

Proyecto Fin de Carrera

Ingeniería de Telecomunicación

Caracterización de pacientes epilépticos mediante el electroencefalograma

Autor: Paula Ramírez Sánchez

Tutor: Rubén Martín Clemente

Dpto. Teoría de la Señal y Comunicaciones
Escuela Técnica Superior de Ingeniería
Universidad de Sevilla

Sevilla, 2018



Proyecto Fin de Carrera
Ingeniería de Telecomunicación

Caracterización de pacientes epilépticos mediante el electroencefalograma

Autor:

Paula Ramírez Sánchez

Tutor:

Rubén Martín Clemente

Profesor titular

Dpto. de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2018

Proyecto Fin de Carrera: Caracterización de pacientes epilépticos mediante el electroencefalograma

Autor: Paula Ramírez Sánchez

Tutor: Rubén Martín Clemente

El tribunal nombrado para juzgar el Proyecto arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2018

El Secretario del Tribunal

A Rosa, Raquel y Elena

A mis maestros

Agradecimientos

A todas aquellas personas que me han acompañado durante toda esta andadura. Familia, amigos, pareja, que son mis pilares diarios. Cuatro años en los que han sido mi soporte, mi guía y por los que ahora mismo soy quien soy.

Agradecer a la Universidad de Sevilla, y en particular a mis profesores, toda la enseñanza que me han proporcionado durante la carrera y la gran cantidad de conocimiento adquirido, que sin duda soy consciente de que gracias a ello podré avanzar profesionalmente y seguir retroalimentándome durante toda mi vida.

Finalmente, dedico estas últimas líneas a mi padre, que haya dónde esté me ha estado dando fuerzas para seguir adelante y nunca rendirme.

En este estudio se realizarán pruebas y diversas medidas de parámetros sobre señales electroencefalográficas de pacientes con epilepsia intratable. Con ello se busca detectar con la mayor eficacia posible la ocurrencia de un ataque epiléptico gracias al conocimiento de cómo varían ciertos parámetros en este tipo de señales cuando el paciente sufre convulsiones. Esto permitirá, además, maximizar el tiempo entre la detección de la crisis y el comienzo de la misma, ganando tiempo de actuación para poder aplicar algún fármaco. Por último, se pretende conocer cuánto tiempo antes podríamos detectar la crisis antes de que ocurra.

Abstract

In this study, we will perform numerous tests and measurements of parameters on electroencephalographic signals from patients with intractable epilepsy. The aim is to detect as efficiently as possible the occurrence of an epileptic seizure observing how certain parameters vary in this type of signals when the patient suffers seizures. This will also allow maximizing the time between the detection of the crisis and the beginning of it, so we will have more time to act, maybe applying a drug. Finally, we want to know how many times we need to detect the crisis before it happens.

Índice

Agradecimientos	ixx
Resumen	xi
Abstract	xii
Índice	xv
Índice de Tablas	xviii
Índice de Figuras	xx
Notación	xxiv
1 Introducción	13
2 Epilepsia	15
2.1. <i>Síntomas</i>	15
2.2. <i>Causas</i>	15
2.3. <i>Diagnóstico</i>	15
2.4. <i>Tratamiento</i>	16
2.5. <i>Tipos de crisis</i>	16
3 Electroencefalograma	19
3.1. <i>Anatomía del encefalo</i>	19
3.1.1. Electrogénesis cerebral	21
3.1.2. Electrogénesis cortical	22
3.2. <i>Señales EEG</i>	23
3.3. <i>Captación del EEG</i>	23
3.3.1. Tipos de eletrodos	23
3.3.2. Sistema de posicionamiento de electrodos superficiales	25
3.3.3. Montaje de un EEG	25
4 Base de datos	29
5 Pre-Procesamiento	31
5.1. <i>Obtención de las grabaciones</i>	31
5.2. <i>Fases del pre-procesamiento</i>	31
5.2.1. Filtrado a 60 Hz	31
5.2.2. Detección de canales defectuosos	34
5.2.3. Detección de artefactos	37
5.2.4. Detección de segmentos defectuosos adicionales	38
5.2.5. Filtrado a [0.5, 80] Hz	39

5.3. Filtrado en las bandas de interés	39
5.4. División en bloques	42
5.5. Cálculo de parámetros	42
6 Máquina de Soporte Vectorial (SVM)	43
6.1. Clasificador de margen máximo	44
6.2. Clasificador de margen blando	46
6.3. Clasificador no lineal	47
6.4. Implementación en el estudio	48
7 Resultados	49
7.1. Entrenamiento a partir de los 30 segundos	51
7.2. Entrenamiento a partir de un número más elevado de muestras	67
7.3. Estudio con otros parámetros	85
8 Conclusiones	93
Referencias	95
Glosario	98
Anexo	99

ÍNDICE DE TABLAS

Tabla 4-1. Directorio de pacientes con su sexo y edad

30

ÍNDICE DE FIGURAS

Figura 3-1. Partes principales del encéfalo	20
Figura 3-2. Lóbulos cerebrales y tronco del encéfalo	21
Figura 3-3. Capas de la corteza cerebral	22
Figura 3-4. Electrodo superficial en casco de malla	24
Figura 3-5. Electrodo quirúrgico de tipo durales	24
Figura 3-6. Sistema de posicionamiento 10-20 para la colocación de electrodos	25
Figura 3-7. Esquemas de montaje para un registro monopolar un registro monopolar promediado	26
Figura 3-8. Esquema de montaje para un registro bipolar	26
Figura 3-9. Esquema de un montaje longitudinal bipolar (A) y transversal (B)	27
Figura 5-1. Espectro de potencia de chb15_06	32
Figura 5-2. Espectro de potencia de chb15_06 filtrado a 60 Hz	32
Figura 5-3. Espectro de potencia de chb15_40	33
Figura 5-4. Espectro de potencia de chb15_40 filtrado 60 Hz	33
Figura 5-5. Espectros de potencia con canales defectuosos en las grabaciones de chb05	34
Figura 5-6. Canales defectuosos de chb05_06	35
Figura 5-7. Canales defectuosos eliminados de chb05_06	36
Figura 5-8. Espectro de potencia con canales defectuosos de chb13_55	36
Figura 5-9. Canales defectuosos de chb13_55	36
Figura 5-10. Canales defectuosos eliminados de chb13_55	37
Figura 5-11. Parpadeo encontrado en chb15_15	38
Figura 5-12. Artefactos adicionales de chb10	38
Figura 5-13. Espectros de potencia de las grabaciones de chb15 filtrados en [0.5, 80] Hz	39
Figura 5-14. Respuesta en frecuencia filtro Delta	39
Figura 5-15. Respuesta en frecuencia filtro Theta	39
Figura 5-16. Respuesta en frecuencia filtro Alfa	40
Figura 5-17. Respuesta en frecuencia filtro Beta	40
Figura 5-18. Señal de EEG genérica tras aplicar filtro Delta	40
Figura 5-19. Señal de EEG genérica tras aplicar filtro Theta	41
Figura 5-20. Señal de EEG genérica tras aplicar filtro Alfa	41
Figura 5-21. Señal de EEG genérica tras aplicar filtro Beta	42
Figura 6-1. Representación del hiperplano óptimo y sus vectores soporte asociados para un SVM de margen máximo	43

Figura 6-2. Clasificaciones de margen blando: (a) punto xi clasificado correctamente, (b) punto xi clasificado incorrectamente	47
Figura 6-3. Transformación $\Phi(\cdot)$ para hacer los datos linealmente separables en la SVM	47
Figura 7-0. Intervalo de crisis en la banda Delta	49
Figura 7-1. Resultado Sujeto 1: Paciente 5-Caso1 con crisis	50
Figura 7-2. Resultado Sujeto 1: Paciente 5-Caso1 sin crisis	51
Figura 7-3. Resultado Sujeto 1: Paciente 5-Caso2 con crisis	52
Figura 7-4. Resultado Sujeto 1: Paciente 5-Caso2 sin crisis	53
Figura 7-5. Resultado Sujeto 2: Paciente 10-Caso1 con crisis	54
Figura 7-6. Resultado Sujeto 2: Paciente 10-Caso1 sin crisis	55
Figura 7-7. Resultado Sujeto 2: Paciente 10-Caso2 con crisis	56
Figura 7-8. Resultado Sujeto 2: Paciente 10-Caso2 sin crisis	57
Figura 7-9. Resultado Sujeto 3: Paciente 13-Caso1 con crisis	58
Figura 7-10. Resultado Sujeto 3: Paciente 13-Caso1 sin crisis	59
Figura 7-11. Resultado Sujeto 3: Paciente 13-Caso2 con crisis	60
Figura 7-12. Resultado Sujeto 3: Paciente 13-Caso2 sin crisis	61
Figura 7-13. Resultado Sujeto 4: Paciente 15-Caso1 con crisis	62
Figura 7-14. Resultado Sujeto 4: Paciente 15-Caso1 sin crisis	63
Figura 7-15. Resultado Sujeto 4: Paciente 15-Caso2 con crisis	64
Figura 7-16. Resultado Sujeto 4: Paciente 15-Caso2 sin crisis	65
Figura 7-17. Resultado Sujeto 1: Paciente 5-Caso1 con crisis	66
Figura 7-18. Resultado Sujeto 1: Paciente 5-Caso1 sin crisis	67
Figura 7-19. Resultado Sujeto 2: Paciente 10-Caso1 con crisis	68
Figura 7-20. Resultado Sujeto 2: Paciente 10-Caso1 sin crisis	69
Figura 7-21. Resultado Sujeto 2: Paciente 10-Caso1 con crisis	70
Figura 7-22. Resultado Sujeto 2: Paciente 10-Caso1 sin crisis	71
Figura 7-23. Resultado Sujeto 2: Paciente 10-Caso2 con crisis	72
Figura 7-24. Resultado Sujeto 2: Paciente 10-Caso2 sin crisis	73
Figura 7-25. Resultado Sujeto 3: Paciente 13-Caso1 con crisis	74
Figura 7-26. Resultado Sujeto 3: Paciente 13-Caso1 sin crisis	75
Figura 7-27. Resultado Sujeto 3: Paciente 13-Caso1 con crisis	76
Figura 7-28. Resultado Sujeto 3: Paciente 13-Caso1 sin crisis	77
Figura 7-29. Resultado Sujeto 3: Paciente 13-Caso2 con crisis	78
Figura 7-30. Resultado Sujeto 3: Paciente 13-Caso2 sin crisis	79
Figura 7-31. Resultado Sujeto 4: Paciente 15-Caso1 con crisis	80
Figura 7-32. Resultado Sujeto 4: Paciente 15-Caso1 sin crisis	81
Figura 7-33. Resultado Sujeto 4: Paciente 15-Caso2 con crisis	82
Figura 7-34. Resultado Sujeto 4: Paciente 15-Caso2 sin crisis	83

Figura 7-35. Resultado Sujeto 3: Paciente 13-Caso1 con crisis Kurtosis	84
Figura 7-36. Resultado Sujeto 3: Paciente 13-Caso1 sin crisis Kurtosis	85
Figura 7-37. Resultado Sujeto 2: Paciente 10-Caso1 con crisis Kurtosis	86
Figura 7-38. Resultado Sujeto 2: Paciente 10-Caso1 sin crisis Kurtosis	87
Figura 7-39. Resultado Sujeto 1: Paciente 5-Caso1 con crisis Skewness	88
Figura 7-40. Resultado Sujeto 1: Paciente 5-Caso1 sin crisis Skewness	89
Figura 7-41. Resultado Sujeto 4: Paciente 15-Caso2 con crisis Skewness	90
Figura 7-42. Resultado Sujeto 4: Paciente 15-Caso2 sin crisis Skewness	91

Notación

A^*	Conjugado
A^T	Traspuesto
\forall	Para todos, para cualquier
$\ w\ $	Norma de w
\geq	Mayor o igual
\leq	Menor o igual
Σ	Sumario
$ x $	Valor absoluto
\exists	Existe
$\partial_y \partial_x$	Derivada parcial de y , respecto
EEG	Electroencefalograma
:	Tal que
<	Menor
>	Mayor
\	Backlash
\Leftrightarrow	Si y sólo si
\in	Pertenece a

1 INTRODUCCIÓN

En este trabajo se procede a la utilización de un método de detección de crisis epilépticas por el que se analizan en qué condiciones se obtiene la mejor detección posible y con la mayor anticipación. Para ello, se llevan a cabo diversas pruebas con señales provenientes de un electroencefalograma (EEG) en distintas situaciones.

Se van a introducir los diferentes aspectos tratados durante este documento, siendo su estructura:

1. Introducción: Se enuncian los objetivos y alcance del trabajo, así como la presentación de su estructura.
2. Epilepsia: Se explicará cuidadosamente en qué consiste la epilepsia y cómo puede afectar a los pacientes. Entender bien lo anterior será fundamental a la hora de analizar los resultados que se obtengan en el trabajo.
3. Electroencefalograma (EEG): De qué trata la encefalografía, cómo se obtienen las señales y de qué manera colocamos los sensores para conseguirlo.
4. Base de datos: Registro del que obtuvimos las señales y explicación de dónde y cómo se obtuvieron las señales EEG utilizadas.
5. Pre-procesamiento: En este apartado se muestran las técnicas seguidas para el buen acondicionamiento de las señales EEG para el estudio a realizar.
6. Máquina de soporte vectorial (SVM): Explicación teórica de las máquinas de soporte vectorial que nos permitirán distinguir entre un caso epiléptico o no epiléptico.
7. Resultados: En este apartado se expondrán los resultados obtenidos para el estudio, así como su comparación y posteriores conclusiones.
8. Conclusiones: Tras el análisis de los resultados, se expondrán varias conclusiones.

2 EPILEPSIA

La epilepsia se refiere a un trastorno del sistema nervioso central en el que la actividad cerebral se altera, provocando convulsiones o períodos de comportamiento y sensaciones inusuales, tales como la pérdida de conciencia.

Los síntomas derivados de dichas convulsiones pueden variar de un individuo a otro, mientras algunos simplemente permanecen con la mirada fija unos segundos durante el periodo de convulsión, otros mueven repetidamente los brazos o las piernas.

La epilepsia afecta tanto a hombres como a mujeres de todas las razas, grupos étnicos y edades. En todo el mundo, unos 50 millones de personas padecen epilepsia, lo que la convierte en uno de los trastornos neurológicos más comunes.

El tratamiento con medicamentos o, a veces, la cirugía, pueden controlar las convulsiones en la mayoría de las personas con epilepsia. Algunas personas requieren tratamiento de por vida para controlar las convulsiones, pero, para otras, las convulsiones finalmente desaparecen.

2.1 Síntomas

Debido a que la epilepsia es causada por actividad anormal en el cerebro, las convulsiones pueden afectar a cualquier proceso coordinado por éste. Los síntomas varían de una persona a otra y según el tipo de convulsión, siendo los más comunes [1]:

- Confusión temporal
- Episodios de mirada fija
- Movimientos espasmódicos incontrolables de brazos y piernas
- Pérdida del conocimiento o conciencia
- Síntomas psíquicos, como miedo, ansiedad o déjà vu

2.2 Causas

En la mayoría de los casos, la epilepsia no tiene una causa identificable. Sin embargo, en ocasiones este trastorno puede ser causado debido a la influencia genética mediante una mutación heredada, traumatismos en el cráneo que provoquen lesiones en el cerebro, trastornos cerebrales como tumores o incluso enfermedades infecciosas [1].

También, los niños pueden verse afectados por la epilepsia si han sufrido daños cerebrales antes del nacimiento.

2.3 Diagnóstico

El diagnóstico de este trastorno se establece fundamentalmente a través de una historia clínica minuciosa. Suma de la exploración física y neurológica se realizarán algunas pruebas complementarias como análisis de sangre, electroencefalograma y pruebas de imagen como la TAC y la resonancia magnética craneal [2]. Todo ello permite establecer además del diagnóstico de la epilepsia, identificar el tipo de síndrome epiléptico, y en algunos casos, la causa de la epilepsia.

2.4 Tratamiento

Un diagnóstico exacto y cuidadoso del tipo de epilepsia padecida es fundamental para encontrar un tratamiento efectivo. Existen numerosas formas de tratar la epilepsia, y aún no teniendo cura, los tratamientos actuales pueden controlar los ataques aproximadamente de un 80% de los pacientes. Sin embargo, el 20% restante de los pacientes epilépticos tienen ataques que no se pueden tratar adecuadamente con los medios disponibles actualmente, por lo que se hace absolutamente necesario una mejora en los tratamientos o la aparición de otros nuevos [3].

La duración del tratamiento estará determinada por cada paciente y el tipo de epilepsia, siendo tres las posibilidades de proceso: la medicación, la cirugía y una dieta alimenticia específica. En la mayoría de los casos se aplica una combinación de estas modalidades.

Para la mayoría de pacientes epilépticos, los ataques pueden ser controlados con un único medicamento, administrado en la dosis y forma adecuadas.

Cuando lo anterior no es efectivo, y tras realizar un detallado análisis al paciente, se continuaría con la realización de una cirugía. Su objetivo es quitar la parte de tejido cerebral que este dañada para que los ataques no se sigan produciendo, si esta parte es accesible y sobre todo si se trata de un tejido que no cumple ninguna función importante. Esto se conoce como lobectomía.

Si el foco epiléptico no es extirpable, se pasa a otro tipo de cirugías, donde se realizan cortes que impiden la propagación de las crisis epilépticas a otras partes del cerebro, como puede ser la callosotomía.

El caso radical, sería la realización de una hemisferectomía y hemisferotomía que consisten en retirar la mitad de la corteza cerebral.

Para los afectados que son resistentes a la medicación y no pueden ser sometidos a cirugía, puede resultar interesante el uso de dispositivos estimuladores, como el estimulador de nervio vago o el estimulador para la neuroestimulación reactiva por los cuales se envían descargas eléctricas al cerebro para reducir o impedir las crisis. Esto implica una predicción de las crisis, es decir, detectar el ataque epiléptico tiempo antes de que ocurra, objetivo fundamental de esta investigación [4].

En cualquier caso, el tratamiento estará acompañado de una dieta alimenticia complementaria ajustada a las necesidades personales de cada paciente.

2.5 Tipos de crisis

A grandes rasgos se distinguen dos tipos de crisis: las generalizadas, que afectan a toda la superficie del cerebro y provocan la pérdida de conocimiento y las crisis parciales o focales, donde la descarga comienza en una zona concreta que puede extenderse al resto de la corteza cerebral [1].

-Crisis generalizadas: Cómo se ha expuesto, éstas aparentemente se producen en todas las áreas del cerebro.

- Crisis de ausencia: Se caracterizan por episodios de mirada fija en el espacio o movimientos corporales sutiles como parpadeos o chasquidos de los labios. Pueden causar una pérdida breve del conocimiento.
- Crisis tónicas: Causan rigidez muscular. Generalmente afectan a los músculos de la espalda, brazos y piernas, y pueden provocar caídas.
- Crisis atónicas: También conocidas como convulsiones de caída, causan la pérdida del control muscular, que puede provocar un colapso repentino o caídas.
- Crisis clónicas: Se asocian con movimientos musculares espasmódicos repetitivos o rítmicos. Estas convulsiones generalmente afectan el cuello, la cara y los brazos.

- Crisis mioclónicas: Aparecen como movimientos espasmódicos breves repentinos o sacudidas de brazos y piernas.
- Crisis toniclónicas: Son el tipo de crisis epiléptica más intenso y pueden causar pérdida abrupta del conocimiento, rigidez y sacudidas del cuerpo y, en ocasiones, pérdida del control de la vejiga o mordedura de la lengua.

-Crisis focales: Éstas dependerán de la parte de la superficie del cerebro donde se produzcan las convulsiones

- Sin pérdida del conocimiento: Estas convulsiones parciales simples no causan pérdida del conocimiento. Pueden alterar las emociones o cambiar la manera de ver, oler, sentir, saborear o escuchar. También pueden provocar movimientos espasmódicos involuntarios de una parte del cuerpo y síntomas sensoriales como hormigueo y mareos.
- Con alteración de la conciencia: Incluyen pérdida o cambio del conocimiento o la conciencia durante la convulsión parcial compleja. El afectado se queda inmóvil sin responder durante varios segundos o pocos minutos, pero sin perder el tono muscular. Otras veces sí que se mueve, pero tiene una actuación extraña y no responde o lo hace de forma incoherente.
- Evolucionando a crisis convulsiva bilateral: Se da cuando una crisis focal simple o compleja se extiende desde el foco epiléptico a toda la superficie cerebral.
- Espasmos epilépticos: Se producen en niños de meses de edad y es raro que se produzcan en niños mayores de dos años. Consisten en una flexión o extensión brusca del cuerpo y de la cabeza durante varios segundos.

3 ELECTROENCEFALOGRAMA

La electroencefalografía es una técnica de monitorización electrofisiológica que permite registrar la actividad eléctrica del cerebro. Es un método no invasivo, que utiliza electrodos colocados sobre el cuero cabelludo en condiciones basales de reposo, vigilia o sueño, incluso durante diversas activaciones como pueden ser la hiperpnea (estado en el que existe un aumento en la cantidad del aire inspirado, lo que realiza gracias a un aumento en la frecuencia respiratoria como en el volumen inhalado) o la estimulación luminosa intermitente [5].

El equipo utilizado es capaz de medir las fluctuaciones de voltaje o potencial eléctrico sobre el cuero cabelludo causadas por la actividad eléctrica concomitante de una población de neuronas. Dichas fluctuaciones serán caracterizadas en términos de contenido espectral o de características en el dominio del tiempo [6].

A la hora de diagnosticar la epilepsia, el uso del encefalograma nos permite una buena visualización de una actividad eléctrica cerebral anormal y brusca siendo, por tanto, también identificable el tipo de crisis que tiene el paciente.

3.1 Anatomía del encéfalo

El encéfalo es la parte del sistema nervioso central contenida en el cráneo, siendo el centro de control de casi todas las actividades vitales. La médula espinal es la parte del sistema nervioso central situado en el interior del canal vertebral y se conecta con el encéfalo a través del agujero occipital del cráneo. Juntos reciben, integran y correlacionan distintos tipos de información sensorial.

El encéfalo comprende tres partes principales: el cerebro, el cerebelo y el tronco del encéfalo.

- El tronco del encéfalo se sitúa entre el resto del encéfalo y la médula espinal, siendo la mejor ruta de comunicación entre el cerebro anterior, la médula espinal y los nervios periféricos. Por tanto, es la parte del encéfalo en una posición más baja y cercana al cuello. Se encarga de las tareas del sistema nervioso más básicas para nuestra supervivencia como son la regulación y mantenimiento del ritmo cardíaco y el control automático de la respiración [7].

Sus partes son:

- El bulbo raquídeo es la parte del encéfalo que se une a la medula espinal y constituye la parte inferior del tronco encefálico. En el bulbo se localizan fascículos ascendentes (sensoriales) y descendentes (motores) que comunican la médula espinal con el encéfalo, además de numerosos núcleos que regulan diversas funciones vitales, como la función respiratoria, los latidos cardíacos y el diámetro vascular. Otros centros regulan funciones no vitales como el vómito, la tos, el estornudo, el hipo y la deglución.
- La protuberancia está situada justo debajo del mesencéfalo y encima del bulbo raquídeo. En su cara posterior está el cerebelo. Interviene en el control de la respiración, en la transición entre las fases del sueño y en la regulación del nivel de consciencia, entre otros procesos vitales.
- El mesencéfalo se sitúa en la parte más alta del tronco del encéfalo y une éste con el diencefalo y partes de la corteza cerebral y en su parte inferior tiene la protuberancia. Está formado principalmente por el tálamo y el hipotálamo. Interviene en funciones tan primitivas como la regulación del ciclo sueño-vigilia y de la temperatura corporal, pero también juega un papel a la hora de reaccionar rápidamente ante estímulos visuales y auditivos de manera refleja, así como en el control de ciertos movimientos.




Figura 3-1. Partes principales del encéfalo

- El cerebelo ocupa la porción posterior del encéfalo. Su función principal es la coordinación de los movimientos. El cerebelo evalúa cómo se ejecutan los movimientos que inician las áreas motoras del cerebro. Además, participa en la regulación de la postura y el equilibrio.
- El cerebro forma la mayor parte del encéfalo y se apoya en el diencefalo y el tronco del encéfalo. Consta de la corteza cerebral, la sustancia blanca y los núcleos estriados. Está formado por millones de neuronas que permiten regular todas las funciones del cuerpo y de la mente, como por ejemplo: inicio del movimiento, coordinación del movimiento, temperatura, tacto, visión, audición, habla y lenguaje, juicio, razonamiento, solución de problemas, emociones y aprendizaje. Se compone de dos hemisferios. Cada hemisferio cerebral se subdivide en cuatro lóbulos, que se denominan según los huesos que los envuelven: frontal, parietal, temporal y occipital [4].
 - Lóbulo frontal. La sección más grande del encéfalo localizada en la parte frontal de la cabeza, el lóbulo frontal está involucrado en el juicio, toma de decisiones, algunas funciones del lenguaje, características de la personalidad y el movimiento.
 - Lóbulo parietal. Ayuda a una persona a identificar objetos y comprender las relaciones espaciales. El lóbulo parietal también está involucrado en la interpretación del dolor y el tacto en el cuerpo.
 - Lóbulo occipital. El lóbulo occipital es la parte posterior del encéfalo que está involucrado con la visión y el procesamiento de las imágenes.
 - Lóbulo temporal. Los lados del encéfalo, estos lóbulos temporales están involucrados en la memoria, habla y reconocimiento del olor.




Figura 3-2. Lóbulos cerebrales y tronco del encéfalo

En el estudio electroencefalográfico necesitaremos saber dónde y cómo se generan las señales bioeléctricas, lo que se conoce como la electrogénesis. Se procederá a distinguir entre electrogénesis cerebral y electrogénesis cortical.

3.1.1 Electrogénesis cerebral

Una de las funciones básicas del tejido nervioso es la capacidad de generar potenciales eléctricos que son la base de la excitabilidad del organismo. En sí, todo el sistema nervioso posee capacidad electrogénica. Para entender la generación de estos potenciales se precisa un conocimiento de la estructura y las conexiones de las partes cerebrales que los originan. Sin embargo, para los fines del EEG solo serán necesarios considerar la corteza cerebral y las regiones directamente relacionadas con ellas. La corteza se divide en las siguientes capas celulares:

- Capa molecular o plexiforme: Es la parte más exterior de la corteza. Tiene una red densa de fibras nerviosas orientadas tangencialmente.
- Capa granular externa: Se encuentra bajo la capa molecular y contiene una gran cantidad de células piramidales y estrelladas. Las células de esta capa son receptoras, aquellas que reciben toda la información que transmite el cuerpo, los estímulos son recibidos por estas células
- Capa piramidal externa: Formada por células piramidales y presenta una forma irregular, incrementándose su tamaño al profundizar en la capa. Las células de esta capa son efectoras, encargadas de mandar información a otras células, entrando en funcionamiento gracias a los diferentes estímulos que poseen el organismo.
- Capa granular interna: Compuesta de células estrelladas de forma muy compacta y tiene una elevada concentración de fibras horizontales. Las células de esta capa son receptoras.
- Capa ganglionar: Contiene células piramidales grandes y medianas, y un elevado número de fibras horizontales. Las células de esta capa son efectoras.
- Capa multiforme: Contiene células fusiformes.




Figura 3-3. Capas de la corteza cerebral

3.1.2 Electrogénesis cortical

Un fragmento de tejido cortical aislado produce actividad eléctrica espontánea. Se caracterizan por series de ondas lentas sobre las que se superponen ritmos rápidos. Estas señales son consecuencia de la actividad sináptica general de regiones discretas del tejido. A éstas se les llaman generadores, distinguiéndose entre:

- **Generador A:** Situado a unas 500 micras de la superficie cortical está producido por la despolarización de las dendritas apicales de las células piramidales. Su actividad produce ondas negativas en la superficie de la corteza. No tiene relación con la descarga de potenciales de acción de las células.
- **Generador B:** Situado a 900 micras de profundidad. Produce ondas positivas en la superficie cortical y su actividad coincide con la aparición de potenciales de acción (impulsos eléctricos que recorren las neuronas, constituyendo su manera de transmitir información) en las células.
- **Generador C:** Está situado también a 900 micras, pero su actividad determina ondas negativas en la superficie cortical y es el resultado de la hiperpolarización de las células. Su actividad coincide con una interrupción de la descarga de potenciales de acción en las células piramidales.

De forma general, una tensión positiva en la superficie cortical traduce una despolarización en las capas más profundas de la corteza. En cambio, una tensión negativa puede ser resultado, bien de una despolarización superficial, o de una hiperpolarización profunda [4].

3.2 Señales EEG

Las señales EEG tienen una magnitud de 5 a 300 μV y un ancho de banda que va desde los 0.5 Hz hasta los 100 Hz

Las ondas emitidas por el cerebro, que pueden captarse mediante el EEG, se pueden clasificar en distintos tipos, dependiendo de la frecuencia [8]:

-Onda Delta: Con una frecuencia de 0.5-3 Hz, surgen principalmente en el sueño profundo y muy raras veces se pueden experimentar estando despierto

-Onda Theta. Con una frecuencia de 4-7 Hz, se producen durante el sueño o en meditación profunda, presentándose por una activación del lóbulo temporal.

-Onda Alfa: La fuente de estas señales se encuentra en la región occipital durante los estados de relajación. Tienen una frecuencia de 8-12 Hz.

-Onda Beta: Con una frecuencia comprendida entre 13 y 30 Hz. Se registran cuando los sentidos se hallan volcados hacia el exterior y en plena actividad mental, localizándose en zona parietal y frontal.

-Onda Gamma: Son las que ocupan el rango de frecuencias entre 30 y 100 Hz. Están asociadas a situaciones de gran estrés o de gran concentración.

3.3 Captación del EEG

La actividad bioeléctrica puede captarse por diversos procedimientos:

-Sobre el cuero cabelludo.

-En la base del cráneo.

-En cerebro expuesto.

-En localizaciones profundas.

3.3.1 Tipos de electrodos

Para captar la señal se utilizan diferentes tipos de electrodos.

- Electrodo​s superficiales:

Se aplican sobre el cuero cabelludo.

-Adheridos: Pequeños discos metálicos que se adhieren con pasta conductora y se fijan con colodión aislante. Dan resistencias de contacto muy bajas.

-De contacto: Tubos de plata clorurada pequeños roscados a soportes de plástico que se sujetan al cráneo con bandas eléctricas y se conectan con pinzas. En su extremo de contacto se colocan almohadillas humedecidas con solución conductora.

-En casco de malla: Los electrodos están incluidos en un casco elástico lo que supone una mayor comodidad de colocación y confort para el paciente en pruebas de larga duración. Presenta gran inmunidad frente a artefactos.



Figura 3-4. Electrodo superficial en caso de malla

-De aguja: Su uso es muy limitado, sólo en recién nacidos y en UCI. En este caso, su esterilización y manipulación deben ser muy cuidadosos.

- Electrodo basales:

Para el estudio de la cara basal del encéfalo se utilizan electrodos especiales como el faríngeo, el esfenoidal, y el timpánico. Estos electrodos son semi-invasivos, requieren de cirugía menor con anestesia local. Los esfenoidales recogen información de la actividad en la región media temporal y se pueden dejar fijos durante varias semanas sin tener efectos secundarios.

- Electrodo quirúrgicos:

Se utilizan durante el acto quirúrgico y son manipulados exclusivamente por el neurocirujano. Pueden ser duros, corticales o intracerebrales.



Figura 3-5. Electrodo quirúrgico de tipo duros

Para la obtención del encefalograma (EEG) se utilizan electrodos superficiales colocados sobre el cuero cabelludo. Se describe a continuación el posicionamiento de los mismos.

3.3.2 Sistema de posicionamiento de electrodos superficiales

Pese a la existencia de numerosos sistemas de posicionamiento, la disposición de los electrodos en el cuero cabelludo se ajusta al sistema “diez-veinte”, que está catalogados como el método de posicionamiento estándar. El 10 hace referencia a que las distancias reales entre electrodos adyacentes son el 10% del tamaño de la cabeza, mientras que el 20 se refiere al 20% de la distancia total delantera/trasera o derecha/izquierda, de manera que la zona que registre cada electrodo sea comparable entre los registros realizados a diferentes individuos.

Se emplean marcas craneales que son tomadas como puntos de referencia para la localización de los electrodos.

Cada localización posee una letra para identificar el lóbulo y un número para definir la posición del hemisferio. Por lo tanto, tendríamos la siguiente nomenclatura: F (frontal), C (central), T (temporal), P (posterior) y O (occipital). Además, la “z” hace mención al electrodo que se coloca en la línea media del cráneo. Por otro lado, la presencia de números se utiliza para referirnos a la parte izquierda de la cabeza si son impares, y a la parte derecha cuando son pares.

Para realizar una colocación exacta de los electrodos en EEG, se toman una serie de puntos como referencia. Primero, “nasion”, situados entre la frente y la nariz; segundo, el “inion”, que es el punto más bajo del cráneo y el tercero, el “punto pre-auricular”, situado en las orejas [9].




Figura 3-6. Sistema de posicionamiento 10-20 para la colocación de electrodos

3.3.3 Montaje de un EEG

Partiremos de una serie de electrodos situados sobre el cuero cabelludo en las situaciones precisas, determinadas según el sistema internacional “diez-veinte”, para proceder a registrar el EEG. Cada electrodo es un punto de registro, pero es preciso además de disponer de dos terminales para poder realizar el registro, ya que la medida tomada es la diferencia de voltaje entre dos electrodos, dando lugar a múltiples combinaciones. Para ello, habrá que seleccionar cuáles de los electrodos deben ser la fuente de señal registrada en el electroencefalógrafo, dependiendo del número de canales disponibles y del propósito específico del registro a realizar. La clasificación utilizada está basada en [4]

En primer lugar, debemos seleccionar entre registros monopolares y registros bipolares.

- Registros Monopolares:

Se toma la señal de cada uno de los electrodos independientemente de la de los demás. El electrodo de registro se llama electrodo activo y el segundo cable de entrada al equipo se toma de un electrodo llamado de referencia.

Teóricamente este electrodo debe estar situado a potencial cero, aunque ésto en la práctica real nunca hay seguridad de que sea posible de conseguir. Por ésto se emplean referencias aproximadas como son el uso de electrodos en el lóbulo de la oreja, en el mentón o en el mastoides.

También podemos conseguir un electrodo referencial reuniendo todos los demás electrodos entre sí, por lo que tendremos un punto cuyo potencial es la suma de los potenciales individuales de todos los electrodos. Presumiblemente, esta suma será cero, con lo que tendremos ya el punto que buscábamos.




Figura 3-7. Esquemas de montaje para un registro monopolar y un registro monopolar promediado

La interconexión entre todos se realiza por medio de resistencias de valor moderadamente alto (entre 1 y 1.5 M Ω). Este es el llamado sistema Wilson.

Existen otros tipos de referencia diferentes que se utilizan, por ejemplo, para reducir algunas interferencias particulares. Por ejemplo, para reducir los artefactos debidos al electrocardiograma, muy corrientes en los registros referenciales, se disponen dos o más electrodos en lugares próximos al corazón (fuera del cráneo) y se unen entre sí. De esta forma en ellos se cortocircuita la señal electrocardiográfica con lo que ésta se atenúa en gran medida.

▪ Registros Bipolares:

Se toman parejas de electrodos, dos a dos y se registran las diferencias de tensión entre cada par de puntos. Los dos electrodos de cada pareja son activos. Debido a lo anterior, es posible realizar un número enorme de registros bipolares diferentes, y es por ello que muchas de las combinaciones podrían no resultar de interés. Dado esto se seleccionan las más interesantes formándose lo que se denomina montaje.

Se utilizan montajes a largas distancias, cuando se registra entre electrodos no contiguos. Por el contrario, en los montajes a distancias cortas se hacen registros entre electrodos vecinos.




Figura 3-8. Esquema de montaje para un registro bipolar

Por otra parte, los montajes también han sido clasificados por la Federación Internacional de EEG y Neurofisiología en longitudinales y transversales. En los montajes longitudinales se registra la actividad de pares de electrodos dispuestos en sentido anteroposterior de cada mitad del cráneo. En los montajes transversales se realizan registros de pares de electrodos dispuestos transversalmente según los planos sagitales anterior, medio o posterior.




Figura 3-9. Esquema de un montaje longitudinal bipolar (A) y transversal (B)

Se recomienda, además, seguir las siguientes directrices en el diseño de montajes para registro del EEG:

- Registrar como mínimo 8 canales.
- Utilizar el sistema diez-veinte para colocación de electrodos.
- Cada sesión rutinaria de registro EEG debe incluir como mínimo un montaje de los tres tipos principales: referencial, longitudinal bipolar y transversal bipolar

4 BASE DE DATOS

La base de datos del estudio fue recopilada en el Children's Hospital de Boston (<https://physionet.org/physiobank/database/chbmit/>), constando de grabaciones EEG de pacientes pediátricos con convulsiones intratables. Los pacientes fueron monitoreados durante varios días después de la retirada de la medicación anticonvulsiva con el objetivo de caracterizar sus ataques y evaluar su candidatura para la intervención quirúrgica [10].

Las grabaciones, que fueron agrupadas en 23 grupos, se obtuvieron de 22 sujetos (5 hombres con edades entre 3-22 años y 17 mujeres con edades entre 1,5-19 años). El caso chb21 se obtuvo 1,5 años después del caso chb01, perteneciente a la misma mujer.

Cada caso contiene entre 9 y 42 archivos con formato .edf continuos de un único sujeto. En la mayoría de los casos, los archivos .edf contienen exactamente una hora de señales EEG digitalizadas, aunque las que pertenecen al caso chb10 duran dos horas, y las que pertenecen a los casos chb04, chb06, chb07, chb09 y chb23 duran cuatro horas; ocasionalmente, los archivos en los que se registran las convulsiones son más cortos.

Todas las señales se muestrearon a 256 muestras por segundo con una resolución de 16 bits. La mayoría de los archivos contienen 23 señales de EEG (24 o 26 en algunos casos). El sistema Internacional 10-20 se utilizó de posiciones de los electrodos de EEG y la nomenclatura de estas grabaciones.

Además, los archivos llamados chb nn -summary.txt contienen información sobre el montaje utilizado para cada grabación, y el tiempo transcurrido en segundos desde el comienzo de cada .edf archivo al comienzo y al final de cada ataque contenido en él.

En la siguiente tabla, se muestra la edad y sexo de cada paciente de forma detallada:

PACIENTE	SEXO	EDAD
Chb01	F	11
Chb02	M	11
Chb03	F	14
Chb04	M	22
Chb05	F	7
Chb06	F	1.5
Chb07	F	14.5
Chb08	M	3.5
Chb09	F	10
Chb10	M	3
Chb11	F	12
Chb12	F	2
Chb13	F	3
Chb14	F	9

Chb15	M	16
Chb16	F	7
Chb17	F	12
Chb18	F	18
Chb19	F	19
Chb20	F	6
Chb21	F	13
Chb22	F	9
Chb23	F	6

Tabla 4-1. Directorio de pacientes con su sexo y edad

5 PRE-PROCESAMIENTO

En este capítulo exponemos el método propuesto para la detección de una crisis epiléptica. Para ello debemos adaptar las señales para obtener la mayor cantidad de información útil posible. Posteriormente preparamos estas señales para poder estudiarlas después. En último lugar, obtenemos varios parámetros que nos serán de gran utilidad para detectar la crisis.

5.1 Obtención de las grabaciones

Las señales de los pacientes a estudiar han sido obtenidas, como mencionamos en el capítulo anterior, de la base de datos Physionet. Para ello, hemos utilizado su toolbox propia Physiobank ATM (PhysioBank's Automated Teller Machine) [11], con la que podemos explorar fácilmente la base de datos mediante su navegador web.

Physiobank ATM nos permite seleccionar la base de datos deseada, en este caso “CHB-MIT Scalp EEG Database (chbmit)”, y elegir la señal del paciente que deseamos descargar. Además, permite configurar múltiples opciones como son la longitud, formato de tiempo y datos. Por último queda seleccionar el formato deseado, puesto que esta herramienta distingue entre trazados de formas de onda, trazados de histogramas, exportaciones de las señales en múltiples formatos como .edf, .csv, .mat, etc.

En nuestro caso, exportamos las señales a .mat, para poder trabajar con ellas en MATLAB, obteniendo dicho archivo .mat, además de un archivo .info con información relevante acerca de los canales.

5.2 Fases del pre-procesamiento

Las señales biomédicas con las que vamos a tratar son señales débiles en un entorno plagado de interferencias. Las interferencias se deben a posibles artefactos, o simple ruido. Esta fuente de ruido puede ser fisiológica, instrumental, o interferencias de la zona experimental.

Es por ello, que antes de trabajar con las señales, vamos a pre-procesarlas para obtener toda la información útil posible.

Usaremos la aplicación Brainstorm, dedicada al análisis de grabaciones cerebrales, operable desde Matlab. Se seguirán claves principales del preprocesamiento de [12].

5.2.1 Filtrado a 60 Hz

En primer lugar, nos enfocaremos en los patrones de ruido que ocurren continuamente, a frecuencia específicas. Dichos artefactos se pueden corregir mediante filtros de frecuencia, por lo que se aplicaran filtros “NOTCH” o paso de banda antes de aplicar cualquier otro tipo de corrección.

Comenzaremos con una evaluación rápida del nivel de ruido, calculando el espectro de potencia de todas las señales en todas las grabaciones.

Brainstorm evalúa la potencia de las señales MEG / EEG a diferentes frecuencias, utilizando el método de Welch. Divide las señales en ventanas superpuestas de una longitud determinada, calcula la Transformada de Fourier (FFT) de cada uno de estos segmentos cortos y promedia la potencia de los coeficientes de FFT para todas las ventanas superpuestas, obteniéndose el espectro de potencia de la señal.

Una vez obtenido el gráfico, observamos:




Figura 5-1. Espectro de potencia de chb15_06

-Picos de frecuencia relacionados con la línea eléctrica en 60 Hz, 120 Hz, 180 Hz, debido a la línea de alimentación alterna, que en Boston es a 60 Hz. En España aparecerían a 50 Hz.

-Picos de frecuencia a **76 Hz**, probablemente debido a la interferencia de algún equipo médico en la sala.

-Picos relacionados con los ritmos alfa del sujeto: alrededor de **10Hz** y **20Hz**

-Observamos una mayor potencia de señal entre **30Hz y 100Hz** en muchos sensores occipitales. Esto probablemente esté relacionado con cierta tensión en los músculos del cuello debido a una posición de asiento incómoda en el MEG. Veremos más adelante si estos canales deben etiquetarse como malos o no.

Como la interferencia eléctrica es la más notable en la totalidad de nuestras grabaciones, ejecutaremos un filtro de frecuencia para eliminar los armónicos de 60Hz + de los archivos continuos. Los filtros “notch” están adaptados para eliminar contaminaciones bien identificadas de sistemas que oscilan a frecuencias muy estables.




Figura 5-2. Espectro de potencia de chb15_06 filtrado a 60 Hz

Vemos como al aplicar el filtro, los picos eléctricos aparecen atenuados, compensándose su efecto anterior.

Gracias a este procesado, hemos podido detectar grabaciones demasiado contaminadas por las interferencias y por tanto no resultaría eficiente utilizarlas en este trabajo. Observemos el siguiente caso, en el que los picos en frecuencia son muy pronunciados en múltiples de ellas.




Figura 5-3. Espectro de potencia de chb15_40

Ni aún filtrándola, conseguimos un buen resultado para el estudio:




Figura 5-4. Espectro de potencia de chb15_40 filtrado a 60 Hz

5.2.2 Detección de canales defectuosos

También hay que tener presente, que en EEG la calidad de la conexión entre el electrodo y el cuero cabelludo del paciente es muchas ocasiones es demasiado baja para registrar una buena señal.

Trataremos de identificar estos sensores con mala calidad antes de eliminar artefactos, como los parpadeos, ya que en caso contrario puede que no funcionen bien o se propaguen señales malas a todos los canales.

Algunos canales defectuosos son fáciles de detectar, sus señales se ven completamente apagadas o totalmente planas en comparación con los otros sensores circundantes. Algunos otros son más difíciles de identificar.

Como podemos observar en las siguientes imágenes, donde se ha calculado la densidad espectral de potencia, hemos detectado los canales defectuosos (canales en rojo) y se han marcado como tales.




Figura 5-5. Espectros de potencia con canales defectuosos en las grabaciones de chb05

Contemplamos cómo los valores de los canales marcados se diferencian notablemente de los valores de la densidad espectral de potencia de los demás. Brainstorm nos permite seleccionar estos canales defectuosos y marcarlos como defectuosos. Podemos ver como los canales FZ-CZ y CZ-FZ se muestran casi totalmente planos frente a los demás, en la siguiente imagen:




Figura 5-6. Canales defectuosos de chb05_06

A continuación, se muestran los canales resultantes tras haber marcado los anteriores como malos:




Figura 5-7. Canales defectuosos eliminados de chb05_06

Otro caso a destacar, sería el siguiente, perteneciente al paciente 13, en el que los sensores correspondientes a T7-FT9 y FT9-FT10, correspondientes a los electrodos cercanos a las orejas, muestran un comportamiento totalmente alejado de los otros electrodos.

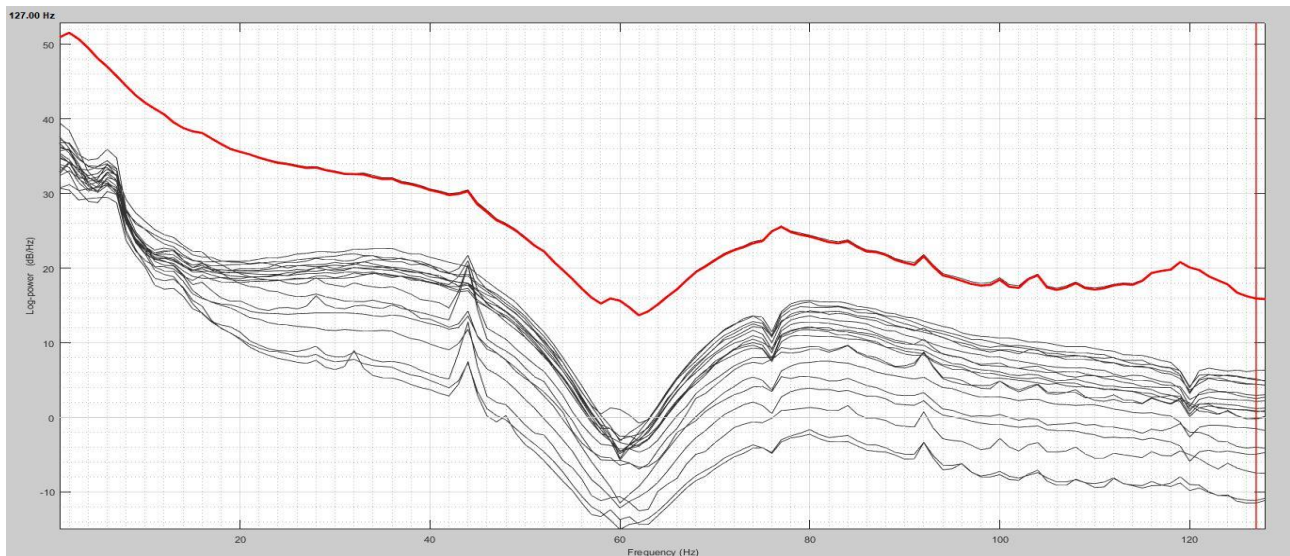


Figura 5-8. Espectro de potencia con canales defectuosos de chb13_55

Tanto es así, que en la siguiente figura podemos observar un comportamiento bastante inusual en los primeros segundos de grabación, donde las señales EEG correspondientes a dichos canales presentan múltiples variaciones en su comportamiento.




Figura 5-9. Canales defectuosos de chb13_55

Una vez marcados, como canales defectuosos, nuestra señal se vería de la siguiente manera:




Figura 5-10. Canales defectuosos eliminados de chb13_55

5.2.3 Detección de artefactos

Antes hemos mostrado como eliminar patrones de ruido que se producen continuamente y en frecuencias específicas. Sin embargo, la mayoría de los eventos que estropean las grabaciones EEG no persisten y abarcan un gran rango de frecuencia o solapan con las frecuencias de las señales cerebrales que nos interesan. Es por ello, que los filtros de frecuencia no son apropiados para corregir los movimientos oculares, latidos cardíacos u otras actividades musculares.

Una forma muy interesante de eliminar los parpadeos es usar la técnica ICA (Independent Component Analysis), que permite separar las señales EEG en componentes independientes, no solo relacionadas con la actividad cerebral sino también con movimientos musculares o parpadeos, que vienen entremezclados en las señales EEG. Tras la separación es más fácil eliminar las componentes que no provienen de la actividad cerebral [13].

A pesar de su buen funcionamiento, ICA es un proceso muy lento debido a su gran complejidad computacional. Es por esto, que en este trabajo se ha decidido eliminar los parpadeos manualmente, eliminando los trozos de señal dónde aparezcan parpadeos uno a uno. Lo anterior puede ser tedioso ya que se trabaja con grabaciones de varias horas, sin embargo, tan sólo será necesario eliminar los parpadeos de las zonas de interés y no todos los parpadeos de las señales, reduciendo así la labor a realizar. Sólo se eliminarán los parpadeos de varios minutos en cada grabación.

En la siguiente figura, observaremos la ocurrencia del parpadeo efectuado por el paciente 15 entre los 740 y 750 segundos. De manera clara, observamos un prominente pico negativo en los canales correspondientes a los electrodos cercanos a la zona de los ojos. Ya que este fenómeno podría contaminar los resultados de nuestro estudio, dicho intervalo de tiempo será suprimido.




Figura 5-11. Parpadeo encontrado en chb15_15

5.2.4 Detección de segmentos defectuosos adicionales

Previamente hemos corregido de nuestras señales los artefactos a frecuencias fijas (líneas eléctricas) y algunos artefactos estándar y reproducibles (parpadeos). Sin embargo, existen otras posibles fuentes de ruido que pueden arruinar el uso de nuestras grabaciones.

Dado lo anterior, se ha realizado una detección de artefactos, mediante un mecanismo de detección automática basado en SSP (Proyección del Espacio de Señal), en dos bandas de frecuencia, elegidas debido a la predictibilidad de los artefactos en estas bandas.

- **1-7 Hz:** típicamente relacionado con el movimiento del sujeto, los movimientos oculares y el trabajo dental (u otro metal)
- **40-240 Hz:** relacionado con el ruido muscular y algunos artefactos de los sensores

Una vez detectados los artefactos, marcas verdes (1-7 Hz) y azules (40-240 Hz) en la figura, se marcan como malos para identificar su aparición en nuestras grabaciones.




Figura 5-12. Artefactos adicionales de chb10

5.2.5 Filtrado a [0.5,80] Hz

Por último, se ha aplicado un filtro paso de banda entre 0.5 y 80 Hz, puesto que engloban las frecuencias a las que nos interesa trabajar en este estudio.




Figura 5-13. Espectros de potencia de las grabaciones de chb15 filtrados en [0.5, 80] Hz

Realizando este filtrado, nos zafamos, por ejemplo, de los destacados picos en frecuencias en los armónicos 120Hz y en adelante, vistos anteriormente, ya que como hemos mencionado para trabajar con nuestras señales EEG nos bastará un intervalo frecuencial menor.

5.3 Filtrado en las bandas de interés

Tras el filtrado inicial se realizarán otros cuatro filtrados. Cada uno de estos filtrados pertenece a un rango de frecuencia distinto. Estos cuatro rangos de frecuencias son los correspondientes a los cuatro rangos de interés: Delta (0.5-4 Hz), Theta (4-7 Hz), Alpha (8-12 Hz) y Beta (13-30 Hz). A la salida de estos filtros se obtendrán cuatro señales de la misma longitud pertenecientes cada una a un rango de frecuencias distinto.

Mostramos la respuesta en frecuencia de cada uno de los filtros a aplicar:




Figura 5-14. Respuesta en frecuencia filtro Delta

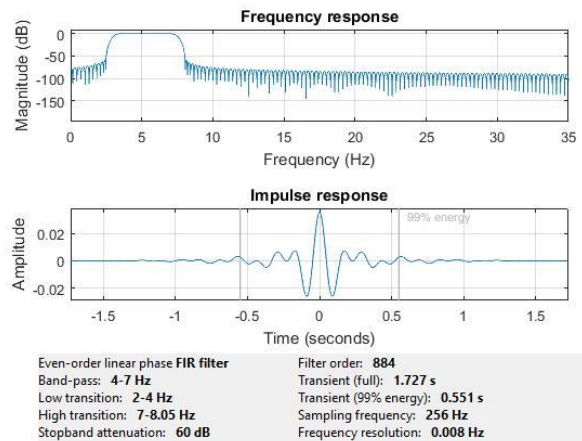


Figura 5-15. Respuesta en frecuencia filtro Theta




Figura 5-16. Respuesta en frecuencia filtro Alfa

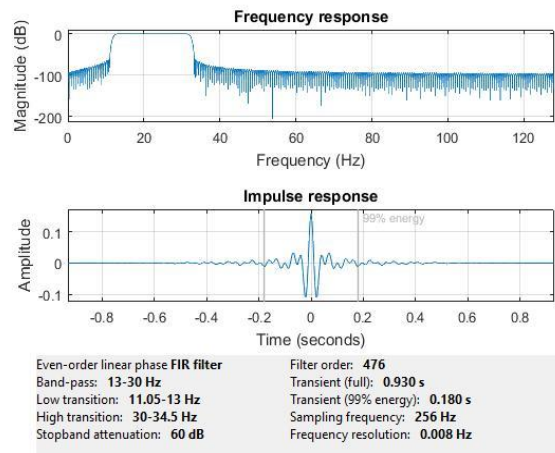


Figura 5-17. Respuesta en frecuencia filtro Beta

- Filtro paso banda (0.5-4Hz): En este rango se encuentra la onda Delta (descrita en el Capítulo3). Aplicando dicho filtro, la señal EEG nos queda:




Figura 5-18. Señal de EEG genérica tras aplicar filtro Delta

- Filtro paso banda (4-7Hz): En este rango se encuentra la onda Theta (descrita en el Capítulo3). Aplicando dicho filtro, la señal EEG nos queda:



Figura 5-19. Señal de EEG genérica tras aplicar filtro Theta

- Filtro paso banda (8-12Hz): En este rango se encuentra la onda Alpha (descrita en el Capítulo3). Aplicando dicho filtro, la señal EEG nos queda:




Figura 5-20. Señal de EEG genérica tras aplicar filtro Alfa

- Filtro paso banda (13-30Hz): En este rango se encuentra la onda Beta (descrita en el Capítulo3). Aplicando dicho filtro, la señal EEG nos queda:

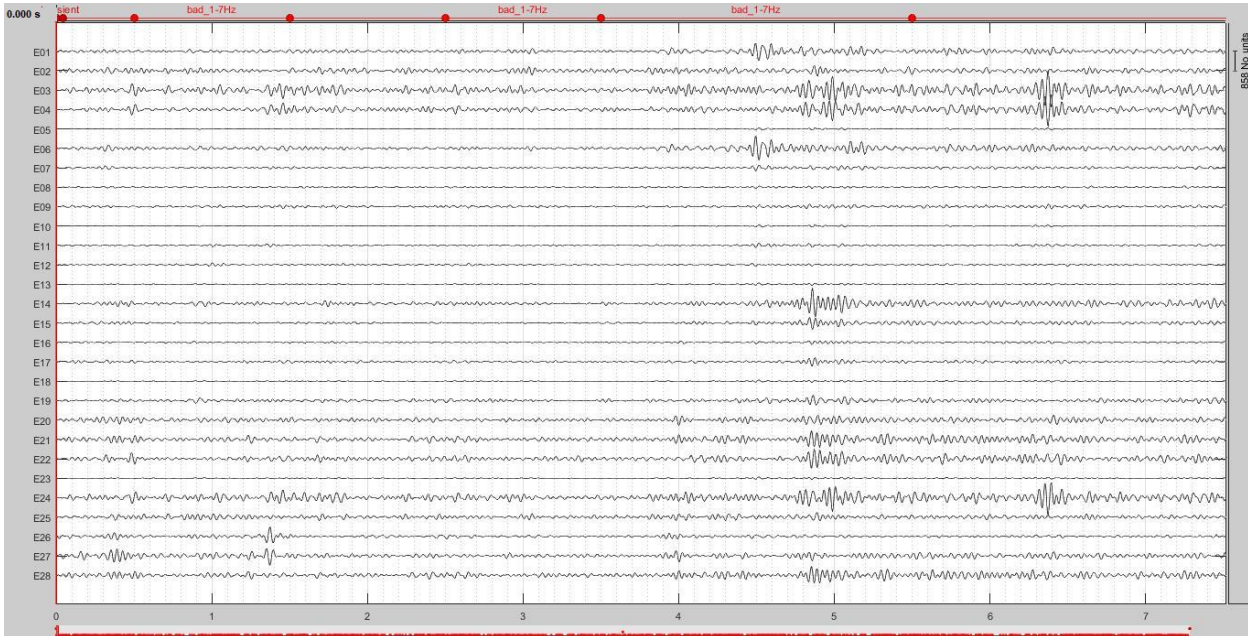


Figura 5-21. Señal de EEG genérica tras aplicar filtro Beta

5.4 División en bloques

Una vez hemos filtrado las señales, debemos dividir las en instantes temporales de las señales cerebrales. Por ello, se segmentará la señal EEG bruta en diferentes épocas que recojan los eventos que originan la crisis epilepticas. Las épocas en cuestión serán instantes de tiempos de variada duración dentro del EEG continuo total. La división se realizará mediante bloques de 1 segundo.

En particular hemos extraído mediante el script “principal” de Matlab, tres diferentes matrices para cada grabación de los pacientes estudiados correspondientes a los instantes de ataque epiléptico, instantes previos al ataque epiléptico e instantes donde no se detecta ningún tipo de ataque.

5.5 Cálculo de parámetros

Una vez hemos obtenido las particiones de las señales, procedemos al cálculo de algunos parámetros de interés. Éstos serán: la potencia, la kurtosis y la skewness o coeficiente de asimetría. El proceso se realizará mediante el script “CalculaParam” de Matlab, por el cual obtenemos como resultado tres matrices para cada parámetro correspondientes a los 3 intervalos estudiados (previo crisis, crisis, no crisis), para cada grabación. Éstas matrices constarán de un número de columnas igual al número de segundos del intervalo que estemos estudiando, pues como se ha dicho anteriormente, el calculo de los parámetros se hará en bloques de 1 segundo. Puesto que trabajaremos con 4 pacientes con 3 grabaciones cada uno, para cada paciente obtendremos 27 matrices. Siendo 108 las matrices totales obtenidas.

Cada matriz tendrá unas dimensiones de 23 filas (ya que trabajamos con 23 canales) y n columnas, siendo n el número de segundos.

6 MÁQUINA DE SOPORTE VECTORIAL (SVM)

Las Máquinas de Soporte de Vectores (Support Vector Machine, SVM) son unos sistemas de aprendizaje que pertenecen a la rama de clasificadores lineales generalizados, aplicables tanto en problemas de clasificación como de regresión. En este trabajo utilizaremos este sistema para predecir las crisis epilépticas. Nos basaremos en las ideas presentadas en [13].

Las máquinas de soporte basan su estructura en una red estática de núcleos o kernels que operan sobre vectores de características que han sido transformados a un espacio de dimensión mayor a a del espacio de características original.

Su mayor ventaja es la capacidad de generalización, basada en la determinación del hiperplano que da lugar a la máxima distancia de sepatación entre los vectores transformados. Cuanto mayor sea esta distancia, mejor será la capacidad de generalización del clasificador.

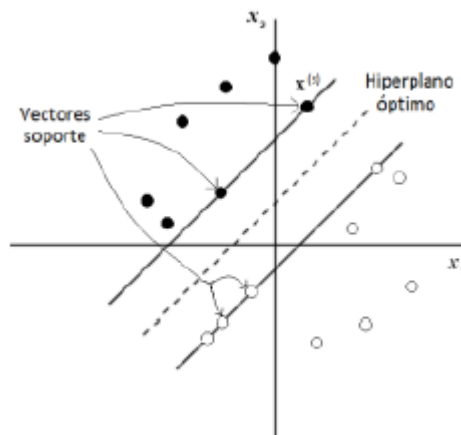


Figura 6-1. Representación del hiperplano óptimo y sus vectores soporte asociados para un SVM de margen máximo

Las etapas empleadas por las SVM para realizar una clasificación de patrones son las siguientes:

1. Transformación de los datos o vectores de características de entrada a un espacio de mayor dimensión a través de una función. El objetivo es formular el problema de modo que el procedimiento de clasificación transforme implícitamente los datos operando con funciones kernel, K .
2. Cálculo del hiperplano óptimo que maximiza la distancia entre las clases consideradas.

6.1 Clasificador de margen máximo

El clasificador de margen máximo es el modelo más simple de las máquinas de soporte vectorial. El margen es definido como la distancia mínima entre el hiperplano de separación de las clases y los datos de entrenamiento más cercanos. Cuanto mayor sea el margen, mayor poder de generalización tendrá el clasificador implementado.

La clasificación de margen máximo solo tiene validez para datos linealmente separables en el espacio de características, por lo que no puede ser usada en la mayor parte de problemas reales. No obstante, es un modelo sencillo de entender y será útil para introducir la forma de procesamiento usada por las SVM.

La explicación de la implementación del modelo se detalla solo para la clasificación de los datos en dos clases, pero las conclusiones son extrapolables para casos de múltiples clases.

El problema planteado es el siguiente:

Dado un conjunto de datos o vectores de entrada $x \in \mathbb{R}^n$ de las diferentes clases e y $y \in \mathbb{N}$, se deseará encontrar el valor de los parámetros del hiperplano óptimo: $\{w, b\}$, que da lugar al margen máximo. Esto es:

$$w^T x_i + b \geq y_i = \begin{cases} y_i = 1 & \forall x_i \in C_i = A \\ y_i = -1 & \forall x_i \in C_i = B \end{cases} \quad (6-1)$$

$$\rightarrow \exists (w^*, b^*) \quad / \quad w^{T*} x + b^* = 0 \quad \text{Hiperplano óptimo}$$

Maximizando el margen y paralelos al hiperplano óptimo, se encuentran otros dos hiperplanos, H_1 y H_2 , que contienen al menos un vector de cada clase, denominados vectores de soporte. La expresión matemática de dichos hiperplanos es la siguiente:

$$H_1 : w^T x + b = 1 \quad (6-2)$$

$$H_2 : w^T x + b = -1 \quad (6-3)$$

Como el vector w es perpendicular al hiperplano que define, la distancia del hiperplano al origen del sistema de coordenadas viene dada por:

$$d = \frac{b}{\|w\|} \quad (6-4)$$

donde $\|w\|$ se refiere a la norma euclídea de w . Además, usando las ecuaciones (6-2), (6-3), se obtiene que la distancia entre H_1 y H_2 es:

$$d = \frac{2}{\|w\|} \quad (6-5)$$

Por tanto, el objetivo de maximizar la distancia de separación entre ambos hiperplanos es equivalente a minimizar $\|w\|$. Además, la solución propuesta debe evitar que haya vectores de entrada dentro de la región entre los hiperplanos H_1 y H_2 , es decir:

$$y_i(w^T x_i + b) \geq 1, \quad 1 \leq i \leq N \quad (6-6)$$

siendo N el número de datos o vectores de entrada proporcionados para el entrenamiento de la SVM. Todas estas restricciones dan lugar al siguiente problema de optimización:

$$\text{minimizar: } \Omega(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \quad (6-7)$$

$$\text{sujeto a: } y_i \mathbf{w}^T \mathbf{x}_i + b \geq 1, \quad 1 \leq i \leq N \quad (6-8)$$

Para resolver el problema anterior, se utiliza el método de los multiplicadores de Lagrange, dando lugar a la siguiente función lagrangiana:

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^N \alpha_i [y_i (\mathbf{w}^T \mathbf{x}_i + b) - 1] \quad (6-9)$$

donde $\alpha_i \geq 0$ son los multiplicadores de Lagrange. Derivando esta ecuación en función de \mathbf{w} y b , e igualando a cero, se consiguen las dos condiciones de optimización:

$$\frac{\delta L(\mathbf{w}, b, \alpha)}{\delta b} = 0 \rightarrow \mathbf{w} = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i \quad (6-10)$$

$$\frac{\delta L(\mathbf{w}, b, \alpha)}{\delta b} = 0 \rightarrow 0 = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i \quad (6-11)$$

Por lo tanto, se puede decir que:

$$\mathbf{w}^T \mathbf{w} = \mathbf{w}^T \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i = \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \quad (6-12)$$

Sustituyendo, se obtiene la función a maximizar $Q(\alpha)$:

$$L(\mathbf{w}, b, \alpha) = Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \quad (6-13)$$

Sujeta a las siguientes restricciones:

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad (6-14)$$

$$\alpha_i \geq 0 \quad \forall i = 1, \dots, N$$

donde se puede demostrar que sólo los α_i de los vectores de soporte son distintos de cero. Por lo tanto, el hiperplano de separación óptima, H_0 , depende únicamente de los vectores soporte calculados en el entrenamiento. Entonces, una vez calculados los valores óptimos de α_i^* se obtendrán finalmente los coeficientes del hiperplano:

$$\alpha_i^* \Rightarrow \mathbf{w}^* = \sum_{i=1}^N \alpha_i^* y_i \mathbf{x}_i \rightarrow b^* = 1 - \mathbf{w}^{*T} \mathbf{x}_s \quad (6-15)$$

6.2 Clasificador de margen blando

El clasificador de margen máximo tiene el problema de considerar que la región comprendida entre los hiperplanos H_1 y H_2 está libre de vectores ya que no contempla errores en el entrenamiento. Esta situación no se cumple casi nunca en las aplicaciones reales y por ello se creó la idea de margen blando para los casos en que no sea posible encontrar un hiperplano de separación óptimo H_0 .

En margen blando, se busca el hiperplano óptimo con el fin de que sea capaz de separar los datos con el menor número de errores, y que el margen sea el máximo entre los datos clasificados correctamente. Esta nueva variante introduce un nuevo conjunto de variables, denominadas variables de holgura: $\xi_i \geq 0$, $i = 1, \dots, N$.

Estas nuevas variables permiten ponderar el grado de declasificación de cada vector tal que:

$$y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \quad i = 1, \dots, N \quad (6-16)$$

Dónde:

$$\xi_i \geq 0 \quad \forall i \Rightarrow \begin{cases} 0 \leq \xi_i \leq 1 & \rightarrow \text{clasificación correcta} \\ \xi_i > 1 & \rightarrow \text{clasificación incorrecta} \end{cases} \quad (6-17)$$

De esta forma, se ha originado una nueva función objetivo, $\Omega(\mathbf{w}, \xi)$ que contiene un término que penaliza a las variables de holgura, convirtiendo la optimización en un balance entre el mayor margen y el error de penalización. En el caso de que la función de penalización sea lineal, la ecuación objetivo se transforma en:

$$\text{minimizar:} \quad \Omega(\mathbf{w}, h) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \quad (6-18)$$

$$\text{sujeto a:} \quad y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \quad 1 \leq i \leq N \quad (6-19)$$

En definitiva, se consigue implementar esta nueva restricción siguiendo un proceso similar al del clasificador de margen máximo. Las funciones de penalización no lineales se utilizarán en casos donde es necesario minimizar el efecto de muestras anómalas. Sin embargo, estas funciones presentan el inconveniente de aumentar la complejidad de la resolución de los problemas.




Figura 6-2. Clasificaciones de margen blando: (a) punto x_i clasificado correctamente, (b) punto x_i clasificado incorrectamente.

6.3 Clasificador no lineal

En la mayoría de las aplicaciones reales, los anteriores procedimientos lineales para realizar la clasificación no serían válidos. Este conflicto, motivó a crear un nuevo tipo de SVM basada en la función de transformación no lineal $\Phi(\cdot)$ para transformar el conjunto de datos originales a otro de mayor dimensión en el que las características transformadas fueran separables linealmente. Así, mediante el conjunto transformado, se emplearía el algoritmo lineal de determinación del hiperplano óptimo H_0 , para la separación de los conjuntos.

La clasificación en el nuevo espacio será, por tanto, lineal, aunque el espacio original no tiene por qué serlo.

El algoritmo resultante para la clasificación no lineal será similar al descrito para la clasificación lineal con la única diferencia de que el vector x tendrá que ser sustituido por $\Phi(x)$, que poseerá mayor dimensión. Además, el producto escalar de las transformaciones de los vectores originales será sustituido por una función kernel, $K(x, x_k)$, no lineal que solo dependerá de los vectores originales. De esta forma, no sería preciso transformar directamente los datos de entrada al entrenar la SVM y, por lo tanto, sería mucho menos costoso computacionalmente. Existen multitud de funciones kernel, las más comunes son las funciones de base radial y las polinómicas de grado n .




Figura 6-3. Transformación $\Phi(\cdot)$ para hacer los datos linealmente separables en la SVM

6.4 Implementación en el estudio

Para el uso de las Máquinas de Vectores de Soporte (explicadas anteriormente) se ha hecho uso del toolbox LIBSVM (A library for Support Vector Machines) de Matlab [11]. LIBSVM es un software integrado para realizar la clasificación, regresión y estimación de distribuciones mediante SVM.

Las muestras de los sujetos de la base de datos de este estudio han sido divididas de forma aleatoria: un porcentaje se han usado para entrenar a la máquina y el porcentaje restante ha servido para testear su funcionamiento.

Por último, para la implementación final de este tipo de clasificador, se ha realizado una exploración con la finalidad de seleccionar el tipo de kernel, junto con sus parámetros óptimos para cada agrupación de los electrodos. De esta forma, conseguiremos que se maximicen las tasas de acierto. Por tanto, observando cada sujeto, se obtendrán los parámetros óptimos para la implementación de la SVM.

Así, con la mayor probabilidad de acierto, podremos predecir la crisis epiléptica en cada sujeto.

7 RESULTADOS

En este capítulo se ha abordado el análisis exhaustivo de los resultados obtenidos, y a partir de ahí razonar sobre ellos. Se expondrán diferentes casos con la descripción de sus resultados y la discusión de los mismos.

Previamente, cabe distinguir entre los dos tipos de crisis: crisis generalizadas y crisis focales. Las crisis generalizadas se caracterizan por que las crisis epilépticas afectan a toda la superficie cerebral mientras que las crisis focales recaban en una zona concreta del cerebro, más reducida. Esas zonas en las crisis focales se donominan focos epilépticos. En este tipo de crisis son en las que nos centraremos en este estudio.

Expuesto lo anterior, se hace necesario un análisis individual de cada sujeto estudiado ya que tendrán focos epilépticos distintos, es más, estos podrían variar a lo largo de la toma de datos cómo veremos más adelante. Es por ello, que se ha realizado un estudio exhaustivo para hallar los dos mejores electrodos de cada paciente en sus respectivas grabaciones, pues a partir de las medidas tomadas en ellos obtendremos los resultados. Para ello, se ha realizado una comparación de los resultados obtenidos para cada par de electrodos (de los 23 totales) uno a uno en las zonas estudiadas, y así nos hemos quedado con los que ofrecían un índice de acierto mayor en cada caso. Una vez caracterizado el sujeto se toman los electrodos en la zona adecuada y podremos comprobar si hay riesgo de crisis, o por el contrario no la hay, observando las siguientes situaciones en estos apartados:

- Apartado 1:

En este primer apartado tomamos tres grabaciones de cada paciente. Una para entrenamiento de la SVM y dos como test.

Para cada grabación, hemos obtenido 30 vectores de un segundo, a partir de los 30 segundos previos al comienzo de una crisis. Por tanto, trabajaremos con 30 segundos de muestras. Éstos serán los vectores de crisis.

De igual modo, nos desplazamos 30 minutos después de que haya ocurrido una crisis, ya que nos hemos asegurado qué es una zona con ausencia de crisis, y extraemos otro periodo de 30 segundos. Tendremos, por tanto, otros 30 vectores sin crisis.

En total para cada grabación de cada paciente obtenemos 60 vectores, 30 con crisis y 30 sin crisis. Tras esto, se ha calculado la potencia para cada vector en los 23 canales que posee cada uno, mediante la función “CalculaParam”. Las matrices son 23×30 y en todo el apartado se trabajará con la potencia.

Una vez calculado lo anterior, se continuará con la obtención de los resultados para cada paciente. En cada caso de los que se verán en este apartado procederemos a pasar los 30 vectores con crisis y 30 vectores sin crisis de la grabación elegida como entrenamiento a la SVM. A partir de la clasificación que le hemos indicado, se le pasarán los 30 vectores con crisis y los 30 vectores sin crisis de las grabaciones utilizadas como test, y la maquina de soporte vectorial será capaz de hacer una estimación de la probabilidad de crisis o ausencia de la misma que hay si le pasamos dichos vectores.

Como veremos más adelante, los resultados que obtenemos en este apartado no son demasiado buenos puesto que, aunque en algunos casos obtenemos resultados de más de un 80 % de acierto, en otros hace una clasificación errónea indicándonos que no existe crisis en intervalos que si la hay o viceversa.

- Apartado 2:

En el segundo apartado, de nuevo, tomamos tres grabaciones de cada paciente. Sin embargo, ahora dos serán para entrenamiento de la SVM y una para test.

Para cada grabación, hemos obtenido 30 vectores de un segundo al igual que en el apartado anterior, de nuevo 30 segundos previos a la crisis. Por tanto, igualmente trabajaremos con 30 segundos de muestras. Éstos serán los vectores de crisis.

Como antes, nos desplazamos 30 minutos después de que haya ocurrido una crisis, y extraemos otro periodo de 30 segundos. Tendremos, por tanto, otros 30 vectores sin crisis.

En total para cada grabación de cada paciente obtenemos 60 vectores, 30 con crisis y 30 sin crisis. Tras esto, se ha calculado la potencia para cada vector en los 23 canales que posee cada uno, mediante la función “CalculaParam”. Las matrices son 23x30 y en todo el apartado se trabajará con la potencia.

En este caso la obtención de los resultados para cada paciente será diferente. En cada caso de los que se verán en este apartado procederemos a pasar los 60 vectores con crisis y 60 vectores sin crisis como entrenamiento a la SVM, aumentando el número de vectores de entrenamiento para garantizarnos una gran mejora de los resultados. Como se ha dicho antes, ahora estamos pasando 2 grabaciones como entrenamiento por paciente, de ahí los 60 vectores de crisis y ausencia de crisis. A partir de la clasificación que le hemos indicado, se le pasarán los 30 vectores con crisis y los 30 vectores sin crisis de la grabación restante utilizada como test, y la máquina de soporte vectorial será capaz de hacer una estimación de la probabilidad de crisis o ausencia de la misma que hay si le pasamos dichos vectores.

Observaremos posterior que los resultados que obtenemos en este apartado han mejorado significativamente con respecto a los del apartado anterior al aumentar el número de muestras. Se consiguen probabilidades del 80-95% de acierto, incluso en varios casos se obtiene un 100% de probabilidad de que ocurrirá una crisis.

- Apartado 3:

En el último apartado de este capítulo se ha intentado estudiar la probabilidad con la que se producirá una crisis o no con otros parámetros que no sean la potencia de las señales.

En concreto, se estudiarán los parámetros Kurtosis y Skewness. El procedimiento para la obtención de los vectores es análogo al apartado anterior con la única salvedad de que, en vez de calcular su potencia, calcularemos la Kurtosis o la Skewness.

Veremos que los resultados obtenidos en este apartado son muy pobres ya que se obtienen probabilidades muy bajas además de no clasificar correctamente si nos encontramos en un intervalo de crisis o no.

Por último, cabe mencionar que la banda elegida para el estudio, en los tres apartados, y en la cual se han obtenido los resultados es la banda Delta, ya que es en la que mejor se distinguen las crisis, basándonos en [13], y cómo podemos observar a continuación:




Figura 7-0. Intervalo de crisis en la banda Delta.

7.1 Entrenamiento a partir de los 30 segundos

En éste primer apartado, se ha tomado de la base de datos varios registros de una hora de duración de cada paciente, a lo largo de las 24 horas de estudio. Para cada uno, se ha identificado los instantes de crisis y se han generado vectores de entrenamiento para SVM a partir de los 30 segundos anteriores a cada crisis. De igual forma, hemos generado el mismo número de vectores asociados a la ausencia de crisis. Por ultimo se generan los vectores de test. Ya que procedimos a una division en bloques de 1 segundo, trabajaremos con 30 vectores para cada caso.

De cada sujeto analizamos tres grabaciones. Una será escogida cómo entrenamiento y las dos restantes cómo test. Se verá en el siguiente apartado cómo afecta la eleccion del número de grabaciones cómo entrenamiento.

En cada uno de los casos que veremos a continuación se ha realizado un estudio comparativo para elegir los electrodos más significativos de cada sujeto, ya que como se ha explicado antes, el foco epiléptico variará entre ellos.


En las figuras que se obtendrán de ahora en adelante, las cruces corresponden a los vectores de crisis (rojas entrenamiento, rosas test) y las estrellas a los vectores de ausencia de crisis (verdes entrenamiento, celestes test)

I. Sujeto 1: Niña con crisis epileptica intractable con 7 años de edad.

- CASO 1: Introducimos cómo grabación de entrenamiento la número 6, tanto de crisis como de su ausencia. Y se probará cómo test la grabación 16 que contiene crisis en el rango 2317-2413s.

Como hemos dicho, los vectores son tomados en función del foco epiléptico de cada sujeto, por lo que se ha necesitado un analisis de cada uno. Para éste paciente, los electrodos tomados son CZ-PZ (eje de abscisas) y T8-P8 (eje de ordenadas). Éstos corresponden a la zona posterior derecha.

-Introducimos los vectores con crisis:



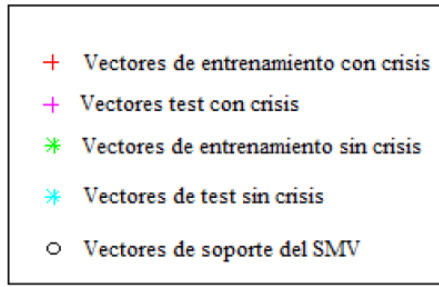



Figura 7-1. Resultado Sujeto 1: Paciente 5-Caso1 con crisis

Dados los vectores elegidos, se ha conseguido una alta probabilidad de crisis, cómo se puede observar en la disposición de las cruces rosas. Sin embargo existe un pequeño error, ya que hay algún vector clasificado como no crisis, mostrado en las estrellas azules.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 53.333333%

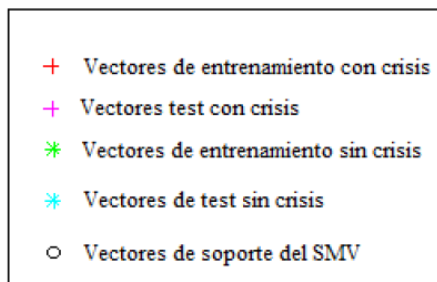



Figura 7-2. Resultado Sujeto 1: Paciente 5-Caso1 sin crisis

Para este caso, se ha obtenido una clasificación peor ya que solo detectamos la ausencia de crisis con la probabilidad del 53,33 %.

- CASO 2: Introducimos como grabación de entrenamiento la número 6, tanto de crisis como de su ausencia. Y se probará como test la grabación 22 que contiene crisis en el rango 2348-2465s.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 83.333333%





Figura 7-3. Resultado Sujeto 1: Paciente 5-Caso2 con crisis

Al igual que en caso anterior, la mayoría de los vectores son clasificados como crisis, aunque esta vez en un porcentaje menor.

-Introducimos vectores sin crisis:



Hay crisis con una probabilidad de 93.333333%

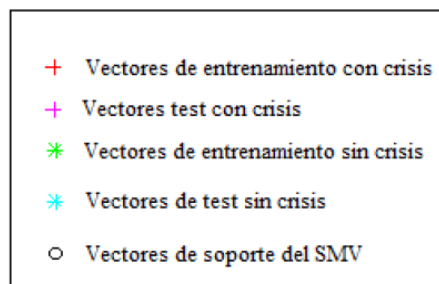


Figura 7-4. Resultado Sujeto 1: Paciente 5-Caso2 sin crisis


Dado éste resultado, observamos como son muy pocos los vectores clasificados como ausencia de crisis (estrellas azules). Es por ello que se obtiene una probabilidad de crisis del 93,3%.

II. Sujeto 2: Niño con crisis epiléptica intractable con 3 años de edad.

- CASO 1: Introducimos cómo grabación de entrenamiento la número 20, tanto de crisis como de su ausencia. Y se probará cómo test la grabación 31 que contiene crisis en el rango 3801-3877s.

Para éste paciente, los electrodos tomados son FZ-CZ (eje de abscisas) y T8-P8 (eje de ordenadas). Éstos corresponden a la zona central derecha.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 83.333333%

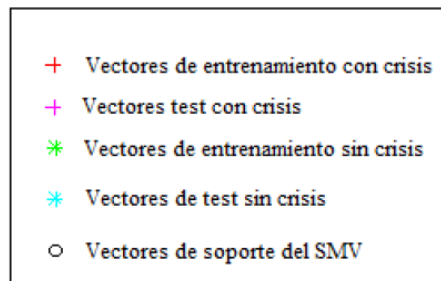



Figura 7-5. Resultado Sujeto 2: Paciente 10-Caso1 con crisis

La probabilidad de crisis obtenida para éste sujeto es levemente menor comparada con el sujeto anterior. Sin embargo, se sigue obteniendo un buen resultado ya que se alcanza una precisión del 83,3%

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 96.666667%

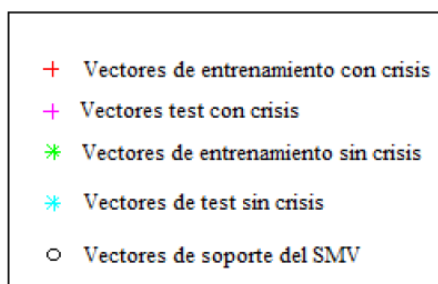


Figura 7-6. Resultado Sujeto 2: Paciente 10-Caso1 sin crisis

En la figura, se percibe con gran claridad cómo los vectores pasados han sido clasificados como ausencia de crisis. Existe una alta presencia de cruces celestes, obteniéndose una probabilidad de casi el 100 %. Podemos percatarnos que la potencia de las componentes sin crisis es bastante menor a la que tienen los componentes previos a un ataque, donde la potencia alcanzará valores muy similares de potencia a los que caracterizan a un ataque epiléptico.

- CASO 2: A continuación introducimos como test la grabación 89 que contiene crisis en el rango 1383-1437s.

-Introducimos los vectores con crisis:

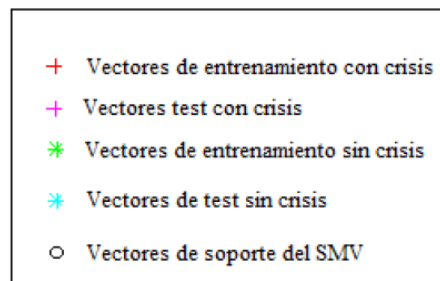



Figura 7-7. Resultado Sujeto 2: Paciente 10-Caso2 con crisis

En éste caso, el clasificador nos da como resultado que no existe crisis en un porcentaje muy alto cuando le estamos pasando vectores previos a una crisis. Este acontecimiento puede deberse que incluso para un mismo sujeto, el foco epiléptico puede varias a lo largo de la toma de datos, que ha sido de un día entero, obteniéndose resultado no tan favorable como el recién obtenido. En el siguiente apartado se hará un mayor hincapié en este asunto.

-Introducimos vectores sin crisis:




Figura 7-8. Resultado Sujeto 1: Paciente 5-Caso2 sin crisis


Ahora conseguimos una clasificación más exacta, aunque el porcentaje no es muy alto. En algunos momentos previos a la crisis el nivel de potencia aún no es demasiado significativo y guarda bastante relación con los niveles de potencia de intervalos de ausencia de crisis. Es por ello, que la maquina de soporte vectorial puede obtener resultados no demasiado precisos.

III. Sujeto 3: Niña con crisis epiléptica intractable con 3 años de edad.

- CASO 1: Introducimos cómo grabación de entrenamiento la número 19, tanto de crisis como de su ausencia. Y se probará cómo test la grabación 55 que contiene crisis en el rango 2436-2454s.

Los electrodos tomados con mejores resultados son F8-T8 (eje de abscisas) y FT9-FT10 (eje de ordenadas). Éstos engloban la parte superior de la cabeza de un lado a otro, y la parte superior derecha.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 93.333333%




Figura 7-9. Resultado Sujeto 3: Paciente 13-Caso 1 con crisis

Obtenemos como resultado una buena probabilidad de crisis, en concreto, del 93,3 %. Podemos observar como las cruces rosas predominan en la figura anterior.

-Introducimos vectores sin crisis:

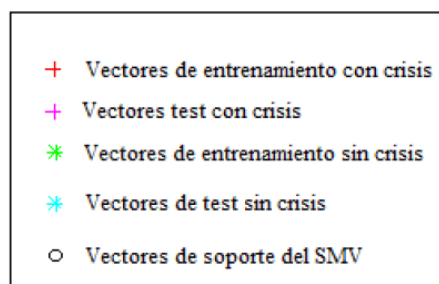




Figura 7-10. Resultado Sujeto 3: Paciente 13-Caso1 sin crisis

De nuevo, obtenemos un resultado bastante bueno, esclareciéndose así que para este sujeto los intervalos de crisis y ausencia de la misma están bien diferenciados y que es perfectamente posible prever un ataque segundos antes de que se produzca.

- CASO 2: A continuación introducimos cómo test la grabación 60 que contiene crisis en el rango 638-660s.

-Introducimos los vectores con crisis:



No hay crisis con una probabilidad de 70.000000%

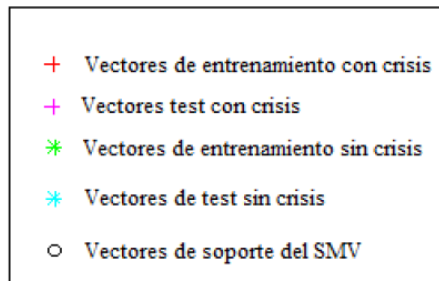



Figura 7-11. Resultado Sujeto 3: Paciente 13-Caso2 con crisis

Tras los excelentes resultados conseguidos anteriormente, ahora se ha obtenido una estimación errónea puesto el SVM no clasifica adecuadamente los vectores con las grabaciones y electrodos elegidos para este paciente. Al contrario de lo esperado, se indica ausencia de crisis en un 70 %.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 60.000000%

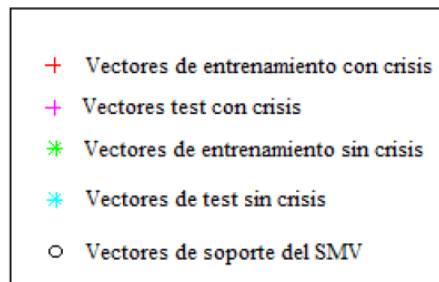


Figura 7-12. Resultado Sujeto 3: Paciente 13-Caso2 sin crisis


Ahora conseguimos una clasificación más exacta, aunque el porcentaje no es muy alto, un 60% de acierto.

IV. Sujeto 4: Niño con crisis epiléptica intractable con 16 años de edad.

- CASO 1: Introducimos como grabación de entrenamiento la número 6, tanto de crisis como de su ausencia. Y se probará como test la grabación 15 que contiene crisis en el rango 1748-1591 s.

Los electrodos seleccionados para este paciente son P8-O2 (eje de abscisas) y CZ-PZ (eje de ordenadas), correspondientes a la parte posterior derecha.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 80.000000%

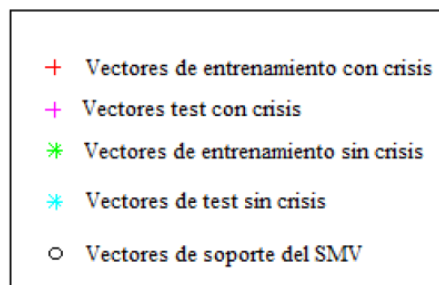



Figura 7-13. Resultado Sujeto 4: Paciente 15-Caso1 con crisis

De éste paciente, es representativo que los niveles de potencia son varios órdenes de magnitud menor que en todos los anteriores. En cuanto a la estimación, se obtiene un buen resultado con una probabilidad del 80%.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 66.666667%





Figura 7-14. Resultado Sujeto 4: Paciente 15-Caso 1 sin crisis

Se ha obtenido una probabilidad de ausencia de crisis del 66,66 %, con una clara separación de las regiones y un predominio de cruces celestes (vectores clasificados como no crisis).

- CASO 2: A continuación introducimos cómo test la grabación 20 que contiene crisis en el rango 607-662s.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 96.666667%

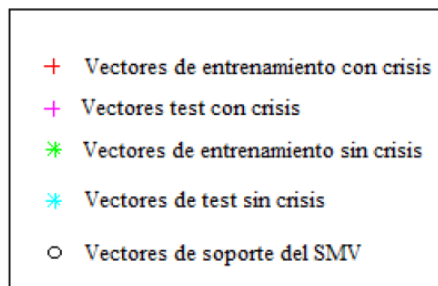



Figura 7-15. Resultado Sujeto 4: Paciente 15-Caso2 con crisis

En la figura de arriba, podemos observar como se ha obtenido una probabilidad bastante alta, casi del 100% en la que las cruces de color rosas, clasificadas como vectores con crisis predominan el espacio de estimación.

-Introducimos vectores sin crisis:



Hay crisis con una probabilidad de 60.000000%

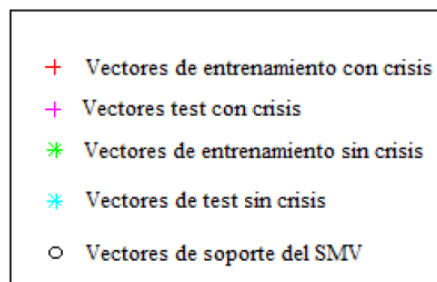


Figura 7-16. Resultado Sujeto 4: Paciente 15-Caso2 sin crisis

De nuevo, obtenemos una clasificación de crisis cuando hemos introducido vectores con crisis. En este caso, de un 60%.

❖ RESUMEN:

En este primer apartado, los resultados obtenidos no son demasiado exactos. En muchos casos, la SVM no clasifica correctamente si nos encontramos en un intervalo de crisis o en un intervalo sin crisis, pese a que en otros casos se consiguen probabilidades de acierto altas, superiores al 80%. Esto puede ser debido a que no hemos pasado un número suficiente de muestras como entrenamiento, se procederá a aumentarlas en el apartado siguiente. También procederemos a la elección de los dos mejores electrodos no solo para cada paciente sino también en cada grabación de cada paciente, ya que las medidas fueron tomadas en un intervalo muy grande de tiempo, de 24 horas de duración. Lo anterior también podría haber influido en los resultados obtenidos.

7.2 Entrenamiento a partir de un número más elevado de muestras

En la sección anterior, se pudo observar cómo a partir del uso de la máquina de soporte vectorial (SVM) se hacía posible la distinción entre épocas con y sin crisis con bastante exactitud, a partir de unos vectores dados. Sin embargo, en alguno de los casos los resultados eran inexactos, y no se clasificaban correctamente los vectores.

Esta situación puede deberse a que no hemos tomado el número de vectores de entrenamiento lo suficientemente elevado para conseguir minimizar el error en las estimaciones. Como se adelantó anteriormente, el foco epiléptico dónde se da lugar el ataque varía de un paciente a otro, y puesto que la toma de datos se realiza durante un gran periodo de tiempo, éste también puede variar significativamente de una grabación a otra, en sus respectivos intervalos de ataque. No se debe olvidar también, que el nivel de las señales neuronales es muy bajo, y que cualquier contaminación puede interferir de modo que distorsione o enmascare la información útil.

Cómo es de esperar, a medida que nos acerquemos más a los instantes de crisis, mejor podremos predecir el comienzo de las mismas. Es por ello que para los casos que se verán a continuación, se han generado vectores de entrenamiento y test para SVM entre los 30 segundos previos al ataque. De la misma manera, se generan un mismo número de vectores asociados a la ausencia de crisis. Ya que procedimos a una división en bloques de 1 segundo, trabajaremos con 30 vectores para cada caso.

Por todas las razones enunciadas, en este apartado se ha procedido, de nuevo, al análisis de tres grabaciones de cada paciente. Sin embargo, ahora dos de ellas serán tomadas como entrenamiento y la restante como test. Cómo para cada grabación obtenemos 30 vectores de crisis y 30 de no crisis. Al tomar dos grabaciones por paciente, como entrenamiento trabajaremos con 120 vectores frente a 60 vectores de test.


En cada uno de los casos que veremos a continuación se ha realizado un estudio comparativo para elegir los electrodos más significativos de cada sujeto para cada momento, ya que como se ha explicado antes, el foco epiléptico variará entre ellos y entre los instantes estudiados.

I. Sujeto 1: Niña con crisis epiléptica intractable con 7 años de edad.

- CASO 1: Introducimos como grabaciones de entrenamiento la número 6 y la 16, tanto de crisis como de su ausencia. Y se probará como test la grabación 22 que contiene crisis en el rango 2348-2465s.

Dado los vectores introducidos, se hace un estudio comparativo para elegir con que electrodos se consigue una mejor aproximación para el intervalo de tiempo estudiado. En este caso serán, P8-O2 (eje de abscisas) y T8-P8 (eje de ordenadas), correspondientes a la zona occipital derecha.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 83.333333%

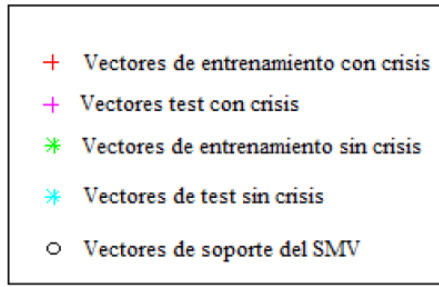



Figura 7-17. Resultado Sujeto 1: Paciente 5-Caso1 con crisis

Dado los vectores elegido, se ha conseguido una alta probabilidad de crisis, cómo se puede observar en la disposición de las cruces rosas. Sin embargo existe un pequeño error, ya que hay algún vector clasificado como no crisis, mostrado en las estrellas azules.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 80.000000%

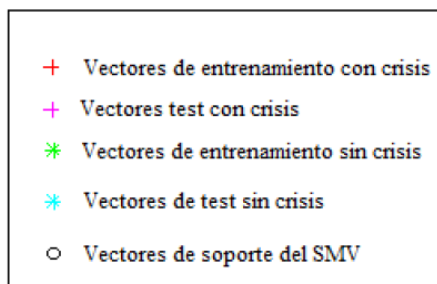


Figura 7-18. Resultado Sujeto 1: Paciente 5-Caso1 sin crisis

Para este caso, conseguimos obtener una probabilidad de acierto mucho más alta que la obtenida en el apartado anterior, que fué de un 53,3 % para este sujeto. El SVM hace una muy clara separación de regiones dónde el número de vectores identificados como ausencia de crisis (estrellas azules) es mucho mayor a los de crisis (cruces rosas)

II. Sujeto 2: Niño con crisis epileptica intractable con 3 años de edad.

- CASO 1: Introducimos como grabaciones de entrenamiento la número 31 y la número 89, tanto de crisis como de su ausencia. Y se probará como test la grabación 20 que contiene crisis en el rango 3686-3906s.

Para éste paciente, los electrodos tomados son P3-O1 (eje de abscisas) y F8-T8 (eje de ordenadas). Localizados en la zona occipital izquierda y frontal derecha.

-Introducimos los vectores con crisis:






Figura 7-19 Resultado Sujeto 2: Paciente 10-Caso1 con crisis

De nuevo obtenemos una muy buena precision, con una probabilidad de crisis del 90%.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 83.333333%





Figura 7-20 Resultado Sujeto 2: Paciente 10-Caso1 sin crisis

Para este paciente, podemos destacar también los resultados obtenidos mediante los electrodos P7-O1 (eje de abcisas) y F8-T8 (eje de ordenadas)

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 86.666667%

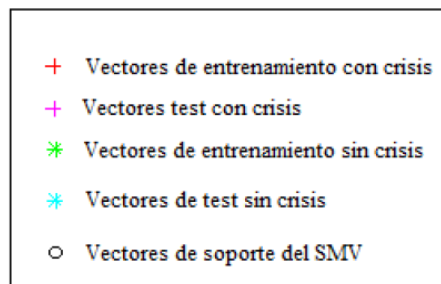



Figura 7-21. Resultado Sujeto 2: Paciente 10-Caso1 con crisis

La probabilidad de crisis sigue siendo muy alta, obteniéndose un 86,66 % de acierto. Podemos observar como de manera muy clara los vectores de crisis se encuentran en la parte derecha del plano mientras que los de ausencia de crisis están a la izquierda.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 93.333333%

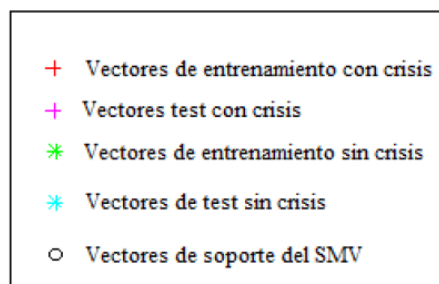



Figura 7-22. Resultado Sujeto 2: Paciente 10-Caso1 sin crisis

Destacamos cómo en este apartado, las probabilidades de ausencia de crisis son mucho más elevadas que en la sección anterior, rondando el 100 % de acierto. Se hace efectiva por tanto la elección de un mayor número de vectores de entrenamiento.

- CASO 2: A continuación introducimos cómo entrenamiento las grabaciones 20 y 89 y como test la grabación 31 que contiene crisis en el rango 3801-3877s.

Los electrodos implicados son: C4-P4 (eje de abscisas) y T8-P8 (eje de ordenadas) que se ubican en el lóbulo temporal derecho.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 86.666667%

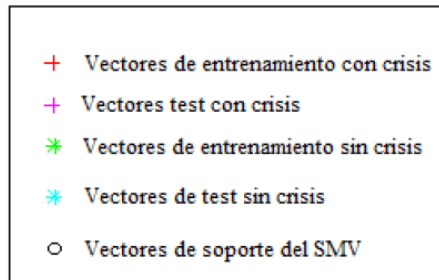


Figura 7-23. Resultado Sujeto 2: Paciente 10-Caso2 con crisis

-Introducimos vectores sin crisis:




Figura 7-24. Resultado Sujeto 1: Paciente 5-Caso2 sin crisis


En éste segundo caso, seguimos obteniendo una buena probabilidad de crisis a costa de disminuir un poco la probabilidad de ausencia de crisis cuando pasamos como test vectores sin crisis. De igual forma, el SVM hace una buena clasificación diferenciando de manera clara y precisa las regiones, como se observa en las figuras anteriores.

III. Sujeto 3: Niña con crisis epiléptica intractable con 3 años de edad.

- CASO 1: Introducimos como grabaciones de entrenamiento las número 19 y 60, tanto de crisis como de su ausencia. Y se probará como test la grabación 55 que contiene crisis en el rango 2436-2454s.

Los electrodos tomados con mejores resultados son F7-T7 (eje de abscisas) y T7-FT9 (eje de ordenadas). Situados en la parte superior izquierda según indica el Sistema de posicionamiento 10-20.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 100.000000%

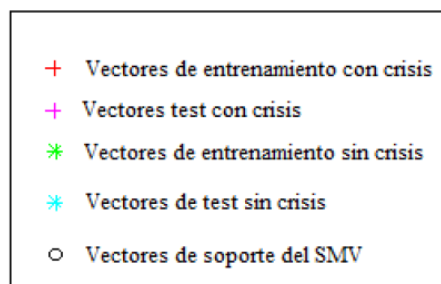


Figura 7-25. Resultado Sujeto 3: Paciente 13-Caso1 con crisis

Se ha obtenido una probabilidad de crisis del 100%, todos los vectores han sido clasificados como crisis (cruces rosas), por lo que con toda seguridad podríamos estimar la aparición de un ataque epiléptico unos segundos antes de que ocurra.

-Introducimos vectores sin crisis:

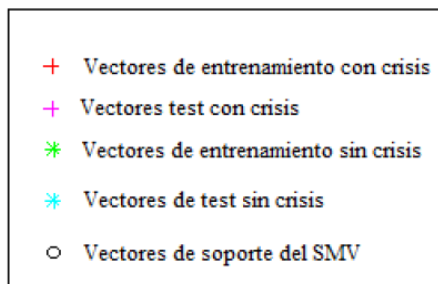




Figura 7-26. Resultado Sujeto 3: Paciente 13-Caso 1 sin crisis

De nuevo, obtenemos un resultado excelente, donde la probabilidad de ausencia de crisis es del 100 %. Podemos ver como el nivel de señal de los vectores clasificados como crisis (estrellas celestes) es menor que el nivel de señal de los vectores de entrenamiento con crisis, como se observa en la figura.

Igualmente, obtenemos unas probabilidades de acierto totales si nos fijamos en los electrodos F8-T8 y T7-FT9, que engloban la parte superior de la cabeza. Zona para la que, anteriormente en la sección anterior, no se había conseguido unas probabilidades tan elevadas.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 100.000000%

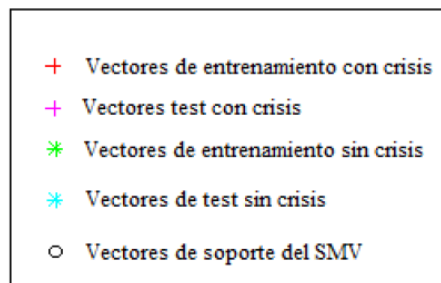



Figura 7-27. Resultado Sujeto 3: Paciente 13-Caso1 con crisis

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 100.000000%

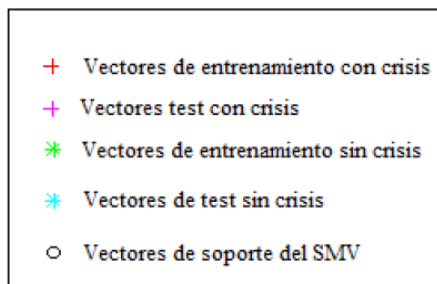


Figura 7-28. Resultado Sujeto 3: Paciente 13-Caso1 sin crisis

De nuevo, se han conseguido unas probabilidades de acierto del 100%, garantizando la presencia de crisis cuando introducimos el primer tipo de vectores, y la ausencia de crisis cuando introducimos vectores muy lejanos a la crisis.

- CASO 2: A continuación introducimos cómo test la grabación 19 que contiene crisis en el rango 2007-2121s. Siendo las grabaciones elegidas como entrenamiento la 55 y 60.

Los electrodos tomados con mejores resultados son F7-T7 (eje de abscisas) y FT10-T8 (eje de ordenadas). Sitados en la zona parietal del cerebro.

-Introducimos los vectores con crisis:

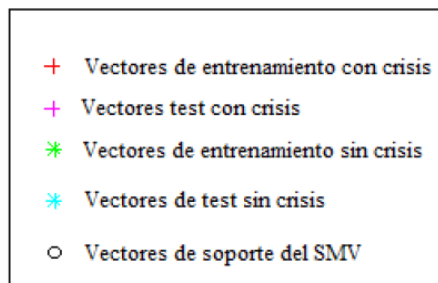




Figura 7-29. Resultado Sujeto 3: Paciente 13-Caso2 con crisis

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 66.666667%

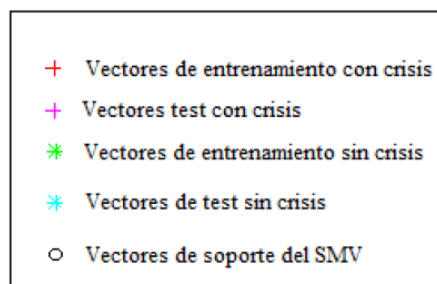


Figura 7-30. Resultado Sujeto 3: Paciente 13-Caso2 sin crisis


Para este caso, se han obtenido unos resultados peores que en el anterior, pero se sigue corroborando una alta probabilidad de acierto cuando pasamos como test vectores previos a una crisis epiléptica.

IV. Sujeto 4: Niño con crisis epiléptica intractable con 16 años de edad.

- CASO 1: Introducimos cómo grabaciones de entrenamiento la 6 y la 20, tanto de crisis como de su ausencia. Y se probará cómo test la grabación 15 que contiene crisis en el rango 1748-1591 s.

Los electrodos seleccionados para éste paciente son FP1-F3 (eje de abscisas) y T8-P8 (eje de ordenadas), correspondientes los primeros a la zona frontal, cerca de los ojos.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 80.000000%




Figura 7-31. Resultado Sujeto 4: Paciente 15-Caso1 con crisis

De éste paciente, es representativo que los niveles de potencia son varios órdenes de magnitud menor que en todos los anteriores. En cuanto a la estimación, se obtiene un buen resultado con una probabilidad del 80%.

-Introducimos vectores sin crisis:


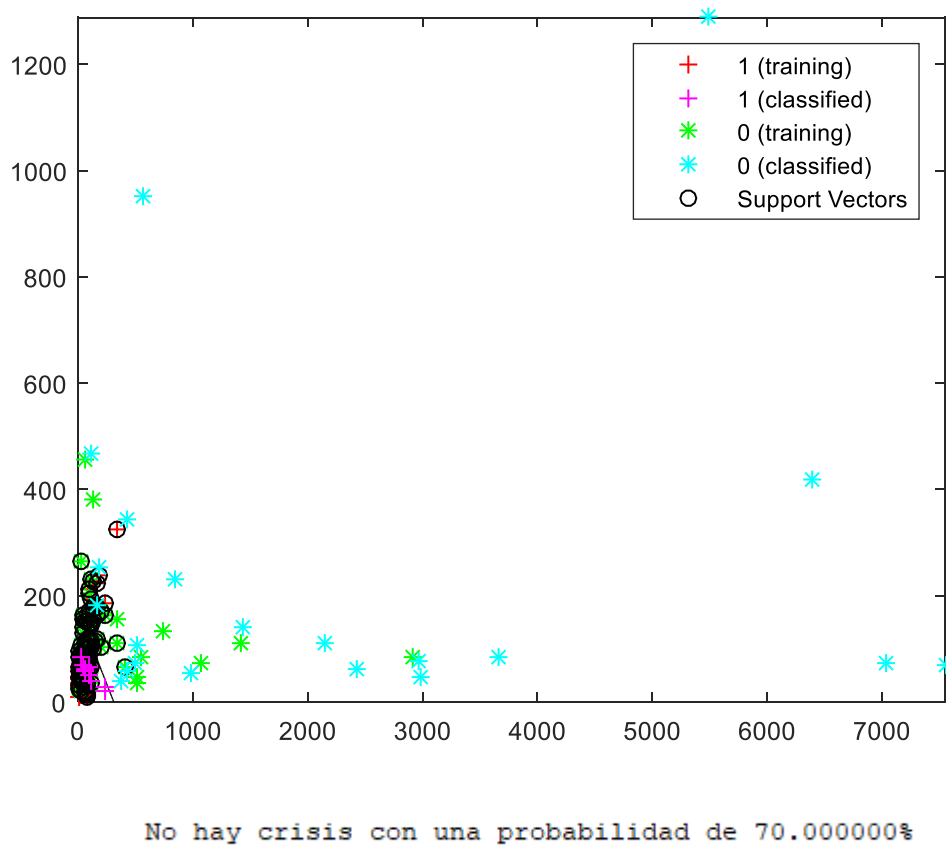



Figura 7-32. Resultado Sujeto 4: Paciente 15-Caso 1 sin crisis

En este caso hay que tener en cuenta que al estar los electrodos cercanos a los ojos, las grabaciones pueden presentar picos de potencia en zonas de ausencia de crisis debido a la realización de pestaños por parte del paciente. Es por ello, que la probabilidad de no crisis puede verse afectada por lo anterior en este caso.

- CASO 2: A continuación introducimos cómo test la grabación 6 que contiene crisis en el rango 272-397s. Como entrenamiento usaremos las grabaciones 15 y 20 de este paciente.

Tras el estudio comparativo, los electrodos elegidos para obtener los resultados son F4-C4 (eje de abscisas) y T8-P8 (eje de ordenadas) situados en la zona derecha de la cabeza.

-Introducimos los vectores con crisis:



Hay crisis con una probabilidad de 90.000000%

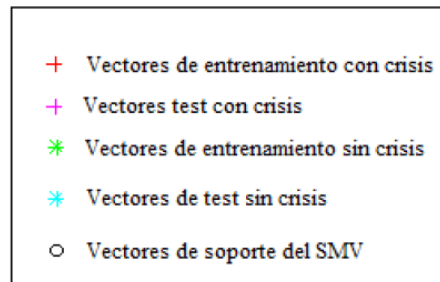



Figura 7-33. Resultado Sujeto 4: Paciente 15-Caso2 con crisis

En la figura de arriba, podemos observar como se ha obtenido una probabilidad bastante alta, casi del 100 % en la que las cruces de color rosas, clasificadas como vectores con crisis predominan el espacio de estimación.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 86.666667%

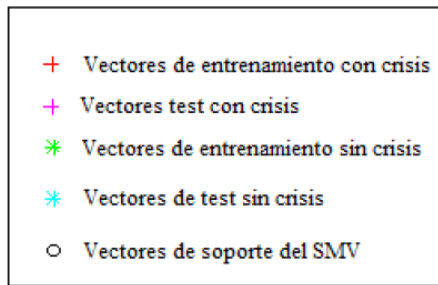


Figura 7-34 Resultado Sujeto 4: Paciente 15-Caso2 sin crisis

Como vemos, también se consigue una alta probabilidad de ausencia de crisis al pasarle los vectores de test de esta grabación.

❖ RESUMEN:

Cómo hemos podido observar en los resultados anteriores, el aumento del número de muestras de entrenamiento se ha reflejado en un aumento de la probabilidad de acierto así cómo de una correcta clasificación de todos los casos. Las probabilidades obtenidas son superiores al 80 % en la mayoría de los casos e incluso se han obtenido probabilidades del 100% como en el caso 1 del sujeto 3. Como pasaba también en el primer apartado de este capítulo existen casos en los que la probabilidad de ausencia de crisis no es demasiado elevado, del 60-70% pero esto se puede deber a que los niveles de las señales EEG son muy débiles y es difícil a veces distinguir periodos de ausencia de crisis con periodos previos a la crisis dónde aún no se producen picos de potencia muy abruptos. También hemos elegido pares de electrodos específicos para cada situación lo que ha mejorado los resultados obtenidos en el apartado 7.1

7.3 Estudio con otros parámetros

Dado los resultados obtenidos en los apartados anteriores mediante el estudio de la potencia, podríamos preguntarnos si ésto se pudieran extrapolar a otros parámetros que no sean la potencia de la señal, como por ejemplo la Kurtosis y la Skewness.

- Kurtosis:

La Kurtosis es una medida estadística, que determina el grado de concentración que presentan los valores de una variable alrededor de la zona central de la distribución de frecuencias.


Vamos a estudiar los resultados que proporciona la SVM cuando introducimos vectores de Kurtosis en alguno de los casos previamente mostrados:

I. Sujeto 3: Niña con crisis epileptica intractable con 3 años de edad.

- CASO 1: Introducimos como grabaciones de entrenamiento las número 19 y 60, tanto de crisis como de su ausencia. Y se probará cómo test la grabación 55 que contiene crisis en el rango 2436-2454s.

Los electrodos tomados con mejores resultados son F7-T7 (eje de abscisas) y T7-FT9 (eje de ordenadas). Situados en la parte superior izquierda según indica el Sistema de posicionamiento 10-20.

-Introducimos los vectores con crisis:



No hay crisis con una probabilidad de 63.333333%

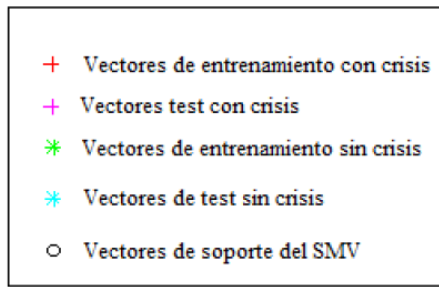



Figura 7-35. Resultado Sujeto 3: Paciente 13-Caso1 con crisis Kurtosis

De la figura anterior, se obtiene un resultado bastante malo acerca de la probabilidad de crisis pues nos indica que pasandole vectores con crisis tendríamos casi un 70% de probabilidad de la ausencia de ataque.

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 60.000000%

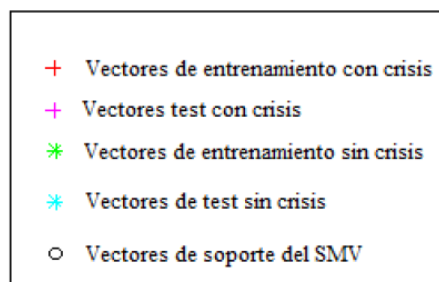


Figura 7-36. Resultado Sujeto 3: Paciente 13-Caso1 con crisis Kurtosis

II. Sujeto 2: Niño con crisis epileptica intractable con 3 años de edad.

- CASO 1: Introducimos cómo grabaciones de entrenamiento la número 31 y la número 89, tanto de crisis como de su ausencia. Y se probará cómo test la grabación 20 que contiene crisis en el rango 3686-3906s.

Para éste paciente, los electrodos tomados son P3-O1 (eje de abscisas) y F8-T8 (eje de ordenadas). Localizados en la zona occipital izquierda y frontal derecha.

-Introducimos los vectores con crisis:

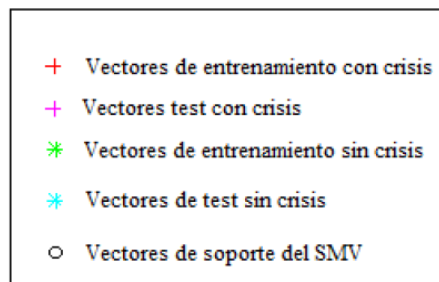




Figura 7-37 Resultado Sujeto 2: Paciente 10-Caso1 con crisis Kurtosis

De nuevo obtenemos una muy buena precision, con una probabilidad de crisis del 90%.

-Introducimos vectores sin crisis:



Hay crisis con una probabilidad de 76.666667%




Figura 7-38 Resultado Sujeto 2: Paciente 10-Caso1 sin crisis Kurtosis

De nuevo, para este caso, también se obtiene un resultado erróneo, pues resulta una probabilidad de casi el 80 % de crisis cuando estudiamos intervalos de ausencia de ella.

Conclusión:

De los casos recientemente estudiados, podemos concluir que el parámetro de la Kurtosis no es una buena estimación para nuestro estudio. Esto se debe a que mediante la comparación de valores de Kurtosis no es posible obtener una buena diferenciación en la máquina de soporte vectorial de las regiones de crisis y no crisis.

▪ Skewness:

La Skewness es una medida de asimetría, las cuales son indicadores que permiten establecer el grado de simetría (o asimetría) que presenta una distribución de probabilidad de una variable aleatoria.


Vamos a estudiar los resultados que proporciona la SVM cuando introducimos vectores de Skewness en alguno de los casos previamente mostrados:

III. Sujeto 1: Niña con crisis epileptica intractable con 7 años de edad.

- CASO 1: Introducimos cómo grabaciones de entrenamiento la número 6 y la 16, tanto de crisis como de su ausencia. Y se probará cómo test la grabación 22 que contiene crisis en el rango 2348-2465s.

Dado los vectores introducidos, se hace un estudio comparativo para elegir con que electrodos se consigue una mejor aproximación para el intervalo de tiempo estudiado. En este caso serán, P8-O2 (eje de abcisas) y T8-P8 (eje de ordenadas), correspondientes a la zona occipital derecha.

-Introducimos los vectores con crisis:



Misma probabilidad de crisis que no crisis

Obtenemos igualdad en las probabilidades de crisis y ausencia de crisis. Un resultado bastante pobre teniendo en cuenta que estamos pasándole vectores muy próximos a la presencia de un ataque.

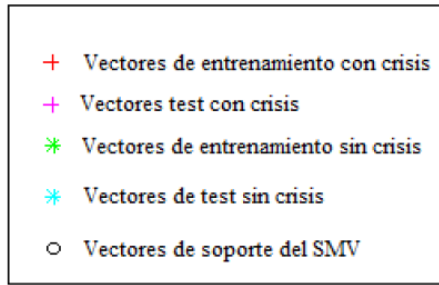



Figura 7-39 Resultado Sujeto 2: Paciente 10-Caso1 con crisis Skewness

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 56.666667%

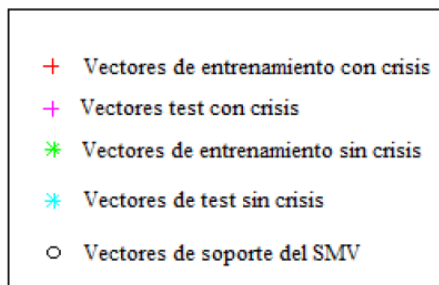



Figura 7-40. Resultado Sujeto 2: Paciente 10-Caso1 sin crisis Skewness

IV. Sujeto 4: Niño con crisis epileptica intractable con 16 años de edad.

- CASO 2: A continuación introducimos cómo test la grabación 6 que contiene crisis en el rango 272-397s. Como entrenamiento usaremos las grabaciones 15 y 20 de este paciente.

Tras el estudio comparativo, los electrodos elegidos para obtener los resultados son F4-C4 (eje de abscisas) y T8-P8 (eje de ordenadas) situados en la zona derecha de la cabeza.

-Introducimos los vectores con crisis:



Misma probabilidad de crisis que no crisis

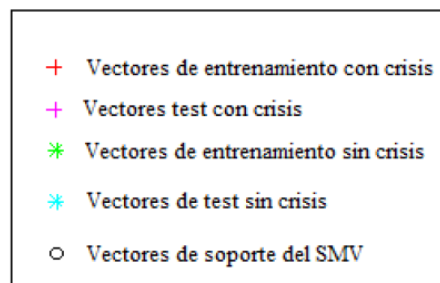



Figura 7-41. Resultado Sujeto 4: Paciente 15-Caso2 con crisis Skewness

-Introducimos vectores sin crisis:



No hay crisis con una probabilidad de 53.333333%

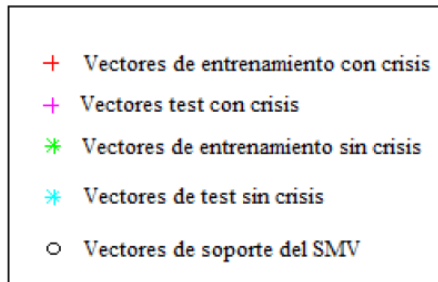


Figura 7-42 Resultado Sujeto 4: Paciente 15-Caso2 sin crisis Skewness

De nuevo, los resultados obtenidos nos muestran probabilidades de acierto muy inexactas que no nos permiten afirmar un comportamiento claro durante el intervalo estudiado de si el paciente sufrirá una crisis o no próximamente.

Conclusión:

De los casos recientemente estudiados, podemos concluir que la Skewness tampoco no es útil como parámetro para comparar las situaciones que queremos caracterizar, por lo que no podemos clasificar las épocas en situaciones de crisis o ausencia de ellas.

❖ RESUMEN:

De los resultados obtenidos en este ultimo apartado podemos concluir que mediante el estudio de parámetros como la Kurtosis o la Skewness no se obtienen buenos resultados para la clasificación de crisis epilépticas. Hemos obtenido probabilidades en torno al 50-60% en la mayoría de casos e incluso se nos ha indicado que no había crisis en vectores en lo que si existía y viceversa.

8 CONCLUSIONES

Tras mostrar los resultados en el capítulo anterior, se procede a finalizar este trabajo con su correspondiente conclusión.

Primeramente, el preprocesado de las grabaciones es una actividad vital antes del estudio, pues las señales encefalográficas se caracterizan por tener un bajo nivel de señal y son fácilmente interferibles. Cualquier ruido, interferencia eléctrica o movimientos involuntarios del paciente pueden falsear los resultados.

En segundo lugar, se ha comprobado que el mejor filtrado para la detección de crisis epilépticas es el realizado a 0-5-4 Hz por un filtro Delta. Pues aplicando otros filtros como los Theta, Beta y Alfa, se consigue una distinción peor de los intervalos de crisis epiléptica.

Otro aspecto que recalcar es la necesidad de un estudio individual de cada sujeto. Esto es preciso ya que las crisis que sufren los pacientes son focales, es decir, se inician en una zona específica del cerebro para más tarde extenderse a toda la superficie. Incluso, como hemos podido observar, los focos epilépticos pueden variar en un mismo paciente de un momento a otro. Es por ello que hay que determinar que sensores escoger para cada paciente, dependiendo del intervalo de tiempo considerado y del número de muestras tomadas. Una vez identificado el foco epiléptico, la probabilidad de detectar la crisis anticipada es bastante favorable, por encima del 80% en la mayoría de los casos.

Los resultados mencionados, por otro lado, han sido basados en la potencia de la señal, pues como hemos comprobado anteriormente, el uso de otros parámetros como la Kurtosis o la Skewness se hacen ineficientes para el objetivo de este estudio.

Hemos podido comprobar que, dependiendo del paciente, la crisis puede ser detectada con mayor o menor anterioridad, este puede ser debido a los diferentes estados que puede atravesar un paciente antes de sufrir un ataque convulsivo (nerviosismo, ansiedad, estrés, etc). Sería interesante ahondar en ese aspecto y poder caracterizar dichos estados para así preveer el ataque dependiendo de los síntomas que presente el paciente.

Finalmente, otra línea futura, y más similar al estudio aquí realizado sería estudiar otros parámetros como la covarianza o medidas frecuenciales que mediante la Transformada de Fourier podría resultar de mucha utilidad tratándose de señales EEG.

REFERENCIAS

- [1] Epilepsia - Síntomas y causas [online]. 2017. Available from: <http://www.mayoclinic.org/es-es/diseases-conditions/epilepsy/symptoms-causes/syc-20350093>.
- [2] Diagnóstico de la epilepsia. Guía ápice de la epilepsia. [online] 2017. Available from: <https://www.apicepilepsia.org/tratamiento-de-la-epilepsia/diagnostico-de-la-epilepsia/>.
- [3] Epilepsia: Tratamientos, Síntomas, Causas e Información [online]. 2015. Available from: <https://cuidateplus.marca.com/enfermedades/neurologicas/epilepsia.html>.
- [4] Sanmillán Vidoy, F.L. (2017). Detección de Crisis Epilépticas a partir del Electroencefalograma. Departamento Teoría de señal y Comunicaciones. Universidad de Sevilla.
- [5] «Wikipedia,» 2018. [online]. Available from: https://en.wikipedia.org/wiki/Delta_wave. [Último acceso: 2018].
- [6] Electroencefalografía (EEG). BrainsSings. [online]. Available from: <https://www.brainsigns.com/es/science/s2/technologies/eeg>
- [7] Triglia, A. Tronco del encéfalo: funciones y estructuras [online]. Available from: <https://psicologiaymente.com/neurociencias/tronco-del-encefalo-funciones>.
- [8] De la Torre Abaitua, J. (2012). Procesado de señales EEG para un interfaz cerebro-máquina (BCI). Departamento de Teoría de la Señal y Comunicaciones. Universidad Carlos III de Madrid.
- [9] González Sánchez, J. Técnicas de toma de datos y análisis de ELECTROENCEFALOGRAFÍA. Universidad de Sevilla, Facultad de biología, Departamento de Fisiología Animal. Septiembre 2014.
- [10]Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. PhysioBank, PhysioToolkit y PhysioNet: componentes de un nuevo recurso de investigación para señales fisiológicas complejas. *Circulation* 101 (23): e215-e220; 2000 (13 de junio).
- [11] Physiobank ATM [online]. 2018. Available from: <https://physionet.org/cgi-bin/atm/ATM>
- [12] EEG y Epilepsia [online]. 2018. Available from: <https://neuroimage.usc.edu/brainstorm/Tutorials/Epilepsy>
- [13] Cortés Dominguez, A. (2017). Procesamiento de señales para la detección anticipada de Crisis Epilépticas en el EEG. Sanmillán Vidoy, F.L. (2017). Detección de Crisis Epilépticas a partir del Electroencefalograma. Departamento Teoría de señal y Comunicaciones. Universidad de Sevilla.
- [14]Santos Mayo, L. (2015). Desarrollo y evaluación de clasificadores neuro-genéticos basados en señales de EEG para la ayuda al diagnóstico de la esquizofrenia. Máster universitario en investigación en tecnología de la información y las comunicaciones. Universidad de Valladolid.
- [15]Mora López-Tercero, I. Detección de crisis epilépticas a partir de señales EEG mediante índices basados en el algoritmo de Lempel-Ziv. Escuela Politécnica Superior de Ingeniería de Vilanova y Geltrú, Ingeniería en Electrónica Industrial y Automática. Julio 2013.
- [16] Shoeb, A., Gutttag, J. Application of Machine Learning To Epileptic Seizure Detection. Appearing in Proceeding of the 27th International Conference on Machine Learning, Haifa, Israel, 2010.
- [17] Shoeb, A., Edwards, H., Connolly, J., Bourgeois, B., Treves, S., and Gutttag, J. Patient-specific seizure onset detection. *Epilepsy and Behavior*, 5(4):483–98, Aug 2004.

[18] Ali Shoeb. Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment. PhD Thesis, Massachusetts Institute of Technology, September 2009.

GLOSARIO

EEG: Electroencefalograma	13
SVM: Máquina de Soporte Vectorial	13
TAC: Tomografía Axial Computarizada	15
PhysioBank ATM: PhysioBank's Automated Teller Machine	31

ANEXO: CÓDIGOS MATLAB

A continuación, se mostrarán los códigos realizados en Matlab para la obtención de los resultados del Capítulo 7.

- “principal.m”: Este es el código base, a partir del cual cargamos las grabaciones de los pacientes y se llama a las diferentes funciones para calcular los parámetros. Sus entradas indican el inicio de un intervalo donde no hay crisis y la duración del intervalo previo a la crisis que queremos estudiar.

```
function principal(tnoat, tp)

    %%CLASIFICACIÓN DE LOS ARCHIVOS
    %a=1; %banda
    %b=1; %paciente
    %c=1; %grabacion

    %Intervalo de tiempo de ausencia de crisis pasado como entrada en
    segundos
    tnoataque=tnoat*256; %Pasamos a muestras

    %Duracion del intervalo previo a la crisis a estudiar
    tprevio=tp*256; %Pasamos a muestras

    %Cargo la matriz donde se encuentran los instantes inicial y final de
    %crisis de la grabacion de cada paciente
    M=load('MatrizTiempo.mat');
    m=M.MatrizTiempo;

    j=1;
    %Bucles for para recorrer todas las bandas, grabaciones y pacientes
    for a=1:4
        for b=1:4
            for c=1:3
                %Cargo la matriz del paciente en cuestion

                v=load(strcat(num2str(a), num2str(b), num2str(c), '.mat')
                );
                matriz=v.F;

                %Función que extrae los tiempos inicial y final
                %delataque
                %de la matriz de tiempos explicada anteriormente.

                [tiniA, tfinA]=ProcesaTiempo(m, b, c);
                tfinA=tfinA+2; %Nada
                %A continuacion, extraigo tres matrices, con periodos
                % sinataque, con ataque y previos al ataque. Y las
                % guardo su numero identificativo.
                t1=tiniA-tnoataque;
                if t1<0
                    t1=tiniA+tnoataque; %instante sin crisis
                    %Matriz de ausencia de crisis
                    MatrizNA= matriz(:, t1:(t1+tprevio)); %indicamos la
                    duracion de la matriz (30s)
```

```

        nNA=strcat('MatrizNA', num2str(a), num2str(b), num2str(c)
        , '.mat');
        save(nNA, 'MatrizNA');
    else
        MatrizNA= matriz(:, t1:(t1+tprevio)); %indicamos la
duracion de la matriz (30s)

        nNA=strcat('MatrizNA', num2str(a), num2str(b), num2str(c)
        , '.mat');
        save(nNA, 'MatrizNA');
    end

    %Matriz de crisis
    MatrizA=matriz(:, tiniA:(tiniA+tprevio)); %indicamos la
duracion de la matriz (30s)

    nA=strcat('MatrizA', num2str(a), num2str(b), num2str(c), '.mat')
    ;
    save(nA, 'MatrizA');

    %Matriz previo a crisis
    MatrizPA=matriz(:, (tiniA-tprevio-1):(tiniA-1));
%indicamos la duracion de la matriz (30s)

    nPA=strcat('MatrizPA', num2str(a), num2str(b), num2str(c), '.mat
    ');
    save(nPA, 'MatrizPA');

    %Función para calcular la potencia, skewness y kurtosis de
    %cada grabacion para las 3 matrices de tiempo.

    [PotNA, PotA, PotPA, SkewNA, SkewA, SkewPA, KurtNA, KurtA, KurtPA]=CalculaParam
    (MatrizNA, MatrizA, MatrizPA);

    %El resultado son 9 matrices de 23 filas (canales) ytantas
    %columnas como tiempo de estudio.

    %Guardo cada matriz con su numero identificativo

    nPot=strcat('PotenciaNA', num2str(a), num2str(b), num2str(c), '.mat');
        save(nPot, 'PotNA');

    nPot=strcat('PotenciaA', num2str(a), num2str(b), num2str(c), '.mat');
        save(nPot, 'PotA');

    nPot=strcat('PotenciaPA', num2str(a), num2str(b), num2str(c), '.mat');
        save(nPot, 'PotPA');

    nSkew=strcat('SkewnessNA', num2str(a), num2str(b), num2str(c), '.mat');
        save(nSkew, 'SkewNA');

    nSkew=strcat('SkewnessA', num2str(a), num2str(b), num2str(c), '.mat');
        save(nSkew, 'SkewA');

```

```

nSkew=strcat('SkewnessPA',num2str(a),num2str(b),num2str(c),'.mat');
save(nSkew,'SkewPA');

nKurt=strcat('KurtosisNA',num2str(a),num2str(b),num2str(c),'.mat');
save(nKurt,'KurtNA');

nKurt=strcat('KurtosisA',num2str(a),num2str(b),num2str(c),'.mat');
save(nKurt,'KurtA');

nKurt=strcat('KurtosisPA',num2str(a),num2str(b),num2str(c),'.mat');
save(nKurt,'KurtPA');

clear v

end
end
end
clear all

```

- “ProcesTiempo”: Simplemente extrae el tiempo inicial y final de una crisis. Cada paciente tendrá 2 columnas. En las primeras estarán los tres instantes iniciales de sus tres grabaciones utilizadas. En su segunda columna, los tres instantes finales.

```

function [t1,t2] = ProcesaTiempo(M,b,c)
%matriz que extrae los tiempos iniciales y finales de cada paciente y
%grabacion en funcion de sus numeros identificativos.
%La matriz M es 3x8 de ahi los indices utilizados.
switch b
case 1
switch c
case 1
t1=M(c,1);
t2=M(c,2);
case 2
t1=M(c,1);
t2=M(c,2);
case 3
t1=M(c,1);
t2=M(c,2);
end

case 2
switch c
case 1
t1=M(c,3);
t2=M(c,4);
case 2
t1=M(c,3);
t2=M(c,4);
case 3
t1=M(c,3);
t2=M(c,4);
end
end

```

```

        end

    case 3
        switch c
            case 1
                t1=M(c,5);
                t2=M(c,6);
            case 2
                t1=M(c,5);
                t2=M(c,6);
            case 3
                t1=M(c,5);
                t2=M(c,6);
        end

    case 4
        switch c
            case 1
                t1=M(c,7);
                t2=M(c,8);
            case 2
                t1=M(c,7);
                t2=M(c,8);
            case 3
                t1=M(c,7);
                t2=M(c,8);
        end

    end
end
end

```

- “CalculaParam”: Se calculan matrices de los 3 parámetros estudiados en bloques de 1 segundo para instantes con, sin y previos a crisis.

```
function
```

```
[PotNA, PotA, PotPA, SkewNA, SkewA, SkewPA, KurtNA, KurtA, KurtPA]=CalculaParam
(MatrizNA, MatrizA, MatrizPA);
```

```

% Calcula para grabacion los tres parametros para cada una de las tres
% matrices estudiadas. Las matrices tendran 23 filas (canales) y un
numero
% de columnas igual a la longitud del intervalo estudiado. Los
paramatros
% se calculan en bloques de un segundo
j=1;
x=1;
while (x+255)<=7680 %Duracion 30 segundos
    for i=1:length(MatrizNA(:,1))
        PotNA(i,j)=mean((MatrizNA(i,x:(x+255))).^2);
        SkewNA(i,j)=skewness(MatrizNA(i,x:(x+255)));
        KurtNA(i,j)=kurtosis(MatrizNA(i,x:(x+255)));

        PotA(i,j)=mean((MatrizA(i,x:(x+255))).^2);
        SkewA(i,j)=skewness(MatrizA(i,x:(x+255)));
        KurtA(i,j)=kurtosis(MatrizA(i,x:(x+255)));

        PotPA(i,j)=mean((MatrizPA(i,x:(x+255))).^2);
        SkewPA(i,j)=skewness(MatrizPA(i,x:(x+255)));
    end
    j=j+1;
    x=x+255;
end

```

```

KurtPA(i,j)=kurtosis(MatrizPA(i,x:(x+255)));

end
x=x+256;
j=j+1;
end

```

- Script “svm”: En este script se procede a la clasificación de los vectores seleccionados para cada caso mediante las funciones “svmtrain” y “svmclassify”.

```

%Introducimos la potencia de un rango previo anterior a la crisis
Mpa1=load('PotenciaPA142.mat');
Mpa1=Mpa1.PotPA;
Mpa1=Mpa1';

% Introducimos la potencia de un rango de no crisis
Mna1=load('PotenciaPA142.mat');
Mna1=Mna1.PotNA;
Mna1=Mna1';

%Introducimos la potencia de otro rango previo anterior a la crisis
Mpa2=load('PotenciaPA143.mat');
Mpa2=Mpa2.PotPA;
Mpa2=Mpa2';

% Introducimos la potencia de otro rango de no crisis
Mna2=load('PotenciaNA143.mat');
Mna2=Mna2.PotNA;
Mna2=Mna2';

%Vectores de entrenamiento
training=[Mpa1(1:30,10:5:15);Mpa2(1:30,10:5:15);Mna1(1:30,10:5:15);Mna2(1:30,10:5:15)];

%Distincion de clases
dim=size(training);
group=cell(dim(1),1);
group(1:60,1)={'1'};
group(61:120,1)={'0'};

%Comando para entrena la SMV con los vectores pasados a "training"
SVMstruct=svmtrain(training, group, 'ShowPlot',true);

%Cargo los vectores de test
Mpa3=load('PotenciaPA141.mat');
Mpa3=Mpa3.PotPA;
Mpa3=Mpa3';

Mna3=load('PotenciaNA141.mat');
Mna3=Mna3.PotNA;
Mna3=Mna3';

Sample=Mpa3(1:30,10:5:15);
%Aquí vienen especificados el vector o vectores pasados como test,
%con el fin de que la SMV los clasifique.
species = svmclassify(SVMstruct,Sample, 'ShowPlot',true);

```

```
crisis=0;
sin crisis=0;
for i=1:length(species) %contador de crisis o no crisis para calcular
la
%probabilidad
    if cell2mat(species(i,1))==cell2mat({'1'})
        crisis=crisis+1;
    else
        sin crisis=sin crisis+1;
    end
end
prob_crisis= (crisis/length(species))*100; %Cálculo de probabilidad de
crisis
prob_nocrisis=(sin crisis/length(species))*100; %Cálculo de probabilidad
de no crisis

if crisis > sin crisis
    fprintf('Hay crisis con una probabilidad de %f', prob_crisis)
%Muestra la probabilidad de crisis si es mayor de 50%
    disp('%')
elseif sin crisis > crisis
    fprintf('No hay crisis con una probabilidad de %f', prob_nocrisis)
%Muestra la probabilidad de no crisis si es mayor de 50%
    disp('%')
else
    disp('Misma probabilidad de crisis que no crisis')
end
```