diferentes electrodos.

La duración de las señales será de 4 segundos en todos los casos, lo que permite un análisis estandarizado al ahora de aplicar los diferentes algoritmos.

La primera de las señales sintéticas será una señal contaminada con un artefacto basado en el parpadeo ocular, en inglés denominado *Eye Blink Artifact*. En el análisis de EEG es de los artefactos mas comunes y se trata de una señal no cerebral generada por los músculos oculares, principalmente por el músculo orbicular que circunda los ojos, y que se encarga del parpadeo. Este artefacto suele afectar a la banda de frecuencias δ (delta) y θ (theta) pues su frecuencia está comprendida entre 1Hz y 5Hz. La amplitud suele variar dependiendo de la intensidad y de la persona pero suelen ser de amplitud negativa y superior a las ondas cerebrales y en forma de pico abrupto localizadas en su mayor parte en los electrodos de la zona frontal.

Surgen debido al *Fenómeno de Bell* [36] y [37], pues la córnea de los ojos tiene carga

positiva y la retina tiene carga negativa; cuando parpadeas, los ojos se mueven ligeramente hacia arriba, y la córnea se acerca a los electrodos frontales, los cuales captan una señal positiva que se refleja en el EEG.

Como se puede ver en Fig. 4.4, en la señal sintética se generan tanto la señal base de EEG, como el artefacto y la señal contaminada de EEG que es con la que se trabajará.

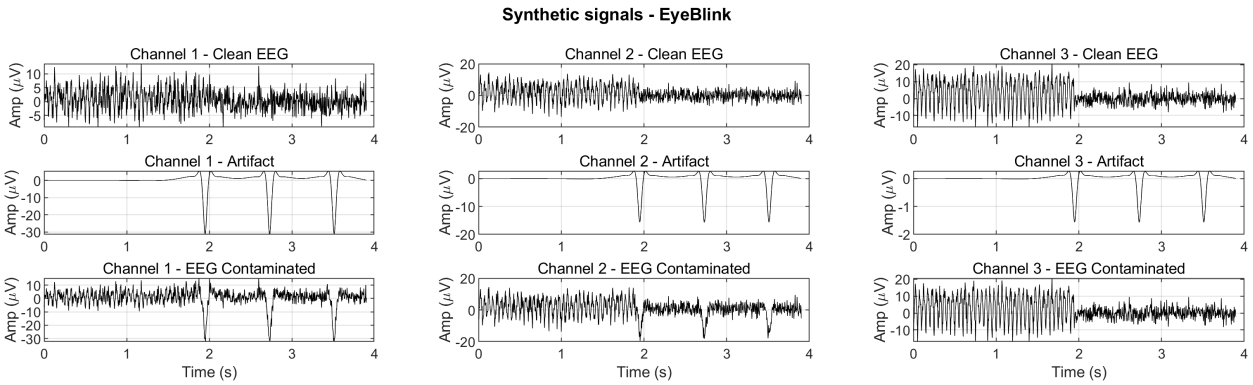


Figura 4.4: Señal sintética para un Eye Blink.

El movimiento de cejas o en ingles *Eye Brow Movement* es la segunda señal sintética con la que se trabajara. Esta señal también produce un artefacto bastante característico mediante un pico breve de amplitud considerable debido a la contracción de músculos faciales próximos a los electrodos frontales debido a la cercanía con los músculos frontales y corrugadores de las cejas. En la Fig. 4.5 podemos ver la señal sintética generada para este estudio.

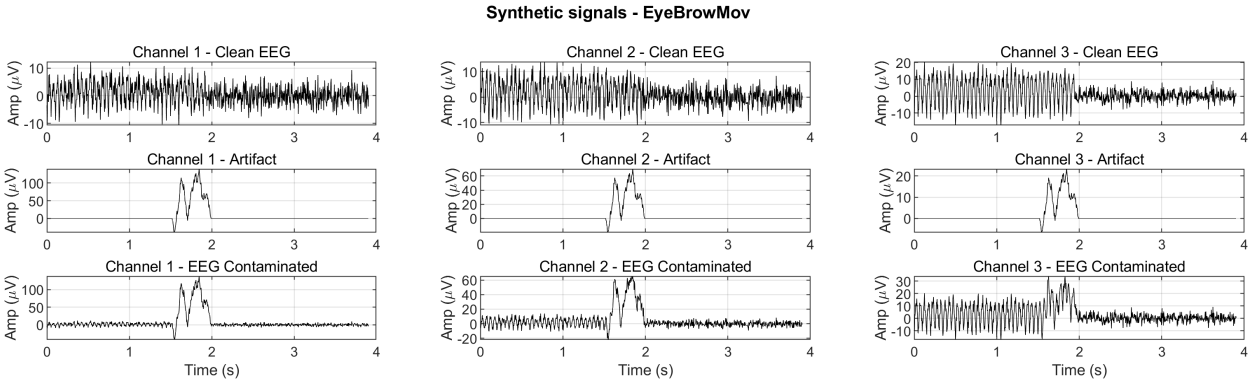


Figura 4.5: Señal sintética Eyerow Movement.

El artefacto por masticación o en ingles *Jaw Clench* será la ultima señal sintética para el análisis y es uno de los artefactos mas sencillos de identificar en una EEG. Se trata de un artefacto muscular que proviene de los músculos maseteros y temporales al apretar o rechinar los dientes. Se caracteriza por un inicio súbito y ráfagas intermitentes de actividad muy rápida y generalizada, el cual no comparte una morfología a ninguna otra actividad cerebral importante. En la Fig. 4.6 se puede ver la señal sintética generada para los test.

Este artefacto no posee ningún patrón rítmico o sostenido, por lo que si el sujeto aprieta de forma prolongada la mandíbula, el artefacto aparecerá como una actividad continua de alta frecuencia, mientras que si solo se trata de movimientos puntuales, se verán picos agudos repetitivos.

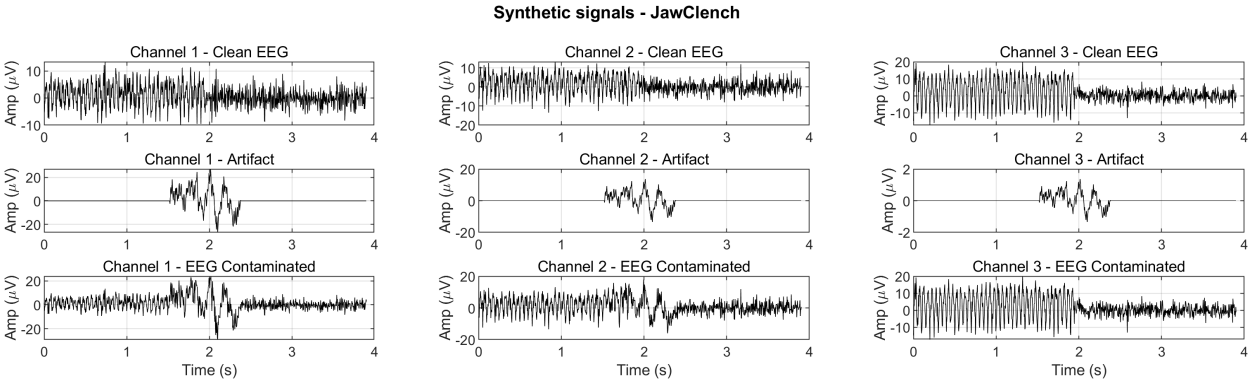


Figura 4.6: Señal sintética Jaw Clench.

Estas tres señales serán las que compongan el catálogo de señales sintéticas para el test de algoritmos basados en EMD. Con ellas se abarca una amplia variedad de señales con características y formas diferentes que son esenciales en el estudio de artefactos en EEG.

4.2.2. Eliminación artefacto mediante EMD

Como se ha descrito en el capítulo anterior, la Descomposición Empírica de Modos (EMD) es un método de descomposición de señales no lineales y no estacionarias. Su objetivo es descomponer una señal en modos intrínsecos de oscilación denominados IMFs. En este apartado se van a tratar tres señales sintéticas generadas deliberadamente para ver el rendimiento del algoritmo.

En el caso del artefacto *Eye Blink*, la señal sintética con la que se trabajará será la de la Fig.4.7,también definida en la sección anterior. Esta señal estará ya prepocesada mediante un filtro *Notch* que permitirá eliminar las componentes de 60Hz que pueden aparecer derivadas de la red eléctrica. También se ha procedido a extraer la media de la señal para centrar los datos alrededor del cero y a eliminar la tendencia de la señal, permitiendo así eliminar componentes de muy baja frecuencia.

Tras la etapa de *Pre-Procesado* de la señal, se ha realizado la segmentación por ventanas, seleccionando únicamente los segmentos de señal donde se presenta el artefacto, en este caso, se ha convenido aplicar al artefacto una ventana temporal $t \in [1{,}7,\ 3{,}8]$, con una duración total de $\Delta t = 2{,}1\,\mathrm{s}$, duración que recoge los tres impulsos que podemos ver en el artefacto. El tamaño de la ventana con esta duración daba un mejor rendimiento que si se realizaba una segmentación individual por cada uno de los impulsos.

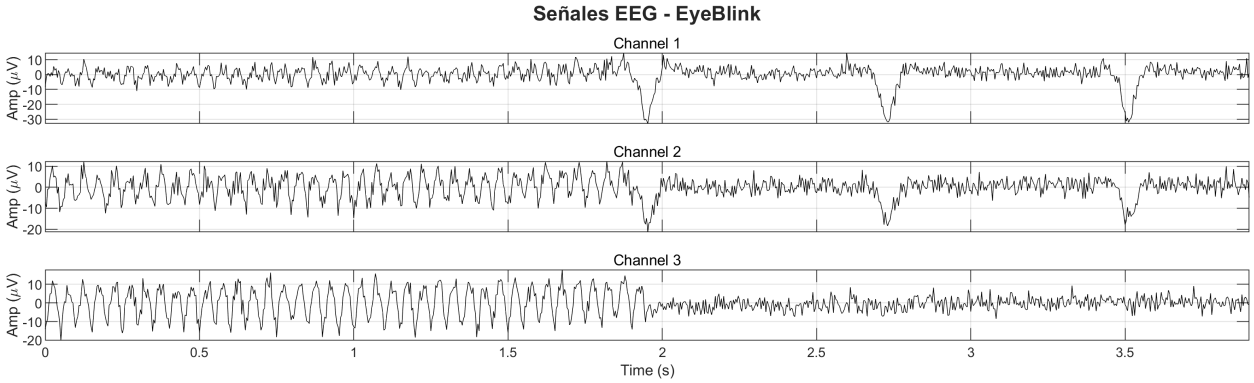


Figura 4.7: Señal sintética EEG simulando un Eye Blink.

Tras la segmentación para la selección de una parte de la señal se procederá a aplicar el algoritmo **EMD**. Al tratarse de una señal multicanal, se aplicará el algoritmo de forma independiente a cada uno de los canales, cuya descomposición esta ilustrada en la Fig. 4.8. Se puede apreciar que el número de IMFs de la descomposición de cada una de las señales es diferente, esto es debido a que el número de IMFs está determinado según las características de cada señal.

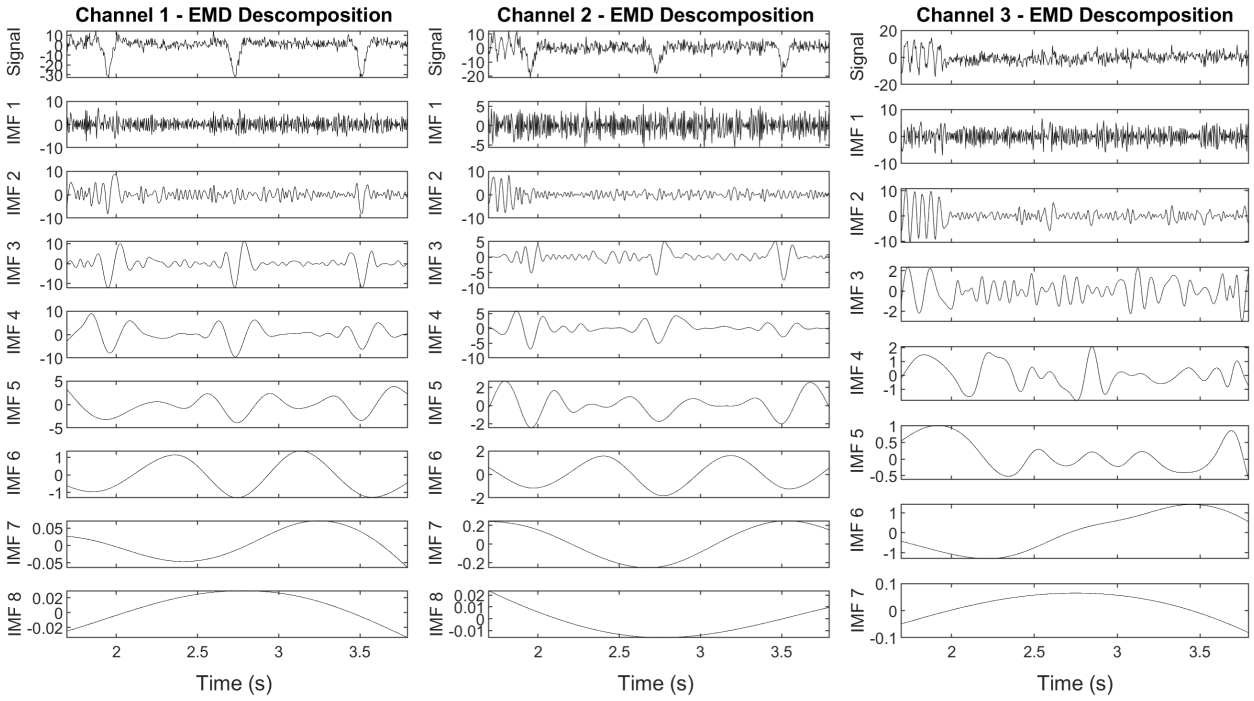


Figura 4.8: Descomposición EMD para señales de Eye Blink.

Una vez realiza la descomposición empírica en modos, cada canal quedará descompuesto en una serie de subseñales denominados IMFs. El objetivo es identificar los IMFs que contienen características del artefacto para poder tratarlas y así reducir su influencia en la señal original. Para ello se ha realizado un estudio en profundidad sobre diferentes características e índices estadísticos de cada IMF, con el fin de encontrar información contrastada que

respalde la selección.

Dado que cada una de estas características están en diferentes escalas, se ha realizado una normalización de datos, buscando que todos los canales EEG tengan la misma amplitud relativa.

Los resultados obtenidos de las normalizaciones para la señal sintética Eye Blink están agrupados en la Fig.4.9.

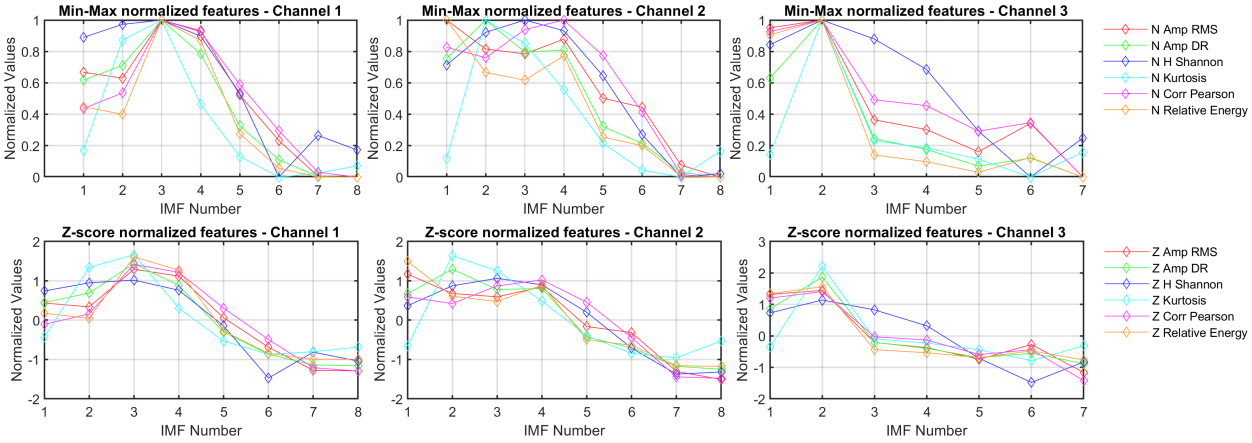


Figura 4.9: Características normalizadas para EyeBlink sintético

En este figura se puede apreciar como hay algunos IMFs que presentan un mayor valor para estas características, lo que permite identificarlos como los IMFs candidatos. En los casos probados que se van a describir, se ha tomado la Energía Relativa como marcador más fiable y el que se tomará como referencia.

El valor de energía relativa que se empleará será una medida no normalizada, pues será un porcentaje respecto a la energía completa de la señal del canal. La selección de IMFs mediante el marcador de Energía relativa se realizará a través de un umbral (Threshold), el cual se ha definido en un valor de 20 %. Si la energía relativa de una IMF supera este umbral, será seleccionada para su posterior procesamiento.

En la Fig.4.10 se muestran dos diagramas. El primero es un mapa de calor que representa la energía relativa de cada IMF y de cada uno de los canales de la señal, permitiendo visualizar su contribución a la energía total de cada canal. El segundo diagrama ubicado en la parte derecha, presenta el mismo mapa, resaltando únicamente las IMFs seleccionadas, es decir, aquellas que superan el umbral previamente establecido.

El procesamiento de estas IMFs puede abordarse mediante diferentes estrategias de filtrado. En el caso de estudio, se ha optado por la eliminación total de los IMFs seleccionados, garantizando así una supresión definitiva de los componentes indeseados.

El diagrama con las IMFs que permanecen y con las que han sido eliminadas se puede ver en la Fig.4.11.

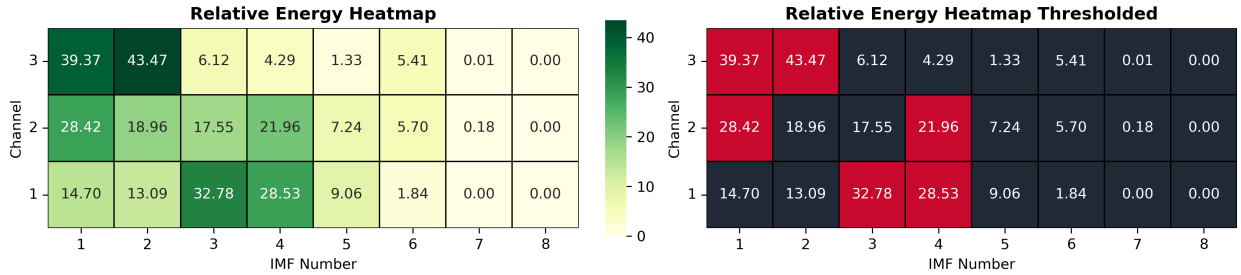


Figura 4.10: HeatMap de Energia Relativa para señal sintética Eye Blink mediante EMD.

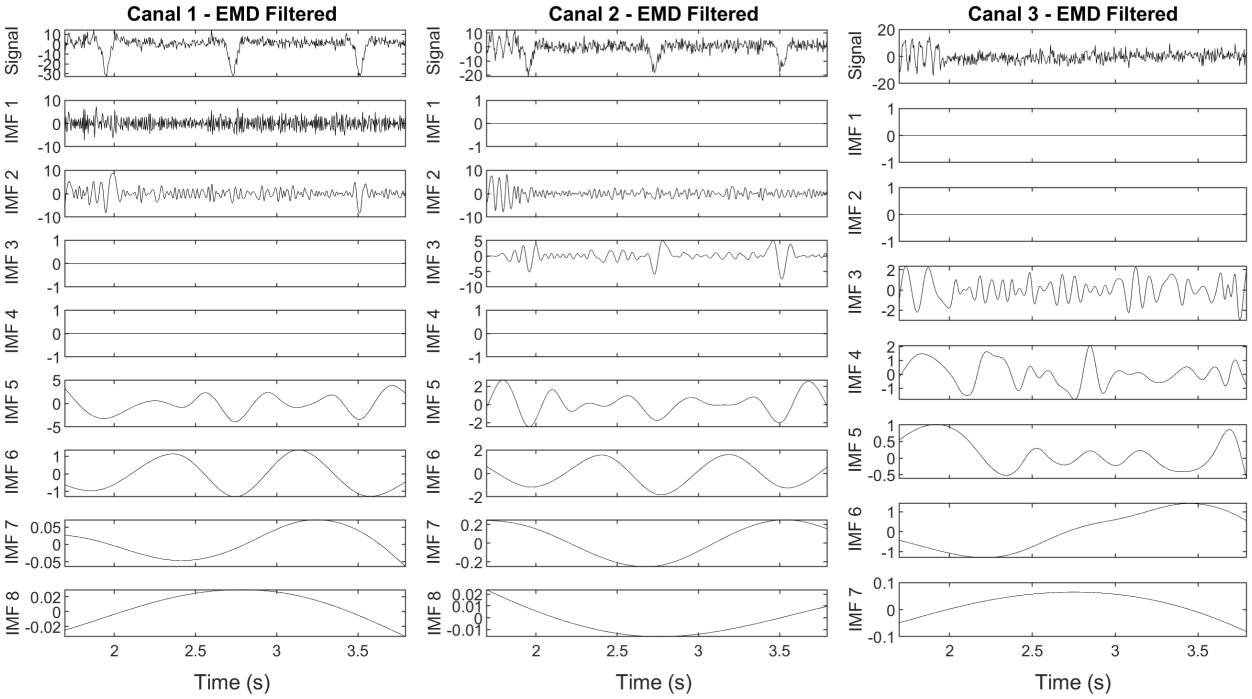


Figura 4.11: Descomposición EMD para señal sintética Eye Blink con IMFs eliminadas.

Con todas las IMFs resultantes del filtrado selectivo realizado, se lleva a cabo la reconstrucción de la señal original. Este proceso consiste en sumar todas las IMF de un canal, incluyendo el residuo final obtenido del proceso de descomposición. Con este proceso obtendremos una primera versión de la señal reconstruida, la cual conservará toda la información relevante de la señal de origen.

Esta primera versión necesita de una fase de postprocesado para restaurar completamente las características de la señal original. En esta fase se añade la tendencia y la media que previamente se había eliminado en la etapa de preproceado, obteniendo así la señal final reconstruida.

En la Fig.4.12 se puede observar dos gráficas comparativas donde se pueden ver tanto la señal original artefactuada de la que partíamos y la señal reconstruida final que se ha obtenido a través del proceso.

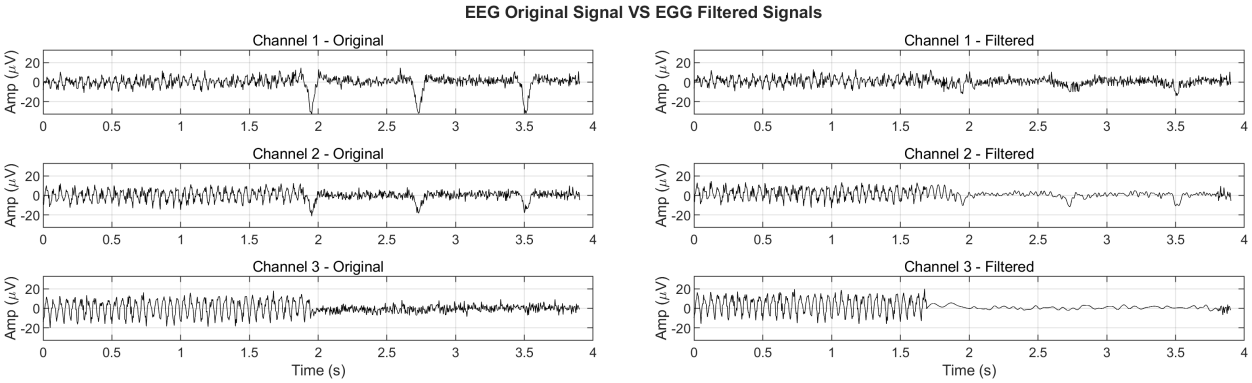


Figura 4.12: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto EyeBlink mediante el método EMD.

Como se puede apreciar visualmente, hay una parte importante de componente artefactuada que ha sido eliminada, especialmente en el Canal 1. Este primer canal tiene la característica que su relación Señal-Artefacto es mas acentuada, dado que su señal base tiene una potencia menor y la componente artefactual presenta una potencia mayor.

En la comparativa de los Canales 2 y 3, se puede observar que la componente artefactual sí que ha sido parcialmente eliminada, pero parte de la información de la señal también ha sido eliminada de la señal base. Esto puede deberse a que la relación Señal-Artefacto de estos dos canales es mucho menor y las componentes pueden mezclarse en la descomposición empírica de modos.

Los resultados obtenidos para las métricas anteriormente definidas con EMD se pueden ver en Fig.4.13

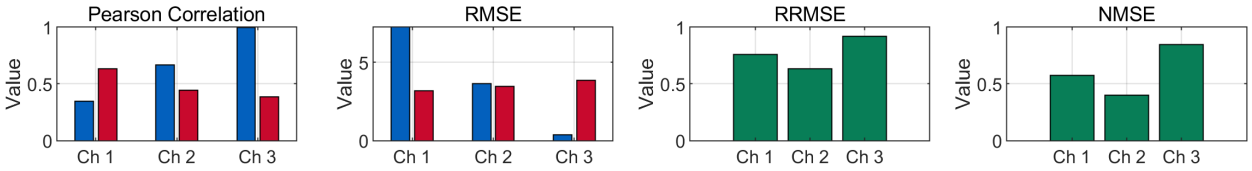


Figura 4.13: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método EMD sobre artefacto EyeBlink.

Análogamente, como método comparativo para evaluar el rendimiento del proceso, se ha realizado una comparativa de la densidad del espectro de potencia según las bandas utilizadas en el estudio de señales EEG.

Los resultados obtenidos para EMD están en la Fig.4.14 donde en color negro será la señal original y en color rojo la señal reconstruida según el modulo aplicado.

Para el caso del artefacto producido por un movimiento de ceja, denominado en inglés *EyeBrow*, se ha realizado el mismo estudio realizado anteiormente. En Fig4.15 se muestra la comparación de la señal original y la señal final reconstruida, obtenida tras aplicar el proceso

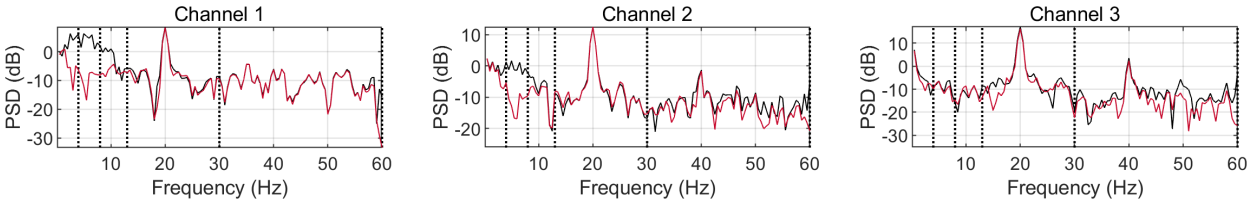


Figura 4.14: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método EMD aplicado al artefacto EyeBlink.

de reducción de artefactos mediante el método *EMD*.

De forma visual, se puede apreciar que se ha retirado gran parte de componente artefactual, al igual que se ha eliminado una parte de componente fundamental de la señal original.

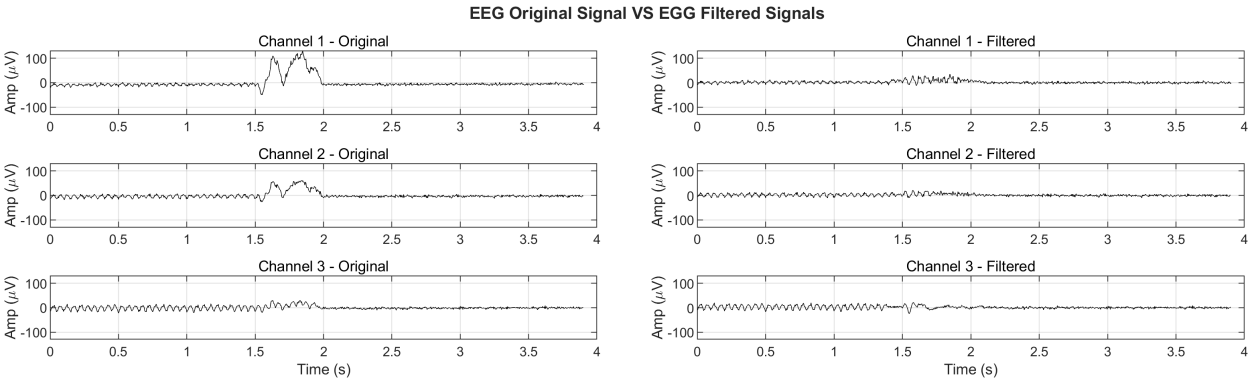


Figura 4.15: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto EyeBrow Movement mediante el método EMD.

En la Fig.4.16 se presentan las métricas comparativas de la reconstrucción, donde se puede apreciar que la reconstrucción frente a este tipo de artefacto es un poco mejor en todos los canales.

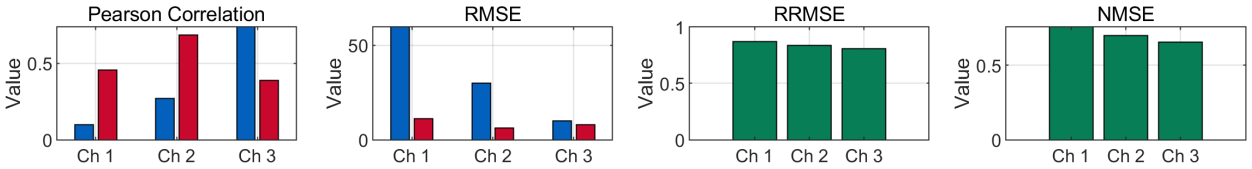


Figura 4.16: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método EMD sobre artefacto EyeBrow Movement.

En la Fig.4.17 se muestra el análisis por bandas de frecuencia de las dos señales, la señal original y la señal reconstruida, donde se observa la disminución de las frecuencias bajas pertenecientes a las bandas *Delta, Theta y Alpha.*

Análogamente, para el artefacto generado por contracción de los músculos mandibulares, denominado Jaw Clench Movement se presenta la Fig.4.18 con la comparativa de las señales, antes y después de la reducción utilizando EMD.

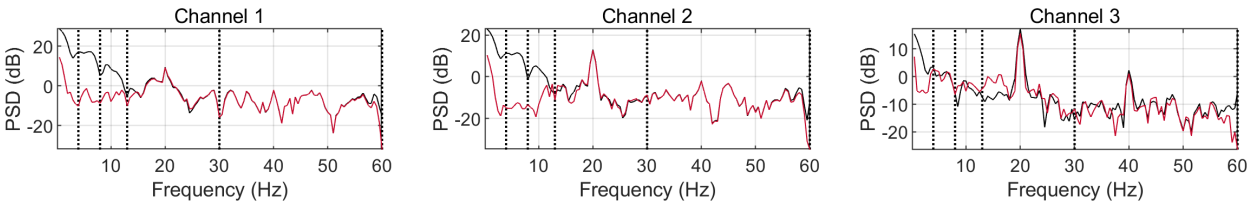


Figura 4.17: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método EMD aplicado al artefacto EyeBrow Movement.

Se puede observar que el método es capaz de reducir el artefacto en algunos canales, aunque a costa de eliminar parte de la señal que no se considera artefactual. Esto sucede en el tramo temporal seleccionado para realizar el proceso de reducción de artefacto, donde se hace evidente la transición de la zona segmentada.

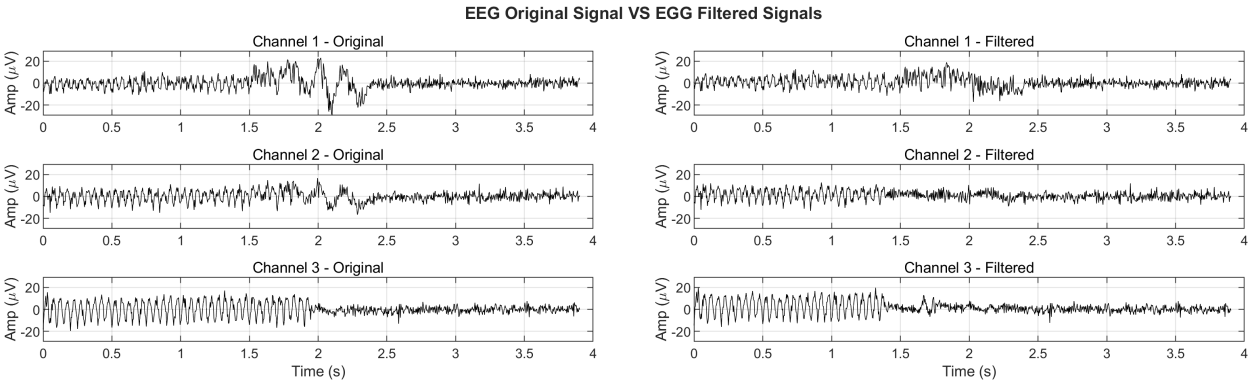


Figura 4.18: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto JawClench mediante el método EMD.

En la Fig.4.19 se aprecian las métricas de los resultados de la descontaminación, donde se puede ver que el canal tres, por sus características de intensidad de artefacto y frecuencias, ha sido empeorado considerablemente, mientras que los canales uno y dos han sido mejorados levemente.

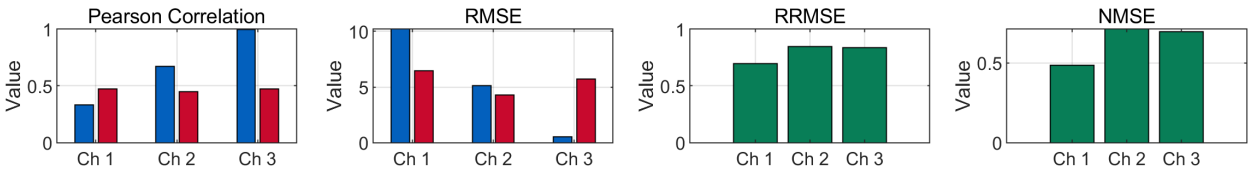


Figura 4.19: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método EMD sobre artefacto JawClench.

En la Fig.4.20 se muestran las densidades del espectro de potencia, donde se puede observar que los canales 1 y 2, son mejorados levemente en la banda *Theta*.

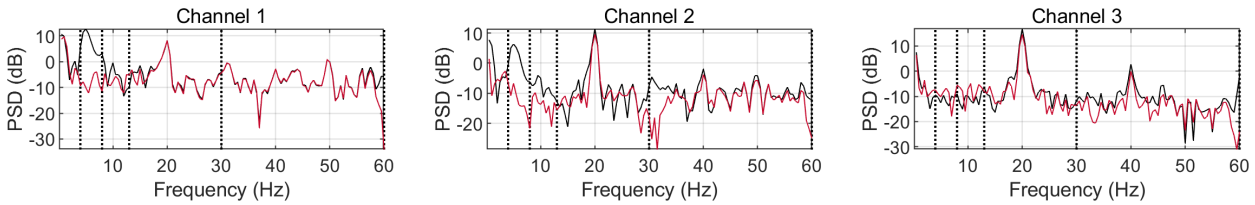


Figura 4.20: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método EMD aplicado al artefacto JawClench.

4.2.3. Eliminación artefacto mediante MEMD

En este apartado se realizarán los tres test con señales sintéticas, procesándolos de forma equivalente pero aplicando **MEMD**, una extensión de EMD, diseñada específicamente para el tratamiento de señales multicanal o multivariadas como son las señales EEG. Esta técnica permite la descomposición simultánea de todos los canales, preservando la coherencia temporal y espacial entre ellos.

Tras realizar el paso de *preprocesado* y de *enventanado* como se ha realizado anteriormente, se procede a aplicar el algoritmo MEMD para los tres canales de forma simultánea. Esto nos dará una descomposición conjunta, donde en todos los canales se obtendra el mismo número de IMFs. En la Fig.4.21 se muestra la señal sintética original y sus respectivas funciones de modo intrínseco extraídas de la descomposición.

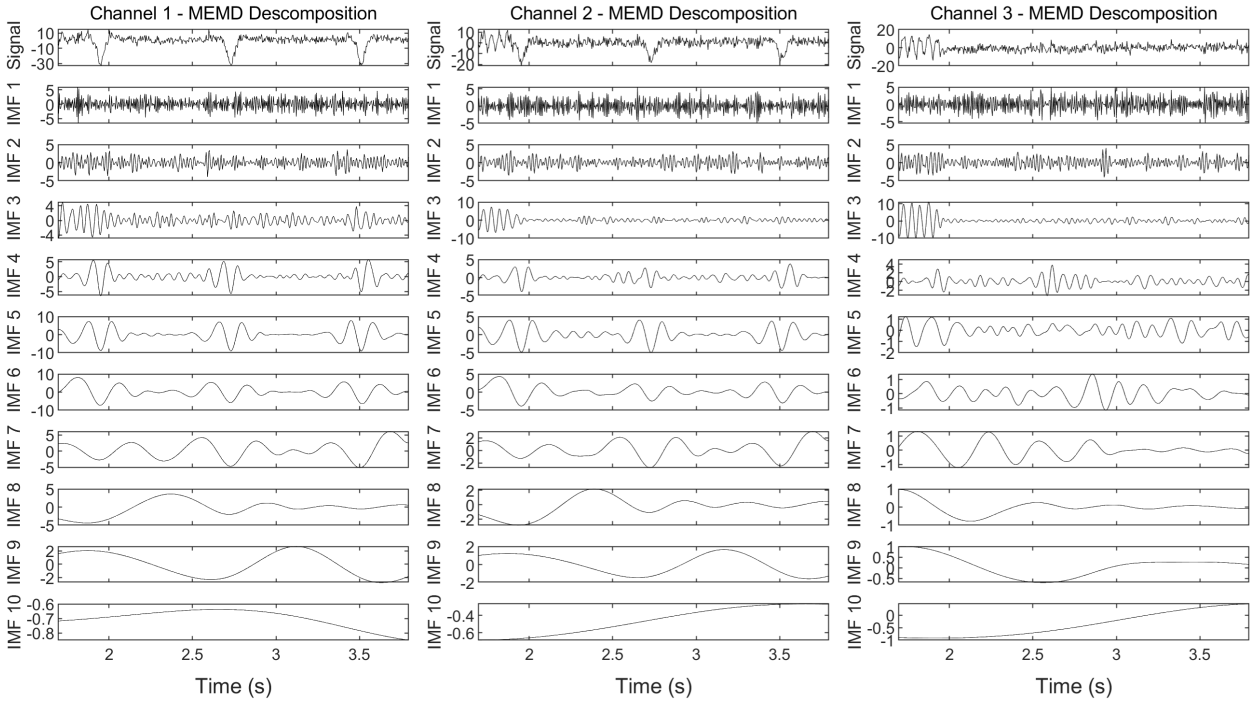


Figura 4.21: Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink)

Una vez realizada la descomposición MEMD, se procede a realizar un análisis de las métricas características normalizadas para cada canal, ilustrándose en la Fig.4.22, buscando

elementos de las diferentes IMF que nos indiquen un contenido alto de componente artefactual.

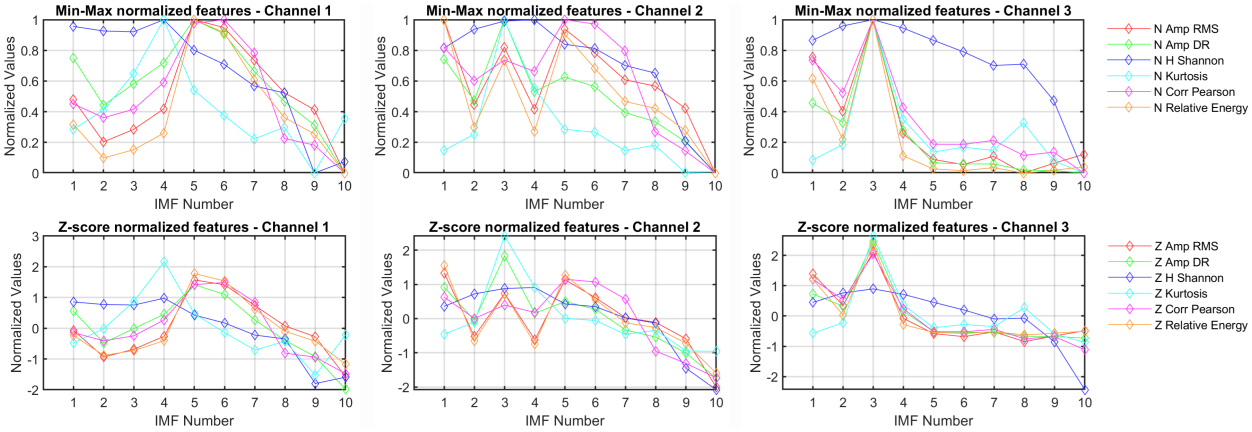


Figura 4.22: Análisis de métricas normalizadas por canal tras descomposición MEMD asociado al artefacto de parpadeo ocular (Eye Blink)

En dicho análisis, se observan ciertas particularidades en algunas IMF. En el canal 1, las IMF 5, 6 y 7 presentan valores de métricas notablemente más elevados quedando así marcados. De manera similar, en el canal 3, la IMF 3 destaca significativamente sobre las demás.

Tras la revisión de las métricas características y la realización de diversas pruebas empíricas, se vuelve a considerar la energía relativa como la métrica principal para la selección de los modos candidatos a ser eliminados.

Para este proceso de selección, se ha establecido un umbral del 10 % de energía relativa, dado que valor ha proporcionado los mejores resultados en términos de eliminación efectiva del artefacto. En la Fig.4.23 se presentan los mapas de calor de la Energía Relativa y los Modos seleccionados para su eliminación.

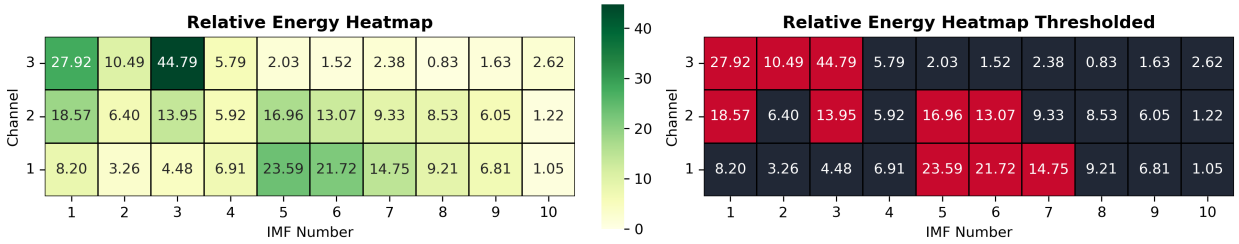


Figura 4.23: Mapa de calor de la energía relativa por canal EEG para la detección del artefacto de Eye Blink y Mapa de calor de los modos positivos seleccionados por canal para el filtrado del artefacto.

Los modos seleccionados tras el análisis han sido eliminados, para reducir al máximo su aportación artefactual en la reconstrucción. Este proceso se recoge en la Fig.4.24.

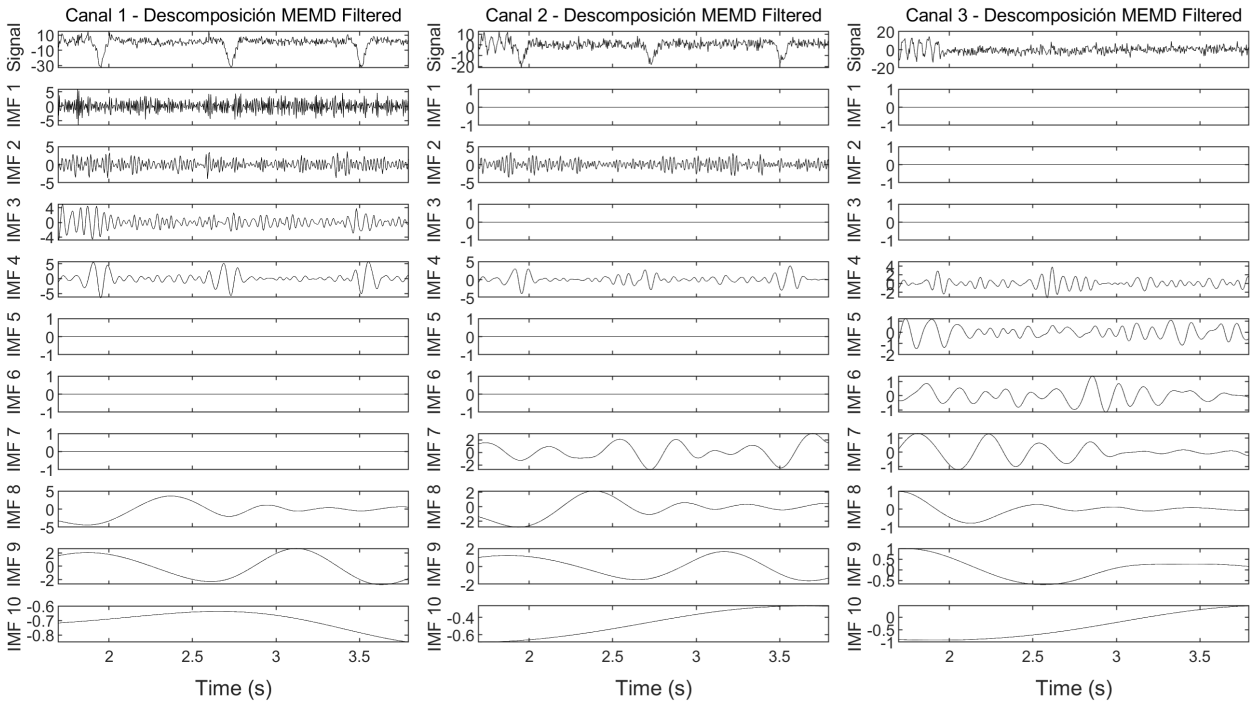


Figura 4.24: Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink) tras etapa de filtrado.

En la Fig.4.25, se presenta, tanto la señal original de cada canal, como una representación de la señal reconstruida tras la aplicación del proceso con el algoritmo MEMD. Se puede apreciar de forma visual, como en el canal 1, se ha disminuido considerablemente el artefacto, ademas de realizar una mejor integración de la zona segmentada en la señal completa.

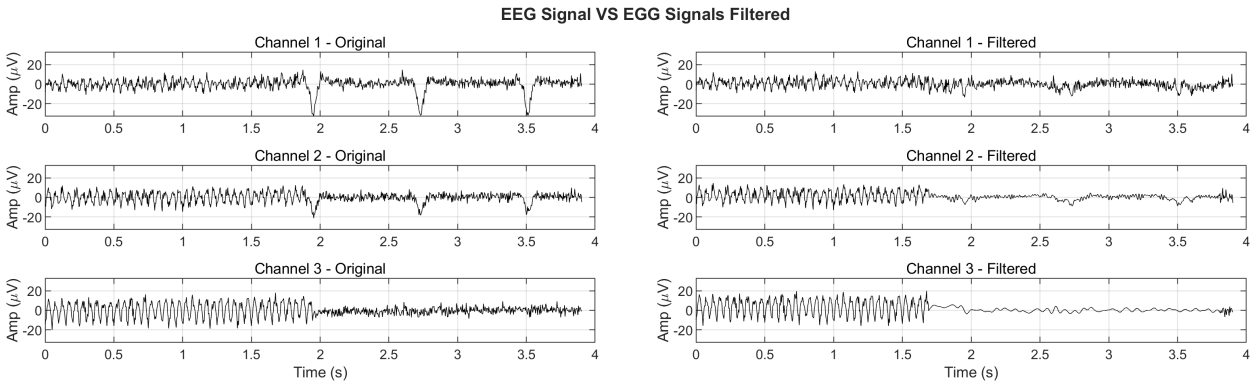


Figura 4.25: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de parpadeo ocular (Eye Blink) mediante el método MEMD.

Esto se puede constatar mediante el análisis cuantitativo que se muestra en la Fig.4.26, donde comprobamos como la correlación del Canal 1 ha aumentado considerablemente.

En la Fig.4.27 se presentan las gráficas comparativas del espectro de potencia de la señal original y la señal reconstruida, donde vemos como para los canales 1 y 2, se ha visto reducido las bandas *Delta* y *Theta*. En el Canal 3, ha habido una pequeña reducción en la potencia

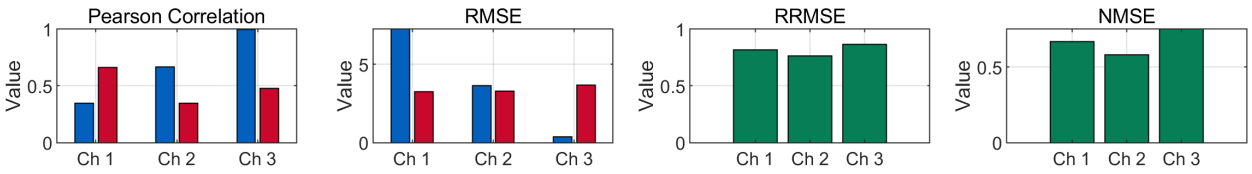


Figura 4.26: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD sobre artefacto de parpadeo ocular (Eye Blink).

de la banda Gamma, la cual no era parte de señal artefactuada, lo que implica un deterioro de la señal.

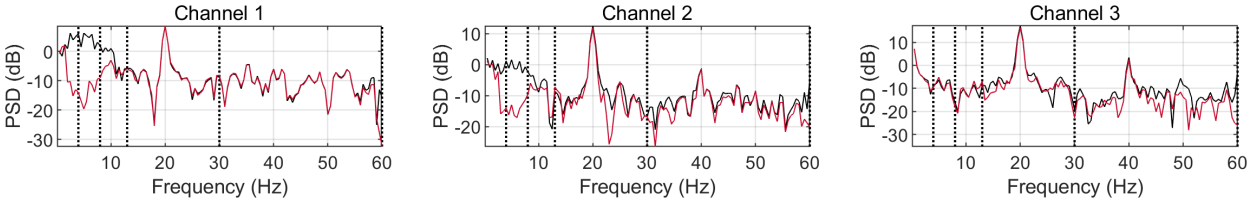


Figura 4.27: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD aplicado al artefacto de parpadeo ocular (Eye Blink).

Como se ha realizado anteriormente, vamos a analizar de forma simplificada los resultados obtenidos para las otras dos señales sintéticas generadas.

En el caso del artefacto producido por un movimiento de ceja, *Eye Brow Movement*, en la Fig.4.28 se observa como ha trabajado el algoritmo con MEMD ante esta señal, pues tenemos la señal original contaminada y la señal con al reducción del artefacto.

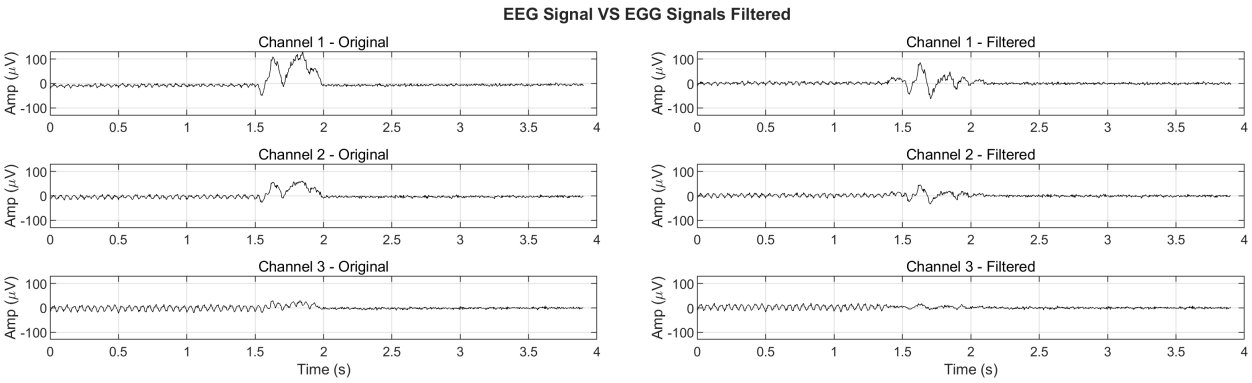


Figura 4.28: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de movimiento de ceja (Eye Brow Movement) mediante el método MEMD.

En la Fig.4.29 se ilustra un análisis de las características usadas para valorar el desempeño del algoritmo y en la Fig.4.30 una comparativa de la densidad espectral de potencia por bandas.

Tanto en la Fig.4.29 como en Fig.4.30 se puede observar, como los canales 1 y 2 han reducido la potencia del artefacto, aumentado así su correlación con la señal original. El canal

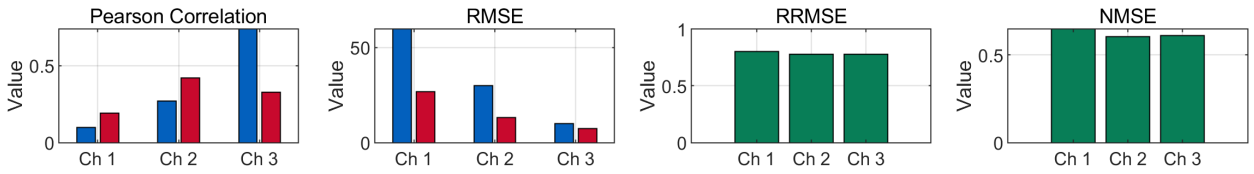


Figura 4.29: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD sobre artefacto de movimiento de ceja (Eye Brow).

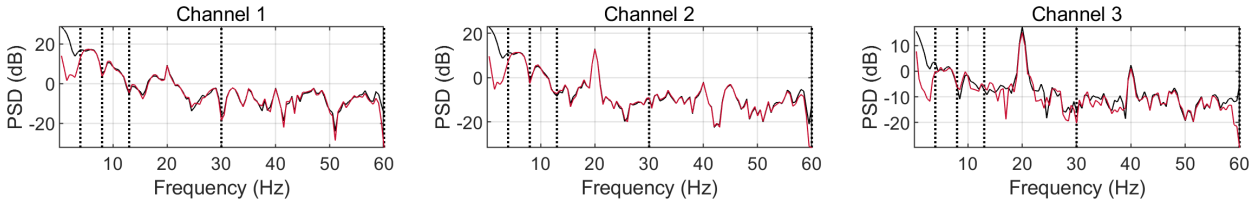


Figura 4.30: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD aplicado al artefacto de movimiento de ceja (Eye Brow).

3 se ha visto afectado tras el procedimiento, dando que su potencia relativa de artefacto y señal portadora eran muy próximas, haciendo que tras el proceso, la señal reconstruida se vea afectada.

Para el caso de las señales sintéticas que simulan un artefacto producido por un apretamiento mandibular, la Fig.Fig.4.31 muestra la gráfica de comparación entre la señal original y la señal reconstruida tras el algoritmo MEMD.

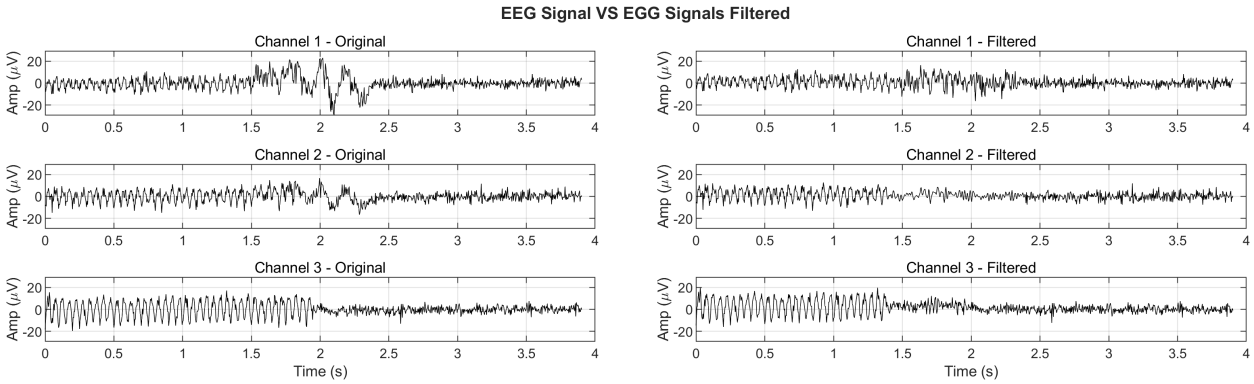


Figura 4.31: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de apretamiento mandibular (Jaw Clench) mediante el método MEMD.

El análisis de las métricas para estudiar el desempeño del algoritmo se muestra en la Fig.4.32, mientras que en la Fig.4.33 se muestra la respuesta del espectro de potencia para todos los canales.

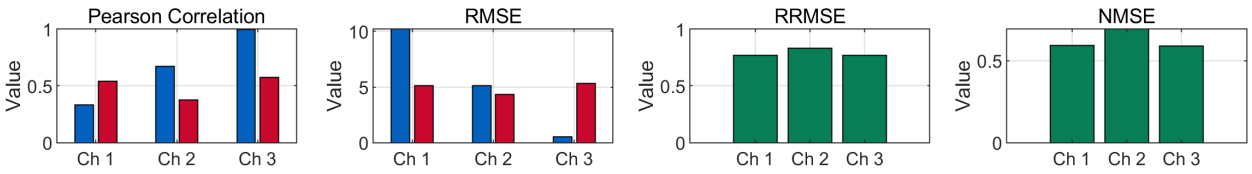


Figura 4.32: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD sobre artefacto de apretamiento mandibular (Jaw Clench).

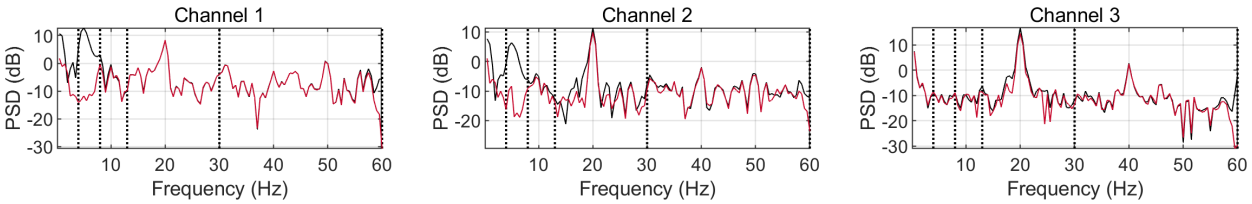


Figura 4.33: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD aplicado al artefacto de apretamiento mandibular (Jaw Clench).

4.2.4. Eliminación artefacto mediante MEMD-FastICA

La hibridación del algoritmo MEMD, que es la combinación de MEMD con otras técnicas para mejorar su rendimiento, es ampliamente diversa y cuenta con numerosas referencias en la literatura [38], [39], [40] y [7]. En este apartado, se presenta una hibridación con el algoritmo FastICA, a la que denotaremos como **MEMD-FICA**. Tal como se explicó en (refCapitulo), el procesamiento mediante FastICA se aplica a los IMFs seleccionados tras la descomposición MEMD, para posteriormente proceder a la completa reconstrucción de la señal.

En el caso de la primera prueba para un artefacto de pestañeo ocular (Eye blink), el inicio del proceso será exactamente el mismo que en el método MEMD, obteniéndose la descomposición como se muestra en la Fig.4.34.

Tras la descomposición analizaremos las métricas, estas están expuestas en Fig.4.22 y en Fig.4.23. Este análisis permitirá determinar que IMFs son candidatas para ser procesadas mediante el algoritmo de análisis de componentes independientes FastICA. Dado que la selección se aplicará al mismo IMF de todos los canales, se evaluará la suma de la energía relativa por canal, seleccionando aquellos IMF con mayor peso. La IMF 1 será descarta por contener componentes de alta frecuencia que podrían alterar en exceso la señal original. En la Fig.4.35 disponemos de los IMFs seleccionados marcados en verde.

Para poder realizar el análisis de componentes independientes mediante el algoritmo de FastICA, es necesario el normalizado de los datos, eliminando la media y la desviación. También es de suma importancia reorganizar los datos de manera que el algoritmo FastICA se aplique a un IMF específico en todos los canales.

Es decir, si se han seleccionado varios IMFs, por ejemplo, el IMF3, IMF5, MF6, IMF7, se debe extraer cada uno de estos modos de todos los canales, agrupándolos según su número

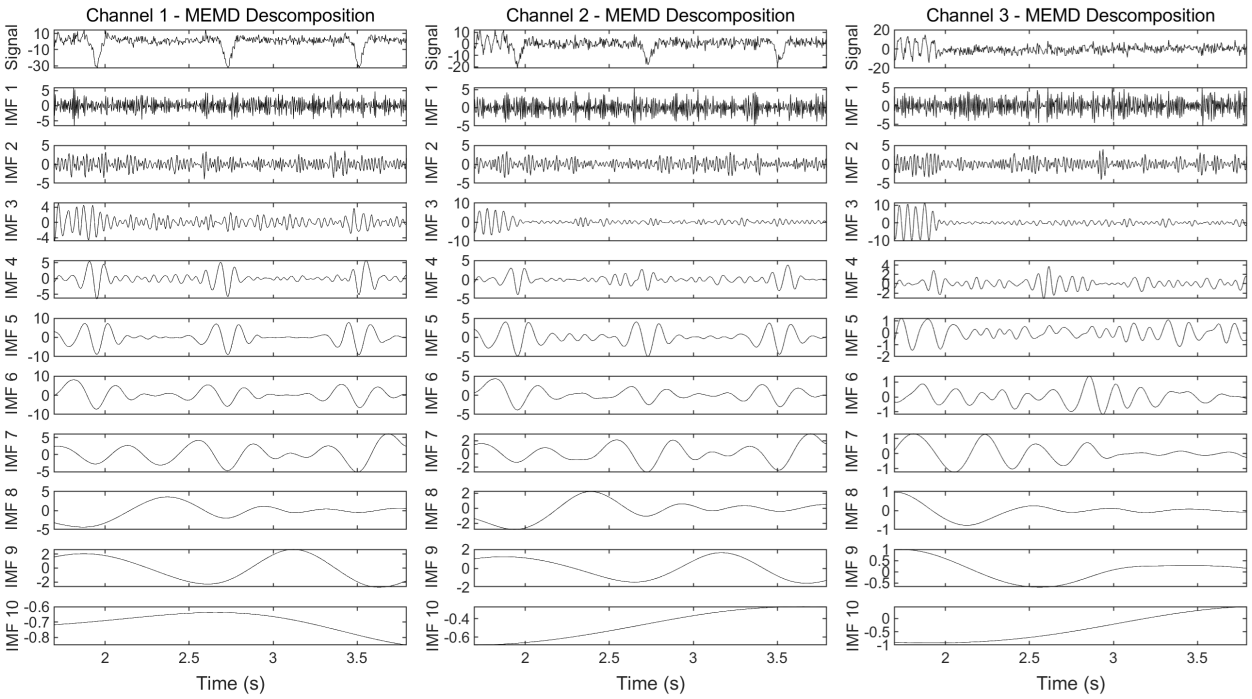


Figura 4.34: Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink)

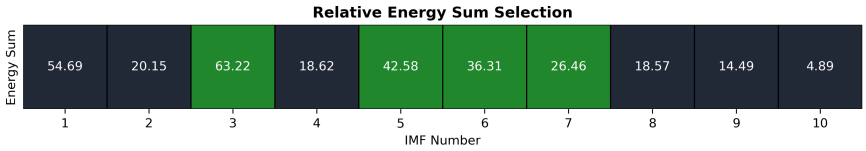


Figura 4.35: Suma de la energía relativa de cada modo, con selección de las IMFs elegidas para ser procesadas mediante el algoritmo FastICA en el contexto del artefacto producido por el parpadeo ocular (Eye Blink)

de orden. En la Fig.4.36 hay una representación de esta estructura.

Una vez realizado el proceso de re-estructuración de los datos se procede a realizar la descomposición de todas las señales con el mismo número de IMF de todos los canales, obteniendo así las señales denominadas Componentes Independientes (CI) como se puede ver en Fig.4.37.

A partir de las CI obtenidas mediante FastICA, se realiza un proceso de reconstrucción de la señal original excluyendo, en cada caso, una de las CI. Para ello, se calcula la proyección individual de cada componente sobre el espacio original y se resta de la señal observada (SO). De esta manera, se obtienen múltiples señales filtradas (SF), cada una correspondiente a la eliminación de una componente distinta, lo que permite evaluar el efecto de cada CI en la señal original.

Con las señales filtradas (SF), se realiza un análisis cuantitativo que incluye el cálculo de la energía, la diferencia de energía respecto a la señal observada original (SO) y la distancia euclidiana entre ambas. Tras una batería de pruebas, se concluye que la diferencia energética

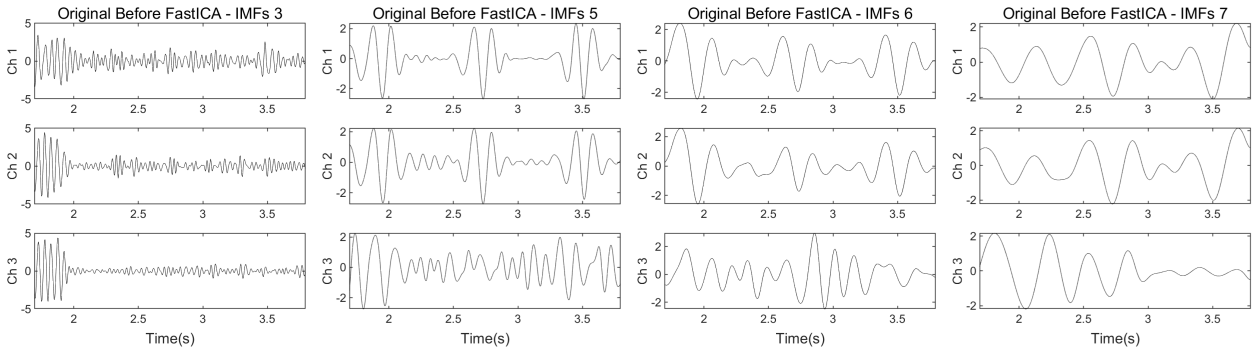


Figura 4.36: Reordenamiento de IMFs para FMEMD parpadeo ocular (Eye Blink)

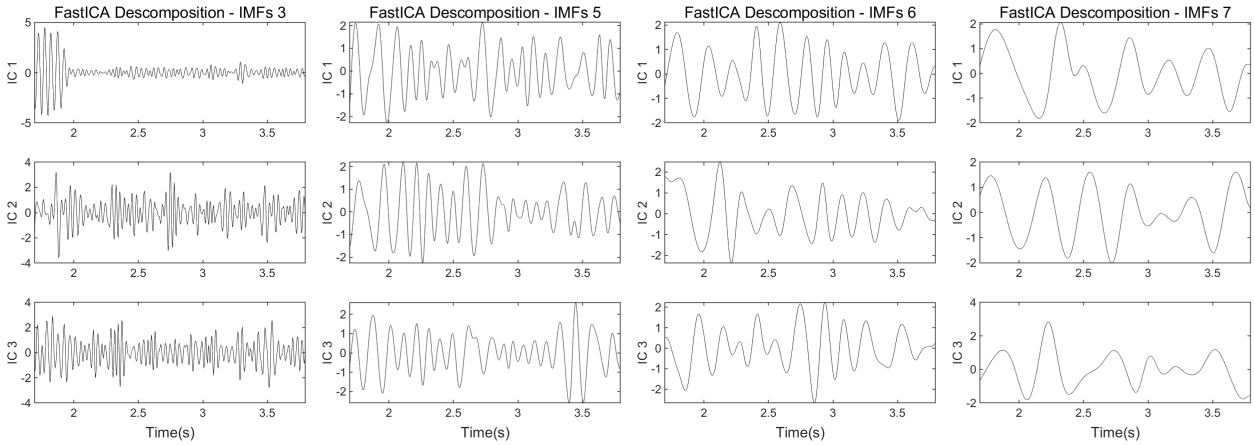


Figura 4.37: Componentes Independientes extraídas por IMF seleccionada mediante FastICA

es el parámetro más eficaz para identificar qué componente independiente (CI) contenía una mayor proporción de contenido artefactual.

En la Fig.4.38 se presentan las gráficas del incremento de energía, definido como la diferencia entre la energía original y la energía calculada tras eliminar la componente independiente (CI) indicada. Como puede observarse, la mayor reducción de energía ocurre en el IMF3 al eliminar la CI1, en los IMF5 e IMF6 al eliminar la CI3, y en el IMF7 al eliminar la CI2.

La representación de las IMF tras el filtrado de las componentes independientes seleccionadas se puede ver en la Fig.4.39.

Finalizado el proceso, será necesario aplicar el proceso inverso, añadir la media y la desviación estándar que fueron eliminadas previamente. A continuación, se deben reorganizar adecuadamente las IMFs para proceder con la reconstrucción del MEMD. La estructura de salida resultante se muestra en la Fig.4.40.

Tras obtener los IMF filtrados, se procederá a la reconstrucción completa de la señal. En la Fig.4.41 se puede observar dos gráficas comparativas donde se pueden ver tanto la señal original artefactuada de la que partíamos y la señal reconstruida final que se ha obtenido a través del proceso. Se puede apreciar que se ha reducido considerablemente el artefacto

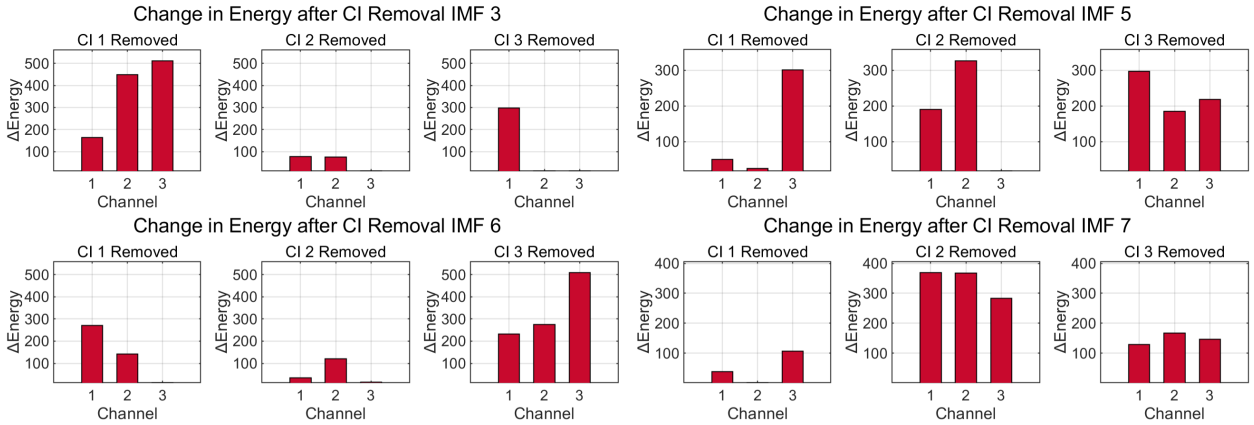


Figura 4.38: Reducción de energía en las reconstrucciones según la CI eliminada para cada colección de IMFs

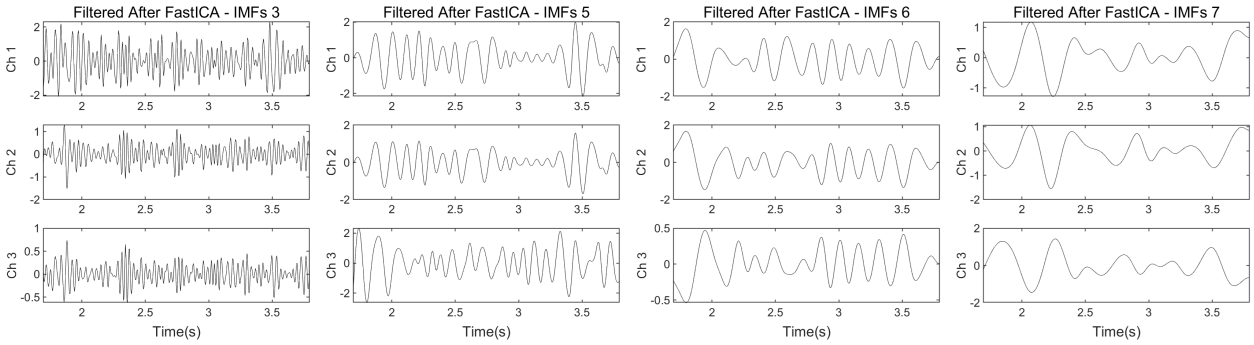


Figura 4.39: Reordenamiento de IMFs para FMEMD tras filtrado con FastICA en parpadeo ocular (Eye Blink)

en los tres canales estudiados, también se puede apreciar, que el proceso no a afectado tan negativamente al canal 3, por lo que podemos considerar un método estable en las tres potencias del artefacto.

En la Fig.4.42 se ilustra un análisis de las características usadas para valorar el desempeño del algoritmo, donde se puede ver un emparejamiento de rendimientos en los tres canales procesados.

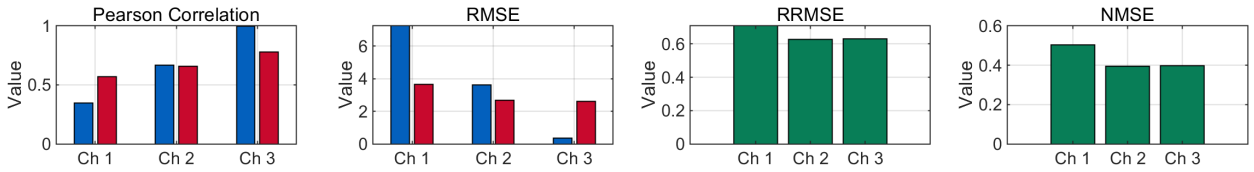


Figura 4.42: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método FICA MEMD sobre artefacto de movimiento de ceja (Eye Brow).

En la Fig.4.43 se puede ver una comparativa de la densidad espectral de potencia por bandas de cada canal, donde se aprecia en los dos primeros canales, una reducción importante de las tres primeras bandas, Delta, Theta y Alfa.

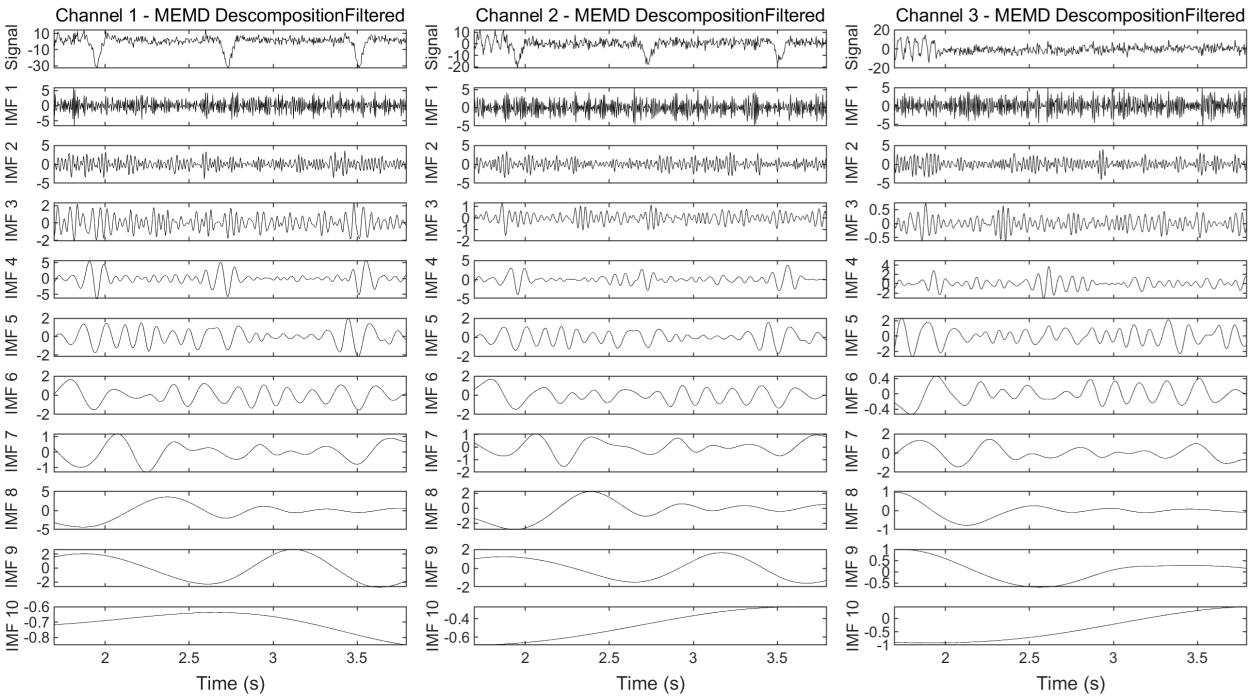


Figura 4.40: Descomposición MEMD por canal para artefacto de parpadeo ocular (Eye Blink) tras el filtrado con FastICA

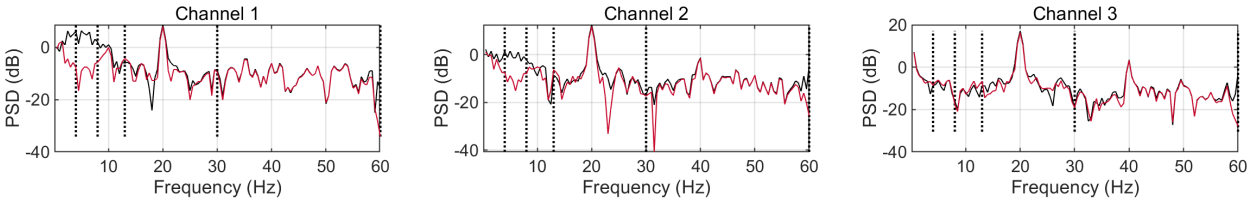


Figura 4.43: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método FICA MEMD aplicado al artefacto de movimiento de ceja (Eye Brow).

Análogamente a lo que se ha realizado para los otros algoritmos, se va a realizar el test con las dos señales restantes de forma simplificada.

En la Fig.4.44 se ilustra el caso de un artefacto producido por un movimiento de ceja, donde se pueden ver tanto las señales de los tres canales originales, como el resultado del proceso realizado mediante el algoritmo MEMD+FICA.

Se observa que, frente a este tipo de artefacto, el algoritmo no logra eliminar completamente el artefacto en los dos primeros canales, quedando un residuo considerable. En la Fig.4.45 se presentan los resultados de las métricas utilizadas para evaluar el rendimiento del algoritmo frente a dicho artefacto.

Asimismo, en la Fig.4.46 se muestran las gráficas de densidad espectral de potencia distribuidas por bandas de trabajo.

El último test consiste en la evaluación del algoritmo frente a una señal sintética generada

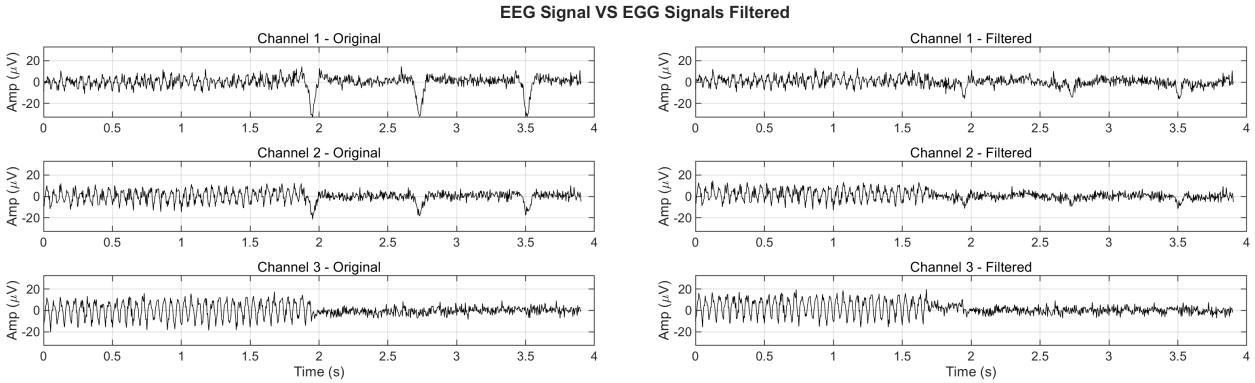


Figura 4.41: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto ocular mediante el método MEMD+FICA.

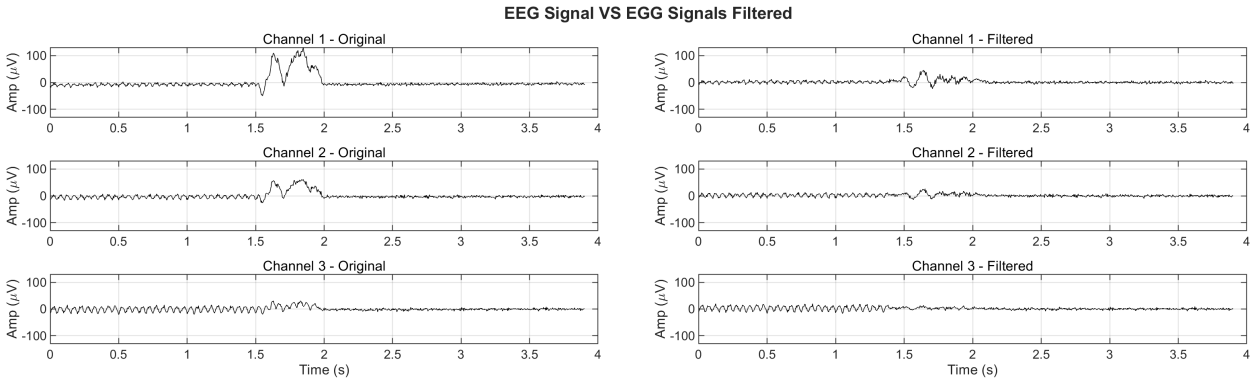


Figura 4.44: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de movimiento de ceja mediante el método MEMD+FICA.

para simular un apretamiento mandibular.

En la Fig.4.47 se muestran nuevamente los tres canales de la señal original correspondiente al test de apretamiento mandibular, en comparación con los tres canales reconstruidos tras ser procesados mediante el algoritmo propuesto.

Como puede observarse, se logra una reconstrucción más precisa en los tres canales. En términos generales, el comportamiento del enfoque MEMD+FICA resulta más satisfactorio que en pruebas anteriores, evidenciando una mayor eficacia.

Como en casos anteriores, en la Fig.4.48 podrá observase el desempeño del algoritmo con las métricas estudiadas en el marco teórico.

De la misma forma, en la Fig.4.49 se tiene el análisis de la densidad del espectro de potencia de los tres canales por bandas de estudio.

Por último, para concluir con el análisis de métodos con señales sintéticas, se presenta en la Fig. 4.50 un resumen gráfico de las métricas obtenidas para cada uno de los métodos.

Así pues, el azul está definido para las métricas obtenidas con EMD, el verde para las métricas de MEMD y en ultimo lugar, en rojo, las métricas obtenidas con el método MEMD

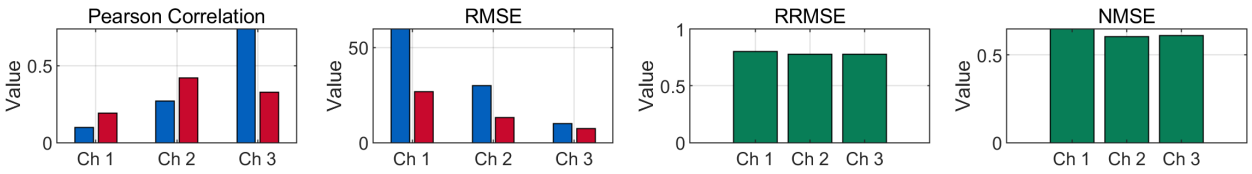


Figura 4.45: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD+FICA sobre artefacto de movimiento de ceja (Eye Brow).

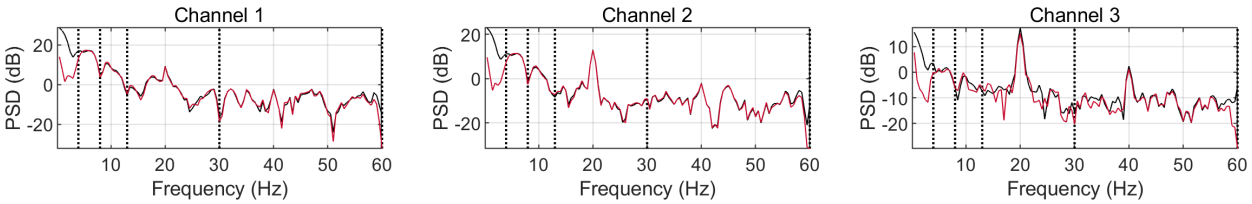


Figura 4.46: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD+FICA aplicado al artefacto de movimiento de ceja (Eye Brow).

+ FastICA.

Análogamente, en la Tab. A.1 del Anexo 1 se presentan los datos numéricos de los mismos indicadores.

4.3. Escenario con Señales reales

Tras realizar las pruebas con señales sintéticas en la Sección 4.2, se procede a aplicar los algoritmos evaluados sobre señales reales de EEG. Estas señales han sido tomadas de la plataforma de **PhysioNet** [41] , el sobrenombre del*Research Resource for Complex Physiologic Signals*, una iniciativa respaldada por el Instituto Nacional de salud de los Estados Unidos (*National Institutes of Health*, NIH).

El objetivo principal de PhysioNet es fomentar la investigación y la educación biomédica, proporcionando acceso gratuito a grandes colecciones de datos fisiológicos y clínicos, así como a software de código abierto relacionado. Esta plataforma es gestionada por el Laboratorio de Fisiología Computacional del MIT.

En la Fig. 4.51 se presenta un esquema completo del proceso que se va a emplear en el análisis de las señales reales. En este apartado veremos el algoritmo que mejor desempeño ha dado MEMD+FastICA aplicado a señales reales.

4.3.1. DETECT Toolbox

DETECT [42] es el acrónimo de *Detection of Events in Continuous Time* y es una herramienta toolbox de MATLAB diseñada para la detección e identificación de eventos en

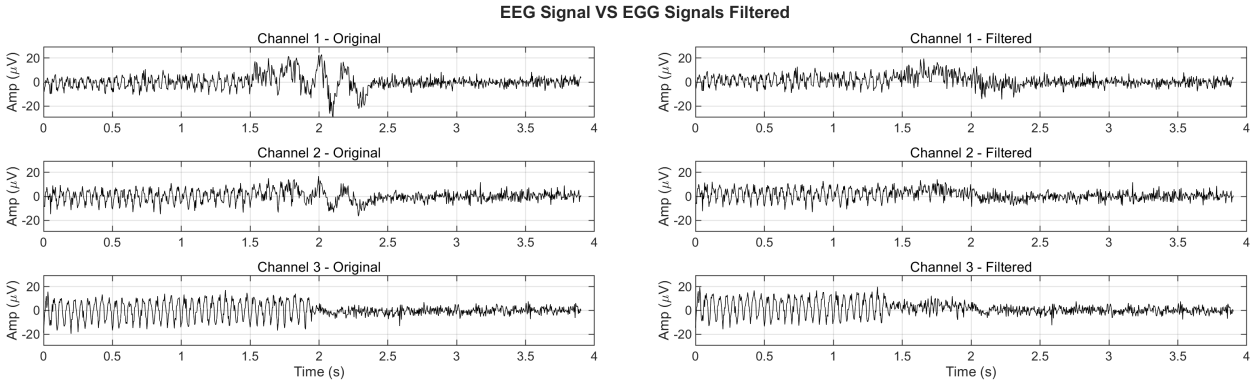


Figura 4.47: Comparación entre la señal sintética original y la señal reconstruida tras la eliminación del artefacto de apretamiento mandibular mediante el método MEMD+FICA.

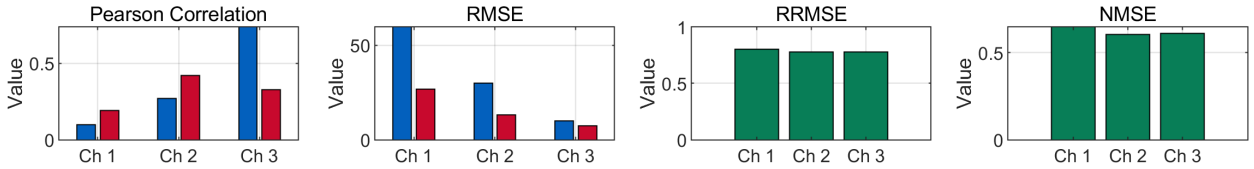


Figura 4.48: Métricas de evaluación cuantitativa para la señal reconstruida tras aplicar el método MEMD+FICA sobre artefacto de un apretamiento mandibular (Jaw Clench).

series temporales largas y multicanal.

Esta herramienta fue desarrollada por el Laboratorio de Visualización y Modelado (*Visualization and Modeling Laboratory*, VML) de la Universidad de Texas en San Antonio (UTSA).

A partir de datos de entrenamiento que contienen los eventos de interés y utilizando una técnica de extracción de características, DETECT permite entrenar un modelo de clasificación y etiquetar datos continuos de series temporales.

Una de sus aplicaciones directas es la detección de artefactos a señales EEG de larga duración, siendo una herramienta que permite entrenar un modelo con múltiples clases de eventos. Para ello, es necesario proporcionar un conjunto de datos de entrenamiento que alimente un clasificador basado en máquinas de vectores soporte (*Support Vector Machine*, SVM).

DETECT informa de los índices temporales en los que se detectan los eventos, así como del tipo de evento clasificado.

DETECT soporta integración con **EEGLAB** [43], que es un entorno basado en MATLAB ampliamente utilizado en el procesamiento y análisis de señales EEG, siendo una de las herramientas mas utilizadas en neurociencia cognitiva y aplicaciones clínicas. Fue desarrollado por Arnaud Delorme y Scott Makeig en el *Swartz Center for Computational Neuroscience* (SCCN), ubicado en la Universidad de California en San Diego (UCSD).

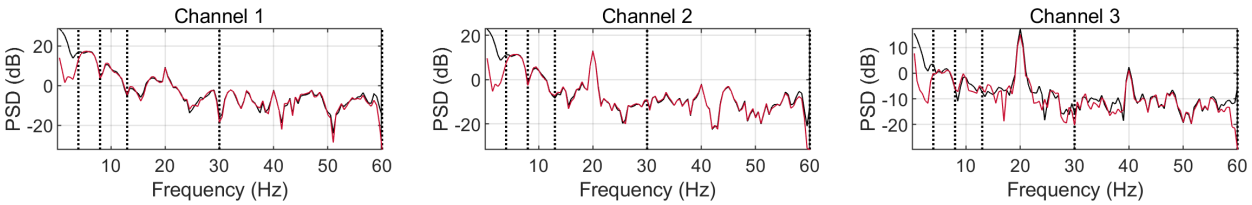


Figura 4.49: Comparación espectral (PSD) de las bandas EEG entre la señal sintética original y la reconstruida tras el método MEMD+FICA aplicado al artefacto de un apretamiento mandibular (Jaw Clench).

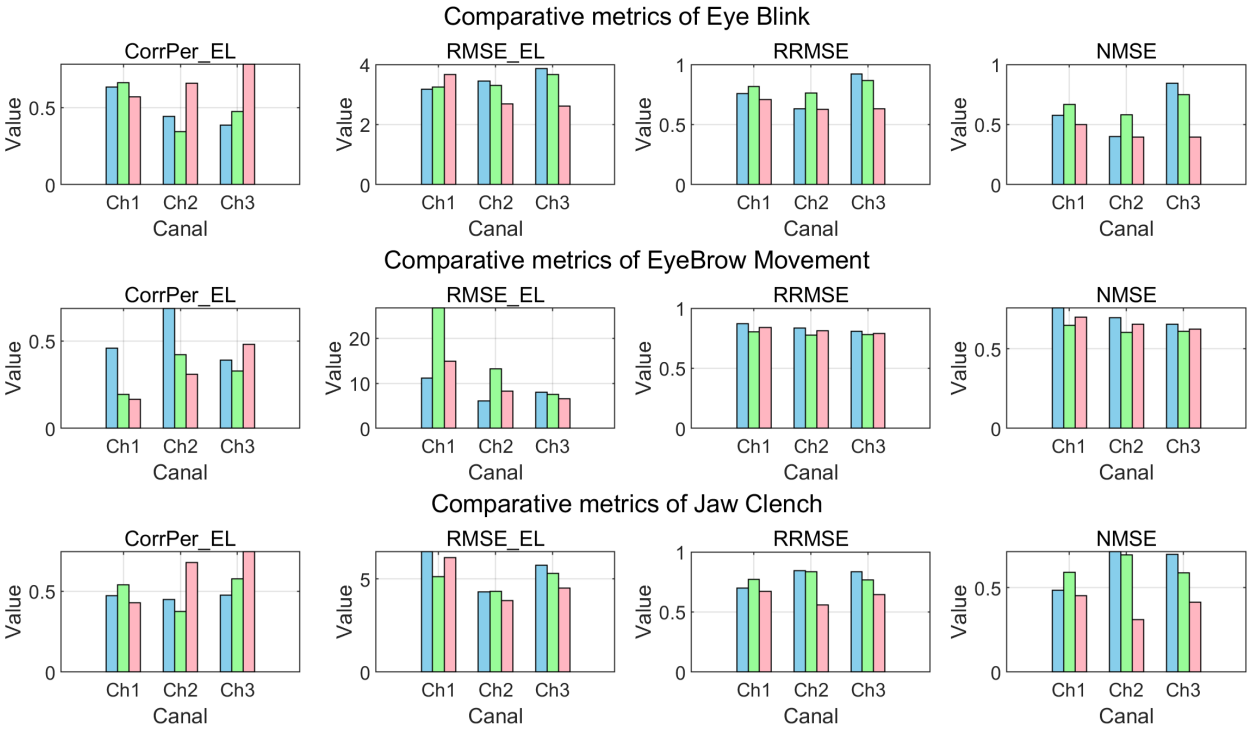


Figura 4.50: Comparativa métricas de los metodos EMD, MEMD y MEMD+FastICA

EEGLAB aporta herramientas generales para el procesamiento de EEG, como preprocesamiento, segmentación o análisis espectral, al igual que un entorno gráfico de representación de las señales EEG.

4.3.2. Procesamiento de canales

Las señales EEG reales utilizadas se han obtenido del *MIT-BIH Polysomnographic Database* siendo el set por defecto utilizado por DETECT para realizar el testing. Son señales de 72 canales muestreadas a 256 Hz y de duración 8 minutos.

Uno de los principales problemas encontrados al intentar procesar las señales EEG de testing con los métodos propuestos anteriormente, ha sido la dimensión de canales que estas contenían. Una de las limitaciones que tiene el método MEMD es el numero de canales de

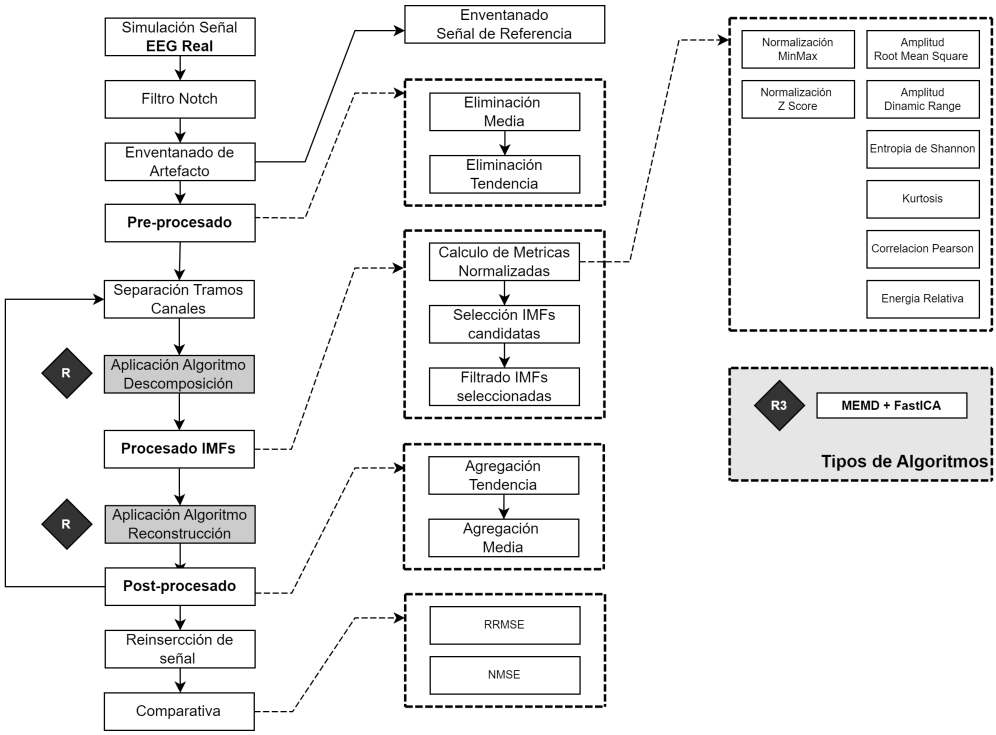


Figura 4.51: Diagrama de flujo para proceso con señales reales.

los datos introducidos. Si bien es cierto, que el algoritmo utilizado es el desarrollado por el profesor *Danilo P.Mandic* del Imperial College de Londres [44], este algoritmo esta limitado a un máximo de 16 canales (ampliable a 32), número a partir del cual empieza a haber mayores problemas de computo al realizar las proyecciones n-dimensionales y el algoritmo no es tan preciso.

Dado que la idea analizar una señal de 72 canales parecía completamente descartada, y para poder utilizar el algoritmo a su máximo rendimiento, se ha procedido a realizar un estudio de la naturaleza y el comportamiento de los canales cuando estos ya estaban enventanados. Para ello se ha utilizado un concepto de brusquedad de señal, que busca detectar cambios rápidos y abruptos en la señal.

Una vez tenemos catalogados los diferentes canales con el índice, se ha realizado una selección mediante el cumplimiento de un umbral y unas condiciones de canales próximos que cumplen o no el umbral.

Bajo estas premisas, se calculan tramos de canales consecutivos que poseen mas actividad artefactual y podemos trabajar con ellos de forma conjunta. Una vez realizado este proceso, se sigue el esquema expuesto en la Fig. 4.51.

4.3.3. MEMD + FastICA sobre señales reales

Se realizarán varias pruebas con las señales descritas en la Sección. 4.3.2, con el fin de ilustrar los resultados obtenidos con el algoritmo MEMD+FastICA, dado que este algoritmo el que mejores resultados ha dado en el estudio con señales sintéticas.

En primer lugar se tomará una ventana de la señal EEG artefactuada detectada mediante DETECT, el cual nos indica el tipo de Artefacto además de los tiempo e indices de inicio y fin del segmento. En la Fig. 4.52 se presenta un primer ejemplo sobre un artefacto Eye Blink real, donde se ve la representación de los 72 canales, y la ventana seleccionada por DETECT con un sombreado gris. Se puede apreciar la existencia tres zonas claramente diferenciables en los canales, donde la presencia artefactual es mas notable.

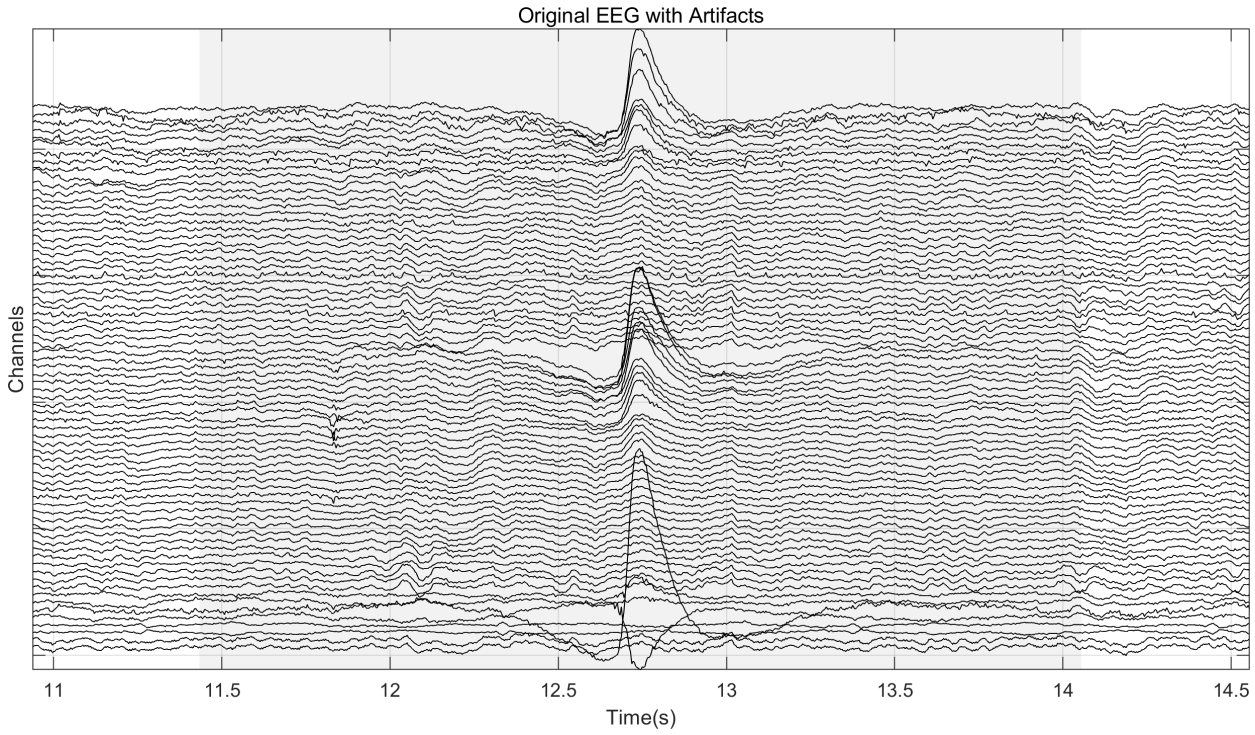


Figura 4.52: Señal EEG con artefacto Eye Blick Real

La selección de estas zonas las obtendremos mediante el indice de brusquedad, en la Fig. 4.53 se puede ver este indice para el ejemplo expuesto, al igual que el umbral de selección y los canales seleccionados en rojo. En este caso concreto, se trabajará con tres zonas de canales, que están ampliamente ligadas.

En cada una de estas iteraciones que se realizará para cada una de las zonas se aplicará el método de MEMD+FastICA, obteniendo finalmente una señal procesada completa. En la Fig.4.54 se presenta una comparación entre la señal enventanada original y la señal enventanada procesada por el algoritmo, donde se aprecia la reducción del artefacto. Como se puede apreciar, para este tipo de artefactos el rendimiento de este método es bastante bueno.

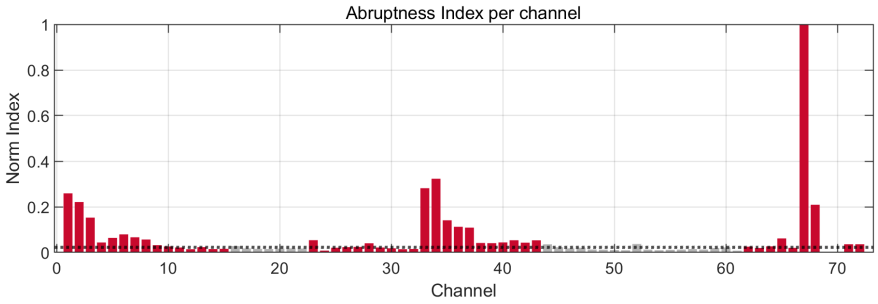


Figura 4.53: Indice de Brusquedad para el artefacto Eye Blick Real

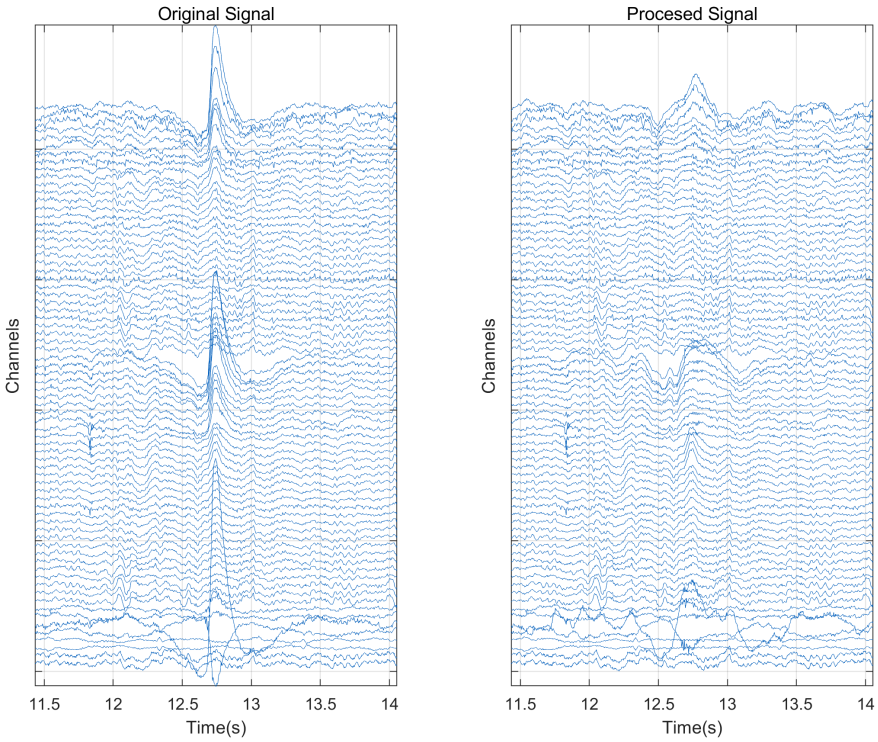


Figura 4.54: Comparativa de señal EEG Original real y Procesada con MEMD+FastICA de un Eye Blink

De la misma forma que se hizo con las señales sintéticas, en la Fig. 4.55 se presentan los parámetros utilizados para evaluar el rendimiento del método propuesto. Para los casos reales se empleará el NNMSE y el RRMSE, ambos calculados con referencia a una señal considerara como limpia de la misma muestra.

En rojo se expone el error de la señal contaminada frente a la señal de referencia, y en azul, el mismo parámetro calculado entre la señal procesada con el algoritmo y la señal referencia. En ambos casos existe una disminución significativa de los errores en las zonas de los canales que han sido tratados con el algoritmo.

En la Fig. 4.56 se pone la señal final reconstruida con su ventana marcada en gris, con el fin de ver la unión de las señales en la ventana con la señal original no tratada en ningún

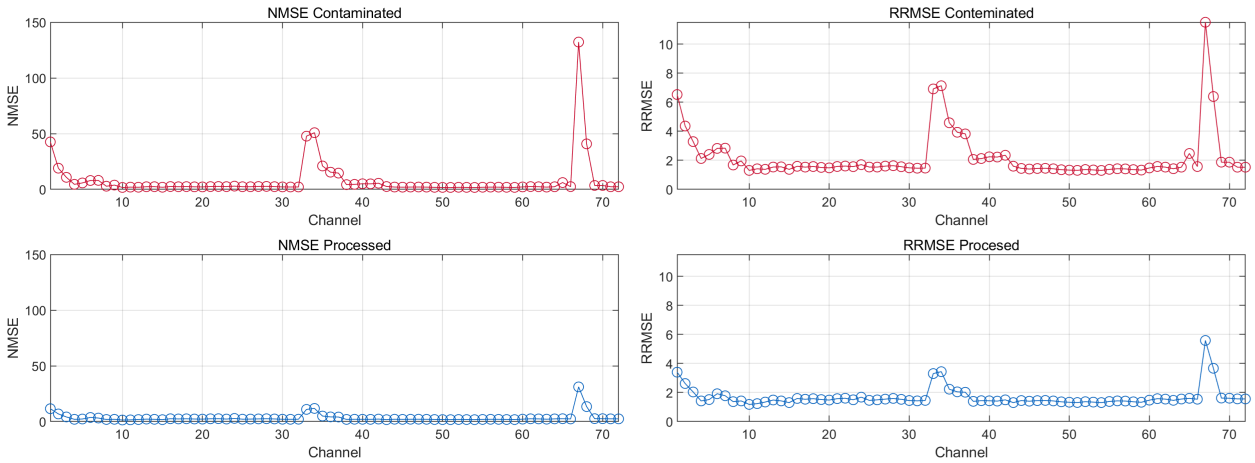


Figura 4.55: Errrores NMSE y RRMSE para el caso de Eye Blink real

canal.

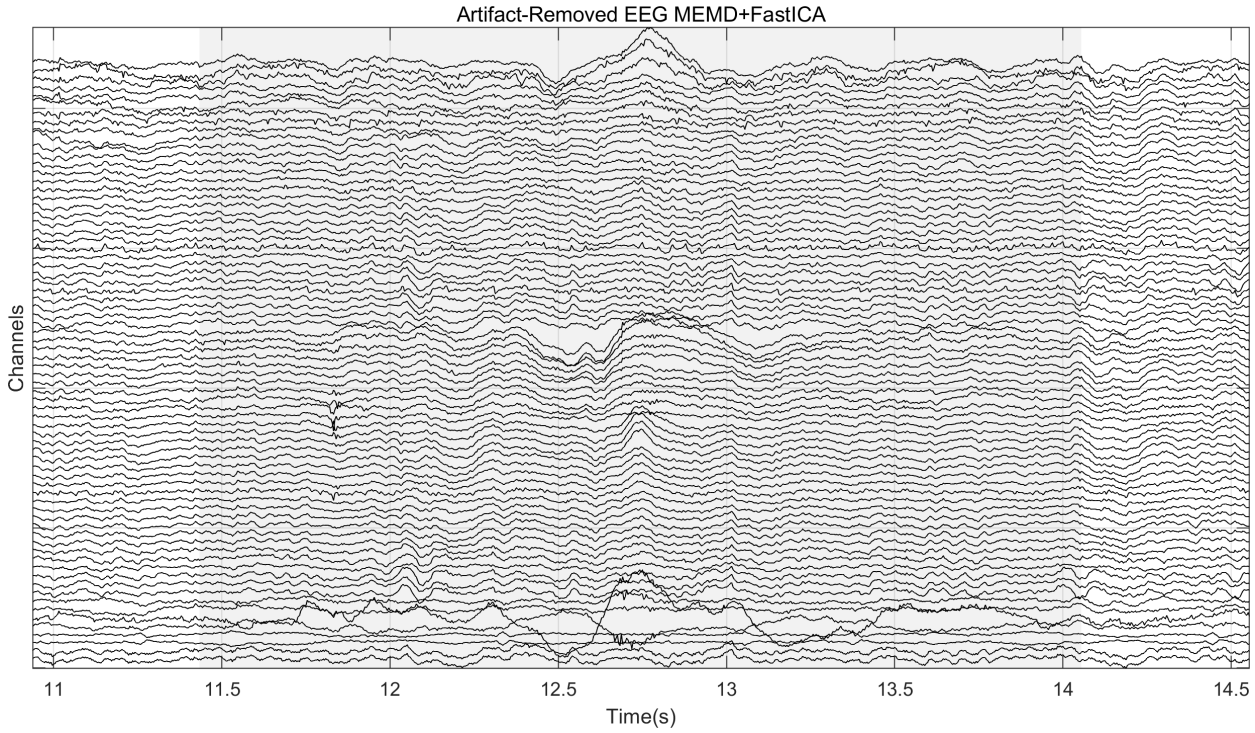


Figura 4.56: Señal EEG con artefacto Eye Blick Real tratado con MEMD+FastICA

Para el caso de una señal de movimientos de ojos, tras realizar todo el proceso obtendremos la reconstrucción de señal de la Fig. 4.57. En esta gráfica podemos ver la comparativa de la señal multicanal original segmentada al artefacto y la misma señal tras el proceso realizado. Se aprecia que el algoritmo reduce la frecuencias mas bajas del artefacto, pero no es capaz de reducir las aportaciones del artefacto de frecuencias mas altas.

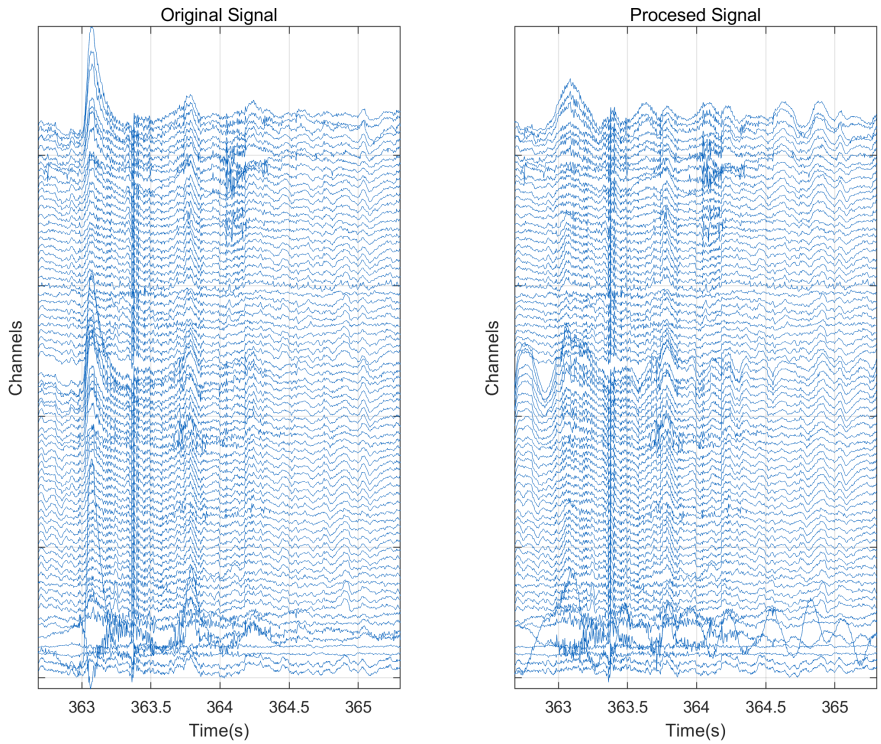


Figura 4.57: Comparativa de señal EEG Original real y Procesada con MEMD+FastICA para el caso Eye Movement

En la Fig- 4.58 las gráficas comparativas de los errores calculados para este tipo de artefacto, donde se aprecia que ha habido una reducción de los errores, aunque visualmente no sea tan notorio.

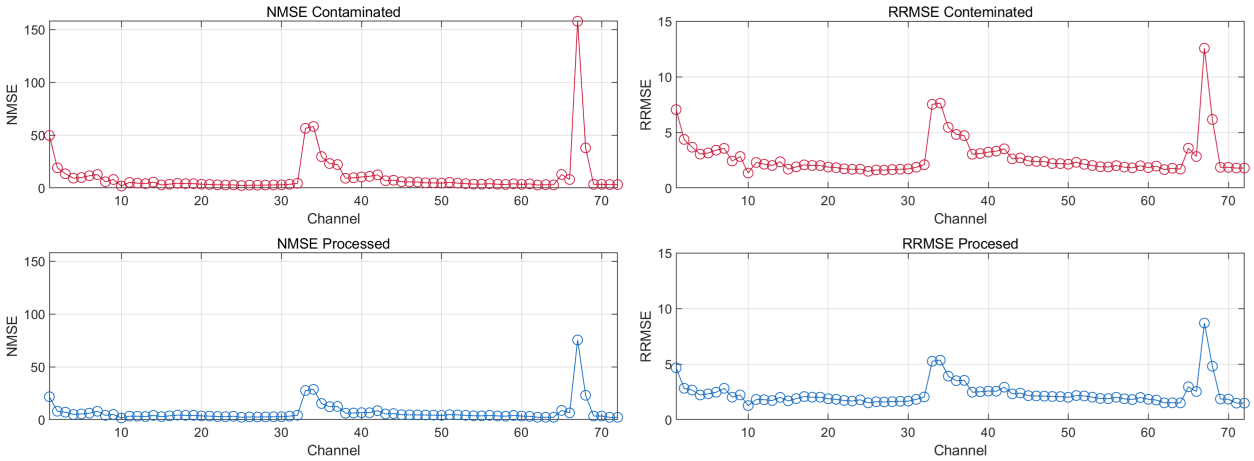


Figura 4.58: Errrores NMSE y RRMSE para el caso de Eye Movement real

Como última señal tratada, realizaremos el procesado para un artefacto producido por un movimiento de mandíbula. En la Fig. 4.59 se puede apreciar como el algoritmo reduce las componentes de baja frecuencias, pero no es capaz de atenuar las altas frecuencias del artefacto.

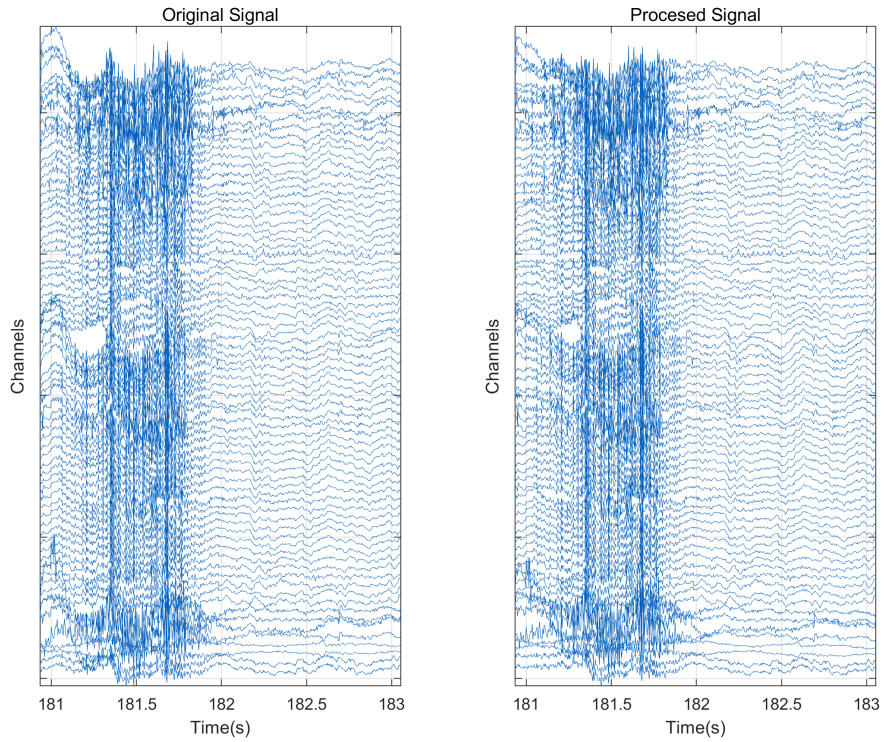


Figura 4.59: Comparativa de señal EEG Original real y Procesada con MEMD+FastICA para el caso Jaw Movement

En la Fig- 4.58 las gráficas comparativas de los errores calculados para este tipo de artefacto, donde se aprecia que ha habido una reducción de los errores muy leve, debido al poco rendimiento producido ante altas frecuencias.

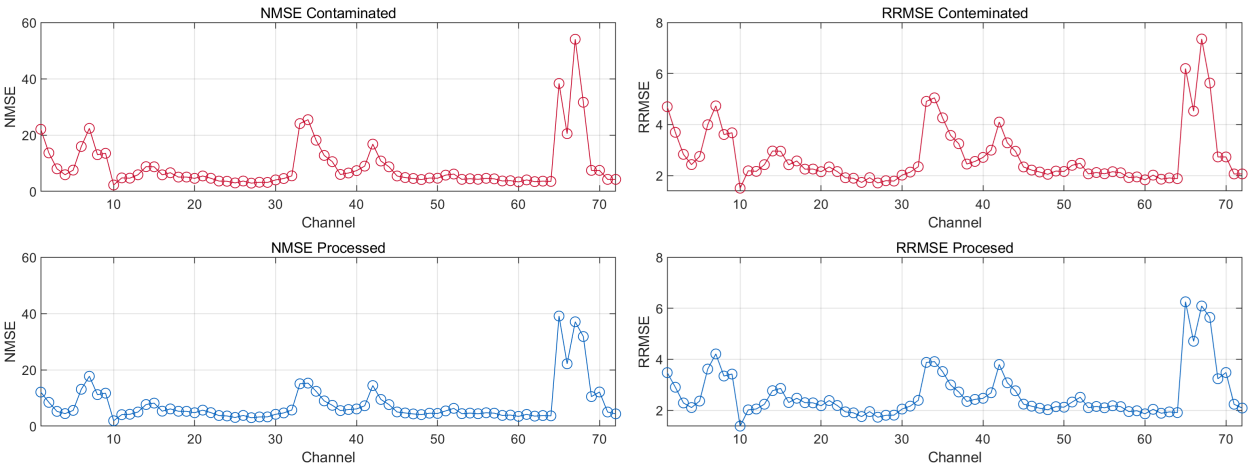


Figura 4.60: Errrores NMSE y RRMSE para el caso de Jaw Movement real

4.4. Discusión

El objetivo de esta sección es analizar los resultados obtenidos mediante los métodos utilizados, para las dos baterías de test realizadas. La primera de ellas con señales sintéticas autogeneradas y la segunda con señales reales.

El primer escenario está basado en tres señales EEG sintéticas generadas con el fin de representar una señal EEG con la aportación de tres artefactos comunes, un pestañeo involuntario, un movimiento de ojos, y un apretón de dientes. Los tres tipos de señales sintéticas son multicanal y constan de tres canales, en los que la aportación del artefacto se produce con una intensidad diferente en cada uno de ellos.

Estas señales multicanal sintéticas han sido procesadas mediante los tres métodos descritos, EMD, MEMD y una hibridación de MEMD+FastICA.

El método de descomposición EMD se ha propuesto como una primera aproximación al método de descomposición adaptativo. Los resultados obtenidos son una clara reducción de la componente artefactual junto con modificación de la parte de la señal encefalográfica pura.

La perturbación de la señal EEG se puede observar en cómo afecta al canal 3, donde la componente artefactuada está en una proporción muy pequeña en comparación con la señal encefalográfica. Se puede apreciar como la correlación de pearson se reduce, evidenciando una pérdida de correlación con la señal sin contaminar y por lo tanto de similitud.

Esto es debido a que las descomposiciones de cada canal no poseen coherencia entre ellas al ser descompuestas de forma independiente, y por lo tanto no es capaz de identificar parte artefactual en relación a las tres señales.

El método MEMD realiza la descomposición teniendo en cuenta la coherencia la coherencia entre canales, lo que se traduce como una variación más uniforme de las características entre distintos canales, como se puede apreciar en la señal de Jaw Clench.

Finalmente el método híbrido de MEMD+FastICA es el que mejores resultados ha obtenido, siendo muy constante tanto en el incremento de la correlación de Pearson, como en la disminución del del RRMSE y del NME, siendo este último el más destacable.

Respecto al análisis de la densidad espectral, la mejora de MEMD+FastICA respecto a los otros métodos viene representada por una reducción de rangos de frecuencias bajas y medias. El trabajo de los algoritmos a frecuencias más altas, se ve un empeoramiento del rendimiento siendo esto mucho más evidente en las pruebas reales.

El segundo escenario propuesto se basa en la aplicación del método MEMD+FastICA, dado que es el que mejor resultado ha dado de rendimiento, en la aplicación a señales EEG reales.

Se ha aplicado este procedimiento a tres tramos de señales artefactuadas con tres tipos

de artefactos.

Para señales como la primera, que se trata de un artefacto derivado de un pestañeo, la solución propuesta descontamina satisfactoriamente parte de la señal, dado que este tipo de artefactos trabaja en bandas bajas como la Delta o Theta. Esta reducción del artefacto se puede apreciar de forma visual y de forma numérica mediante la comparación de RRNSE y NMSE.

Se ha considerado la inspección visual como un criterio de valoración válido, a pesar de su limitada cuantificación, ya que en el ámbito clínico el estudio y análisis de señales EEG se realiza habitualmente mediante esta técnica.

En las dos siguientes señales reales, se puede apreciar un nivel de descontaminación más bajo que en el caso anterior. Los datos numéricos reportan que las tasas de error si que se han reducido después de aplicar el método, pero no lo suficiente para poder apreciarlo visualmente. Esto puede ser debido a que se tratan de artefactos que afectan a bandas de frecuencias más altas.

Capítulo 5

Conclusiones y futuras lineas de trabajo

En este Trabajo de Fin de Máster se ha estudiado el impacto de distintos tipos de artefactos en señales EEG multicanal y se han evaluado diversos métodos de descomposición adaptativa para reducir su influencia en el análisis clínico. El estudio se ha centrado en técnicas como EMD, su extensión MEMD y la versión híbrida MEMD+FasICA, con el objetivo de mejorar la calidad de la señal EEG preservando al máximo la información neurológica relevante.

El trabajo comenzó con una fase de preprocesamiento estándar de las señales EEG, donde se aplicó un filtro Notch para mitigar la interferencia electromagnética de la red eléctrica. Además, se eliminó la media para centrar la señal y se suprimió la tendencia para reducir las componentes de muy baja frecuencia. Estas etapas iniciales fueron fundamentales para garantizar que las señales estuvieran adecuadamente acondicionadas antes de aplicar los métodos de descomposición más avanzados.

Posteriormente se desarrolló un método para buscar características de los IMF obtenidos tras la descomposición. Para ello se usaron diferentes métricas estadísticas y características de las señales con el objetivo de identificar los modos que contenían componentes artefactuales.

La validación del método se realizó en dos fases consecutivas: inicialmente mediante pruebas controladas con una batería de test con señales específicamente diseñadas, donde se comparó el rendimiento de los tres algoritmos (EMD, MEMD y MEMD+FastICA) utilizando múltiples métricas de evaluación.

Posteriormente, se aplicó el método a una segunda batería de test, sobre una base de señales reales, aplicando una técnica de aprendizaje automático basada en SVM para segmentar la señal en regiones lo que permitió identificar la aparición de un artefacto y categorizar los segmentos artefactuados según su tipo, momento de aparición y duración.

A partir de los segmentos identificados, se llevó a cabo un análisis para detectar los canales donde el artefacto era más notable, con mayor contaminación, utilizando un índice de

brusquedad, lo que permitió focalizar el procesamiento en las regiones más afectadas. Posteriormente, la señal se dividió en diferentes tramos para aplicar selectivamente el método más eficaz, el MEMD+FastICA, únicamente en los canales más afectados por la contaminación. Finalmente se evaluó la calidad de la señal reconstruida tras todo el proceso, verificando la efectividad de la limpieza mientras se preservaba la información relevante.

Como posibles líneas de trabajo futuras se plantea la creación de un banco de señales sintéticas más realistas que reproduzcan fielmente las características de un registro EEG multicanal, incorporando mayor variedad de artefactos simultáneos. Este recurso facilitaría considerablemente la validación de nuevos algoritmos de procesamiento de señales EEG. Las pruebas realizadas sobre señales sintéticas son clave para el cálculo de rendimiento, ya que permiten obtener métricas mucho más precisas al contar con la señal EEG limpia, la señal artefactual por separado y la señal contaminada generada de la combinación de ambas dos.

Respecto a la identificación de IMFs con posible contenido artefactual se ha realizado utilizando exclusivamente la energía relativa de cada componente. Como línea futura de trabajo, sería interesante explorar otros métodos de selección, incluyendo potencialmente el desarrollo de un índice como combinación de diferentes características.

Otra posible dirección sería el desarrollo de nuevas técnicas híbridas que combinen MEMD con otros métodos de procesamiento, como técnicas de separación ciega de fuentes u otros enfoques más innovadores aplicados a los IMFs obtenidos.

Finalmente, se propone un estudio más exhaustivo en el análisis de los parámetros de segmentación temporal, particularmente en la selección de ventanas útiles detectadas por el clasificador SVM, ya que su configuración incide directamente en los resultados de la descomposición EMD.

Apéndice A

Anexo

Alg.	Signal	Ch	r CL	r EL	RMSE CL	RMSE EL	RRMSE	NMSE
EMD	Eye Blink	1	0.3472	0.6335	7.2439	3.1836	0.7582	0.5749
		2	0.6666	0.4440	3.6220	3.4483	0.6311	0.3983
		3	0.9963	0.3882	0.3622	3.8672	0.9191	0.8447
	EyeBrow Mov	1	0.0978	0.4572	59.6604	11.1910	0.8698	0.7565
		2	0.2701	0.6872	29.8302	6.1190	0.8354	0.6979
		3	0.7382	0.3890	9.9434	7.9639	0.8091	0.6546
	Jaw Clench	1	0.3313	0.4724	10.1995	6.4463	0.6975	0.4865
		2	0.6702	0.4500	5.0998	4.3021	0.8443	0.7129
		3	0.9970	0.4738	0.5100	5.7270	0.8352	0.6975
MEMD	Eye Blink	1	0.3472	0.6634	7.2439	3.2449	0.8181	0.6694
		2	0.6666	0.3453	3.6220	3.2981	0.7618	0.5804
		3	0.9963	0.4761	0.3622	3.6631	0.8664	0.7507
	EyeBrow Mov	1	0.0978	0.1933	59.6604	26.6472	0.8046	0.6474
		2	0.2701	0.4208	29.8302	13.2078	0.7767	0.6033
		3	0.7382	0.3277	9.9434	7.5003	0.7807	0.6095
	Jaw Clench	1	0.3313	0.5388	10.1995	5.1269	0.7699	0.5928
		2	0.6702	0.3745	5.0998	4.3356	0.8329	0.6937
		3	0.9970	0.5774	0.5100	5.3069	0.7679	0.5897
F-MEMD	Eye Blink	1	0.3472	0.5683	7.2439	3.6713	0.7086	0.5021
		2	0.6666	0.6581	3.6220	2.6919	0.6288	0.3954
		3	0.9963	0.7800	0.3622	2.6077	0.6306	0.3977
	EyeBrow Mov	1	0.0978	0.1668	59.6604	14.8944	0.8376	0.7015
		2	0.2701	0.3082	29.8302	8.2700	0.8103	0.6565
		3	0.7382	0.4813	9.9434	6.5235	0.7909	0.6255
	Jaw Clench	1	0.3313	0.4277	10.1995	6.1457	0.6725	0.4522
		2	0.6702	0.6759	5.0998	3.8257	0.5586	0.3120
		3	0.9970	0.7422	0.5100	4.4947	0.6438	0.4145

Tabla A.1: Comparación de algoritmos para diferentes señales y canales.

Bibliografía

[1] Alexander Pokusay. Human brain structure top view diagram schematic vector illustration medical. `https://depositphotos.com/de/vector/human-brain-structure-top-view-diagram-schematic-vector-illustration-medical-674615030.html`. Depositphotos, accessed on 2025-05-22.

[2] Roberto Sepúlveda, Oscar Montiel Ross, Gerardo Díaz, Daniel Guetierrez, and Oscar Castillo. Classification of encephalographic signals using artificial neural networks. *Computación y Systemas*, 19:69–88, 03 2015. doi: 10.13053/CyS-19-1-1570.

[3] G. Gratton, M. G. H. Coles, and E. Donchin. A new method for off-line removal of ocular artifact. *Electroencephalography and Clinical Neurophysiology*, 55(4):468–484, 1983. doi: 10.1016/0013-4694(83)90135-9.

[4] Pierre Comon. Independent component analysis, a new concept? *Signal Processing*, 36(3): 287–314, 1994. ISSN 0165-1684. doi: https://doi.org/10.1016/0165-1684(94)90029-9. Higher Order Statistics.

[5] Ernst Niedermeyer and Fernando H Lopes da Silva. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins, 5 edition, 2005.

[6] Jose A. Urigüen and Beatriz Garcia-Zapirain. Eeg artifact removal—state-of-the-art and guidelines. *Journal of Neural Engineering*, 12(3):031001, 2015. doi: 10.1088/1741-2560/12/3/031001.

[7] Y. Xu et al. Removal of muscle artefacts from few-channel eeg recordings based on multivariate empirical mode decomposition and independent vector analysis. *Electronics Letters*, 54(8):516–518, 2018. doi: 10.1049/el.2018.0191.

[8] Murtaza Ali, Muhammad Jamil, Adeel Iqbal, Syed Omer Gilani, Rameez Amin, and Aamir Saeed Malik. Effect of eog signal filtering on the removal of ocular artifacts and eeg-based brain-computer interface: A comprehensive study. *Computational Intelligence and Neuroscience*, 2018:1–14, 2018. doi: 10.1155/2018/4853741.

[9] Adam Borowicz. Using a multichannel wiener filter to remove eye-blink artifacts from eeg data. *Biomedical Signal Processing and Control*, 45:246–255, 2018. doi: 10.1016/j.bspc.2018.04.019.

[10] M Fatourechi, A Bashashati, RK Ward, and GE Birch. Removal of eye movement artifacts from eeg signals using pca and ica methods. In *Proceedings of the 26th Annual International*

Conference of the IEEE Engineering in Medicine and Biology Society, pages 5103–5106. IEEE, 2004.

[11] K R Acharya, R Krishnan, P S Iyengar, and C M Lim. Wavelet transform-based artifact removal from eeg signals. *Biomedical Signal Processing and Control*, 8(6):569–577, 2013.

[12] Zhaohua Wu and Norden E Huang. Ensemble empirical mode decomposition: A noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, 1(1):1–41, 2009. doi: 10.1142/S1793536909000047.

[13] María E. Torres, Marcelo A. Colominas, Gastón Schlotthauer, and Patrick Flandrin. A complete ensemble empirical mode decomposition with adaptive noise. In *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 4144–4147. IEEE, 2011. doi: 10.1109/ICASSP.2011.5947265.

[14] Natalia P Castellanos and Valeri A Makarov. Recovering eeg brain signals: Artifact suppression with wavelet enhanced independent component analysis. *Journal of Neuroscience Methods*, 158 (2):300–312, 2006. doi: 10.1016/j.jneumeth.2006.06.005.

[15] Yufeng Zheng and Guoqing Xu. A hybrid method for eeg artifact removal based on independent component analysis and empirical mode decomposition. *Neurocomputing*, 116:34–45, 2013. doi: 10.1016/j.neucom.2012.12.034.

[16] Fabien Lotte, Marco Congedo, Anatole Lécuyer, Frédéric Lamarche, and Bruno Arnaldi. A review of classification algorithms for eeg-based brain–computer interfaces. *Journal of neural engineering*, 4(2):R1–R13, 2007. doi: 10.1088/1741-2560/4/2/R01.

[17] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 454(1971):903–995, 1998. doi: 10.1098/rspa.1998.0193.

[18] N.E. Huang and S.S. Shen. *Hilbert-Huang Transform and Its Applications*. Interdisciplinary mathematical sciences. World Scientific, 2005. ISBN 9789812703347.

[19] A. Zeiler, R. Faltermeier, I. R. Keck, A. M. Tomé, C. G. Puntonet, and E. W. Lang. Empirical mode decomposition - an introduction. In *The 2010 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8, 2010. doi: 10.1109/IJCNN.2010.5596829.

[20] Jose L. Sanchez and Juan J. Trujillo and. Improving the empirical mode decomposition method. *Applicable Analysis*, 90(3-4):689–713, 2011. doi: 10.1080/00036810903569531.

[21] Gabriel Rilling, Patrick Flandrin, and Paulo Gonçalves. On empirical mode decomposition and its algorithms. In *IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing NSIP-03*, Grado, Italy, June 2003.

[22] Baochun xu, Yunlong Sheng, Peijuan Li, Qihua Cheng, and Jingqiu Wu. Causes and classification of emd mode mixing. *Vibroengineering PROCEDIA*, 22, 03 2019. doi: 10.21595/vp.2018.20250.

[23] Yunchao Gao, Guangtao Ge, Zhengyan Sheng, and Enfang Sang. Analysis and solution to the mode mixing phenomenon in emd. In *2008 Congress on Image and Signal Processing*, volume 5, pages 223–227, 2008. doi: 10.1109/CISP.2008.193.

[24] Zhao Jin-ping and Huang Da-ji. Mirror extending and circular spline function for empirical mode decomposition method. *Journal of Zhejiang University-SCIENCE A*, 2:247–252, 07 2001. doi: 10.1631/BF02839453.

[25] Yaguo Lei, Jing Lin, Zhengjia He, and Ming J. Zuo. A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mechanical Systems and Signal Processing*, 35(1):108–126, 2013. ISSN 0888-3270.

[26] Okan Katipoğlu, Sefa Nur Yesilyurt, Huseyin Dalkilic, and Funda Akar. Application of empirical mode decomposition, particle swarm optimization, and support vector machine methods to predict stream flows. *Environmental monitoring and assessment*, 195:1108, 08 2023. doi: 10.1007/s10661-023-11700-0.

[27] Naveed Rehman and D.P. Mandic. Multivariate empirical mode decomposition. *Proc. R. Soc. A*, 466:1291–1302, 01 2010.

[28] Gabriel Rilling, Patrick Flandrin, Paulo Gonçalves, and Jonathan Lilly. Bivariate empirical mode decomposition. *IEEE Signal Processing Letters*, 14, 01 2008. doi: 10.1109/LSP.2007.904710.

[29] Naveed ur Rehman and Danilo P. Mandic. Empirical mode decomposition for trivariate signals. *IEEE Transactions on Signal Processing*, 58(3):1059–1068, 2010. doi: 10.1109/TSP.2009.2033730.

[30] Palani Krishnan, Mable Roshini, and Parvathavarthini Balasubramanian. Integration of multivariate empirical mode decomposition and independent component analysis for fetal ecg separation from abdominal signals. *Technology and health care : official journal of the European Society for Engineering and Medicine*, 24, 06 2016. doi: 10.3233/THC-161224.

[31] Yunchao Yin, Jianting Cao, and Toshihisa Tanaka. Eeg energy analysis based on memd with ica pre-processing. In *Proceedings of The 2012 Asia Pacific Signal and Information Processing Association Annual Summit and Conference*, pages 1–5, 2012.

[32] Xun Chen, Xueyuan Xu, Aiping Liu, Martin J. McKeown, and Z. Jane Wang. The use of multivariate emd and cca for denoising muscle artifacts from few-channel eeg recordings. *IEEE Transactions on Instrumentation and Measurement*, 67(2):359–370, 2018. doi: 10.1109/TIM.2017.2759398.

[33] Aapo Hyvärinen and Erkki Oja. A fast fixed-point algorithm for independent component analysis. *Neural Computation*, 9(7):1483–1492, 1997. doi: 10.1162/neco.1997.9.7.1483.

[34] Sabine Leske and Sarang S. Dalal. Reducing power line noise in eeg and meg data via spectrum interpolation. *NeuroImage*, 189:763–776, 2019. ISSN 1053-8119.

[35] Saroj Bista and Nanda Adhikari. Design of tri-channel active electrode eeg device for classification of motor imagery brainwaves. 12 2017.

[36] Masaki Iwasaki, Christoph Kellinghaus, Andreas V. Alexopoulos, Richard C. Burgess, Arun N. Kumar, Yanning H. Han, Hans O. Lüders, and R. John Leigh. Effects of eyelid closure, blinks, and eye movements on the electroencephalogram. *Clinical Neurophysiology*, 116(4):878–885, 2005. ISSN 1388-2457.

[37] J.W. Britton, L.C. Frey, J.L. Hopp, et al. *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*. American Epilepsy Society, Chicago, 2016.

[38] A. Santillan-Guzman, J. J. Oliveros-Oliveros, and M. M. Morin-Castillo. Introducing a combination of ica-emd to suppress muscle and ocular artifacts in eeg signals. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 1250–1253. IEEE, 2018. ISBN 978-1-5386-3646-6. doi: 10.1109/EMBC.2018.8512581.

[39] Xun Chen, Xueyuan Xu, Aiping Liu, Martin J. McKeown, and Z. Jane Wang. The use of multivariate emd and cca for denoising muscle artifacts from few-channel eeg recordings. *IEEE Transactions on Instrumentation and Measurement*, 67(2):359–370, 2018. doi: 10.1109/TIM.2017.2759398.

[40] S. Das, R.B. Pachori, G.R. Sinha, and U.R. Acharya. Hybrid wavelet and emd/ica approach for artifact suppression in pervasive eeg. *Journal of Neuroscience Methods*, 267:89–107, 2016. doi: 10.1016/j.jneumeth.2016.04.011.

[41] Ary L. Goldberger, Luis A. N. Amaral, Leon Glass, Jeffrey M. Hausdorff, Plamen Ch. Ivanov, Roger G. Mark, Joseph E. Mietus, George B. Moody, Chung-Kang Peng, and H. Eugene Stanley. Physiobank, physiotoolkit, and physionet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23):e215–e220, 2000. doi: 10.1161/01.CIR.101.23.e215.

[42] Vernon Lawhern, W. David Hairston, and Kay Robbins. DETECT: A matlab toolbox for event detection and identification in time series, with applications to artifact detection in eeg signals. *PLoS ONE*, 8(4):e62944, 2013. doi: 10.1371/journal.pone.0062944.

[43] Arnaud Delorme and Scott Makeig. EEGLAB: An open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134(1):9–21, 2004. doi: 10.1016/j.jneumeth.2003.10.009.

[44] Danilo P. Mandic. Emd and multivariate emd matlab toolbox. https://www.commsp.ee.ic.ac.uk/~mandic/research/emd.htm. Accessed: 2025-05-12.