Universidad Nacional de Educación a Distancia

Máster en Ingeniería de Sistemas y Control

Técnicas no supervisadas para la detección de epilepsia

Autor: Bàrbara Ojeda Esquerdo

Directores: Raquel Dormido Canto
Natividad Duro Carralero
Angel Mur Güerri

Curso: 2021 - 2022
Convocatoria: Febrero 2022

Universidad Nacional de Educación a Distancia

Máster en Ingeniería de Sistemas y Control

Técnicas no supervisadas para la detección de epilepsia

Proyecto Tipo A

Autor: Bàrbara Ojeda Esquerdo

Directores: Raquel Dormido Canto
Natividad Duro Carralero
Angel Mur Güerri

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.

Firmado:

Firma del alumno

Resumen:

La epilepsia es un trastorno de la actividad eléctrica cerebral que aparece en forma de ataques . Los ataques epilépticos se pueden registrar en las señales electroencefalográficas (EEG). En este trabajo se desarrolla un método no supervisado para la detección automática de los ataques de epilepsia. Se parte de un método previo de detección de eventos en señales multicanal (UMED). En el presente trabajo se explica la metodología desarrollada en UMED en la que primero se divide la señal en ventanas, se obtienen las características de estas ventanas y, en función de unos índices de validación, se ajustan los parámetros de forma iterativa. Seguidamente se explica cómo se adapta UMED al nuevo objetivo añadiendo un filtro adaptativo, el Análisis de Componentes Principales y el método de clasificación k-means. Finalmente se detallan los resultados conseguidos en los que con 10 clusters y un tamaño de ventana de 1500 muestras se ha obtenido una sensibilidad del 100 % y especificidad del 91 %. Otros resultados no numéricos importantes son la detección de dos ataques en el mismo tramo de señal y la detección de un ataque a partir de la clasificación de las ventanas de otro ataque.

Palabras clave: clasificación no supervisada, clustering, señal multicanal, detección de eventos, caracterización de eventos, EEG, epilepsia

Índice general

Introducción **7**
Identificación del Problema 7
Objetivos y Motivación 9
Organización de la memoria 9

1. Epilepsia y EEG **10**
1.1. La epilepsia 10
1.2. Señales EEG 11
1.3. Base de datos 11

2. Estado del arte **13**
2.1. Machine Learning para Detección y Clasificación de ataques . . . 13
2.2. Machine Learning para Predicción de ataques 15

3. Un método no supervisado: UMED **17**
3.1. Descripción del método UMED 17
3.2. Testeo de UMED para detección de artefactos 19

4. Metodología **21**
4.1. Ventanas deslizantes 21
4.2. Coeficientes Autoregresivos 22
4.3. Análisis de Componentes Principales 23
4.4. Algoritmos de clustering: k-means y Jerárquico 23
4.5. Índices: Sdbw y Silhouette 24
4.6. Sensibilidad y Especificidad 25
4.7. Filtro adaptativo 25

5. Desarrollo y resultados **27**
5.1. Método No Supervisado Implementado 27
5.2. Primer ejemplo ilustrativo del método 28
5.3. Análisis del filtro adaptativo 31
5.4. Estudio sobre el ACP 32
5.5. Análisis de selección de tamaño de ventana 33
5.5.1. CCC más alto 36

5.5.2. Mayor índice de Silhouette 37
5.5.3. Menor diferencia de clusters entre los dos métodos 38
5.5.4. Menor numero de clusters con los dos ındices mayores de 0.5 40
5.6. Análisis de selección de desplazamiento 42
5.7. Dos ataques 43
5.8. Clustering de referencia 44

6. Conclusiones y trabajo futuro **46**
6.1. Trabajo futuro 47

A. Tablas de índices de Silhouette **52**

B. Imágenes de resultados **61**

Índice de figuras

0.1. Ataque epiléptico en una señal EEG. 8

1.1. Electrodos situados en la cabeza y señal EEG. Obtenida de [4]. . 11

2.1. Fases pre-ictal (verde), ictal (rojo) y post-ictal (azul) del ataque epiléptico 15

3.1. Diagrama de flujo del método UMED. 19

4.1. Ventanas deslizantes en una señal multicanal EEG. 21
4.2. Matriz de características de la señal multicanal. Obtenida de [1]. 23
4.3. Dendrograma del método jerárquico. 24
4.4. Filtrado adaptativo de una señal de EEG 26

5.1. 3 canales de la señal usada como ejemplo, con el ataque marcado. 28
5.2. Clasificación de ventanas de la señal EEG del tramo 350-550s con $L_w = 350$, $d = 32$, 5 clusters y 12 componentes principales. . . . 29
5.3. Representación de los dos primeros componentes de cada ventana. 30
5.4. 3 canales de la señal filtrada, con el ataque marcado. 31
5.5. Clasificación de ventanas de la señal EEG filtrada del tramo 350-550s con $L_w = 350$, $d = 32$, 5 clusters y 12 componentes principales. 31
5.6. Clasificación de ventanas de la señal EEG del tramo 350-550s con $L_w = 350$, $d = 32$, 5 clusters y sin usar ACP. 32
5.7. Porcentaje de información que contiene cada componente principal con sus anteriores. 33
5.8. Señal EEG con los intervalos coloreados según el criterio de CCC más alto para k-means, usando $L_w = 1200$, $d = 32$, filtro adaptativo, 17 clusters y 8 componentes principales. 36
5.9. Señal EEG con los intervalos coloreados según el criterio de CCC más alto para jerárquico, usando $L_w = 1200$, $d = 32$, filtro adaptativo, 13 clusters y 8 componentes principales. 37
5.10. Señal EEG con los intervalos coloreados según el criterio de mayor índice de Silhouette, usando $L_w = 1500$, $d = 32$, filtro adaptativo, 17 clusters y 8 componentes principales. 38

5.11. Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método k-means, $L_w = 1450$, $d = 32$, filtro adaptativo, 20 clusters y 8 componentes principales. 39
5.12. Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método k-means, $L_w = 1450$, $d = 32$, filtro adaptativo, 19 clusters y 8 componentes principales. 39
5.13. Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método jerárquico, $L_w = 1450$, $d = 32$, filtro adaptativo, 20 clusters y 8 componentes principales. 40
5.14. Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método jerárquico, $L_w = 1450$, $d = 32$, filtro adaptativo, 19 clusters y 8 componentes principales. 40
5.15. Señal EEG con los intervalos coloreados según el criterio de menor número de clusters con índice de Silhouette mayor a 0.5: método jerárquico, $L_w = 1500$, $d = 32$, filtro adaptativo, 10 clusters y 8 componentes principales. 41
5.16. Señal EEG con los intervalos coloreados según el criterio de menor número de clusters con índice de Silhouette mayor a 0.5: método k-means, $L_w = 1500$, $d = 32$, filtro adaptativo, 10 clusters y 8 componentes principales. 42
5.17. Señal EEG con dos ataques clasificada con 10 clusters. 43
5.18. Señal de referencia clasificada con 10 clusters. 44
5.19. Clasificación hecha a partir del clustering de referencia. 45

B.1. Ventanas según sus dos primeros componentes. Señal filtrada de 350-550s y clasificación con $L_w = 350$, $d = 32$, 5 clusters y 12 componentes principales 62
B.2. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1200$, $d = 32$, 17 clusters y 8 componentes principales 63
B.3. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1200$, $d = 32$, 17 clusters y 8 componentes principales 64
B.4. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1500$, $d = 32$, 17 clusters y 8 componentes principales 65
B.5. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1450$, $d = 32$, 20 clusters y 8 componentes principales 66
B.6. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1450$, $d = 32$, 19 clusters y 8 componentes principales 67

B.7. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1450$, $d = 32$, 20 clusters y 8 componentes principales 68
B.8. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1450$, $d = 32$, 19 clusters y 8 componentes principales 69
B.9. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1500$, $d = 32$, 10 clusters y 8 componentes principales 70
B.10. Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1500$, $d = 32$, 10 clusters y 8 componentes principales 71

Índice de tablas

5.1. Matriz de confusión 29
5.2. Índices de Silhouette resultante de aplicar el método k-means o jerárquico para un tamaño de ventana $L_w = 500$, desplazamiento $d = 32$ y número de clusters entre 2 y 20 34
5.3. Comparación de los resultados de cada tamaño de ventana con mayor índice de Silhouette 35
5.4. Resultados numéricos para el tamaño de ventana elegido según el criterio de CCC más alto. 37
5.5. Resultados numéricos para el tamaño de ventana elegido según el criterio de índice de Silhouette más alto. 37
5.6. Resultados numéricos para el tamaño de ventana elegido según el criterio de menor diferencia de clusters entre los dos métodos. 38
5.7. Resultados numéricos para el tamaño de ventana elegido según el criterio de menor número de clusters con un índice de Silhouette mayor de 0.5. 41
5.8. Resultados numéricos del análisis de selección de desplazamiento para el método k-means. 42
5.9. Resultados numéricos del análisis de selección de desplazamiento para el método jerárquico. 43

Introducción

Identificación del Problema

Las señales EEG (señales electroencefalográficas) son señales multicanal que contienen información de la actividad cerebral. Como tales son generadas por múltiples fuentes o múltiples sensores. En nuestro trabajo se emplearán señales EEG capturadas por 23 sensores distribuidos por la cabeza de los sujetos observados.

Los diferentes canales se pueden representar como las filas de una matriz, mientras que las columnas serían las muestras en los distintos instantes registrados. En el vector 1 vemos un ejemplo con 3 canales de como sería esta matriz, siendo $s_1(t)$ la señal grabada por el primer electrodo, $s_2(t)$ por el segundo y $s_3(t)$ por el tercero, siendo n el número de muestras registradas.

$$S(t) = \begin{bmatrix} s_1(t_1) & s_1(t_2) & ... & s_1(t_n) \\ s_2(t_1) & s_2(t_2) & ... & s_2(t_n) \\ s_3(t_1) & s_3(t_2) & ... & s_3(t_n) \end{bmatrix} \tag{1}$$

El trabajar con señales multicanal implica un tratamiento diferente al caso de trabajar con señales de un único canal. Cualquier estudio sobre señales multicanal implica el análisis para todos los canales y poder seleccionar, si así se requiere, cuáles son los más significativos.

Las señales multicanal se han estudiado en temas de detección de artefactos mediante un método no supervisado denominado UMED (Unsupervised Method Event Detection) [1]. Este método es el estudiado en este trabajo adaptándolo para el caso de la epilepsia. UMED fue desarrollado para detectar variaciones provocadas por movimientos de la mandíbula, parpadeo o movimientos de los ojos. No todas la anomalías se generan fuera del cerebro. Por ejemplo, las anomalías producidas durante un ataque de epilepsia. A priori, las anomalías exteriores al cerebro se detectan mas fácilmente.

En la figura 0.1 vemos un ejemplo de ataque epiléptico, del segundo 440 al 500 aproximadamente. En ella se puede observar que se percibe en varios canales variación en la amplitud y frecuencia, aún así podría confundirse con ruido de la propia señal. Por ese motivo UMED va a ser un potente punto de partida de este trabajo y, a partir de ahí, se irá viendo como conviene más avanzar para nuestro caso concreto.

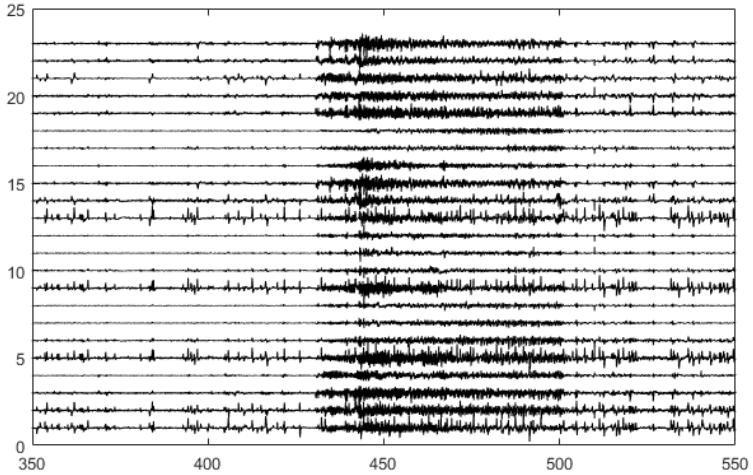

Figura 0.1: Ataque epiléptico en una señal EEG.

Como se explica más adelante en el trabajo, la epilepsia se puede clasificar en 3 tipos [2]: focal, generalizada o desconocida. En el caso de que sea focal, el foco donde se origina el ataque se puede detectar observando la relación de señales entre todos los canales. Este foco puede moverse de sitio durante el ataque y no tiene por que ser igual entre pacientes. De igual manera puede variar la forma de la señal o su intensidad. Por este motivo nos podemos encontrar con que un método generalizado para todos los sujetos no sea tan eficiente como uno con los parámetros personalizados. En la literatura encontrada sobre la detección automática de ataques de epilepsia, tanto supervisada como no supervisada, se hallan ejemplos tanto de métodos con una personalización para cada paciente o sujeto como métodos en los que se trata de encontrar de forma común los ataques de todos.

Finalmente, otra dificultad con la que nos encontramos al desarrollar un método de detección de ataques de epilepsia es que la detección pueda ser online. Para ello el procesamiento de la señal debe ser prácticamente inmediato y se utilizan solo las muestras pasadas de la señal $(t-1, t-2...)$ para detectar si en el momento t empieza el ataque. La detección de ataques epilépticos se realiza de mano de médicos expertos y siempre a posteriori del ataque, excepto en casos puntuales en que se esté justo observando al paciente cuando lo sufre. Éste diagnostico se realiza observando horas y horas de señales de EEG, por lo que la detección automática haría mucho más eficiente la detección, en caso de conseguir que fuera "on-line" mejoraría la calidad de vida de los pacientes y lo más útil sería poder detectar el ataque epiléptico antes de que aparezca.

Objetivos y Motivación

En este trabajo se pretende estudiar si es posible adaptar un método no supervisado de detección de eventos en señales multicanal ya existente (UMED), que se ha demostrado que tiene buenos resultados en otros campos, para detectar ataques de epilepsia.

Como primer objetivo se pretende separar automáticamente y de manera no supervisada los tramos que contienen ataque epiléptico de los que no. Para ello se siguen diferentes pasos en los que se intentará encontrar un resultado numérico cuantificable de la calidad de los agrupamientos encontrados. Aunque sea un método no supervisado, una vez encontrado el agrupamiento se utiliza como referencia la clasificación de las señales hecha por expertos en que señalan los tramos de epilepsia. A parte de esta comprobación, se quiere encontrar un índice que ayude a evaluar los resultados y que sea coherente con la clasificación original de los médicos expertos.

Como objetivo secundario, y siempre en caso de que se llegue a cumplir el primero de manera robusta, predecir el ataque epiléptico en tiempo real. Es sabido que este es uno de los problemas actuales de este campo y que requiere que el método sea fiable y a la vez rápido.

Organización de la memoria

El capítulo 1 describe la enfermedad de la epilepsia y los temas relacionados con ella que nos conciernen más para el estudio que se quiere realizar. También se explican las señales de EEG y la base de datos que usamos.

En el capítulo 2 se resume el estado actual y las técnicas más recientes del tema de la detección y clasificación de ataques de epilepsia, así como para la predicción de estos ataques.

En el capítulo 3 se describe el método del cual parte el actual trabajo: UMED. Es un método no supervisado para la detección de eventos en señales multicanal, este método ha dado buenos resultados en la detección de artefactos en señales EEG.

En el capítulo 4 se definen las técnicas y metodología utilizada en el desarrollo del trabajo. Las técnicas han sido implementadas en Matlab.

El capítulo 5 contiene los resultados obtenidos así como su análisis. En este capítulo se incluyen tanto imágenes como resultados numéricos cuantitativos para poder comparar de manera fidedigna cada prueba.

Finalmente, en el capítulo 6 se recogen las conclusiones extraídas del trabajo realizado y se plantea como se podría continuar y mejorar el estudio buscando la combinación y orden idóneos de las técnicas explicadas en el capítulo 4.

Capítulo 1

Epilepsia y EEG

1.1. La epilepsia

La epilepsia es un trastorno neurológico que afecta a 70 millones de personas en todo el mundo causado por ataques recurrentes que varían las características eléctricas cerebrales durante un tiempo indeterminado. Estos ataques pueden estar acompañados de pérdida del conocimiento, convulsiones o pérdida del control de las funciones motoras del cuerpo, entre otras. Según la clasificación de ataques ILAE del 2017, explicada por R.S. Fisher [2], encontramos 3 tipos de ataque o epilepsia: epilepsia focal, epilepsia generalizada o desconocida. Dentro de cada tipo encontramos también los subtipos de las convulsiones, que pueden ser motoras o no motoras.

Es una enfermedad crónica y los tratamientos actualmente disponibles pueden llegar a ser muy invasivos, como medicación diaria o incluso cirugía. Por este motivo la detección prematura es importante ya que el paciente puede llegar a perder el control motor de su cuerpo, por lo que puede caer y lesionarse durante un ataque. Al ser un trastorno que aparece con mucha frecuencia durante la infancia, la predicción de los ataques antes de que ocurran puede ser beneficioso para el día a día de las personas con epilepsia y de sus cuidadores.

El diagnóstico y detección de ataques lo realizan los neurólogos observando a mano las señales de EEG, que pueden contener horas de grabación, provocando que el trabajo sea tedioso y largo. Poder detectar automáticamente estos ataques epilépticos mejoraría la calidad de vida de los pacientes y facilitaría el trabajo de los médicos.

El ataque de epilepsia se puede generar en diferentes áreas del cerebro por lo que no es conveniente analizar un solo canal. Los ataques del mismo paciente se parecen entre ellos, pero entre diferentes pacientes puede cambiar mucho de características. Hay diversos estudios que usan esta variabilidad entre pacientes para cambiar los parámetros de detección y personalizarlos en cada paciente.

1.2. Señales EEG

El electroencefalograma es una representación de las señales bioeléctricas producidas por la actividad neuronal del cerebro. Se registran con la ayuda de unos electrodos colocados en el cuero cabelludo, esto provoca que el sistema sea no invasivo pero por otro lado la señal tendrá más ruido que con sistemas en que los electrodos están colocados dentro del cráneo. Los electrodos se colocan por toda la cabeza para obtener información lo más global posible creando una señal multicanal. En la figura 1.1 podemos visualizar los electrodos situados en la cabeza y una señal de EEG registrada con ellos.

En nuestro caso se colocaron 23 electrodos más el de referencia, por lo tanto, tendremos 23 canales de EEG. La amplitud de la señal suele estar entre 10 y 100 μV y diferentes bandas de frecuencia entre 0.5 y 500 Hz. Las variaciones de estos parámetros puede indicar diferentes estados del paciente (dormido, activo...), movimientos musculares (de mandíbula, parpadeo...) o incluso anomalías como pueden ser trastornos y enfermedades, entre estas la que nos concierne: la epilepsia [3].

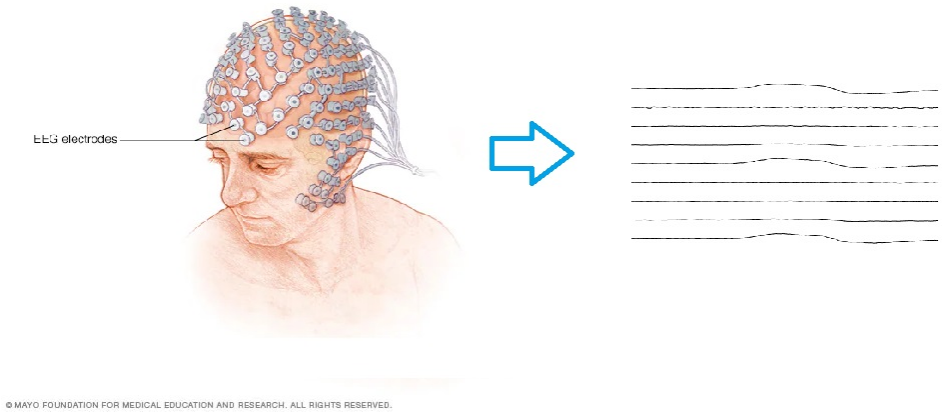

Figura 1.1: Electrodos situados en la cabeza y señal EEG. Obtenida de [4].

1.3. Base de datos

Para realizar el estudio se ha usado un conjunto de señales EEG de larga duración grabadas en el Children's Hospital Boston. Son señales de 23 pacientes pediátricos (entre 1 y 22 años de edad) diferentes con un total de 916h muestreadas a 256Hz. En las grabaciones aparecen 173 ataques de epilepsia detectados y juzgados por expertos. De este modo se puede comparar la salida de nuestro método con la detección de los expertos y evaluar el resultado obtenido.

Los datos están almacenados en ficheros .edf y cada uno contiene 1h de grabación. También se puede leer un resumen por paciente que detalla qué

contiene cada fichero .edf y a qué señal cerebral corresponde cada canal, a parte, de cuando empieza y acaba cada ataque. Los datos pediátricos de EEG usados ses pueden encontrar en la siguiente web de Physionet [5] [6].

Capítulo 2

Estado del arte

Durante los últimos años de investigación se han desarrollado múltiples métodos para la detección de ataques epilépticos. Para resumir un poco estos avances los separamos en dos tipos: Detección y clasificación de ataques y, por otro lado, la predicción de los mismos.

2.1. Machine Learning para Detección y Clasificación de ataques

En esta sección se describen diferentes técnicas y resultados para la detección y clasificación de los ataques de epilepsia a partir de señales de EEG.

En algunos artículos se combinan las señales de EEG con señales de otro tipo como, por ejemplo, ECoG (electrocorticografía) o resonancia magnética. Como en nuestro caso solo se usan las señales EEG no les daremos mucha importancia a estas investigaciones, para darle más a las que son únicamente análisis de EEG.

Todo proceso de detección y clasificación de señales epilépticas empieza con la adquisición de datos. En muchos casos se elige el mismo conjunto de datos del Children Hospital Boston, que es el que utilizamos en este estudio. A partir de ahí se ordenan y transforman las señales para prepararlas para que se puedan analizar. A continuación se usan diferentes técnicas de extracción de características. Finalmente se tendrán que aplicar las técnicas adecuadas para resolver el problema de clasificación.

Las diferentes técnicas de extracción de características de las señales usadas pueden ser en el dominio del tiempo (media, varianza, paso por cero, máximo, mínimo...), en el dominio de la frecuencia (potencia espectral, entropía espectral, energía, frecuencia de pico, frecuencia media), en el dominio del tiempo-frecuencia (mínimo, máximo, entropía de Shannon, desviación estándar...), a partir de la transformada de Fourier (frecuencia media, potencia, frecuencia pico...) o bien a partir de la transformada discreta o continua de Wavelet (Variación acotada, coeficientes, energía, desviación estándar de energía...). En cuanto

a métodos de clasificación se utilizan varios, tanto supervisados (SVM, ELM, Random Forest, Bayesiano...) como no supervisados (KNN, Redes neuronales, ACP...).

A continuación se comentan los estudios que presentan mejores resultados y en qué se ha basado el cálculo de este resultado, ordenándolos en función del método o métodos de clasificación que usan.

Guo et al. [7] propone un método que usa características de longitud de línea basadas en la descomposición multiresolución de transformada de ondas (DWT) y se combina con una red neuronal artificial (ANN) para clasificar las señales de EEG. Evalua la precisión de la clasificación y obtiene un 99,6 % de acierto. Tzallas et al. [8] extraen características con métodos de tiempo-frecuencia de la señal EEG que representan la distribución de energía en este mismo plano. Esas características se utilizan como entrada en una red neuronal artificial (ANN) obteniendo una precisión de entre 97.72 % y 100 %.

Orellana y Cequeira [9] usan un método off-line personalizado para cada paciente que aplica un clasificador de bosque aleatorio. El rendimiento de este método alcanzó el 97,12 % de especificidad, el 99,29 % de sensibilidad y una tasa de falsos positivos de $0,77$ por hora. Mursalin et al. [10] también usan un clasificador de bosque aleatorio con una precisión de la clasificación del 98,45 %. Hussein et al. [11] desarrolla un método basado en regresión robusta penalizada por L1 y con los parámetros obtenidos se alimenta un bosque aleatorio obteniendo entre 90 y 100 % de precisión, sensibilidad y especificidad, dependiendo de las condiciones ambientales de las señales. Sharma et al. [12] usando un clasificador de bosque también obtienen buenos resultados usando como características de la señal la descomposición de ésta en sus funciones de modo intrínseco. Con éste método obtiene una sensibilidad del 98.4 %, una especificidad del 98.6 % y una precisión del 96.4 %.

En cuanto a las Máquinas de vectores de soporte (SVM) tenemos varios ejemplos, mencionamos a continuación algunos de ellos. Zabihi et al. [13] desarrollan un método en el que extraen diferentes características de la señal en el dominio del tiempo, de la frecuencia, del tiempo-frecuencia y características no lineales, para finalmente usar como clasificador una máquina de vectores soporte, con los conjuntos de entrenamiento y test conteniendo el 50 % de ataque y no ataque. Con esto obtienen una sensibilidad del 90.64 % y especificidad del 99.32 %. Subasi et al. [14] usan diferentes configuraciones de los parámetros del kernel para encontrar el que les da mejor precisión de la clasificación, llegando a un óptimo del 99.38 %. También Fasil y Rajesh [15] usan SMV para la clasificación de las señales, en este caso usando características de energía exponencial en el dominio del tiempo. De este modo consiguen 89 % y 99.5 % de precisión con dos conjuntos de datos diferentes.

Finalmente se resumen diferentes estudios que usan combinaciones de métodos. Amin et al. [16] extraen características a partir de la transformada de onda discreta (DWT) y usan diferentes clasificadores y medidas de rendimiento: SVM, Perceptrón multicapa y KNN (K-Nearest Neighbor) por un lado y precisión, sensibilidad, especificidad y valores de precisión. Resumiendo los resultados se podría decir que obtienen más de un 98 % de precisión con los diferentes cla-

sificadores. Raghu y Sriraam [17] extrajeron un conjunto de 28 características del tiempo, la frecuencia y en el dominio estadístico y las características significativas se seleccionaron mediante el análisis de componentes más próximos (NCA), evaluaron el rendimiento del algoritmo utilizando SVM, KNN, el bosque aleatorio y los clasificadores de refuerzo adaptativo (AdaBoost). Los mejores resultados los obtubieron con la SVM: sensibilidad del 97.6 %, especificidad del 94.4 %, precisión del 96.1 %, tasa de predicción positiva del 92.8 % y de predicción negativa del 98,8 %.

Existen muchos estudios más sobre la detección y clasificación de ataques de epilepsia. Se trata siempre de encontrar el equilibrio entre la precisión y la complejidad que tiene el método, dependiendo de la aplicación concreta.

2.2. Machine Learning para Predicción de ataques

Para poder predecir un ataque epiléptico hay que tener un sistema en línea, por lo tanto se debe garantizar que el tiempo de procesado de los datos y clasificación de los mismos no sea mayor que la lectura de la señal. El objetivo es detectar la fase pre-ictal de la señal, zona verde de la figura 2.1. Se añade, por lo tanto, otra variable para evaluar los métodos: el tiempo de anticipación de la predicción respecto al ataque.

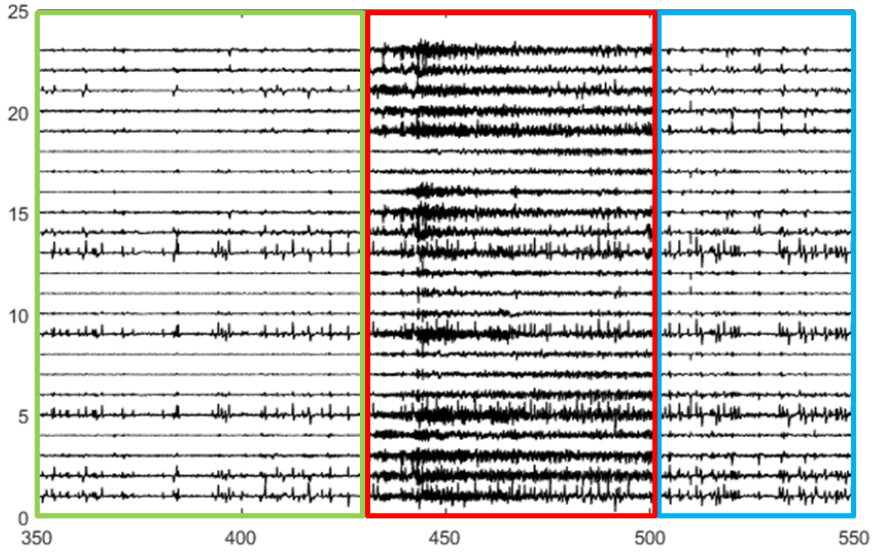

Figura 2.1: Fases pre-ictal (verde), ictal (rojo) y post-ictal (azul) del ataque epiléptico

Este tipo de estudio se remonta a varias décadas atrás. Ya en los años 70 se hicieron las primeras investigaciones para la predicción de ataques de epilepsia y se usaban medidas lineales para la extracción de características [18].

Por supuesto, a medida que ha avanzado el tiempo y la tecnología se han obtenido resultados mejores. Usman y Fong [19] aplican descomposición en modo empirico (EMD) para el pre-procesado de la señal y extraen características en el dominio del tiempo y la frecuencia para predecir los ataques. Con este método consiguen una sensibilidad del 92.23 %, una especificidad del 93.38 % un tiempo máximo de anticipación de la predicción de 33.46 minutos y una media de anticipación de 23.48 minutos.

Bhattacherjee [20] usa la transformada de wavelet compleja de árbol dual (DT-CWT) para procesar la señal y extraer características del dominio del tiempo y la frecuencia. Luego usa una máquina de vector de soporte como clasificador. Con estas técnicas consigue un 85,9 % de precisión y una predicción media de 60 minutos. Zandi et al. [21] desarrollaron un método basado en el análisis de los intervalos de cruce por cero y se sacan medidas de similitud y disimilitud con un modelo de mezcla bayesiana y gaussiana y finalmente se calcula un índice combinado y se compara con un umbral especifico para cada paciente. Se logró una sensibilidad del 88.34 %, una tasa de predicción falsa del 0,155 por hora y una media de tiempo de anticipación de 22.5 minutos. Teixeira et al. [22] hacen un estudio comparativo de varias técnicas de Machine Learning (diferentes redes neuronales y máquinas de vectores de soporte) obteniendo como resultado medio 73.5 % de sensibilidad y 15.8 minutos de anticipación del ataque.

Existen muchos mas estudios a los mencionados, con este resumen puede uno hacerse una idea de en que estado están los estudios hoy en día y qué resultados son competitivos con el estado del arte actual.

Capítulo 3

Un método no supervisado: UMED

El presente trabajo tiene su origen en un método desarrollado previamente para la clasificación de señales multicanal. Dicho método se basa en la detección y caracterización de eventos desconocidos de manera no supervisada, de donde saca su nombre: UMED (Unsupervised Method for Event Detection) [1] [23].

Las señales con las que trabaja UMED se caracterizan por una secuencia de eventos donde el número, la duración y el periodo entre eventos puede cambiar de manera aleatoria. Para poder caracterizar los eventos (cambios en la naturaleza de la señal durante un periodo de tiempo) se transforman estas señales en grupos de secuencias temporales de fácil interpretación y el algoritmo detecta los eventos. Para el caso de UMED se han usado señales de EMG (electromiograma) [1] para detectar movimientos musculares del brazo y de EEG (electroencefalograma) [23] para detectar movimiento de los ojos y la mandíbula.

3.1. Descripción del método UMED

UMED selecciona un conjunto de ventanas por medio de una ventana deslizante que se desplaza a lo largo de la señal multicanal. Cada ventana se particulariza por un vector de características obtenidas por sus coeficientes autorregresivos de orden 2 y que captan el comportamiento de la señal. La detección de los eventos en cada señal multicanal se realiza mediante una clasificación no supervisada de sus vectores de características. La calidad de esta clasificación (y el número de eventos detectados) depende significativamente del tamaño de la ventana deslizante. Es por eso que el algoritmo busca un tamaño de ventana óptimo que proporcione la máxima compacidad y separación del contenido entre los eventos.

A continuación se resume la metodología seguida en UMED.

1. Inicialmente se trocea la señal en ventanas de tamaño L_w mediante un

sistema de ventanas deslizantes donde d es el desplazamiento que se aplica a la ventana.

2. Por cada canal q y ventana $W - i$ se calcula un vector de características calculado con coeficientes autoregresivos y se crea una matriz con todos ellos de tamaño $IN \times Q \times s$ donde IN es el número de ventanas, Q el número de canales y s el número de coeficientes.

3. A continuación se calcula el CCC (Cophenetic Correlation Coefficient) que es la correlación lineal de la distancia a la que estan los objetos en un árbol jerárquico. Si el CCC es menor que un threshold U se vuelven a repetir los pasos 1 y 2 y elegimos un tamaño de ventana mayor. Este proceso se repite hasta que el coeficiente sea mayor de U.

4. Se elige el tamaño de ventana óptimo y se clasifica de modo no supervisado para diferentes números de clusters. Se eligen N_L tamaños de ventana mayores que el obtenido en el punto 3 y se calcula el vector de características de las ventanas por cada tamaño. A continuación se aplica el algoritmo de clustering. Se calcula el índice S_dbw [24] para cada una de estas clasificaciones y se elige el número óptimo de agrupaciones a partir del que tiene el índice S_dbw más bajo.

5. Se agrupan las ventanas consecutivas con la misma clasificación y a estas agrupaciones se llaman intervalos. El inicio y final de estos intervalos se puede definir con la siguiente ecuación:

$$[(i-1) \times d + M \times L_w - \frac{d}{2}, (j-1) \times d + M \times L_w + \frac{d}{2}] \tag{3.1}$$

   Donde i es el número de la primera ventana del intervalo, g el número de la última ventana del intervalo y $M = 6/7$

En la figura 3.1 podemos observar un diagrama de flujo que representa gráficamente el proceso que sigue el método UMED.

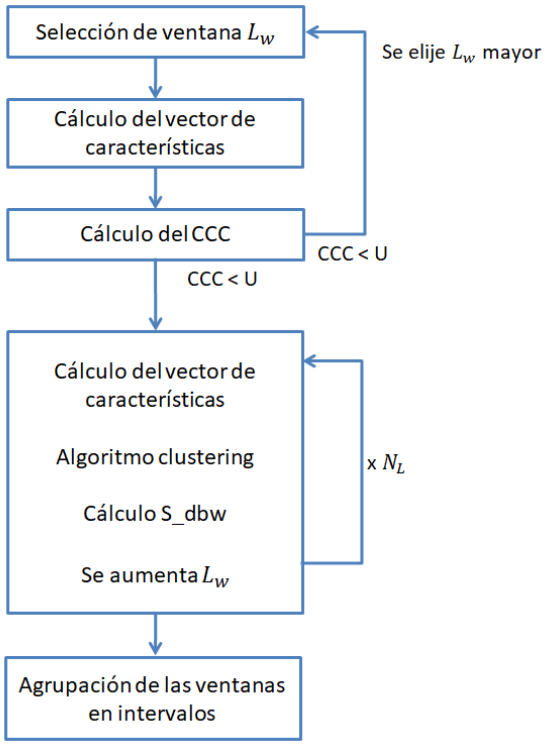

Figura 3.1: Diagrama de flujo del método UMED.

3.2. Testeo de UMED para detección de artefactos

Primero se testea el algoritmo con una señal EEG de 64 canales y de duración de 8 minutos. Existen 6 clases de artefacto en esta señal: ninguno, movimiento de mandíbula, apriete de mandíbula, parpadeo, movimiento del ojo a la izquierdo y movimiento del ojo arriba. Se estudia que valores de CCC y S_dbw se obtienen con ventanas entre $L_w = 135$ y $L_w = 165$ muestras y su número de clusters óptimo. Siguiendo los pasos 1-5 explicados anteriormente se concluye que el tamaño de ventana óptimo es 155 muestras con un número óptimo de clusters de 7.

UMED se compara con un método supervisado que usa las mismas señales de EEG. Éste método concluye que el tamaño óptimo de ventanas es de 128 muestras. Usando este valor para la clasificación no supervisada de UMED se obtiene que la concordancia entre los resultados de ambos métodos es, en el peor de los casos, de más del 80 %. Por lo tanto, UMED obtiene unos resultados parecidos a un método que usa las etiquetas de las señales como referencia. Por

otro lado, con el óptimo encontrado por UMED ($L_w = 155$) se aprecia que las agrupaciones en las que se clasifican las ventanas tienen mayor separación entre ellas.

Para el segundo conjunto de señales (EMG) se prueba el método con 20 señales multicanal diferentes. Se aplican los 5 pasos descritos más alguno extra de caracterización de los eventos y filtrado que no se van a explicar en más profundidad por que no se aplican en el actual trabajo. Se usa un desplazamiento $d = 32$, un modelo autoregresivo AR(2) por cada ventana y se itera entre los tamaños de ventana 200 y 250, comprobando que respetan el límite $U = 0{,}85$. Se concluye que el número óptimo de clusters es 10 con un tamaño de ventana $L_w = 255$.

Con las señales de prueba usadas y estos parámetros se caracterizan todos los eventos correctamente. Este método se podría usar para señales de diferentes campos como: Bioingeniería, Vulcanología, Geofísica, Fusión Nuclear... ya que la naturaleza de las señales que se estudian en ellos es similar a las estudiadas por UMED en el sentido de tener eventos con inicio y duración que pueden variar aleatoriamente.

Capítulo 4

Metodología

En este capítulo se presentan las diferentes aproximaciones que se han utilizado en el desarrollo del método no supervisado propuesto para la detección de ataques en señales de epilepsia. Algunas de estas técnicas se han tomado del método original UMED y otras se han ido buscando y seleccionando según se ha ido avanzando el trabajo. En este apartado se describen las técnicas en el orden cronológico en el que se han implementado en el método propuesto.

4.1. Ventanas deslizantes

Este mecanismo consiste en separar las señales en segmentos más pequeños para facilitar su análisis y comparación. Los segmentos se llamaran ventanas, tienen un tamaño L_w y se toman cada d muestras. Es decir, si la ventana W_i abarca el tramo de señal $[t_1, t_2]$ la ventana W_{i+1} ocupa el tramo $[t_1 + d, t_2 + d]$. Se puede observar una aclaración gráfica en la figura 4.1. Cabe destacar que en nuestro caso, al ser una señal multicanal, cada ventana segmenta todos los canales siguiendo el mismo orden, solo se segmenta la señal en el eje X.

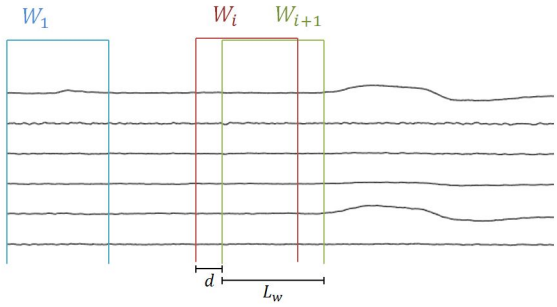

Figura 4.1: Ventanas deslizantes en una señal multicanal EEG.

Todas las ventanas tienen el mismo tamaño, por lo tanto, se puede calcular

el número total de ventanas en un tramo de duración T segundos:

$$n_{\text{windows}} = \left\lfloor \frac{T \times f_s - L_w + d}{d} \right\rfloor \tag{4.1}$$

Donde f_s es la frecuencia de muestreo de la señal de EEG, en nuestro caso todas las señales tienen $f_s = 256Hz$ y $\lfloor \ \rfloor$ representa la parte entera.

En el método UMED del cual se parte se eligieron ventanas de tamaño $L_w = 155$ y $d = 32$. Se parte de estos valores pero también se estudiará como varía el resultado en función de estos parámetros.

Se debe tener en cuenta que se van a filtrar, analizar y clasificar las ventanas enteras. Normalmente el desplazamiento d es más pequeño que L_w para obtener un solapamiento cuando la ventana se desplaza, esto se debe de tener en cuenta al reconstruir la señal cuando se haya clasificado cada ventana, ya que cada ventana representa un tramo menor a L_w para que no se solape o duplique la información.

4.2. Coeficientes Autoregresivos

Tras aplicar el método de ventanas deslizantes la señal queda dividida en un conjunto de ventanas. Cada ventana se caracterizará por un vector de características que representará el comportamiento de la señal multicanal en esa ventana. La selección de las características es un paso muy importante pues determinará la calidad de la clasificación del método.

Un modelo autoregresivo es una representación de un proceso en el que la variable de interés depende de sus observaciones pasadas. Un modelo autoregresivo de orden p para un solo canal se puede escribir como:

$$y(t) = \sum_{i=1}^{p} \alpha_i y(t-i) + \epsilon_t \tag{4.2}$$

Donde p es el número de puntos de tiempo anteriores que se usan para modelar el actual, α los coeficientes autoregresivos y ϵ ruido blanco.

Los coeficientes autoregresivos tienen como propiedad que son invariantes a los cambios de escala. Esta característica es a priori buena para la detección de ataques de epilepsia, ya que los resultados son independientes del sistema de adquisición y, además, la amplitud de una señal puede depender del paciente. De ese modo las variaciones entre pacientes no van a afectar tanto.

Según el estudio realizado por V. Lawern [25] y por herencia del proyecto UMED se ha elegido usar coeficientes autoregresivos de orden 2 para caracterizar cada ventana. Se compone una matriz de coeficientes de $m \times n$ donde m es el número de ventanas y n el de coeficientes autoregresivos de cada ventana, que siempre serán 2 coeficientes por 23 canales, es decir, 46 coeficientes para cada ventana. En la figura 4.2 podemos visualizar un ejemplo de este orden de los coeficientes en la matriz de características.

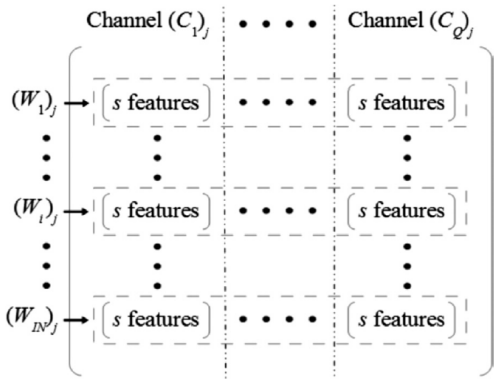

Figura 4.2: Matriz de características de la señal multicanal. Obtenida de [1].

4.3. Análisis de Componentes Principales

El Análisis de Componentes Principales (ACP) es una de las herramientas más ampliamente aplicadas para resumir patrones comunes de variación entre variables. Esto se debe a que es una herramienta simple y no paramétrica aplicable para extraer información relevante de datos de cualquier campo de estudio que se quiera, desde neurociencia hasta infografía. [26]

El ACP toma un conjunto de datos con varias dimensiones y trata de reducirlas perdiendo el mínimo de información posible. Básicamente, se busca un nuevo sistema de coordenadas en el cuál en la primera dimensión se captura la mayor varianza de los datos, en la segunda dimensión la segunda mayor varianza, y así sucesivamente. Los datos resultantes de un análisis ACP son esencialmente combinaciones lineales de los datos originales que capturan la mayor parte de la varianza en los datos.

Una vez se ha conseguido una matriz con los coeficientes de cada ventana y canal, se usa el ACP y se eligen los componentes que tienen más información, los n primeros. En nuestro caso se han realizado pruebas con 2 y 3 componentes y también escogiendo los componentes que conjuntamente contienen el 90 % de la información.

4.4. Algoritmos de clustering: k-means y Jerárquico

El objetivo del trabajo es un método no supervisado de clasificación, por lo tanto, se utilizan métodos de clustering. El clustering consiste en agrupar puntos de características similares y determinar patrones entre ellos. Existen diferentes métodos: unos buscan un número concreto de agrupaciones finales, otros una separación mínima entre las diferencias de los clusters. De entre los existentes se utiliza el método jerárquico que se empleaba en método UMED y por otro

lado se ha decidido añadir al estudio el método K-means.

El agrupamiento jerárquico [27] es un método de análisis de grupos puntuales, en el cual se busca construir una jerarquía de grupo, basándose en la distancia entre los grupos. En la figura 4.3 tenemos un ejemplo de un dendrograma, que representa la jerarquía entre los componentes del grupo, representados en el eje X, y a que distancia están, eje Y. Cuanto más abajo se junten dos componentes más similares son, por lo tanto se puede definir la altura a la que se separan los grupos sin saber cuantos grupos obtendremos al final o bien cuantos grupos queremos obtener sin saber cuan separados estarán. La altura a la que está el enlace entre dos componentes se denomina distancia cofenética. El coeficiente de correlación cofenética es la correlación linear entre las distancias de todo el dendrograma. Este coeficiente se puede usar para saber la fidelidad de la clasificación, cuanto más cercano a 1 sea este coeficiente mejor es la clasificación.

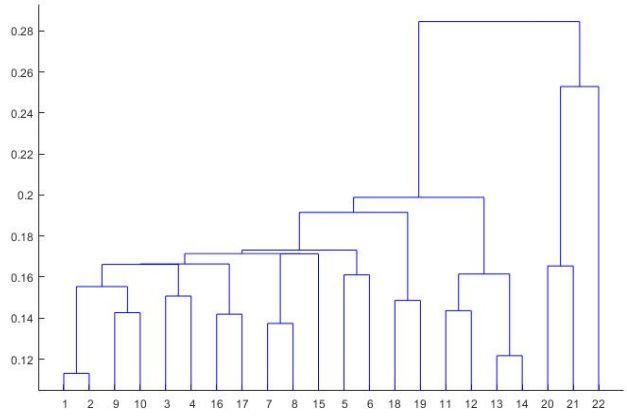

Figura 4.3: Dendrograma del método jerárquico.

Por otro lado el K-means [28][29], tiene como objetivo la partición de un conjunto de n observaciones en k grupos en el que cada observación pertenece al grupo cuyo valor medio es más cercano. Este método es iterativo, empieza asignando k centros de agrupación y en la primera iteración calcula la distancia entre todos los puntos y los centros de agrupación, asigna cada observación a su agrupación más cercana. Para la siguiente iteración calcula los nuevos centros de grupo y vuelve a calcular la distancia entre las observaciones y estos. Este proceso se sigue n veces o hasta que no haya cambios durante algunos ciclos.

4.5. Índices: Sdbw y Silhouette

Una vez se ha agrupado en diferentes clusters todas las ventanas de la señal se usan unos índices para cuantificar cómo de buena es esa agrupación y, en teoría, con el mejor valor de índice obtendríamos la mejor detección de ataque de

epilepsia. Miden la calidad del resultado de un clustering basándose en lo densos, compactos y distanciados que están los agrupamientos. Se usan los siguientes índices:

S_dbw[24]: Cuanto menor sea su valor mejor es la clasificación del conjunto.

Silhouette[30]: Cuanto mayor sea su valor mejor es la clasificación del conjunto.

Se elige un rango de valores de número de clusters y se calculan estos índices para cada valor, en principio tendríamos que ver un pico, que sería nuestro valor óptimo de número de clusters. En nuestro caso el rango de valores es $[2, 20]$, ya que hay dos casos en las señales: ataque y no ataque, y se considera adecuado dejar de margen hasta 20 clusters para ver si es posible detectar un patrón de clusters previos al ataque para la detección del mismo.

4.6. Sensibilidad y Especificidad

La sensibilidad y la especificidad [31] son términos que nos ayudan a evaluar clasificaciones binarias. Concretamente la sensibilidad nos indica la probabilidad de que un verdadero positivo sea clasificado como tal, en nuestro caso nos indica la probabilidad de que una ventana con ataque epiléptico sea clasificada como ataque. En cambio, la especificidad calcula la probabilidad de que un verdadero negativo sea clasificado como negativo, por lo tanto, en el caso de este estudio de que una ventana sin ataque sea clasificada como no ataque.

Las ecuaciones que calculan estos dos términos son las siguientes:

$$Sensibilidad = \frac{VP}{VP + FN} \tag{4.3}$$

$$Especificidad = \frac{VN}{VN + FP} \tag{4.4}$$

Donde VP indica el número de verdaderos positivos (ventanas con ataque epiléptico en las que se detecta el ataque), VN el de verdaderos negativos (ventanas sin ataque clasificadas como no-ataque), FP el número de falsos positivos (ventanas clasificadas como ataque que no contienen ataque en realidad) y FN el de falsos negativos (ventanas con ataque clasificadas como si no tubieran ataque). No es muy habitual usar estas probabilidades en métodos no supervisados, pero se ha decidido calcularlos en cada prueba para hacernos una idea más consolidada de los resultados que se van obteniendo, aparte de los índices explicados en el apartado anterior.

4.7. Filtro adaptativo

Como novedad respecto al método UMED se plantea filtrar la señal antes de analizarla y procesarla. Este tipo de filtro está extraído del estudio realizado por A. Garcés [32]. A diferencia de otros filtros digitales el adaptativo varía en el tiempo sus coeficientes del filtro lineal $H(z)$ y su frecuencia para predecir

la señal, y obtener un error calculando la diferencia entre la señal de salida y la real. Teniendo en cuenta el cambio que provoca el ataque de epilepsia en la señal, con el error de salida del filtro se puede hacer el análisis y clasificación para obtener la detección e incluso predicción de ataques de epilepsia.

En la figura 4.4 podemos observar un ejemplo de un filtrado adaptativo de un solo canal de EEG. En la primera figura 4.4a tenemos la señal obtenida directamente de la base de datos, en la figura 4.4b la señal a la salida del filtro y en la última 4.4c el error calculado como la diferencia entre las dos primeras señales. Se observa que a simple vista no hay mucha diferencia entre las señales de entrada y de salida, por eso también la magnitud del error es menor que la de las señales.

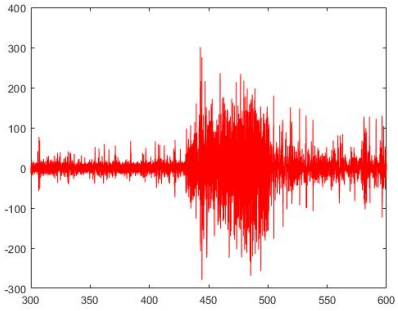

(a) Señal de EEG

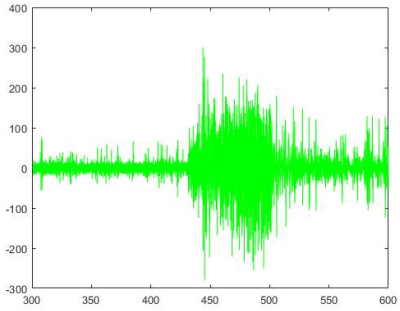

(b) Señal a la salida del filtro

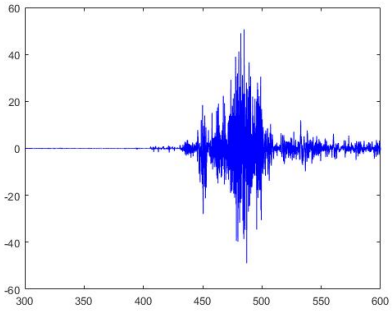

(c) Error

Figura 4.4: Filtrado adaptativo de una señal de EEG

La idea principal es que usando el error como señal de análisis se pueden obtener mejores resultados ya que se puede observar más diferencia proporcionalmente entre los tramos de ataque y los de no ataque que en la señal inicial. Por otro lado, el inconveniente es que hay menos información disponible para una predicción del ataque.

Capítulo 5

Desarrollo y resultados

En este capítulo se recogen los resultados y análisis más significativos que se han realizado.

5.1. Método No Supervisado Implementado

Haciendo uso de las técnicas comentadas en el Capítulo 4 en este trabajo y utilizando Matlab, se ha implementado el siguiente método no supervisado para la detección de ataques en señales de epilepsia:

- Leer los ficheros con la señal EEG, donde se puede elegir que tramo leer y guardar el intervalo donde estaba el ataque (inicialmente y para simplificar se leen tramos con un único ataque).
- Separar la señal en ventanas.
- Se pasan las ventanas por un modelo autoregresivo de segundo grado (AR(2)).
- Se realiza un Análisis de Componentes Principales con los 46 componentes resultantes de los 23 canales. Se ha decidido usar para la clasificación el número de componentes principales que contiene el 90 % de la información.
- Se realiza la clasificación con uno de los dos métodos: k-means o Jerárquico. Como características de entrada de la función se usan todos o algunos componentes calculados en el punto anterior. Se obtiene una imagen de los canales de EEG con cada ventana pintada con el color de su cluster.
- Se observa qué clusters tienen un porcentaje elevado de sus ventanas dentro del ataque y se divide la clasificación en 2: ataque y no ataque.
- Se compara la clasificación de cada ventana con su naturaleza real. A partir de aquí se puede obtener un resumen de los verdaderos positivos,

verdaderos negativos, falsos positivos y falsos negativos, así como los valores de los índices S_dbw, Silhoutte y, en caso de haber usado el método Jerárquico, el coeficiente CCC. Para facilitar el estudio se realizan unas imágenes en que se muestran las ventanas ordenadas temporalmente o bien según sus componentes principales. En la sección siguiente se ilustra con un ejemplo.

- Se agrupan las ventanas consecutivas con misma clasificación en intervalos.

5.2. Primer ejemplo ilustrativo del método

Con la finalidad de dar una visión global del método que se acaba de comentar, en esta sección se muestra un ejemplo del método propuesto.

Usaremos el tramo de señal 03 del paciente 03, que contiene un ataque desde $t = 432s$ hasta $t = 501s$, lo analizaremos en el tramo 350-550 s. En la figura 5.1 podemos observar los tres primeros canales de la señal, las líneas verticales rojas indican el inicio y final del ataque. Como la frecuencia de muestreo de las señales es de $256Hz$ tenemos 51200 muestras. Para este caso vamos a suponer que el tamaño que se selecciona para la ventana es $L_w = 350$ y para el desplazamiento $d = 32$. Por lo tanto, usando la ecuación 4.1 obtenemos 1590 ventanas. Además en este ejemplo se considerarán 5 clusters, 12 componentes principales y se utilizará como método de clustering en método jerárquico.

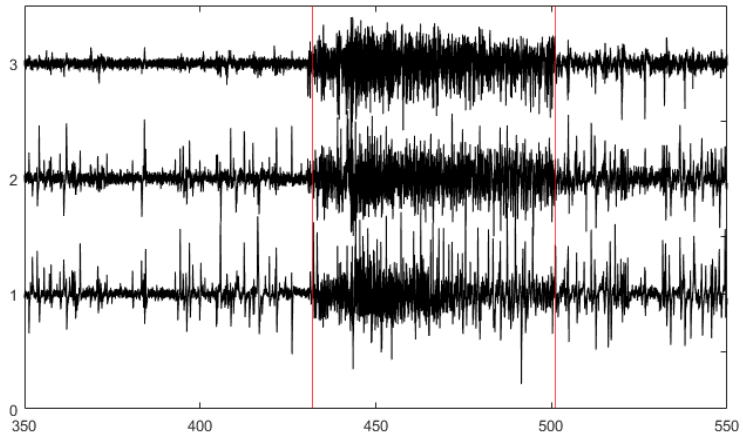

Figura 5.1: 3 canales de la señal usada como ejemplo, con el ataque marcado.

El coeficiente cophenetico obtenido es $CCC = 0{,}7656$. En la figura 5.2 observamos la señal EEG del tramo 350-550 s con el ataque marcado como en la figura 5.1 (mediante las líneas verticales rojas) pero esta vez observando todos los canales. Los tramos de colores indican los intervalos, es decir, las agrupaciones

de ventanas consecutivas iguales. Por lo tanto, según esta clasificación podemos deducir que todos los tramos coloreados en cian son ventanas agrupadas en el mismo cluster y parecidas entre ellas. Del mismo modo las otras agrupaciones obtenidas, mostradas en rosa, verde, rojo y azul oscuro representan los distintos clusters de ventanas que se obtienen.

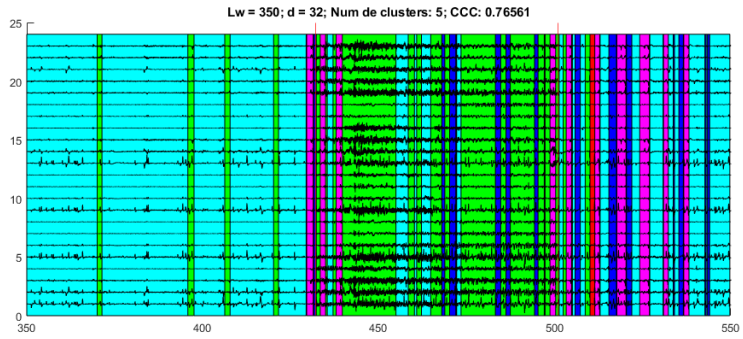

Figura 5.2: Clasificación de ventanas de la señal EEG del tramo 350-550s con $L_w = 350$, $d = 32$, 5 clusters y 12 componentes principales.

A partir de ahí se observa qué agrupaciones tienen más ventanas dentro del ataque, a estos se los considera ataque epiléptico. En la figura 5.2 vemos que entre las dos lineas verticales rojas que indican el ataque hay muchos intervalos verdes. De manera automática el programa realizado detecta este hecho y considera que si un cluster tiene más del 40 % de sus ventanas dentro del ataque es ataque epiléptico. En nuestro ejemplo tenemos dos clusters que indican ataque epiléptico: el verde y el azul oscuro. Por consiguiente tres clusters que indican no ataque: rojo, cian y rosa.

Con esta agrupación de clusters en dos grupos (ataque y no ataque) podemos obtener la matriz de confusión expresada en la tabla 5.1. Esta matriz indica los cuatro posibles estados de una clasificación binaria: predicho como positivo y su valor real es positivo (verdadero positivo), predicho como positivo pero su valor real es negativo (falso positivo), predicho como negativo y su valor real es negativo (verdadero negativo) y predicho como negativo y su valor real es positivo (falso negativo). Con estos datos y usando las ecuaciones 4.3 y 4.4 podemos calcular la $sensibilidad = 0{,}79$ y la $especificidad = 0{,}86$. En nuestro caso el término positivo indica ataque epiléptico y el término negativo indica que ese tramo no contiene ataque.

		Valor predicho	
		Positivo	Negativo
Valor real	Positivo	430	112
	Negativo	145	903

Tabla 5.1: Matriz de confusión

Otro modo de visualizar los datos es representando cada ventana según sus dos primeros componentes principales, el primero en el eje X y el segundo en el eje Y. En la figura 5.3 tenemos 3 formas de pintar estos datos para que nos ayuden a comparar las clasificaciones realizadas. En la figura 5.3a observamos el análisis ACP coloreado con 2 colores: verde y rojo, el primero indica las ventanas que no tienen ataque realmente y el segundo las que tienen ataque. Esta figura nos servirá como comparación con la realidad. En la segunda figura 5.3b tenemos pintadas las ventanas según el cluster en el que han sido clasificadas. Debe observarse que los colores coinciden con los de la figura 5.2. Finalmente, en la última figura 5.3c podemos ver los cuatro diferentes estados expresados en la matriz de confusión 5.1 siendo verde el verdadero positivo, rojo el verdadero negativo, amarillo falso negativo y rosa falso positivo.

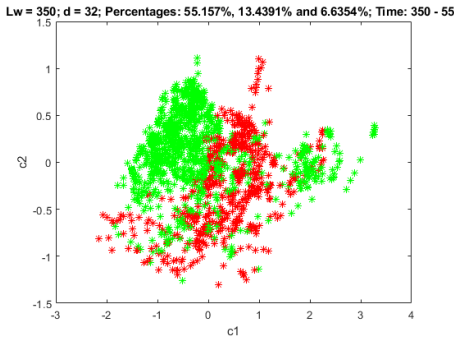

(a) rojo: ataque, verde: no ataque

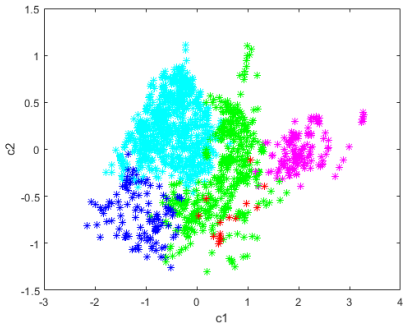

(b) Clasificación realizada

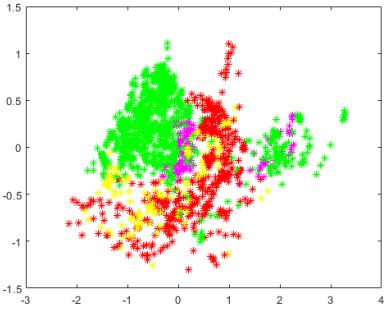

(c) verde: VP, rojo: VN, amarillo: FN, rosa: FP

Figura 5.3: Representación de los dos primeros componentes de cada ventana.

Finalmente se obtienen los índices $S_dbw = 0{,}2858$ y $Silhouette = 0{,}3804$.

Terminada la primera ejecución del algoritmo se analiza el resultado y se varía el tamaño de la ventana, el desplazamiento, el número de componentes principales que se usa para la clasificación o el número de clusters en que se quiere separar la señal.

Este primer ejemplo, utilizado como ilustración del método servirá como punto de comparación de las siguientes pruebas y ejemplos que se realicen.

5.3. Análisis del filtro adaptativo

Se ha realizado un ánalisis del método propuesto cuando las señales son filtradas mediante el filtro adaptivo presentado en la sección 4.7. Se usa la señal de error (diferencia entre la salida y la señal deseada) del filtro para el análisis. En la figura 5.4 vemos como la señal tiene menos picos que su equivalente del ejemplo anterior (figura 5.1) y por lo tanto se ve un poco más limpia.

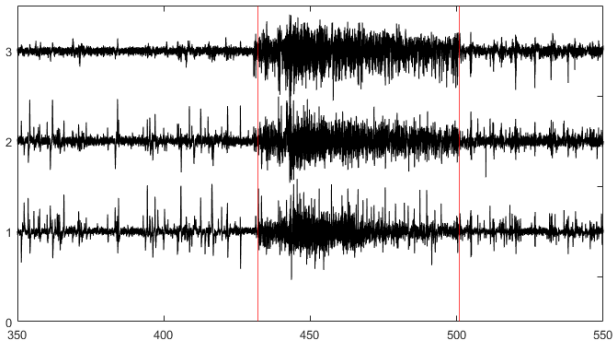

Figura 5.4: 3 canales de la señal filtrada, con el ataque marcado.

Para poder realizar una comparación más exacta se mantienen las variables del primer ejemplo ($L_w = 350$, $d = 32$, 5 clusters, 12 componentes principales y método jerárquico) y se obtiene la clasificación mostrada en la figura 5.5. El resto de figuras de este ejemplo se encuentran en el anexo B.

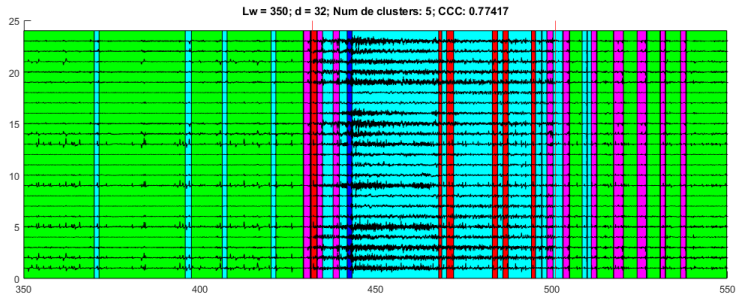

Figura 5.5: Clasificación de ventanas de la señal EEG filtrada del tramo 350-550s con $L_w = 350$, $d = 32$, 5 clusters y 12 componentes principales.

En cuanto a datos numéricos obtenemos los siguientes: $CCC = 0{,}7742$, Sensibilidad = 0.93, Especificidad = 0.9, $Sdbw = 0{,}2170$ y $Silhouette = 0{,}2659$. Por lo tanto, todos los datos excepto Silhouette, que es un poco más bajo, indican que es mejor clasificación que la realizada sin filtro. También gráficamente se observa a simple vista que los intervalos estan más definidos en el segundo ejemplo. No es un caso aislado, ya que se ha observado una mejora en los datos al usar el filtro adaptativo para la mayoría de combinaciones de variables.

5.4. Estudio sobre el ACP

En esta sección se analizar la utilidad del Análisis de Componentes Principales para la clasificación de ventanas, y en caso de ser útil cuántos componentes se deben usar.

En la figura 5.6 se representa la clasificación de las ventanas de la señal estudiada en el apartado 5.2 con los mismos datos y variables, a excepción de que en ese estudio no se utilizaba el análisis de componentes principales, sino los coeficientes AR de la ventanas como características para la clasificación de las observaciones. De la imagen no hay forma de distinguir qué tramo contiene ataque y cuál no. No son mejores el resto de resultados numéricos de este ejemplo: $S_dbw = 0{,}3495$, $Silhouette = 0{,}2849$, $CCC = 0{,}7692$, $Sensibilidad = 0{,}062$ y $Especificidad = 1$. La especificidad tan alta se debe a que se han considerado prácticamente todas las ventanas como no ataque.

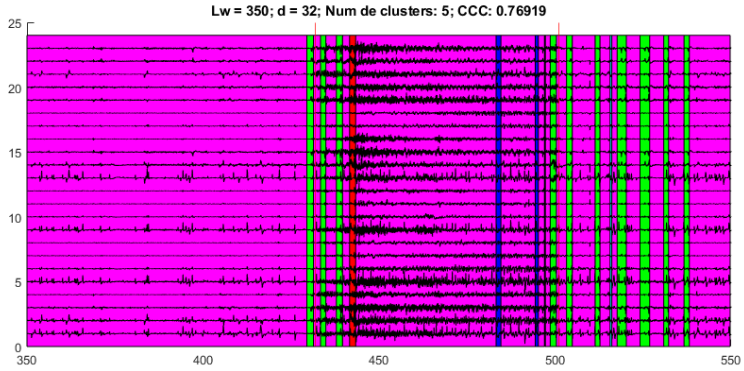

Figura 5.6: Clasificación de ventanas de la señal EEG del tramo 350-550s con $L_w = 350$, $d = 32$, 5 clusters y sin usar ACP.

En la figura 5.7 se puede observar gráficamente qué porcentaje de información contiene cada componente principal y sus anteriores. Observamos como los primeros aportan mucha información (el primero solo ya tiene el 55 %) y los del final muy poca (del 25 al 46 sube menos de un 2 %). Se decide mantener el valor de 90 % como punto intermedio entre tener mucha información y no cargar con componentes innecesarios el método de clustering.

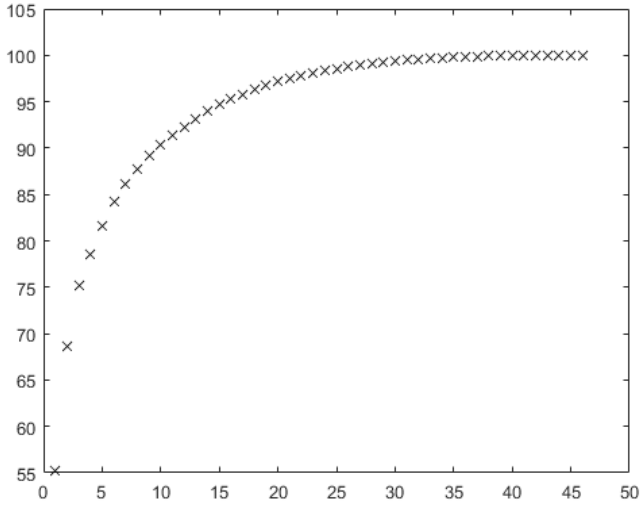

Figura 5.7: Porcentaje de información que contiene cada componente principal con sus anteriores.

5.5. Análisis de selección de tamaño de ventana

En el método propuesto un paso fundamental es la selección del tamaño de ventana en la que dividimos la señal multicanal. Para poder fijar un tamaño adecuado de ventana se ha desarrollado un script diferente para poder analizar varios tamaños de ventana y números de clusters y compararlos a la vez, iterando sobre las dos variables. En este caso no extraemos ningún resultado gráfico, solamente el índice *Silhouette*.

Se aprovecha este apartado para introducir un segundo tramo de la señal con la que se ha trabajado, perteneciente al mismo paciente. Se trata del tramo 04, en el que el ataque epiléptico está entre el segundo 2162 y 2214 y nosotros analizamos el tramo del 2000s al 2300s.

Para cada tamaño de ventana entre 50 y 1500 aumentando de 50 en 50 se calcula el valor del índice *Silhouette* de la clasificación con el método k-means y el método jerárquico. Por cada ventana se calcula el índice para los números de clusters entre 2 y 20. El desplazamiento se mantiene siempre en $d = 32$ y se usan los componentes principales que aportan el 90 % de la información. Por cada tamaño de ventana obtenemos un cuadro similar al mostrado en la tabla 5.2.

Para cada ventana se almacena el número de clusters cuyo índice de Silhouette es más alto para cada uno de los métodos de clustering (en el caso de la tabla 5.2 sería el de 2 clusters para k-means y 3 en jerárquico) y comparamos todos los tamaños de ventana. Como resultado se obtiene la tabla 5.3. La tendencia

Lw	500	nº clusters	k-means	Jerárquico
d	32	2	0.4076	0.3840
nº windows	2385	3	0.3997	0.3878
nº comp	11	4	0.3481	0.3148
CCC	0.6951	5	0.3660	0.3258
		6	0.3541	0.3284
		7	0.3626	0.3207
		8	0.3424	0.3259
		9	0.3662	0.3142
		10	0.3692	0.3266
		11	0.3635	0.3135
		12	0.3710	0.3271
		13	0.3539	0.3169
		14	0.3414	0.3228
		15	0.3358	0.3380
		16	0.3648	0.3012
		17	0.3360	0.3067
		18	0.3494	0.3022
		19	0.3535	0.2963
		20	0.3473	0.2881

Tabla 5.2: Índices de Silhouette resultante de aplicar el método k-means o jerárquico para un tamaño de ventana $L_w = 500$, desplazamiento $d = 32$ y número de clusters entre 2 y 20

del CCC y del índice de Silhouette es ir aumentando, tanto para el método jerárquico como para el K-means. En cuanto al valor del número óptimo de clusters en las ventanas menores de 600 siempre es 2 o 3, pero son resultados que no se pueden tener en cuenta ya que los índices son demasiado bajos.

Lw	**nº win**	**nº comp**	**CCC**	**nº clust**	**k-means**	**nº clust**	**Jerar**
50	2399	15	0.6287	2	0.2952	2	0.2769
100	2397	15	0.6461	2	0.3220	2	0.2720
150	2396	15	0.6498	2	0.3305	2	0.2608
200	2394	14	0.6599	3	0.3480	2	0.3790
250	2393	13	0.6781	3	0.3672	2	0.3612
300	2391	13	0.6780	3	0.3764	2	0.4110
350	2390	12	0.6838	3	0.3856	2	0.3743
400	2388	11	0.6710	3	0.3950	2	0.4201
450	2386	11	0.7039	3	0.3985	2	0.4202
500	2385	11	0.6951	2	0.4076	3	0.3878
550	2383	10	0.6981	2	0.4101	3	0.3949
600	2382	10	0.7085	2	0.4249	16	0.3738
650	2380	10	0.7151	2	0.4229	3	0.4087
700	2379	10	0.6941	20	0.4258	18	0.3718
750	2377	9	0.7147	15	0.4614	16	0.4159
800	2376	9	0.7115	15	0.4605	14	0.4376
850	2374	9	0.7045	15	0.4744	17	0.4451
900	2372	9	0.7121	13	0.4797	14	0.4561
950	2371	9	0.7155	13	0.4905	20	0.4257
1000	2369	8	0.6954	16	0.5098	20	0.4655
1050	2368	8	0.7244	19	0.5135	2	0.5007
1100	2366	8	0.7269	15	0.5297	19	0.4902
1150	2365	8	0.7281	19	0.5327	15	0.4875
1200	2363	8	0.7378	17	0.5407	13	0.4770
1250	2361	8	0.7376	16	0.5532	12	0.5048
1300	2360	8	0.7136	15	0.5429	17	0.5036
1350	2358	8	0.7216	20	0.5606	13	0.5168
1400	2357	8	0.7230	19	0.5615	13	0.5333
1450	2355	8	0.7281	20	0.5723	19	0.5442
1500	2354	8	0.7298	17	0.5732	19	0.5404

Tabla 5.3: Comparación de los resultados de cada tamaño de ventana con mayor índice de Silhouette

De este análisis se puede concluir que el tamaño de ventana que obtiene mejores resultados es significativamente mayor (alrededor de las 1000 muestras) que el que suponíamos inicialmente de 155 muestras, herencia del método UMED.

En esta prueba se realiza el análisis para ambos métodos de clasificación: Jerárquico y K-means. No se obtiene una diferencia clara entre ellos sobre cuál da mejores resultados. Más bien se decide usar ambos para ver si coinciden los tamaños de ventanas óptimos de ambos.

A partir del estudio de los diferentes tamaños de ventana se quiere profundizar en los que han dado mejores resultados. Para ello se eligen los tamaños de ventana que tengan al menos uno de los índices de Silhouette entre ambos métodos que sea mayor de 0.5. Este criterio selecciona las ventanas entre 1000

y 1500 segundos. Entre ellas se eligen varias para hacer la comparación con los siguientes criterios:

- Mayor CCC
- Mayor índice de Silhouette
- Menor diferencia entre el número de clusters calculado con k-means y con jerárquico
- Menor número de clusters con los dos índices mayores de 0.5

A continuación se explican en profundidad todos los casos usando el mismo código de Matlab que en el primer ejemplo para poder visualizar los resultados numérica y gráficamente.

5.5.1. CCC más alto

El caso que tiene mayor CCC es el del tamaño de ventana $L_w = 1200$ con $CCC = 0{,}7378$. Para 1200 muestras de ventana los índices que han resultado mayores son con 17 clusters usando K-means y con 13 clusters usando método jerárquico. En la tabla 5.4 se muestran el índice de Silhouette, S_dbw, sensibilidad y especificidad de este caso usando método k-means y jerárquico. En la figura 5.8 podemos observar como queda la clasificación de los intervalos en el caso de usar K-means y en la figura 5.9 para el método jerárquico. Las figuras que muestran las ventanas según sus dos primeros componentes principales se encuentran en el anexo B.

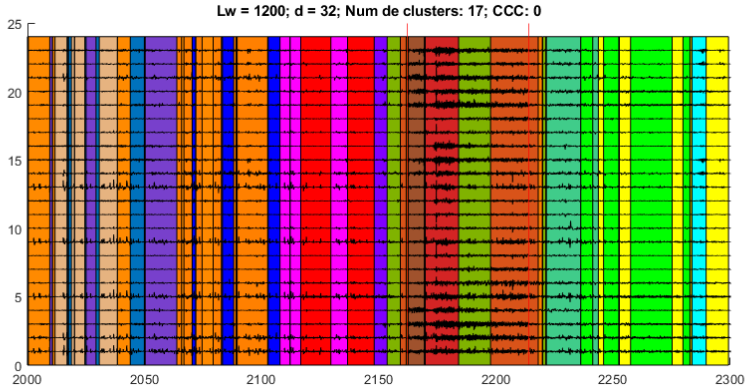

Figura 5.8: Señal EEG con los intervalos coloreados según el criterio de CCC más alto para k-means, usando $L_w = 1200$, $d = 32$, filtro adaptativo, 17 clusters y 8 componentes principales.

	Silhouette	S_dbw	Sensibilidad	Especificidad
K-means	0.5407	0.104	1	0.9244
Jerárquico	0.477	0.1174	1	0.9168

Tabla 5.4: Resultados numéricos para el tamaño de ventana elegido según el criterio de CCC más alto.

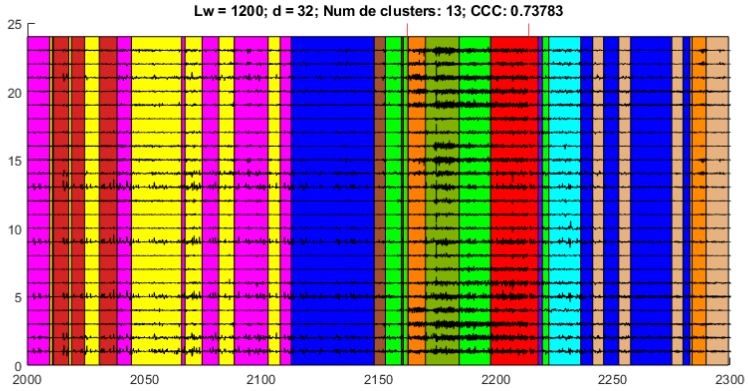

Figura 5.9: Señal EEG con los intervalos coloreados según el criterio de CCC más alto para jerárquico, usando $L_w = 1200$, $d = 32$, filtro adaptativo, 13 clusters y 8 componentes principales.

5.5.2. Mayor índice de Silhouette

El mayor índice de Silhouette se obtiene al aplicar el método de clustering k-means con 17 clusters en la señal troceada en ventanas de 1500 muestras de tamaño. El índice obtenido es de 0.5732. Obtenemos la clasificación mostrada en la figura 5.10, un índice $S_dbw = 0{,}0917$, una sensibilidad de 1 y una especificidad de 0.9209. En la tabla 5.5 se resumen estos resultados. En el anexo B podemos encontrar las tres figuras que muestran las ventanas según sus dos primeros componentes y coloreadas en función de su clasificación.

	Silhouette	S_dbw	Sensibilidad	Especificidad
K-means	0.5732	0.0917	1	0.9209

Tabla 5.5: Resultados numéricos para el tamaño de ventana elegido según el criterio de índice de Silhouette más alto.

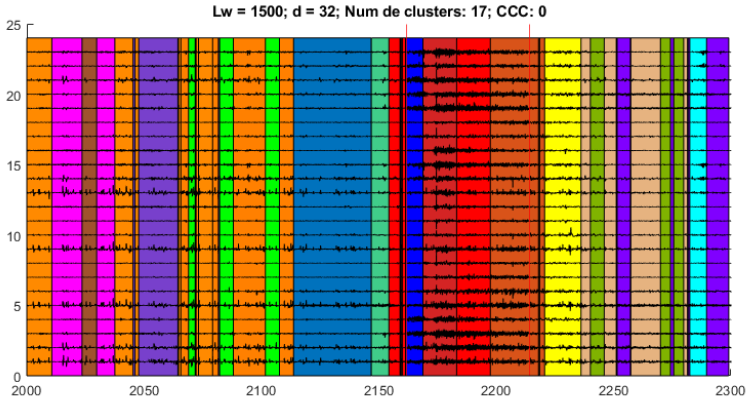

Figura 5.10: Señal EEG con los intervalos coloreados según el criterio de mayor índice de Silhouette, usando $L_w = 1500$, $d = 32$, filtro adaptativo, 17 clusters y 8 componentes principales.

5.5.3. Menor diferencia de clusters entre los dos métodos

Este criterio pretende buscar cuando ambos métodos tienen el mismo número óptimo de clusters, o en caso de que no se cumpla nunca, el más cercano. En nuestro caso se cumple con la ventana $L_w = 1450$ donde k-means obtiene su óptimo en 20 clusters y el jerárquico en 19. Para estudiar bien este caso vamos a realizar el test para los 4 posibles casos: k-means con 20 clusters, k-means con 19, jerárquico con 20 y jerárquico con 19.

Los resultados numéricos de estos ejemplos se encuentran resumidos en la tabla 5.6. El CCC obtenido para este tamaño de ventana con el método jerárquico es de 0.728. En la figura 5.11 se observa gráficamente la clasificación para el caso de k-means con 20 clusters, en la figura 5.12 para k-means con 19 clusters, 5.13 método jerárquico con 20 clusters y 5.14 método jerárquico con 19 clusters. Podemos encontrar más figuras de estos resultados en el anexo B.

	Silhouette	**S_dbw**	**Sensibilidad**	**Especificidad**
K-means 20 clusters	0.5723	0.0772	1	0.9375
K-means 19 clusters	0.5483	0.083	1	0.9163
Jerárquico 20 clusters	0.5442	0.0841	1	0.9168
Jerárquico 19 clusters	0.5347	0.0805	1	0.9108

Tabla 5.6: Resultados numéricos para el tamaño de ventana elegido según el criterio de menor diferencia de clusters entre los dos métodos.

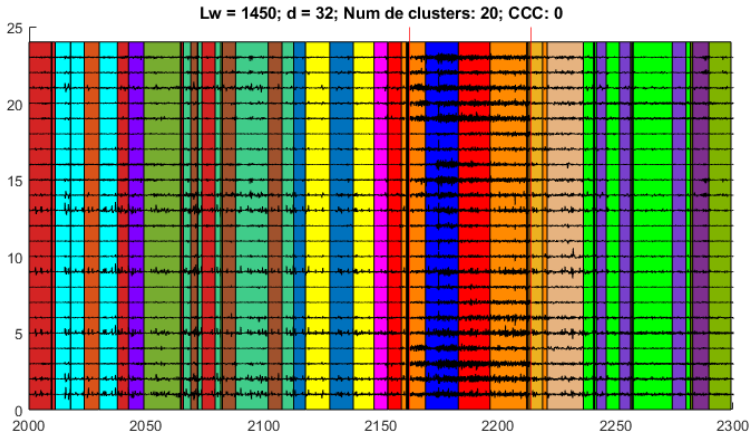

Figura 5.11: Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método k-means, $L_w = 1450$, $d = 32$, filtro adaptativo, 20 clusters y 8 componentes principales.

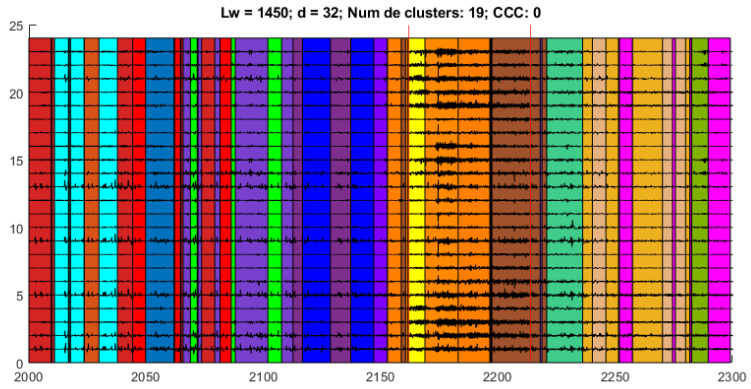

Figura 5.12: Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método k-means, $L_w = 1450$, $d = 32$, filtro adaptativo, 19 clusters y 8 componentes principales.

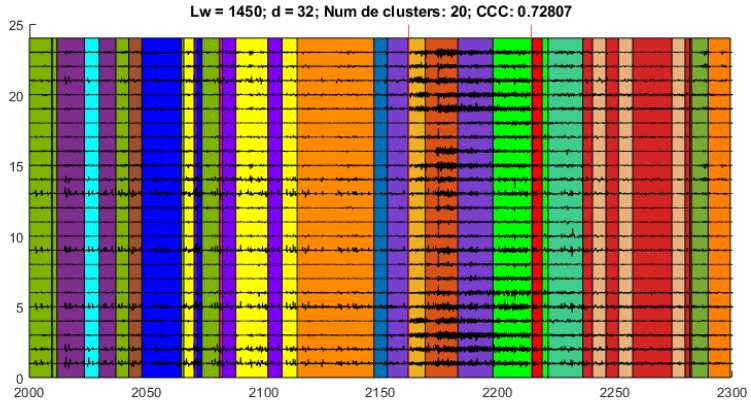

Figura 5.13: Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método jerárquico, $L_w = 1450$, $d = 32$, filtro adaptativo, 20 clusters y 8 componentes principales.

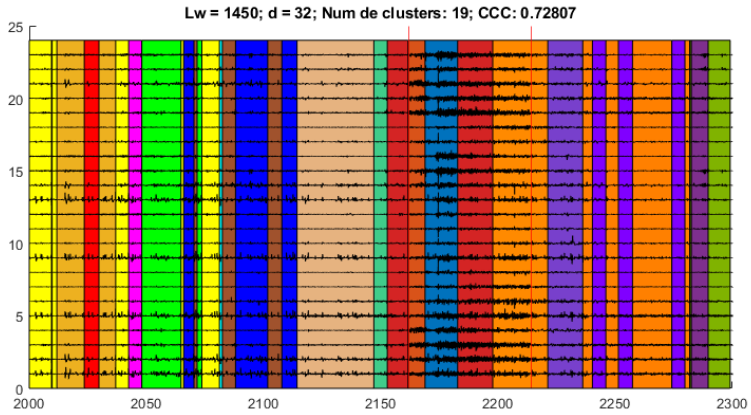

Figura 5.14: Señal EEG con los intervalos coloreados según el criterio de menor diferencia entre el número de clusters: método jerárquico, $L_w = 1450$, $d = 32$, filtro adaptativo, 19 clusters y 8 componentes principales.

5.5.4. Menor numero de clusters con los dos ındices mayores de 0.5

Para este criterio se debe buscar en la tabla que contiene los índices de Silhouette de todas las combinaciones de número de ventana y número de clusters, a diferencia de la tabla 5.3 en la que solo aparecen los mayores índices de cada ventana. Esta tabla la podemos encontrar en el anexo A. Entre ellos

hemos buscado el que para un valor mínimo de índice de Silhouette de 0.5 en ambos métodos de clustering tenga el menor número de clusters. Esta condición se cumple con el tamaño de ventana $L_w = 1500$ y 10 clusters. Hemos realizado el estudio para ambos métodos.

En la figura 5.15 podemos observar el resultado de aplicar el método jerárquico a las ventanas de tamaño 1500 con 10 clusters. Por otro lado, en la figura 5.16 vemos el resultado del mismo test aplicando el método k-means. Para más figuras de este ejemplo debemos consultar el anexo B. En la tabla 5.7 se resumen los resultados numéricos para ambos métodos.

	Silhouette	**S_dbw**	**Sensibilidad**	**Especificidad**
K-means	0.5392	0.1417	1	0.8926
Jerárquico	0.5001	0.1384	1	0.9113

Tabla 5.7: Resultados numéricos para el tamaño de ventana elegido según el criterio de menor número de clusters con un índice de Silhouette mayor de 0.5.

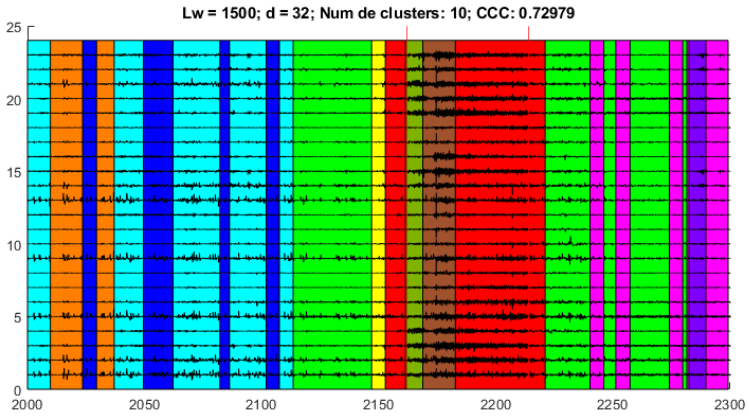

Figura 5.15: Señal EEG con los intervalos coloreados según el criterio de menor número de clusters con índice de Silhouette mayor a 0.5: método jerárquico, $L_w = 1500$, $d = 32$, filtro adaptativo, 10 clusters y 8 componentes principales.

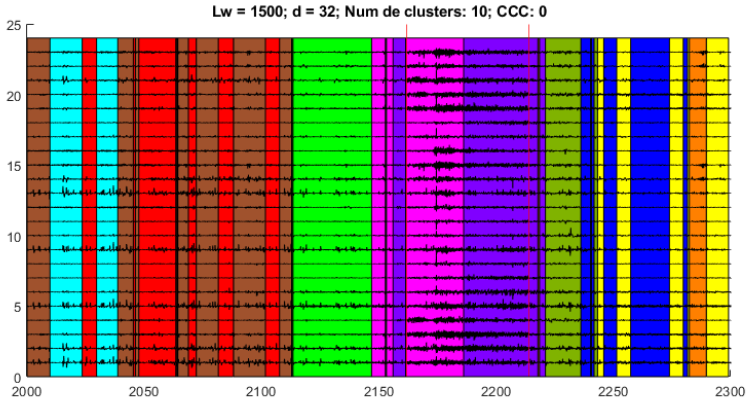

Figura 5.16: Señal EEG con los intervalos coloreados según el criterio de menor número de clusters con índice de Silhouette mayor a 0.5: método k-means, $L_w = 1500$, $d = 32$, filtro adaptativo, 10 clusters y 8 componentes principales.

5.6. Análisis de selección de desplazamiento

En esta sección se pretende estudiar como varía el resultado de la clasificación modificando el desplazamiento de las ventanas. Un desplazamiento pequeño garantiza una resolución de la detección pequeña, mientras que con un desplazamiento grande se realizan menos cálculos para hacer pero se pierde calidad de detección.

Se prueban los tamaños 32 (original), 128 (4 veces el original), 256 (8 veces el original) y 384 (12 veces el original). Partimos de un tamaño de ventana $L_w = 1500$ y 10 clusters.

Empezamos con el análisis del método k-means, en la tabla 5.8 se exponen los índices S_dbw y Silhouette y la sensibilidad y especificidad para cada uno de los desplazamientos elegidos en el estudio.

d	**32**	**128**	**256**	**384**
Silhouette	0.5392	0.5096	0.487	0.4665
S_dbw	0.1415	0.152	0.1438	0.1463
Sensibilidad	1	1	1	1
Especificidad	0.8926	0.9294	0.8992	0.8916

Tabla 5.8: Resultados numéricos del análisis de selección de desplazamiento para el método k-means.

Por otro lado, en la tabla 5.9 estan los resultados del método jerárquico.

d	32	128	256	384
Silhouette	0.5001	0.4929	0.463	0.5026
S_dbw	0.1384	0.1584	0.1343	0.1422
Sensibilidad	1	1	1	1
Especificidad	0.9113	0.9234	0.9153	0.9337
CCC	0.7298	0.7357	0.7275	0.7313

Tabla 5.9: Resultados numéricos del análisis de selección de desplazamiento para el método jerárquico.

Como que el procesador es capaz de realizar el procesado de cada desplazamiento con $d = 32$ se va a mantener este valor ya que asegura la calidad de los resultados.

5.7. Dos ataques

Una de las cuestiones a resolver es si con el método desarrollado y con los parámetros elegidos se puede detectar más de un ataque y que todos ellos compartan los mismos clusters.

Para comprobar esta hipótesis creamos una señal ficticia en la que se unen dos tramos que tienen ataque para crear uno largo con dos. Esto se hace por el simple hecho de que no tenemos a nuestra disposición ningún tramo tan corto con dos ataques. Elegimos los dos tramos del paciente 03 con los que hemos trabajado anteriormente, el 03 del segundo 300 al 600 y el tramo 04 del segundo 2000 al 2300.

Aplicamos el método con el tamaño de ventana de 1500 muestras y buscando 10 clusters. Usando el método k-means obtenemos el resultado de la figura 5.17.

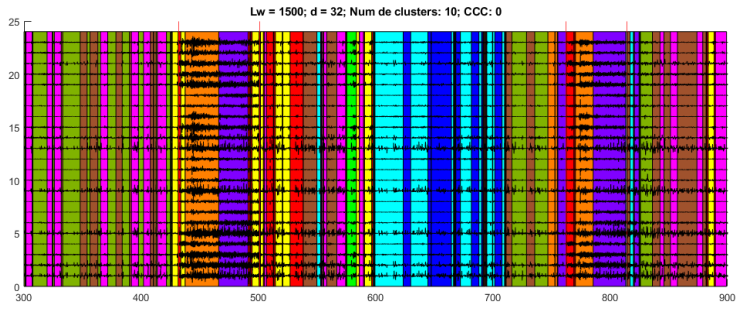

Figura 5.17: Señal EEG con dos ataques clasificada con 10 clusters.

Se puede observar como los clusters naranja y morado se comparten en ambos ataques, además de estar en el mismo orden no aparecen en ningún otro lugar de la señal. Los clusters rojo y amarillo también parecen estar involucrados pero no definen tan bien el ataque.

Los clusters anteriores a los ataques son diferentes y por lo tanto según su comportamiento se puede encontrar un patrón característico que pueda predecir los ataques.

5.8. Clustering de referencia

Otro test interesante que se ha llevado a cabo es la creación de un cluster de referencia para un determinado ataque A detectar un ataque B a partir de él. Vamos a ver un ejemplo para aclarar esta idea.

Como ataque A seleccionamos el del tramo 04 del paciente 03 en el intervalo 2000-2300s. Usamos el script de Matlab para filtrar, separar en clusters y clasificar la señal y guardamos las agrupaciones obtenidas. En la figura 5.18 podemos ver el resultado gráfico de esta clasificación, el cluster rojo, verde oscuro y marron son ataque, el resto no.

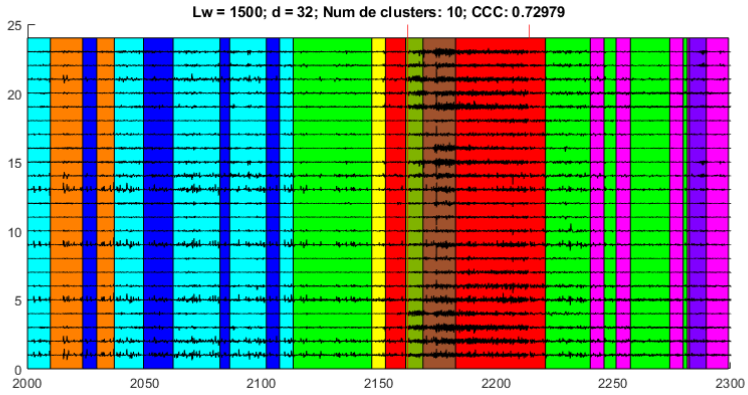

Figura 5.18: Señal de referencia clasificada con 10 clusters.

Como ataque B seleccionamos el tramo 03 del paciente 03 en el intervalo 300-600s. En vez de hacer la clasificación habitual, separamos la señal en ventanas, las filtramos y calculamos sus coeficientes AR(2). Se comparan los coeficientes AR de cada ventana con los del ataque A y se le asigna el cluster de la ventana con los AR más parecidos. De esta manera obtenemos la figura 5.19.

Pese a que el resultado de la clasificación del tramo B no es tan limpio como el del A en el sentido de que hay intervalos muy cortos en el B, se puede ver como la clasificación es bastante buena y tenemos de nuevo los clusters rojo, verde oscuro y marron dentro del ataque.

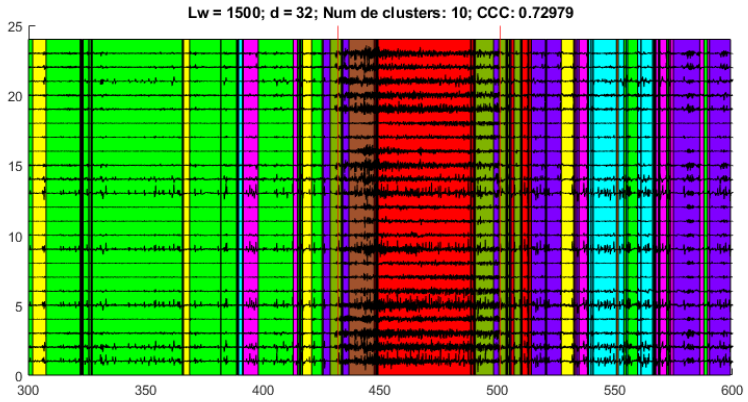

Figura 5.19: Clasificación hecha a partir del clustering de referencia.

Capítulo 6

Conclusiones y trabajo futuro

Según el objetivo expuesto al inicio del trabajo que consistía en adaptar un método no supervisado para la detección de eventos en señales multicanal ya existente (UMED), para detectar ataques de epilepsia, se podría concluir que este trabajo ha conseguido una parte importante del mismo. Los puntos conseguidos se detallan a continuación:

- Se ha establecido un método a partir de UMED añadiendo alguna aproximación y cambiando los valores de las variables para adaptarlo a la detección de ataques de epilepsia.
- Ha sido necesario determinar nuevos parámetros para el algoritmo UMED ya que los CCC obtenidos son inferiores a 0.85. Un resultado clustering disminuye con el valor CCC y por ello los coeficientes SDBW y Silhouette tienen un peor comportamiento. En este contexto quizás Silhouette es mejor pues es mas robusto al ruido. Y también es bueno analizar los resultados de dos métodos de clustering diferentes para determinar los mejores parámetros.
- Se ha podido encontrar un filtro adecuado para aplicar a las señales y de este modo añadirlo al método UMED para la detección de ataques de epilepsia.
- Se ha observado que los tamaños de ventana necesarios para nuestro objetivo son mucho mayores que los usados en UMED. Los artefactos exteriores son más importantes que los ataques de epilepsia. En consecuencia la calidad del clustering es mejor y por tanto los coeficientes SDBW y Silhouette tienen un mejor comportamiento. Aumentando el tamaño de la ventana ha permitido obtener clusteres de mejor calidad.

- El mejor resultado se ha alcanzado cuando se ha utilizado el filtro adaptativo, el Análisis de Componentes Principales con 8 componentes (aportando el 90 % de información), un tamaño de ventana de 1500 muestras, desplazamiento de 32 muestras y buscando 10 clusters.

  Esto ha sido posible gracias a haber escogido los resultados óptimos entre todos los obtenidos en base a unos parámetros bien seleccionados.

- Se ha avanzado en la clasificación de clusters para detectar ataques epilépticos. Obteniendo resultados positivos para la detección de dos ataques ataques en la misma señal y para la detección de un ataque con los clusters de referencia encontrados en otro ataque.

6.1. Trabajo futuro

A partir de estos logros deben considerarse las siguientes líneas que quedan abiertas:

- Estudiar si es adecuado elegir un número menor de canales para optimizar el método.

- Aumentar el estudio con señales de más pacientes. Con mas pacientes se podría ver si el método funciona sin necesidad de personalizar el método a cada paciente.

- Finalmente, se considera de más dificultad pero merecedor de un mayor estudio el análisis de los clusters anteriores al ataque. De esta forma se podría encontrar un patrón característico que permita predecir el ataque antes de que ocurra.

Bibliografía

[1] Angel Mur, Raquel Dormido, Jesús Vega, Sebastian Dormido-Canto, and Natividad Duro. Unsupervised event detection and classification of multichannel signals. *Expert Systems with Applications*, 54:294–303, 2016.

[2] Robert S. Fisher. The new classification of seizures by the international league against epilepsy 2017. *Current Neurology and Neuroscience Reports*, 17:48 –, 2017.

[3] Anilkumar AC Nayak CS. Eeg normal waveforms, 2021.

[4] Mayo Clinic. Eeg (electroencephalogram).

[5] Physionet. Chb-mit scalp eeg database.

[6] A. Shoeb. Application of machine learning to epileptic seizure onset detection and treatment. 2009.

[7] Dorado J Rabuñal JR Pazos A Guo L, Rivero D. Automatic epileptic seizure detection in eegs based on line length feature and artificial neural networks. *Journal of neuroscience methods*, 191:101–109, 08 2010.

[8] Tsipouras M. G. Fotiadis D. I. Tzallas, A. T. Automatic seizure detection based on time-frequency analysis and artificial neural networks. *Computational Intelligence and Neuroscience*, 12 2007.

[9] Marco A. Pinto-Orellana and Fábio R. Cerqueira. Patient-dependent epilepsy seizure detection using random forest classification over one-dimension transformed eeg data. *bioRxiv*, 2016.

[10] M. Mursalin, Yuan Zhang, Yuehui Chen, and N. Chawla. Automated epileptic seizure detection using improved correlation-based feature selection with random forest classifier. *Neurocomputing*, 241:204–214, 2017.

[11] Ramy Hussein, Mohamed Elgendi, Zhen Jane Wang, and Rabab Kreidieh Ward. Robust detection of epileptic seizures based on l1-penalized robust regression of eeg signals. *Expert Syst. Appl.*, 104:153–167, 2018.

[12] Rishi Raj Sharma, Piyush Varshney, Ram Bilas Pachori, and Santosh Kumar Vishvakarma. Automated system for epileptic eeg detection using iterative filtering. *IEEE Sensors Letters*, 2(4):1–4, 2018.

[13] Morteza Zabihi, Serkan Kiranyaz, Turker Ince, and Moncef Gabbouj. Patient-specific epileptic seizure detection in long-term eeg recording in paediatric patients with intractable seizures. volume 2013, pages 7.06–7.06, 01 2013.

[14] A. Subasi. Epileptic seizure detection using hybrid machine learning methods. *Neural Computing and Applications*, 31:317 – 325, 01 2019.

[15] O. Fasil and R. Rajesh. Time-domain exponential energy for epileptic eeg signal classification. *Neuroscience Letters*, 694:1 – 8, 02 2019.

[16] Ahmad RF Badruddin N Kamel N Hussain M Chooi WT Amin HU, Malik AS. Feature extraction and classification for eeg signals using wavelet transform and machine learning techniques. *Australas Phys Eng Sci Med.*, 38:139–149, 03 2015.

[17] Raghu Shivarudhrappa and Natarajan Sriraam. Classification of focal and non-focal eeg signals using neighborhood component analysis and machine learning algorithms. *Expert Systems with Applications*, 113, 06 2018.

[18] Qadir J Sivathamboo S Kwan P Kuhlmann L O'Brien T Razi A. Rasheed K, Qayyum A. Machine learning for predicting epileptic seizures using eeg signals: A review. *IEEE Rev Biomed Eng.*, 14:139–155, 01 2021.

[19] Syed Muhammad Usman and Simon Fong. Epileptic seizures prediction using machine learning methods. *Computational and Mathematical Methods in Medicine*, 2017, 12 2017.

[20] Indrani Bhattacherjee. Epileptic seizure prediction using machine learning techniques on real-time eeg signals. pages 221–226, 2021.

[21] Ali Shahidi Zandi, Reza Tafreshi, Manouchehr Javidan, and Guy A. Dumont. Predicting epileptic seizures in scalp eeg based on a variational bayesian gaussian mixture model of zero-crossing intervals. *IEEE Transactions on Biomedical Engineering*, 60(5):1401–1413, 2013.

[22] César Alexandre Teixeira, Bruno Direito, Mojtaba Bandarabadi, Michel Le Van Quyen, Mario Valderrama, Bjoern Schelter, Andreas Schulze-Bonhage, Vincent Navarro, Francisco Sales, and António Dourado. Epileptic seizure predictors based on computational intelligence techniques: A comparative study with 278 patients. *Computer Methods and Programs in Biomedicine*, 114(3):324–336, 2014.

[23] Angel Mur, Raquel Dormido, Jesús Vega, Natividad Duro, and Sebastian Dormido-Canto. Unsupervised event characterization and detection in multichannel signals: An eeg application. *Sensors*, 16(4), 2016.

[24] M. Halkidi and M. Vazirgiannis. Clustering validity assessment: finding the optimal partitioning of a data set. In *Proceedings 2001 IEEE International Conference on Data Mining*, pages 187–194, 2001.

[25] Vernon Lawhern, W. David Hairston, Kaleb McDowell, Marissa Westerfield, and Kay Robbins. Detection and classification of subject-generated artifacts in eeg signals using autoregressive models. *Journal of Neuroscience Methods*, 208(2):181–189, 2012.

[26] J Shlens. A tutorial on principal component analysis. *Educational*, 51, 04 2014.

[27] Contreras P Murtagh F. Algorithms for hierarchical clustering: an overview. *WIREs Data Mining Knowl Discov*, 00:1–12, 12 2011.

[28] Xin Jin and Jiawei Han. *K-Means Clustering*, pages 563–564. Springer US, Boston, MA, 2010.

[29] Ch Rama Devi Y Leela Sandhya Rani, P Naga Deepthi. Clustering algorithm for temporal data mining: An overview. *International Journal of Emerging Technology and Advanced Engineering*, 3, 2013.

[30] P. J. Rousseeuw. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20:53–65, 1987.

[31] Kai Ming Ting. *Sensitivity and Specificity*, pages 901–902. Springer US, Boston, MA, 2010.

[32] Agustina Garces, Lorena Orosco, Pablo Diez, and Eric Laciar. Adaptive filtering for epileptic event detection in the eeg. *Journal of Medical and Biological Engineering*, 39, 03 2019.

ACP	Análisis de Componentes Principales
AR	Método Auto Regresivo
CCC	Coeficiente de Correlación Cofenético
d	Desplazamiento
ECoG	Electrocorticograma
EEG	Electroencefalograma
EMG	ElectroMiograma
FN	Falso Negativo
FP	Falso Positivo
ILAE	Liga Internacional contra la Epilepsia
L_w	Tamaño de ventana
UMED	Unsupervised Method for Event Detection
VN	Verdadero Negativo
VP	Verdadero Positivo

Listado de siglas, abreviaturas y acrónimos

Apéndice A

Tablas de índices de Silhouette

	L_w = 50		L_w = 100	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.2952	0.2769	0.3220	0.2720
3	0.2339	0.1830	0.2953	0.2235
4	0.2119	0.1745	0.2587	0.1995
5	0.2174	0.1598	0.2606	0.2066
6	0.2180	0.1453	0.2665	0.2095
7	0.1909	0.1298	0.2449	0.2072
8	0.1866	0.1337	0.2430	0.1934
9	0.1839	0.1280	0.2337	0.1902
10	0.1746	0.1105	0.2211	0.1700
11	0.1747	0.0916	0.2214	0.1669
12	0.1665	0.0926	0.2092	0.1542
13	0.1644	0.0909	0.2047	0.1487
14	0.1542	0.0864	0.1983	0.1341
15	0.1546	0.0876	0.1992	0.1261
16	0.1470	0.0696	0.1920	0.1245
17	0.1514	0.0704	0.1956	0.1161
18	0.1501	0.0704	0.1917	0.1211
19	0.1435	0.0677	0.1931	0.1124
20	0.1482	0.0662	0.1772	0.1163

	L_w = 150		L_w = 200	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.3305	0.2608	0.3370	0.3790
3	0.3226	0.1913	0.3480	0.3112
4	0.2822	0.1886	0.3030	0.2224
5	0.2775	0.1946	0.2940	0.2359
6	0.2866	0.1836	0.3057	0.2092
7	0.2726	0.2045	0.2928	0.2076
8	0.2694	0.2025	0.2937	0.2070
9	0.2595	0.2015	0.2841	0.1968
10	0.2506	0.1967	0.2658	0.1897
11	0.2469	0.1917	0.2708	0.2043
12	0.2329	0.1925	0.2748	0.1983
13	0.2362	0.1648	0.2697	0.2101
14	0.2331	0.1588	0.2466	0.2066
15	0.2401	0.1450	0.2487	0.2041
16	0.2148	0.1481	0.2495	0.2046
17	0.2223	0.1469	0.2487	0.1905
18	0.2030	0.1484	0.2459	0.1981
19	0.2208	0.1451	0.2493	0.2034
20	0.2185	0.1368	0.2426	0.1944

	L_w = 250		L_w = 300	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.3335	0.3612	0.3517	0.4110
3	0.3672	0.3401	0.3764	0.3444
4	0.3168	0.2638	0.3255	0.2519
5	0.2997	0.2523	0.2977	0.2762
6	0.3172	0.2410	0.3199	0.2604
7	0.3075	0.2407	0.3127	0.2612
8	0.3089	0.2297	0.3188	0.2473
9	0.2942	0.2329	0.3083	0.2233
10	0.2836	0.2467	0.3211	0.2355
11	0.2933	0.2504	0.2950	0.2372
12	0.2818	0.2444	0.3014	0.2444
13	0.2753	0.2056	0.2978	0.2283
14	0.2694	0.2023	0.2963	0.2162
15	0.2704	0.2075	0.2827	0.2046
16	0.2652	0.2035	0.2847	0.2121
17	0.2592	0.1952	0.2800	0.2148
18	0.2724	0.1912	0.2823	0.2178
19	0.2752	0.1902	0.2765	0.2100
20	0.2718	0.1953	0.2915	0.2125

	L_w = 350		L_w = 400	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.3749	0.3743	0.3889	0.4201
3	0.3856	0.3644	0.3950	0.3559
4	0.3323	0.2710	0.3448	0.3043
5	0.3425	0.2849	0.3329	0.2993
6	0.3249	0.2822	0.3509	0.3034
7	0.3224	0.2633	0.3454	0.3016
8	0.3271	0.2667	0.3446	0.2989
9	0.3409	0.2746	0.3595	0.3164
10	0.3086	0.2548	0.3448	0.2929
11	0.3258	0.2627	0.3542	0.3001
12	0.3195	0.2669	0.3320	0.3101
13	0.2976	0.2607	0.3262	0.2953
14	0.3003	0.2424	0.3181	0.2859
15	0.3128	0.2440	0.3289	0.2679
16	0.2867	0.2380	0.3259	0.2547
17	0.3001	0.2407	0.3542	0.2658
18	0.3049	0.2500	0.3357	0.2772
19	0.2920	0.2527	0.3237	0.2751
20	0.3078	0.2523	0.3332	0.2744

	L_w = 450		L_w = 500	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.3962	0.4202	0.4076	0.3840
3	0.3985	0.3590	0.3997	0.3878
4	0.3488	0.3161	0.3481	0.3148
5	0.3619	0.3104	0.3660	0.3258
6	0.3434	0.3104	0.3541	0.3284
7	0.3560	0.2989	0.3626	0.3207
8	0.3637	0.2975	0.3424	0.3259
9	0.3667	0.3203	0.3662	0.3142
10	0.3488	0.2964	0.3692	0.3266
11	0.3461	0.3033	0.3635	0.3135
12	0.3315	0.3006	0.3710	0.3271
13	0.3390	0.2863	0.3539	0.3169
14	0.3540	0.2797	0.3414	0.3228
15	0.3395	0.2864	0.3358	0.3380
16	0.3204	0.2979	0.3648	0.3012
17	0.3366	0.3079	0.3360	0.3067
18	0.3408	0.2892	0.3494	0.3022
19	0.3356	0.2879	0.3535	0.2963
20	0.3450	0.2851	0.3473	0.2916

	L_w = 550		L_w = 600	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4101	0.3861	0.4249	0.3608
3	0.4071	0.3949	0.4056	0.3656
4	0.3539	0.3006	0.3522	0.2979
5	0.3752	0.3293	0.3800	0.3294
6	0.3775	0.3392	0.3801	0.3222
7	0.3708	0.3315	0.3935	0.3304
8	0.3746	0.3384	0.3819	0.3321
9	0.3820	0.3408	0.3933	0.3299
10	0.3768	0.3537	0.3872	0.3285
11	0.3611	0.3346	0.3850	0.3440
12	0.3632	0.3496	0.3730	0.3542
13	0.3902	0.3220	0.4012	0.3689
14	0.3953	0.3345	0.3763	0.3550
15	0.3680	0.3249	0.3973	0.3647
16	0.3697	0.3301	0.3890	0.3738
17	0.3865	0.3358	0.4014	0.3654
18	0.3806	0.3228	0.3837	0.3556
19	0.3543	0.3248	0.3822	0.3562
20	0.3763	0.3293	0.3735	0.3552

	L_w = 650		L_w = 700	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4229	0.3932	0.4248	0.3487
3	0.4075	0.4087	0.4158	0.3675
4	0.3513	0.2943	0.3538	0.3244
5	0.3838	0.2882	0.3861	0.3527
6	0.3834	0.3266	0.3761	0.3436
7	0.3812	0.3379	0.3943	0.3538
8	0.3989	0.3209	0.4047	0.3522
9	0.3996	0.3264	0.4019	0.3648
10	0.3935	0.3408	0.3780	0.3529
11	0.3993	0.3569	0.4118	0.3585
12	0.4163	0.3654	0.4016	0.3704
13	0.4037	0.3757	0.4103	0.3689
14	0.4053	0.3899	0.4070	0.3594
15	0.4151	0.3947	0.4079	0.3655
16	0.4175	0.3736	0.4237	0.3666
17	0.3964	0.3743	0.4162	0.3620
18	0.4061	0.3678	0.4116	0.3718
19	0.4085	0.3697	0.4168	0.3669
20	0.4087	0.3793	0.4258	0.3685

	L_w = 750		L_w = 800	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4328	0.3920	0.4322	0.3984
3	0.4250	0.4047	0.4259	0.4150
4	0.3642	0.3372	0.3674	0.3311
5	0.3920	0.3428	0.3698	0.3292
6	0.3950	0.3559	0.3963	0.3475
7	0.4063	0.3627	0.4195	0.3685
8	0.4158	0.3611	0.4137	0.3637
9	0.4285	0.3644	0.4342	0.3727
10	0.4226	0.3818	0.4260	0.3875
11	0.4242	0.4024	0.4448	0.3906
12	0.4433	0.3927	0.4495	0.4115
13	0.4183	0.4042	0.4531	0.4160
14	0.4471	0.3930	0.4273	0.4376
15	0.4614	0.4059	0.4605	0.4208
16	0.4537	0.4159	0.4393	0.4148
17	0.4484	0.4140	0.4477	0.4074
18	0.4202	0.4070	0.4354	0.4047
19	0.4359	0.4073	0.4472	0.4070
20	0.4404	0.4063	0.4285	0.4138

	L_w = 850		L_w = 900	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4273	0.3686	0.4274	0.4284
3	0.4277	0.3914	0.4323	0.3775
4	0.3707	0.3481	0.3771	0.3203
5	0.3948	0.3604	0.3977	0.3410
6	0.3988	0.3638	0.4139	0.3555
7	0.4099	0.3685	0.4148	0.3696
8	0.4177	0.3587	0.4112	0.3874
9	0.4366	0.3643	0.4381	0.3899
10	0.4313	0.3841	0.4199	0.3937
11	0.4327	0.4071	0.4670	0.4066
12	0.4580	0.4210	0.4554	0.4332
13	0.4405	0.4327	0.4797	0.4533
14	0.4704	0.4403	0.4735	0.4561
15	0.4744	0.4322	0.4644	0.4310
16	0.4641	0.4387	0.4689	0.4261
17	0.4534	0.4451	0.4709	0.4185
18	0.4600	0.4347	0.4552	0.4158
19	0.4587	0.4203	0.4534	0.4204
20	0.4616	0.4257	0.4721	0.4255

	L_w = 950		L_w = 1000	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4248	0.3973	0.4325	0.4032
3	0.4368	0.4204	0.4472	0.4003
4	0.3813	0.3316	0.3928	0.3769
5	0.4016	0.3537	0.3983	0.3799
6	0.4166	0.3623	0.4169	0.3707
7	0.4062	0.3764	0.4314	0.3799
8	0.4321	0.3570	0.4476	0.3707
9	0.4502	0.3774	0.4582	0.3766
10	0.4386	0.3822	0.4838	0.4229
11	0.4604	0.3830	0.4749	0.4461
12	0.4729	0.3910	0.4746	0.4358
13	0.4905	0.4009	0.5078	0.4493
14	0.4594	0.4177	0.4802	0.4356
15	0.4755	0.4077	0.4851	0.4475
16	0.4728	0.4110	0.5098	0.4464
17	0.4787	0.4108	0.4893	0.4521
18	0.4748	0.4124	0.4903	0.4617
19	0.4603	0.4160	0.4878	0.4569
20	0.4802	0.4257	0.4799	0.4655

	L_w = 1050		L_w = 1100	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4317	0.5007	0.4289	0.4041
3	0.4489	0.4305	0.4509	0.4046
4	0.3946	0.3453	0.3969	0.3296
5	0.4145	0.3741	0.4184	0.3349
6	0.4321	0.3809	0.4337	0.3534
7	0.4368	0.3906	0.4205	0.3703
8	0.4524	0.4150	0.4517	0.3886
9	0.4487	0.4071	0.4578	0.4006
10	0.4804	0.4093	0.4816	0.4372
11	0.4944	0.4375	0.5058	0.4374
12	0.4906	0.4312	0.4760	0.4379
13	0.5023	0.4470	0.5134	0.4608
14	0.4889	0.4509	0.4692	0.4639
15	0.4940	0.4431	0.5297	0.4601
16	0.5011	0.4518	0.5294	0.4728
17	0.5004	0.4339	0.4972	0.4746
18	0.4958	0.4411	0.5202	0.4837
19	0.5131	0.4526	0.4933	0.4902
20	0.4856	0.4495	0.5039	0.4723

	L_w = 1150		L_w = 1200	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4148	0.3914	0.4152	0.3936
3	0.4561	0.3999	0.4588	0.4174
4	0.3988	0.3520	0.4000	0.3766
5	0.4164	0.3486	0.4242	0.3890
6	0.4289	0.3663	0.4383	0.4058
7	0.4425	0.3849	0.4457	0.4184
8	0.4529	0.4027	0.4524	0.4166
9	0.4658	0.4267	0.4716	0.4096
10	0.4873	0.4176	0.4626	0.4565
11	0.5001	0.4525	0.4959	0.4745
12	0.4830	0.4652	0.4925	0.4687
13	0.5172	0.4704	0.4917	0.4770
14	0.5240	0.4811	0.5168	0.4613
15	0.5285	0.4875	0.5254	0.4753
16	0.4947	0.4872	0.5190	0.4605
17	0.5125	0.4676	0.5407	0.4596
18	0.5031	0.4745	0.5044	0.4601
19	0.5327	0.4795	0.5183	0.4665
20	0.5222	0.4753	0.5086	0.4740

	L_w = 1250		L_w = 1300	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4157	0.3966	0.4171	0.3994
3	0.4604	0.4460	0.4652	0.4495
4	0.4030	0.3473	0.4061	0.3742
5	0.4253	0.3647	0.4296	0.3800
6	0.4407	0.4263	0.4451	0.4362
7	0.4517	0.4271	0.4256	0.4475
8	0.4685	0.4384	0.4727	0.4496
9	0.4751	0.4507	0.4786	0.4777
10	0.4664	0.4774	0.4986	0.4563
11	0.4928	0.4791	0.4565	0.4630
12	0.5181	0.5048	0.5369	0.4898
13	0.5101	0.4778	0.5180	0.4912
14	0.5462	0.4864	0.5330	0.5019
15	0.5242	0.4947	0.5429	0.5004
16	0.5532	0.4891	0.5077	0.4944
17	0.5089	0.4901	0.5340	0.5036
18	0.5172	0.5039	0.5249	0.4969
19	0.5378	0.4994	0.5324	0.4980
20	0.5100	0.5014	0.5612	0.4989

	L_w = 1350		L_w = 1400	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4178	0.4044	0.4191	0.4059
3	0.4684	0.4399	0.4721	0.4191
4	0.4072	0.3866	0.4126	0.3683
5	0.4317	0.4099	0.3917	0.3821
6	0.4354	0.4275	0.4500	0.4072
7	0.4702	0.4380	0.4542	0.4259
8	0.4724	0.4633	0.4511	0.4393
9	0.4709	0.4629	0.4838	0.4420
10	0.5159	0.4976	0.5314	0.4643
11	0.5418	0.5118	0.5214	0.5028
12	0.5468	0.5062	0.5008	0.5167
13	0.5244	0.5168	0.5272	0.5333
14	0.5318	0.4891	0.5556	0.5002
15	0.5334	0.5004	0.5370	0.5010
16	0.5208	0.4910	0.5357	0.5009
17	0.5505	0.4926	0.5259	0.4978
18	0.5403	0.4964	0.5563	0.4969
19	0.5269	0.4958	0.5315	0.4967
20	0.5606	0.5072	0.5612	0.5035

	L_w = 1450		L_w = 1500	
nº clust	**k-means**	**Jerárquico**	**k-means**	**Jerárquico**
2	0.4204	0.4060	0.4253	0.4017
3	0.4747	0.4484	0.4772	0.4373
4	0.4146	0.3909	0.4161	0.3825
5	0.4392	0.3943	0.4408	0.3959
6	0.4445	0.4272	0.4477	0.4245
7	0.4627	0.4386	0.4724	0.4368
8	0.4849	0.4505	0.4927	0.4564
9	0.5090	0.4610	0.5027	0.4637
10	0.4939	0.4944	0.5392	0.5001
11	0.5260	0.5133	0.5309	0.5151
12	0.5287	0.5297	0.5378	0.5236
13	0.5450	0.5235	0.5523	0.5009
14	0.5359	0.5355	0.5463	0.5012
15	0.5707	0.5402	0.5484	0.5110
16	0.5527	0.5317	0.5428	0.5221
17	0.5603	0.5311	0.5732	0.5149
18	0.5583	0.5329	0.5605	0.5296
19	0.5483	0.5442	0.5702	0.5404
20	0.5723	0.5347	0.5461	0.5361

Apéndice B

Imágenes de resultados

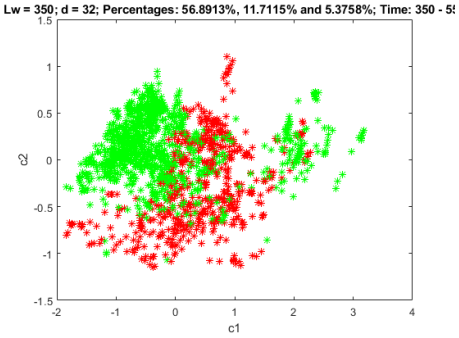

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

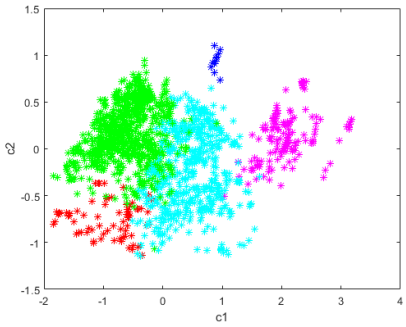

(b) Clasificación realizada (color según su cluster)

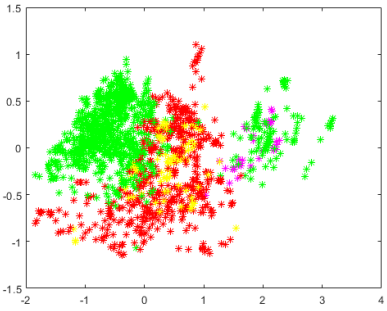

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.1: Ventanas según sus dos primeros componentes. Señal filtrada de 350-550s y clasificación con $L_w = 350$, $d = 32$, 5 clusters y 12 componentes principales

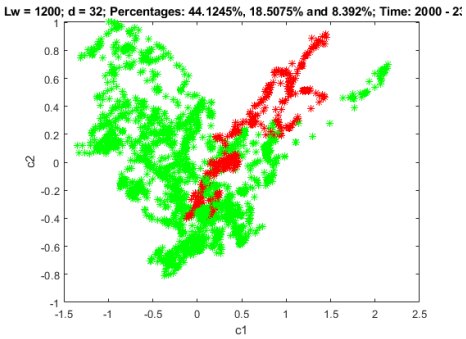

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

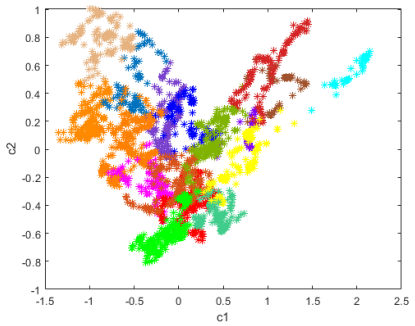

(b) Clasificación realizada (color según su cluster)

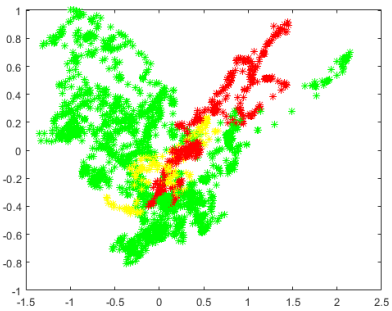

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.2: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1200$, $d = 32$, 17 clusters y 8 componentes principales

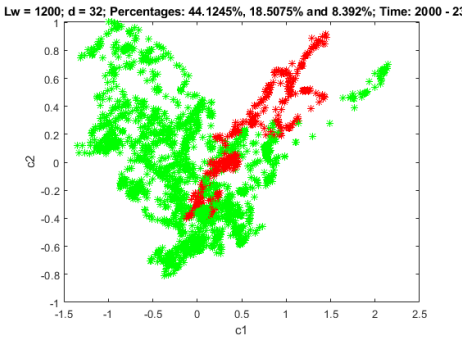

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

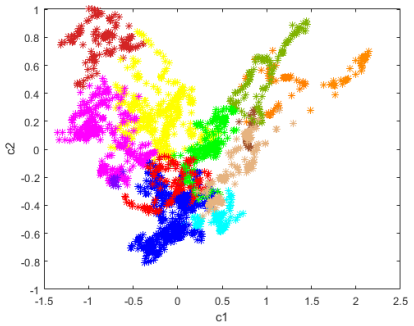

(b) Clasificación realizada (color según su cluster)

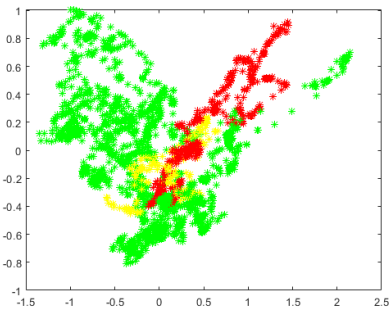

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.3: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1200$, $d = 32$, 17 clusters y 8 componentes principales

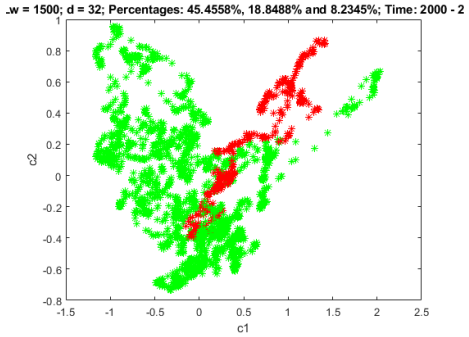

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

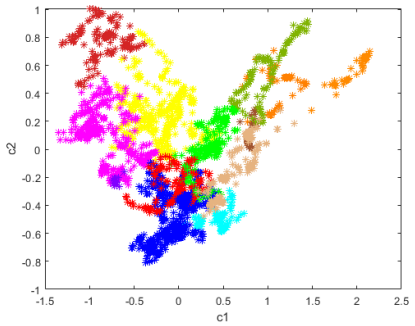

(b) Clasificación realizada (color según su cluster)

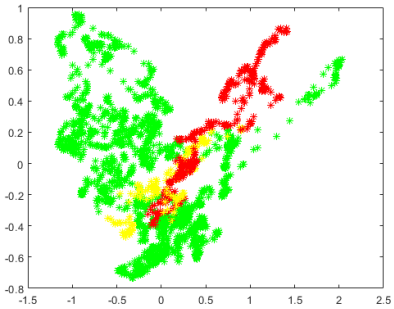

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.4: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1500$, $d = 32$, 17 clusters y 8 componentes principales

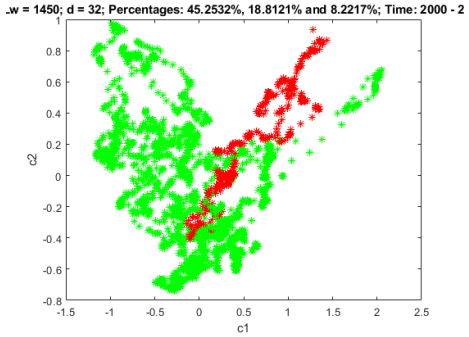

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

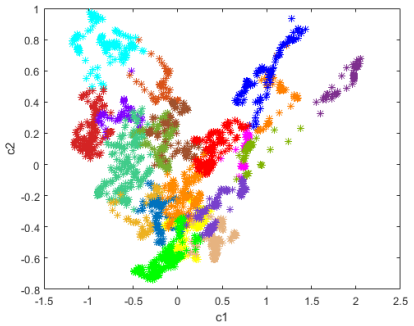

(b) Clasificación realizada (color según su cluster)

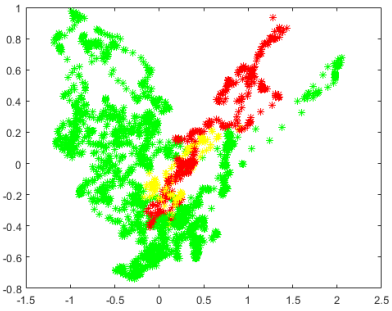

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.5: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1450$, $d = 32$, 20 clusters y 8 componentes principales

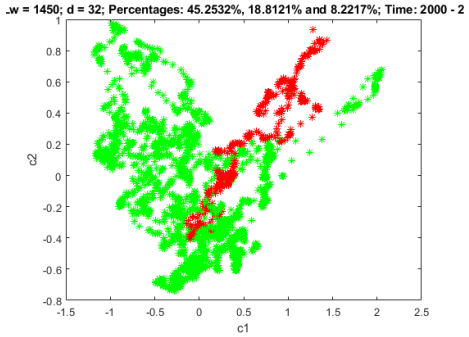

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

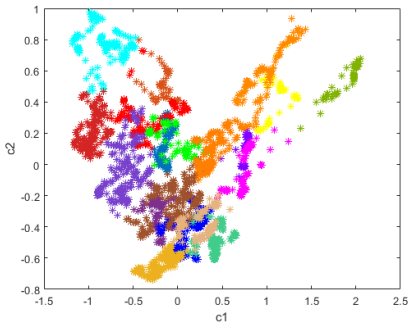

(b) Clasificación realizada (color según su cluster)

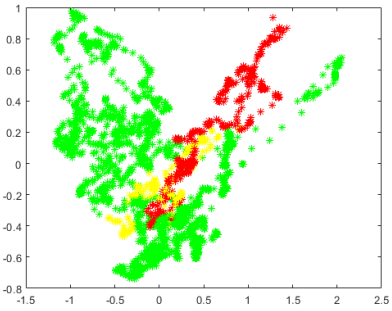

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.6: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1450$, $d = 32$, 19 clusters y 8 componentes principales

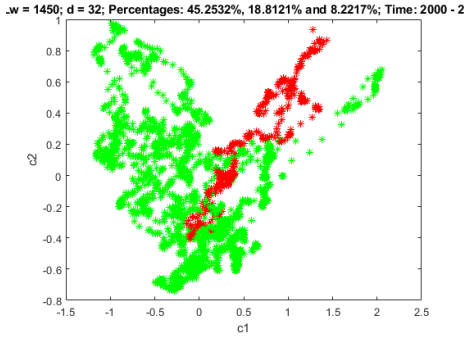

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

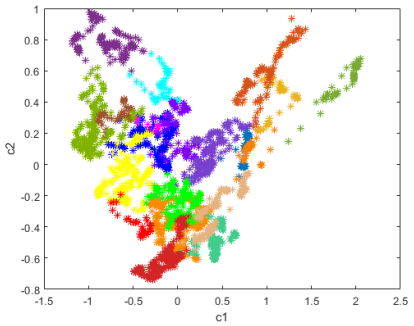

(b) Clasificación realizada (color según su cluster)

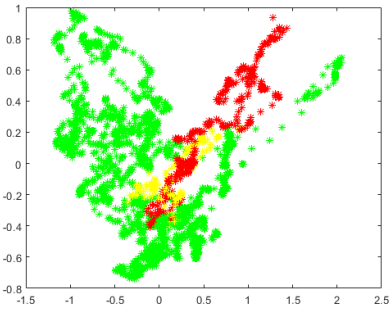

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.7: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1450$, $d = 32$, 20 clusters y 8 componentes principales

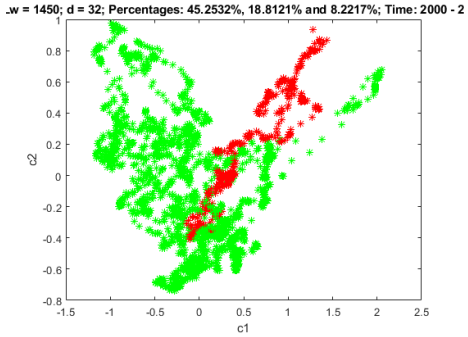

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

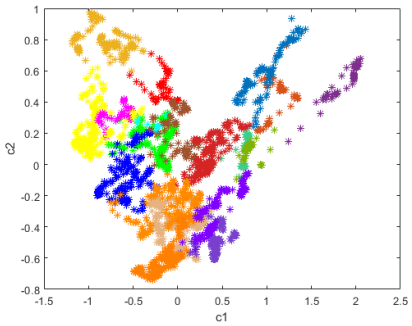

(b) Clasificación realizada (color según su cluster)

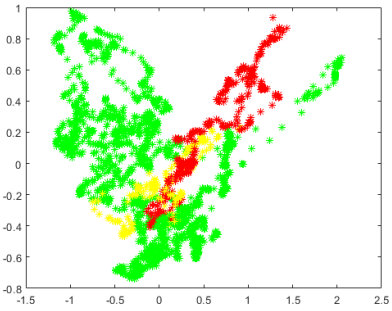

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.8: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1450$, $d = 32$, 19 clusters y 8 componentes principales

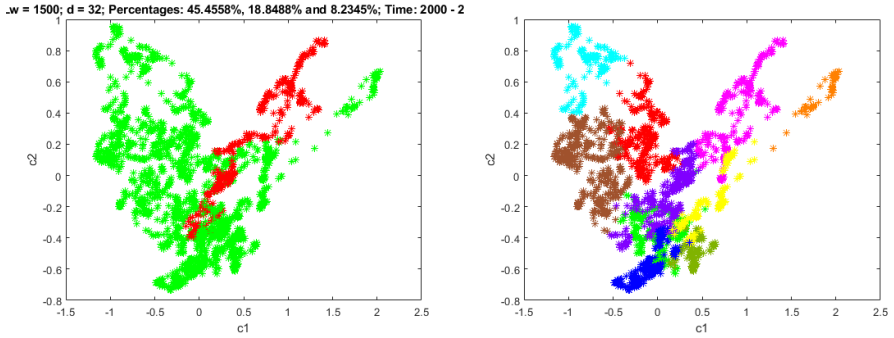

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

(b) Clasificación realizada (color según su cluster)

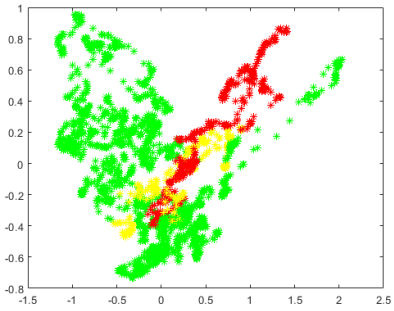

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.9: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método k-means, $L_w = 1500$, $d = 32$, 10 clusters y 8 componentes principales

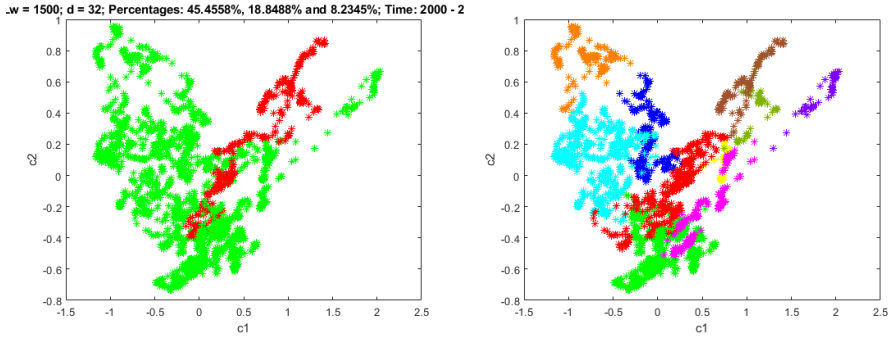

(a) Naturaleza de cada ventana (rojo: ataque, verde: no ataque)

(b) Clasificación realizada (color según su cluster)

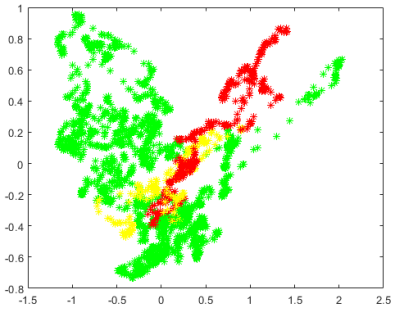

(c) verde: verdadero positivo, rojo: verdadero negativo, amarillo: falso negativo, rosa: falso positivo

Figura B.10: Ventanas según sus dos primeros componentes. Señal filtrada de 2000-2300s y clasificación con método jerárquico, $L_w = 1500$, $d = 32$, 10 clusters y 8 componentes principales