

Predicción de eventos epilépticos mediante técnicas de aprendizaje profundo usando señales EEG.

Ing. Gerardo Hernández Nava

2023



Universidad Autónoma de Querétaro Facultad de Ingeniería

Predicción de eventos epilépticos
mediante técnicas de aprendizaje
profundo usando señales EEG.

Tesis

Que como parte de los requisitos para
obtener el grado de

Maestro en Ciencias en Inteligencia Artificial

Presenta:

Ing. Gerardo Hernández Nava

Dirigido por:

Dr. Juan Manuel Ramos Arreguín

Co-dirigido por:

Dr. Sebastián Salazar Colores

Querétaro, Qro. a septiembre de 2023



Dirección General de Bibliotecas y Servicios Digitales
de Información



Predicción de eventos epilépticos mediante técnicas
de aprendizaje profundo usando señales EEG.

por

Gerardo Hernández Nava

se distribuye bajo una [Licencia Creative Commons
Atribución-NoComercial-SinDerivadas 4.0
Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/).

Clave RI: IGMAC-309232



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Maestría en Ciencias en Inteligencia Artificial

Predicción de eventos epilépticos mediante técnicas de
aprendizaje profundo usando señales EEG.

Tesis

Que como parte de los requisitos para obtener el Grado de
Maestro en Ciencias en Inteligencia Artificial

Presenta
Ing. Gerardo Hernández Nava

Dirigido por:
Dr. Juan Manuel Ramos Arreguín

Co-dirigido por:
Dr. Sebastián Salazar Colores

Dr. Juan Manuel Ramos Arreguín
Presidente

Dr. Sebastián Salazar Colores
Secretario

Dr. Saúl Tovar Arriaga
Vocal

Dr. Jesús Carlos Pedraza Ortega
Suplente

Dr. Cesar Javier Ortiz Echeverri
Suplente

Centro Universitario, Querétaro, Qro.
Fecha de aprobación por el Consejo Universitario (Septiembre 2023)
México

Dedicatorias

Dedico este trabajo, fruto de inquebrantable esfuerzo y dedicación, a las personas que han sido faros en mi travesía académica y personal:

*A mi amada madre, **Rosa María**, quien me brindó las lecciones invaluable de estudio y paciencia, siendo esa persona que se sentaba conmigo para que el niño travieso e hiperactivo hiciera la tarea. Sacrificando sus tardes y, muchas veces, horas de sueño, enfrentando mis frustraciones y creando melodías para la preparación de mis exámenes. Encaminándome al arduo y sorprendente mundo del estudio.*

*A mi valiente padre, **Salvador**, quien me enseñó que las recompensas llegan con esfuerzo y sacrificio, cuyo compromiso incuestionable con el bienestar de nuestra familia ha sido una fuente constante de inspiración. Tus palabras, "Todo lo que hagas es por tu bien y para mí siempre será un orgullo", resuenan en mi corazón como un faro de determinación.*

*A mi querida hermana, **Diana**, cuya inquebrantable fe en mí ha sido un pilar de apoyo y confianza, incluso en los momentos en que yo mismo dudaba.*

*A mi entrañable abuelo, **José**, mi mejor amigo en esta travesía llamada vida. Agradezco los momentos compartidos, los secretos guardados y los sabios consejos que has brindado.*

*A todos esos seres queridos que ya no están con nosotros, pero han formado parte de lo que soy ahora, en especial a **Anita (Juanibel)**, a mis abuelitas **Rosario** y **Coti** y mi abuelito **José**. Siempre vivirán en mi corazón y mi alma.*

IV

*A **Sheila**, cuyo apoyo incondicional ha sido una clave fundamental de este proceso, adoptando este proyecto como propio, alentándome a seguir adelante y por ser el equipo que somos ahora.*

*A mis amigos, **Kike, Gabi, Javi** y **Mata**, por el gran apoyo que me han dado y ser esos hermanos que la vida me regaló.*

*También a ti, **Dios** y **Virgen de Guadalupe**, por dotarme de la habilidad, la capacidad y la fortaleza necesaria para alcanzar mis metas y llegar hasta donde estoy hoy. Espero con humildad que continúen iluminando mi camino y guiándome en el futuro.*

Los amo...

Agradecimientos

Agradezco ampliamente al Dr. Arreguín por sus valiosas palabras y aportaciones que enriquecieron considerablemente este proyecto. Así como al Dr. Salazar por ser un gran guía durante este proceso, por su generosidad al compartirme sus conocimientos y experiencia.

Agradezco a la Universidad Autónoma de Querétaro y Consejo Nacional de Humanidades Ciencias y Tecnologías (CONAHCYT) por otorgarme la beca que hizo posible mi dedicación a tiempo completo a esta investigación y el entorno propicio para llevar a cabo esta investigación.

Asimismo, quiero expresar mi agradecimiento al Centro de Investigaciones en Óptica por brindarme el espacio y los recursos necesarios para llevar a cabo esta investigación. De igual manera por el tiempo y recibimiento brindado durante mi estancia de investigación.

En resumen, este trabajo no habría sido posible sin el apoyo y la contribución de muchas personas, así como de las instituciones que respaldaron mi camino académico. A todos ustedes, les extiendo mi más sincero agradecimiento.

Índice general

1	Introducción	1
2	Fundamentación teórica	5
2.1	Epilepsia	5
2.2	Electroencefalograma	6
2.3	Dominios y características	7
2.3.1	Dominio del tiempo	7
2.3.2	Dominio de la frecuencia	8
2.3.3	Dominio tiempo-frecuencia	9
2.3.4	Características	10
2.4	Tipos de aprendizaje	15
2.4.1	Aprendizaje supervisado	15
2.5	Aprendizaje profundo	15
2.6	Aprendizaje autosupervisado	16
2.6.1	Tareas pretexto	16
2.7	Análisis de Componentes Principales	18
2.8	Transformada Wavelet Continua	18
2.9	Redes neuronales artificiales	19
2.9.1	Redes neuronales convolucionales	20
2.9.2	Redes neuronales recurrentes	21
2.9.3	Redes Neuronales LSTM	21
2.9.4	Redes Neuronales GRU	22

2.9.5	Redes Neuronales Transformer	23
2.10	Cifras de mérito	23
3	Antecedentes	27
4	Hipótesis	33
5	Objetivos	35
5.0.1	Objetivo general	35
5.0.2	Objetivos específicos	35
6	Metodología	37
6.1	Búsqueda y análisis de base de datos	39
6.1.1	Base de datos de la Universidad de Bonn	39
6.1.2	Base de datos de la <i>American Epilepsy Society</i>	40
6.1.3	Base de datos del <i>Boston Children’s Hospital</i> y el <i>Massachusetts Ins-</i> <i>titute of Technology</i>	41
6.2	Detección de eventos epilépticos	41
6.2.1	Búsqueda de Ictal-Net	41
6.2.2	Busqueda de Parallel Ictal-Net	46
6.3	Predicción de eventos epilépticos mediante PIN	53
6.4	Creación de base de datos	56
6.5	Predicción de eventos epilépticos	60
7	Resultados y discusión	63
7.1	Detección de eventos epilépticos mediante Ictal-net	63
7.2	Detección de eventos epilépticos con Parallel Ictal-net	72
7.3	Predicción de eventos epilépticos con Parallel Ictal-net	81
7.4	Generación de base de datos	86
7.5	Predicción de eventos epilépticos mediante parámetros calculados en el do- minio del tiempo y de la frecuencia	88

8 Conclusiones	91
Anexo 1	103
Anexo 2	111
Anexo 3	175
Anexo 4	179
Anexo 5	185

Índice de cuadros

3.1	Análisis histórico de investigaciones orientadas a predecir eventos epilépticos.	29
6.1	Conjunto de hiperparámetros y valores modificados durante la búsqueda de Ictal-net.	45
6.2	Conjunto de variables modificadas durante la búsqueda de Parallel Ictal-net.	47
7.1	Matriz de confusión obtenida de la evaluación de Ictal-net para la detección de eventos epilépticos.	72
7.2	Matriz con las configuraciones de las 13 mejores arquitecturas para la detección de eventos epilépticos.	76
7.3	Arquitecturas propuestas y estado del arte en detección de eventos epilépticos.	79
7.4	Porcentaje de información brindada por cuatro canales y diferentes métodos de estandarización.	81
7.5	Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con escalogramas como entrada y la metodología propuesta en esta tesis.	82
7.6	Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con espectogramas como entrada y la metodología propuesta en esta tesis.	82

7.7	Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con escalogramas como entrada y la metodología encontrada en algunos proyectos del estado del arte.	83
7.8	Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con espectogramas como entrada y la metodología propuesta en algunos proyectos del estado del arte.	83
7.9	Métricas obtenidas al predecir eventos epilépticos agregando un bloque codificador antes del convolucional es la arquitectura de PIN. . . .	86
7.10	Primer instancias de la base de datos generada.	87
7.11	Matriz de confusión obtenida con el modelo de Extra Trees.	88
7.12	Matriz de confusión obtenida con el modelo Cat Boost.	89
7.13	Matriz de confusión obtenida con el modelo de XGB.	89
Anexo 1.1	PCA con diferentes métodos de normalización sujeto uno 'Dog_1' . . .	104
Anexo 1.2	PCA con diferentes métodos de normalización sujeto dos 'Dog_2' . . .	105
Anexo 1.3	PCA con diferentes métodos de normalización sujeto tres 'Dog_3' . . .	106
Anexo 1.4	PCA con diferentes métodos de normalización sujeto cuatro 'Dog_4' .	107
Anexo 1.5	PCA con diferentes métodos de normalización sujeto cinco 'Dog_5' . .	108
Anexo 1.6	PCA con diferentes métodos de normalización sujeto seis 'Patient_1' .	109
Anexo 1.7	PCA con diferentes métodos de normalización sujeto siete 'Patient_2' .	110
Anexo 2.1	Información proporcionada en la base de datos del MIT-CHB para el sujeto 1.	112
Anexo 2.2	Información proporcionada en la base de datos del MIT-CHB para el sujeto 2.	115
Anexo 2.3	Información proporcionada en la base de datos del MIT-CHB para el sujeto 3.	118
Anexo 2.4	Información proporcionada en la base de datos del MIT-CHB para el sujeto 4.	121

Anexo 2.5	Información proporcionada en la base de datos del MIT-CHB para el sujeto 5.	124
Anexo 2.6	Información proporcionada en la base de datos del MIT-CHB para el sujeto 6.	127
Anexo 2.7	Información proporcionada en la base de datos del MIT-CHB para el sujeto 7.	129
Anexo 2.8	Información proporcionada en la base de datos del MIT-CHB para el sujeto 8.	131
Anexo 2.9	Información proporcionada en la base de datos del MIT-CHB para el sujeto 9.	133
Anexo 2.10	Información proporcionada en la base de datos del MIT-CHB para el sujeto 10.	135
Anexo 2.11	Información proporcionada en la base de datos del MIT-CHB para el sujeto 11.	137
Anexo 2.12	Información proporcionada en la base de datos del MIT-CHB para el sujeto 12.	140
Anexo 2.13	Información proporcionada en la base de datos del MIT-CHB para el sujeto 13.	144
Anexo 2.14	Información proporcionada en la base de datos del MIT-CHB para el sujeto 14.	147
Anexo 2.15	Información proporcionada en la base de datos del MIT-CHB para el sujeto 15.	150
Anexo 2.16	Información proporcionada en la base de datos del MIT-CHB para el sujeto 16.	154
Anexo 2.17	Información proporcionada en la base de datos del MIT-CHB para el sujeto 17.	156
Anexo 2.18	Información proporcionada en la base de datos del MIT-CHB para el sujeto 18.	158

Anexo 2.19 Información proporcionada en la base de datos del MIT-CHB para el sujeto 19.	161
Anexo 2.20 Información proporcionada en la base de datos del MIT-CHB para el sujeto 20.	163
Anexo 2.21 Información proporcionada en la base de datos del MIT-CHB para el sujeto 21.	166
Anexo 2.22 Información proporcionada en la base de datos del MIT-CHB para el sujeto 22.	169
Anexo 2.23 Información proporcionada en la base de datos del MIT-CHB para el sujeto 23.	172

Índice de figuras

2.1	EEG de un evento epiléptico [1].	6
2.2	Señal EEG en el dominio del tiempo [2].	7
2.3	Señal EEG en el dominio de la frecuencia [3].	8
2.4	Señal EEG en el dominio Tiempo-Frecuencia [2].	9
2.5	Diagrama de una RNA [4].	20
2.6	Diagrama de una red neuronal convolucional [5].	21
2.7	Diagrama de una red LSTM [6].	22
2.8	Diagrama de una neurona GRU [6].	23
6.1	Diagrama de flujo de Metodología a gran escala.	38
6.2	Diagrama de flujo para la búsqueda de Ictal-Net.	42
6.3	Muestro y organización de las señales ictales e interictales.	43
6.4	Diagrama de flujo para la búsqueda de Parallel Ictal-Net.	49
6.5	Diagrama de flujo para predecir eventos epilépticos mediante la arquitectura de PIN.	54
6.6	Diagrama de flujo para el desarrollo de una nueva base de datos.	59
6.7	Diagrama de flujo para la búsqueda de un modelo de predicción utilizando la nueva base de datos.	61
7.1	Muestreo y escalograma de señal interictal proveniente de la base de datos de la Universidad de Bonn [7].	64
7.2	Muestreo y escalograma de señal ictal proveniente de la base de datos de la Universidad de Bonn [7].	65

7.3	Precisiones obtenidas con distintos MLP's en la detección de eventos epilépticos.	66
7.4	Configuraciones probadas para la detección de eventos epilépticos mediante MLP.	67
7.5	Precisiones obtenidas con distintas CNN's en la detección de eventos epilépticos.	68
7.6	Configuraciones probadas para la detección de eventos epilépticos mediante CNN.	70
7.7	Arquitectura de la red neuronal convolucional denominada Ictal-net [7].	71
7.8	Combinación de configuraciones para la red neuronal y CWT para la búsqueda de Parallel Ictal-net.	74
7.9	Configuraciones que superan el estado del arte encontrado y sus cifras de mérito	75
7.10	Entrada de Parallel Ictal-net	77
7.11	Arquitectura de Parallel Ictal-net.	78
7.12	Aquitectura de U-net para tarea pretexto.	84
7.13	Arquitectura de Parallel Ictal-net con bloque de codificación.	85
Anexo 3.1	Constancia de registro del protocolo.	176
Anexo 3.2	Autorización del protocolo por parte del H. Consejo de Posgrado e Investigación.	177
Anexo 3.3	Constancia de aprobación por parte del comite de ética.	178
Anexo 4.1	Artículo sobre Ictal-net presentado en el 21° Congreso Nacional de Mecatrónica.	180
Anexo 4.2	Reconocimiento por presentación oral del artículo denominado Ictal-net: Un diseño de CNN para la clasificación de escalogramas de electroencefalogramas con crisis convulsivas.	181

Anexo 4.3	Reconocimiento por el artículo: <i>Ictal-net: Un diseño de CNN para la clasificación de escalogramas de electroencefalogramas con crisis convulsivas.</i>	182
Anexo 4.4	Portada el artículo donde se presenta la arquitectura PIN.	183
Anexo 5.1	Plantilla para protocolo de tesis, dirigido a alumnos de la facultad de ingeniería, en Latex.	186
Anexo 5.2	Portada del artículo <i>Aprendizaje Automático para la Detección del Daño Pulmonar a través de Parámetros Clínicos.</i>	187
Anexo 5.3	Reconocimiento por la aportación al 21° Congreso Nacional de Mecatrónica con el artículo <i>Aprendizaje Automático para la Detección del Daño Pulmonar a través de Parámetros Clínicos.</i>	188
Anexo 5.4	Portada del artículo <i>Análisis de Modelos de Segmentación de Atrofia Peripapilar Alfa y Beta en Imágenes de Fondo de Ojo.</i>	189
Anexo 5.5	Reconocimiento por la aportación al 21° Congreso Nacional de Mecatrónica con el artículo <i>Análisis de Modelos de Segmentación de Atrofia Peripapilar Alfa y Beta en Imágenes de Fondo de Ojo.</i>	190
Anexo 5.6	Póster realizado para presentar en un congreso del Centro de Investigaciones en Óptica.	191
Anexo 5.7	Artículo <i>Desarrollo de una herramienta de diagnóstico temprano de daño pulmonar basada en aprendizaje automático.</i>	192
Anexo 5.8	Página web para realizada para la clasificación de Daño pulmonar presentada en un congreso del Centro de Investigaciones en Óptica.	193
Anexo 5.9	Reconocimiento por la participación en el XX encuentro Participación de la Mujer en la Ciencia	194
Anexo 5.10	Póster presentado en el congreso IEEE CAI 2023.	195
Anexo 5.11	Artículo <i>Improving Idiopathic Pulmonary Fibrosis Damage Prediction with Segmented Images in a Deep Learning Model.</i>	196

Anexo 5.12 Artículo <i>Classification of COVID-19 Mortality Risk: A Neural Network-Based Approach Using Mexican Health Setor Data</i>	197
Anexo 5.13 Reconocimiento por la participación en el 46° Congreso Nacional de Ingeniería Biomédica con el artículo <i>Classification of COVID-19 Mortality Risk: A Neural Network-Based Approach Using Mexican Health Setor Data</i>	198

Resumen

La epilepsia es una de las enfermedades neurológicas más comunes a nivel mundial, afectando a alrededor de 70 millones de personas globalmente y a entre 10.8 y 20 personas por cada mil habitantes en México. Esta enfermedad se caracteriza por convulsiones no provocadas o entumecimientos de forma recurrente y aleatoria, lo cual provoca que las personas que padecen esta enfermedad tengan limitaciones en su vida diaria, teniendo secuelas físicas, emocionales y sociales. La detección y predicción de estos episodios en una señal electroencefalográfica, es una tarea que puede ayudar de múltiples formas tanto al personal de salud como a los sujetos que padecen esta enfermedad. En el estado del arte se han encontrado múltiples trabajos que abordan esta temática utilizando algoritmos de aprendizaje automático, sin embargo, aún existe un margen de mejora en términos de exactitud, precisión, sensibilidad y puntaje F1. Es por ello que en esta tesis se presentan múltiples arquitecturas orientadas a la detección y predicción de eventos epilépticos. Se plantea un procesamiento de las señales utilizando la transformada wavelet continua, caracterización en el dominio del tiempo y de la frecuencia, una clasificación utilizando arquitecturas basadas en redes neuronales convolucionales y módulos de atención para mejorar el rendimiento de las arquitecturas. Obteniendo resultados prometedores, con cifras de mérito entre el 80 y el 100 % según la tarea designada y la arquitectura utilizada. Las evaluaciones se realizaron utilizando técnicas como k-fold y 60-20-20. Cabe resaltar que este proyecto aborda la problemática de la detección y predicción de eventos epilépticos desde el punto de vista de software y hardware.

Palabras clave: Red Neuronal Convolucional, Transformada Wavelet Continua, Atención de Canal Eficiente, Detección y Predicción de Eventos Epilépticos.

Abstract

Epilepsy is one of the most common neurological disorders worldwide, affecting approximately 70 million people globally. In the Mexican population, it occurs in approximately 10.8 to 20 individuals per thousand. This disease is characterized by recurrent and random seizures or numbness, which limits the daily lives of those who suffer from it and leaves physical, emotional, and social consequences. Detecting and predicting these episodes in an electroencephalographic signal is a task that can benefit both healthcare professionals and individuals with epilepsy. In the state of the art, multiple studies have addressed this issue using machine learning algorithms. However, there is still room for improvement in terms of accuracy, precision, sensitivity, and F1 score. Therefore, this thesis presents multiple architectures aimed at detecting and predicting epileptic events. Signal processing is proposed using the continuous wavelet transform, time and frequency domain characterization, as well as classification through architectures based on convolutional neural networks, along with attention modules to enhance the performance of the architectures. Promising results have been obtained in the field of epileptology, ranging from 80 % to 100 % in terms of performance metrics, depending on the specific task and architecture used. Evaluations were conducted using techniques such as k-fold and 60-20-20. It's worth highlighting that this project addresses the issue of epileptic event detection and prediction from both a software and hardware perspective.

Keywords: Convolutional Neural Network, Continuous Wavelet Transform, Efficient Channel Attention, Epileptic Event Detection, Epileptic Event Prediction.

Capítulo 1

Introducción

La Organización Panamericana de la Salud (OPS) define a la epilepsia como un trastorno neurológico crónico que afecta a personas de ambos sexos y de todas las edades, padeciéndola aproximadamente 70 millones de personas en el mundo y en la mitad de los casos no es posible determinar la causa, mientras que en México presenta una prevalencia de entre el 10.8 y 20 personas por cada mil [8], [9]. Esta enfermedad se manifiesta con descargas neuronales anormales de manera recurrente en forma de convulsiones o entumecimientos de algunas partes del cuerpo [10].

Las convulsiones representan un gran riesgo para quienes padecen epilepsia, dado que pueden presentar lesiones graves, siendo las más comunes las fracturas, hematomas, quemaduras, lesiones en tejidos blandos y accidentes por casi ahogamiento, fallecimiento prematuro derivado a accidentes o la muerte súbita e inesperada en la epilepsia (SUDEP, por sus siglas en inglés); por mencionar algunas las lesiones físicas, pero quienes padecen esta enfermedad también sufren de secuelas sociales, como la discriminación, viven dificultades en el ámbito educativo, laboral y en las relaciones interpersonales, llevándolos al suicidio en algunos casos. Inclusive se considera que las personas que padecen epilepsia tienen un 5 % de mayor probabilidad de visitar un servicio de urgencias debido a las lesiones o accidentes que estas pueden provocar [11], [12] Dichos eventos se presentan de forma aleatoria, lo cual aumenta

el riesgo de sufrir accidentes. He ahí la importancia de predecir los eventos, además de que se estaría mejorando la calidad de vida de las personas que padecen epilepsia, así como la de su familia.

La predicción de los eventos epilépticos ayudaría en distintos escenarios. Por ejemplo, a que pacientes y acompañantes tomen las medidas necesarias para disminuir los daños y riesgos que involucran un ataque epiléptico o a que mediante el uso de un neuroestimulador -el cual podría tomarse como el mejor de los escenarios- se evite un evento epiléptico. Pero en ambas opciones se mejoraría la calidad de vida de quienes padecen esta enfermedad, aún más si se considera que al rededor del 30 % de los pacientes que padecen epilepsia son fármaco resistentes y de los pacientes que pueden ser tratados con fármacos muy pocos tienen tratamientos monofarmacológicos.

De tal forma el impacto social que se buscó alcanzar con el desarrollo de este proyecto fue servir como base e inspiración para trabajos futuros para lograr predecir en tiempo real un evento epiléptico, lo cual ayudaría notablemente a mejorar la calidad de vida de las 70 millones de personas en el mundo que la padecen, así como de sus familiares o personas cercanas a ellos, ya que el padecer esta enfermedad trae consigo múltiples repercusiones y evitan un pleno desenvolvimiento social.

El desarrollo de las arquitecturas presentadas en esta tesis, así como la metodología seguida para abordar las tareas planteadas en este escrito, da pie a una posterior implementación de un sistema capaz de monitorear, alertar y prevenir de una futura crisis al paciente, o en el mejor de los casos poder inhibirla.

Dado que se busca que este proyecto sea la antesala de un sistema de predicción, el impacto económico será mayormente notorio cuando dicho sistema se encuentre finalizado y disponible para su comercialización, ya que estará compitiendo con soluciones o tratamientos alternos, tales como, fármacos, cuyo costo anual aproximado es de \$1,500 USD, o en

el caso de que el paciente sea farmacorresistente se tiene la opción de cirugía con un costo aproximado de \$55,000 USD, con el riesgo de presentar futuras secuelas o que los eventos epilépticos se sigan presentando.

Capítulo 2

Fundamentación teórica

A continuación, se presentan los conceptos que soportan el planteamiento del problema de esta investigación. En el cual abordaremos conceptos como la epilepsia; el EEG; así como los dominios en los que se puede trabajar y las características que se pueden obtener; por otro lado, los tipos de aprendizaje básicos para introducir el aprendizaje profundo y posteriormente sobre algunos algoritmos en los que pueden ser aplicados; y para finalizar se hablará sobre algunas cifras de mérito con las cuales se puede calificar el rendimiento de los modelos.

2.1. Epilepsia

En la última definición clínica operativa publicada por la Liga Internacional Contra la Epilepsia (ILAE, por sus siglas en inglés) en 2014 se menciona que la epilepsia es una enfermedad cerebral que se define por cualquiera de las siguientes circunstancias: por la presencia de al menos dos crisis no provocadas con una separación entre ellas mayor a 24 horas, una crisis no provocada con una probabilidad mínima del 60 % de presentar nuevas crisis durante los siguientes 10 años, o bien, tener un diagnóstico de un síndrome de epilepsia [13].

Se dice que una crisis es no provocada cuando existe la ausencia de un factor temporal o reversible que reduzca el umbral y provoque una crisis en ese momento, aunque no es posi-

ble saber con certeza si hay algún factor desencadenante. Una crisis epiléptica es la aparición transitoria de signos y/o síntomas a causa de una actividad neuronal anómala excesiva o simultánea en el cerebro, la cual puede ser registrada mediante un EEG [13].

2.2. Electroencefalograma

El EEG es el registro de la actividad eléctrica de las neuronas (ver Figura 2.1), en el orden de microvolts, a través de electrodos que son distribuidos de forma uniforme en la cabeza. Estos electrodos pueden estar colocados sobre la piel, o bien, en el encéfalo y realizar el registro de forma superficial o profundo [14]. Dichas señales pueden ser manipuladas en distintos dominios para extraer características específicas de la señal.

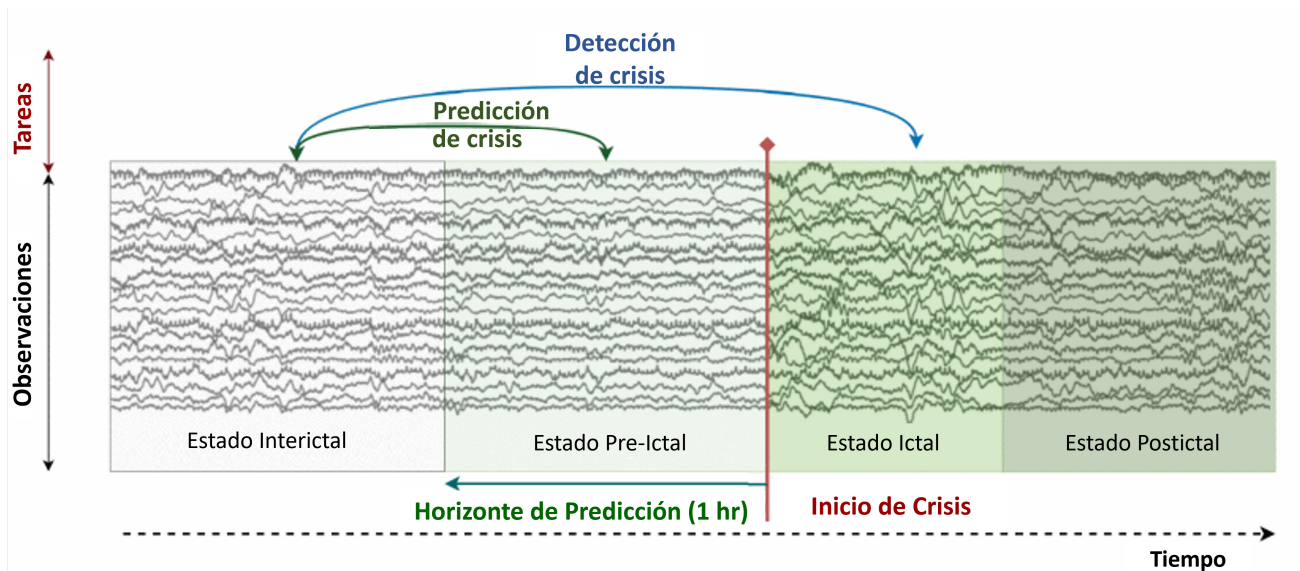


Figura 2.1: EEG de un evento epiléptico [1].

En la Figura 2.1 se puede ver un EEG de un evento epiléptico en el cual se muestran los cuatro estados en los que se clasifica un EEG cuando se presenta un evento epiléptico, que son: Interictal, periodo intermedio entre eventos epilépticos; Pre-ictal, momentos antes de

que se presente el evento; Ictal, es el periodo en el cual está ocurriendo el evento epiléptico; y Postictal, después del evento epiléptico.

2.3. Dominios y características

En el procesamiento de señales existen tres distintos de dominios (tiempo, frecuencia y tiempo-frecuencia) en los cuales las señales pueden ser caracterizadas para poder obtener la mayor información posible y realizar un análisis adecuado de las mismas, en este caso la señal biomédica EEG.

2.3.1. Dominio del tiempo

La ventaja del dominio del tiempo recae en que puede trabajar con la señal cruda o pre-procesada para tener una mejor relación ruido señal. En la Figura 2.2 se puede ver un ejemplo de una señal EEG en el dominio del tiempo.




Figura 2.2: Señal EEG en el dominio del tiempo [2].

Como se puede observar en la Figura 2.2 la señal se representa con una amplitud en el orden de microvolts a través del tiempo. En este dominio se puede extraer una gran cantidad de características como: valor promedio absoluto, cruce de ceros, cambio de signo de pendiente, longitud de onda, energía, potencia media, raíz cuadrada media (RMS), integral de la amplitud, energía no lineal, entropía de Shannon, entropía aproximada, entropía de muestra, entropía de permutación ponderada, entropía difusa, distribución de entropía, entropía de descomposición de valores singulares, patrón de gradiente local, exponente de Hurst, dimensión fractal, entre otros.

2.3.2. Dominio de la frecuencia

Para lograr extraer las características que corresponden al dominio de la frecuencia debemos preprocesar la señal haciendo uso de alguna transformación, tal como la transformada discreta de Fourier, para que la señal quede en dicho dominio. Como se muestra en la Figura 2.3

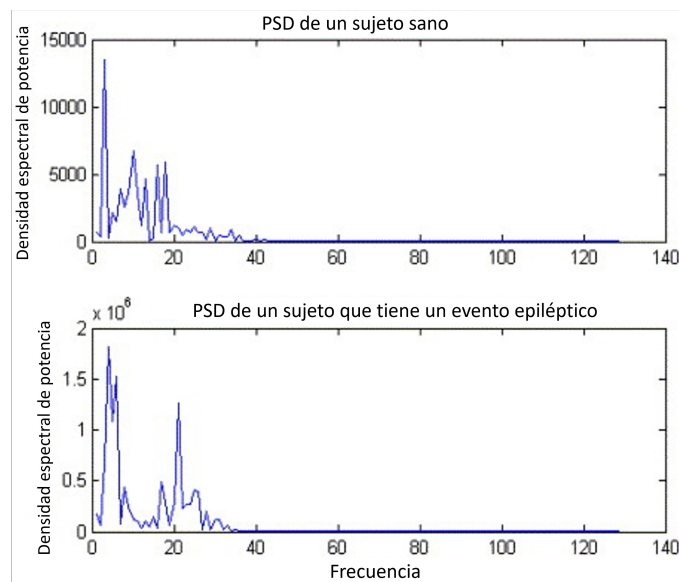


Figura 2.3: Señal EEG en el dominio de la frecuencia [3].

En la Figura 2.3, a diferencia del dominio del tiempo, la señal EEG en el dominio de la frecuencia se muestra con una amplitud que representa la densidad espectral dependiente de las frecuencias que contiene la señal. Las características que se pueden obtener dentro de este dominio son: frecuencia pico, ancho de banda de la frecuencia dominante, ancho de banda ponderada por intensidad, intensidad ponderada de la frecuencia media, entropía espectral, frecuencia de borde espectral, energía y relación de potencia.

2.3.3. Dominio tiempo-frecuencia

Para preprocesar la señal y obtenerla en dicho dominio podemos hacer uso de la transformada wavelet discreta, por mencionar algún preprocesamiento. Ya que las características se calculan a partir de los coeficientes de descomposición. (Ver Figura 2.4)




Figura 2.4: Señal EEG en el dominio Tiempo-Frecuencia [2].

En la Figura 2.4, se muestra la señal EEG original así como en sus diferentes niveles de descomposición, a partir de los cuales se pueden calcular las siguientes características: media, media absoluta, varianza, desviación estándar, asimetría, curtosis, media absoluta, valores máximos y mínimos, RMS, energía potencia promedio, longitud de onda, los indicadores de entropía mencionados anteriormente incluyendo la de Rényi, parámetros de autorregresión y promedio de movimiento móvil autorregresivo.

2.3.4. Características

Cuartiles

Los cuartiles son valores que dividen los datos en cuatro partes iguales, cabe destacar que para poder calcular los cuartiles es importante organizar primero los datos en orden de menor a mayor [15]. Estos valores son utilizados para la analizar la dispersión y la tendencia de la distribución, obteniendo información como rango, tendencia central y dispersión .

- *Primer cuartil (Q1)*: También conocido como el percentil 25, es el valor que separa el 25 % inferior de los datos cuando están ordenados de menor a mayor.
- *Segundo cuartil (Q2)*: Es equivalente a la mediana y es representado por el valor de divide a la mitad los valores ordenados.
- *Tercer cuartil (Q3)*: Conocido como percentil 75, es el valor que separa el 25 % superior de los datos.

Adicionalmente al valor de los cuartiles puede calcularse el *rango intercuartil (RIQ)*, el cual es una medida de dispersión que se utiliza para describir la variabilidad de una distribución de datos y se calcula a través de la ecuación 2.1.

$$RIQ = Q_3 - Q_1 \quad (2.1)$$

Momentos estadísticos

Los momentos estadísticos proporcionan información sobre la distribución de amplitud de una

- *Momento de orden cero:* También conocido como el momento de la media o simplemente la media, representa el valor promedio de los datos. En este caso el valor absoluto de la señal EEG registrada. Se suman todos los valores registrados y se divide entre la cantidad total de los valores, ellos se puede ver en la siguiente ecuación.

$$\bar{x} = \frac{\sum_{i=0}^n |x_i|}{N} \quad (2.2)$$

- *Momento de orden uno:* Este momento está relacionado con la asimetría de la distribución de datos. Si el momento de orden uno es cero, la distribución es simétrica; si es positivo, la distribución tiene una cola sesgada hacia la derecha; si es negativo, tiene una cola sesgada hacia la izquierda [15].
- *Momento de orden dos:* El momento central de orden dos está relacionado con la varianza y desviación estándar de los datos. Entre más grande sea el valor de la desviación estándar este indica una mayor dispersión entre los datos. Para calcular la desviación estándar (s) se utiliza la ecuación 2.3

$$s = \sqrt{\frac{\sum_{i=0}^n (x_i - \bar{x})^2}{N - 1}} \quad (2.3)$$

- *Momento de orden tres:* Coeficiente de asimetría, o en inglés *skewness*, es una medida estadística utilizada para cuantificar la falta de simetría en una distribución de datos. Representa la desviación de la forma de la distribución alrededor de su media. En una distribución perfectamente simétrica, las colas derecha e izquierda tienen la misma forma y tamaño, lo que se refleja en un *skewness* igual a cero. Sin embargo, un *skewness* positivo indica una cola sesgada hacia la derecha, lo que implica que la cola derecha se extiende más hacia valores más altos que la cola izquierda. Por otro lado, un *skewness*

negativo señala una cola sesgada hacia la izquierda, donde la cola izquierda se extiende más hacia valores más bajos que la cola derecha. El valor absoluto del *skewness* ofrece información sobre el grado de asimetría, siendo un valor mayor indicativo de una asimetría más pronunciada [15]. La ecuación 2.4 ayuda a calcular el coeficiente de asimetría.

$$skewness = \frac{\bar{x} - mediana}{s} \quad (2.4)$$

- *Momento de orden cuatro*: También denominado como curtosis, es un parámetro que se utiliza para medir la distribución de las frecuencias relativas de los datos de una muestra entre el centro y los extremos. Se compara con la distribución normal o de Gauss, la cual tiene un coeficiente de curtosis de 3. Para calcular la curtosis se hace uso de la ecuación 2.5 [15].

$$custosis = \frac{\sum_{i=0}^n (x_i - \bar{x})^4}{ns^4} \quad (2.5)$$

Moda

La moda hace referencia a la medida de tendencia central que representa el valor o los valores que se presentan con mayor frecuencia en una distribución de datos. La moda es aplicable tanto a variables numéricas como a variables categóricas. Aunque este valor es sencilla y útil para identificar es importante tener en cuenta que puede haber casos donde no exista una moda clara (distribuciones bimodales o multimodales) o donde todos los valores sean únicos (sin moda).

Coefficiente de variación

El coeficiente de variación (*CV*), dado por la ecuación 2.6, es una medida estadística para cuantificar la dispersión de una distribución en relación a su media. Es expresado como un porcentaje.

$$CV = \frac{s}{\bar{x}} \cdot 100 \quad (2.6)$$

Un CV bajo indica una variabilidad relativa baja en comparación con la media, lo que sugiere que los datos son homogéneos o consistentes. Por otro lado, un coeficiente de variación alto indica una variabilidad alta con relación a la media, lo que sugiere que los datos tienen un comportamiento disperso o heterogéneo [15].

Valor máximo

Es el número con mayor valor observado en un conjunto de datos. Representa el límite superior o el punto más alto alcanzado por la variable en estudio, en este caso el registro de EEG.

Valor mínimo

Al contrario que el valor máximo, el valor mínimo es el número con menor valor dentro del conjunto de datos. Representa el límite inferior o el punto más bajo alcanzado por la variable de estudio.

Análisis de Fluctuación con Eliminación de Tendencia

El Análisis de Fluctuación con Eliminación de Tendencia o (DFA por sus siglas en inglés *Detrended Fluctuation Analysis*), es una técnica utilizada para analizar la estructura de correlación a largo plazo en una serie temporal. Es utilizado de manera frecuente para detectar características inherentes de autosimilitud en las señales de EEG [16]. El DFA proporciona información sobre la dinámica y la autocorrelación de la serie temporal analizada.

Parámetros de Hjorth

Los parámetros de Hjorth son tres medidas utilizadas para caracterizar señales EEG, brindando información temporal y frecuencial. Fueron desarrolladas por el científico Björn Hjorth

en 1970 y son aplicadas ampliamente en la investigación y análisis de la actividad cerebral [15].

- *Actividad*: Es la medida de la amplitud de la señal EEG, mide la cantidad de energía presente en la actividad cerebral. Se calcula como la varianza de la señal, siguiendo la ecuación 2.7.

$$Actividad = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (2.7)$$

- *Movilidad*: Indica la velocidad de cambio de la señal analizada, proporcionando información para evaluar la dinámica temporal de la actividad cerebral. En cuanto más grande sea el valor de este parámetro indica una mayor variabilidad y cambios más rápidos de la señal. La movilidad es calculada mediante la primera derivada de la señal EEG.
- *Complejidad*: Es un parámetro que hace referencia a una variabilidad a largo plazo de la señal EEG. Especialmente está relacionado con la irregularidad y presencia de detalles finos en la señal, es decir a mayor variabilidad mayor número de detalles finos. Para el cálculo de este segundo parámetro se utiliza la segunda derivada.

Potencia relativa

La potencia relativa hace referencia a la distribución de la energía o potencia de una señal en diferentes bandas de frecuencia en relación con la potencia total en la señal. En este sentido, al estar analizando señales EEG se utiliza para estudiar la actividad eléctrica cerebral en diferentes bandas. Principalmente se analizan 5 bandas: la *delta* que se encuentra presente entre los 0.5 y 4 Hz, la *theta* situada entre los 4 y 8 Hz, la *alpha* entre 8 y 13 Hz, *beta* localizada entre los 13 y 30 Hz y la banda *gamma* con frecuencias entre los 30 y 100 Hz [17].

Para calcular la potencia relativa en cada banda de frecuencia, primero se descompone la señal EEG en sus componentes de frecuencia. Posteriormente se calcula la potencia de la

señal en cada banda de frecuencia dividiendo la suma de las potencias en esa banda por la potencia total de la señal.

2.4. Tipos de aprendizaje

Por otro lado, los modelos de aprendizaje profundo están preparados para continuas actualizaciones, ya que la entrada de información es constante y aprenden iterativamente. Existen dos tipos de aprendizajes básicos, el no supervisado y el supervisado, siendo este último más utilizado por los modelos de predicción de eventos epilépticos para su entrenamiento.

2.4.1. Aprendizaje supervisado

En el aprendizaje supervisado se establece un conjunto de datos para comenzar la comprensión del comportamiento de los datos y encontrar patrones para un posterior proceso analítico. Estos algoritmos se entrenan con datos ya procesados y su rendimiento se evalúa con datos de prueba [18].

2.5. Aprendizaje profundo

Ahora bien, el aprendizaje profundo es catalogado como un subconjunto dentro del aprendizaje automático por ciertos autores [19], mientras que para otros es más que eso, es un enfoque de la inteligencia artificial [20] mismos que lo definen como un tipo de aprendizaje que usa como herramienta redes neuronales profundas, las se encuentran divididas principalmente en tres capas, descritas en el siguiente apartado.

2.6. Aprendizaje autosupervisado

Una de las áreas de mayor interés en el campo del aprendizaje profundo es el aprendizaje autosupervisado, que es una forma de entrenar modelos de redes neuronales sin la necesidad de etiquetas de entrenamiento explícitas.

El aprendizaje autosupervisado se basa en la idea de que es posible utilizar los datos de entrada sin etiquetas para aprender una representación latente del mundo que puede ser utilizada para tareas posteriores. En el aprendizaje autosupervisado, a diferencia del supervisado, los modelos se entrenan para realizar tareas relacionadas con la estructura interna de los datos sin la necesidad de etiquetas explícitas [21].

Una de las técnicas más populares en el aprendizaje autosupervisado es la de la predicción de contextos, también conocida como la tarea de autencoders. En esta tarea, se le presenta a la red neuronal una parte de los datos de entrada y se le pide que prediga el resto de los datos que faltan. Al entrenar una red neuronal en esta tarea, se puede aprender una representación latente del mundo que puede ser utilizada en tareas posteriores, como la clasificación o la detección de objetos.

Otra técnica popular en el aprendizaje autosupervisado es la de la generación de imágenes, donde la red neuronal se entrena para generar imágenes similares a las del conjunto de datos de entrada. Esta técnica ha demostrado ser muy útil en tareas como la síntesis de imágenes médicas y la generación de avatares.

2.6.1. Tareas pretexto

Las tareas pretexto son un tipo de tarea autosupervisada que se utilizan para aprender representaciones latentes de los datos que son útiles para tareas futuras. Estas tareas se diseñan de tal manera que el modelo debe aprender una representación latente de los datos que sea útil para la tarea pretexto, pero que también sea generalizable y útil para otras tareas.

Por ejemplo, en el campo de visión por computadora se tienen las siguientes tareas pretexto:

SimCLR: en [22], se utiliza la predicción de la similitud de pares de imágenes como

tarea pretexto para aprender representaciones latentes de imágenes. El modelo resultante ha demostrado un excelente rendimiento en varias tareas de visión por computadora, incluida la clasificación de imágenes y la detección de objetos.

SwAV: en [23], se utiliza la agrupación de vistas de imágenes como tarea pretexto para aprender representaciones latentes de imágenes. El modelo resultante ha demostrado un excelente rendimiento en la clasificación de imágenes y la detección de objetos.

BYOL: en [24], se utiliza la predicción de la versión codificada de la imagen como tarea pretexto para aprender representaciones latentes de imágenes. El modelo resultante ha demostrado un excelente rendimiento en varias tareas de visión por computadora, incluida la clasificación de imágenes y la detección de objetos.

En general, las tareas pretexto se han utilizado con éxito en proyectos de aprendizaje automático y aprendizaje profundo en una amplia variedad de dominios, desde la visión por computadora hasta el procesamiento del lenguaje natural. Estas tareas pueden ayudar a los modelos a aprender representaciones latentes útiles que pueden ser utilizadas para resolver una variedad de tareas diferentes.

Sin embargo, en este proyecto se hizo uso de la tarea pretexto denoising, la cual consiste en eliminar el ruido o la interferencia de una señal o imagen, de tal manera que se pueda obtener una señal o imagen clara y legible.

En el aprendizaje profundo, se ha demostrado que el denoising puede ser utilizado como una tarea pretexto para entrenar modelos de redes neuronales. Al entrenar un modelo de red neuronal en la tarea de denoising, se aprende una representación latente de los datos que es útil para la tarea de denoising, pero también puede ser útil para otras tareas de interés.

Por ejemplo, en el procesamiento de imágenes, la tarea de denoising puede ser utilizada como tarea pretexto para entrenar un modelo de red neuronal que aprenda una representación latente de las imágenes que sea útil para otras tareas de procesamiento de imágenes, como la segmentación de imágenes, clasificación o la detección de objetos en imágenes.

2.7. Análisis de Componentes Principales

El Análisis de Componentes Principales (PCA) es una técnica de reducción de la dimensionalidad que se utiliza para identificar patrones en conjuntos de datos. El objetivo del PCA es encontrar una representación lineal de los datos que capture la mayor cantidad de varianza posible en el conjunto de datos original. En otras palabras, el PCA permite simplificar los datos complejos identificando las variables más importantes [25].

El proceso de PCA comienza con la estandarización de los datos, es decir, se resta la media y se divide por la desviación estándar de cada variable. Luego, se calculan los eigen vectores y los eigen valores de la matriz de covarianza de los datos estandarizados. Los eigen vectores son las direcciones principales en las que los datos varían y los eigen valores representan la cantidad de varianza en los datos que se explica por cada vector propio.

El siguiente paso es ordenar los eigen vectores por su eigen valor, de mayor a menor. Luego, se seleccionan los eigen vectores con los eigen valores más altos, que corresponden a las componentes principales más importantes. Estas componentes principales se utilizan para transformar los datos originales en un nuevo espacio de menor dimensión.

El resultado de la transformación es un conjunto de componentes principales que explican la mayor parte de la varianza en los datos originales. Estas componentes principales también pueden interpretarse como patrones o características importantes en los datos.

El PCA se utiliza en una amplia variedad de campos, como la biología, la genética, la estadística, la psicología, la economía y la informática, entre otros. Se utiliza en la identificación de factores importantes en los datos, la reducción de la dimensionalidad, la visualización de datos, la compresión de imágenes y la detección de anomalías, entre otros usos.

2.8. Transformada Wavelet Continua

La transformada wavelet continua (CWT) es una técnica matemática utilizada para descomponer una señal muestreada continua o discreta en sus componentes de frecuencia [13]. Es utilizada para analizar señales que varían en el tiempo o espacio, ya que proporciona in-

formación tanto temporal como frecuencial de la señal. Una de sus principales ventajas es su capacidad para revelar características de la señal que pueden no ser evidentes con otros métodos, como la transformada de Fourier [14].

Para realizar la CWT, se utiliza una función de onda madre como base para analizar la señal. Cada wavelet madre tiene características específicas como forma de onda con un ancho específico, la cual se utiliza para analizar diferentes componentes de frecuencia de la señal [13]. En la Fig. 1 se muestran algunos ejemplos de funciones wavelet madre.

El análisis de la señal se realiza escalando la función madre y traduciendo la información encontrada en el tiempo de forma tal que coincidan con las diferentes partes de la señal. Los coeficientes wavelet resultantes representan el contenido de frecuencia de la señal en cada escala y ubicación, donde se puede aplicar un procesamiento posterior para obtener un escalograma y se puedan localizar con mayor facilidad las características o patrones que poseen las señales [5].

Un escalograma es una representación gráfica del contenido frecuencial de la señal a lo largo del tiempo [15]. A menudo se utiliza en aplicaciones de procesamiento de señales y procesamiento de imágenes para analizar señales que varían con el tiempo o el espacio [16]–[18].

2.9. Redes neuronales artificiales

Las redes neuronales, también llamadas redes neuronales artificiales (RNA), son un modelo matemático o computacional con un conjunto de unidades de procesamiento llamadas neuronas artificiales, que se encuentran conectadas entre sí (ver Figura 2.5). Las RNA están basadas en un cerebro con sus neuronas y sinapsis, que es la conexión entre ellas. Se considera que el inicio del estudio de las redes neuronales comenzó con la publicación de un artículo en 1943 escrito por McCulloch y Pitts [26], [27].

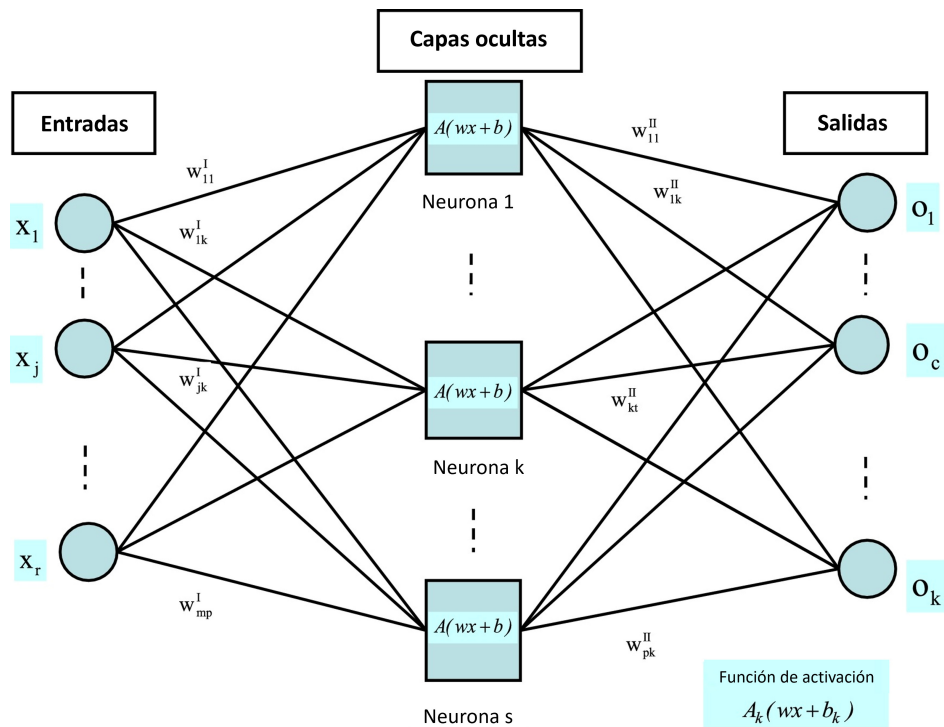


Figura 2.5: Diagrama de una RNA [4].

En la Figura 2.5 se pueden observar las tres capas que componen a estos algoritmos, las cuales son [28], [20]:

- **Capa de entrada:** Sección donde se reciben los datos de entrada.
- **Capa oculta:** El algoritmo puede estar compuesto por una o más capas ocultas. Estas se encargan del procesamiento de los datos y cálculos para realizar la predicción.
- **Capa de salida:** Esta es la última división y se encarga de tomar decisiones o concluir aportando datos de salida.

2.9.1. Redes neuronales convolucionales

Fueron inventadas por Yann LeCun y otros investigadores en 1998. Es una red neuronal compuesta por una o más capas convolucionales. Se construye a partir de tres componentes

principales, acoplamiento de matrices a vectores, regresión logística y un campo receptivo, como se muestra en la Figura 2.6 [20].




Figura 2.6: Diagrama de una red neuronal convolucional [5].

La Figura 2.6 corresponde a una CNN propuesta en el artículo [5], la cual consiste en cuatro capas convolucionales para el análisis de un EEG.

2.9.2. Redes neuronales recurrentes

Las RNN carecen de una estructura de capas definida, ya que las conexiones entre sus neuronas son arbitrarias al grado de crear ciclos para la creación de la temporalidad y de esa forma lograr que la memoria esté presente en una red neuronal [20, 29].

Existen distintos tipos de RNN, estas pueden ser simples, de gran memoria de corto plazo (LSTM) la ventaja de estas redes es que cuentan con tres puertas: la de entrada, olvido y salida; lo cual ayuda a no propagar los errores; y las redes neuronales recurrentes con compuertas (GRU) esta red cuenta con dos puertas la de actualización y la de reajuste [20, 29].

2.9.3. Redes Neuronales LSTM

Las redes LSTM fueron creadas por Hochreiter y Schmidhuber en el año de 1997 [6]. Esta red se caracteriza por las celdas de memoria (ver Figura 2.7). Estas celdas de memoria son utilizadas como una entrada extra teniendo la función de guardar un valor que resulta

importante para ella durante periodos largos o cortos.

Las celdas de memoria contienen tres puertas. Una puerta de entrada que es la que controla la entrada de nueva información; la de olvido, desecha información que ya no le es relevante; y la de salida, controla cuando se utiliza la información recabada. Cada puerta tiene una ponderación para su control los cuales se pueden modificar mediante retropropagación a tiempo [6].

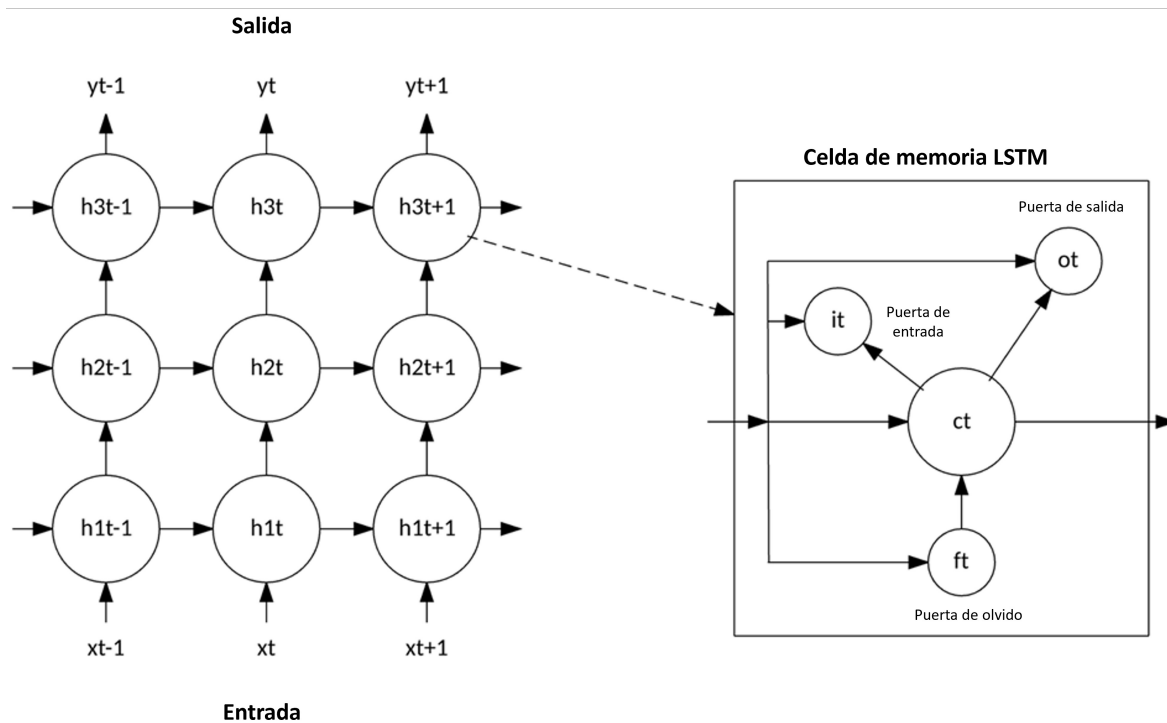


Figura 2.7: Diagrama de una red LSTM [6].

2.9.4. Redes Neuronales GRU

La GRU es una unidad simplificada de las LSTM, pero en comparación llega a tener un rendimiento similar con una ejecución más rápida. Se dice que es simplificada ya que cuentan con dos puertas, la de actualización y la de reajuste (ver Figura 2.8). La de actualización tiene una función similar a la de entrada de la LSTM y la de reajuste define como incorporar la nueva información [6].

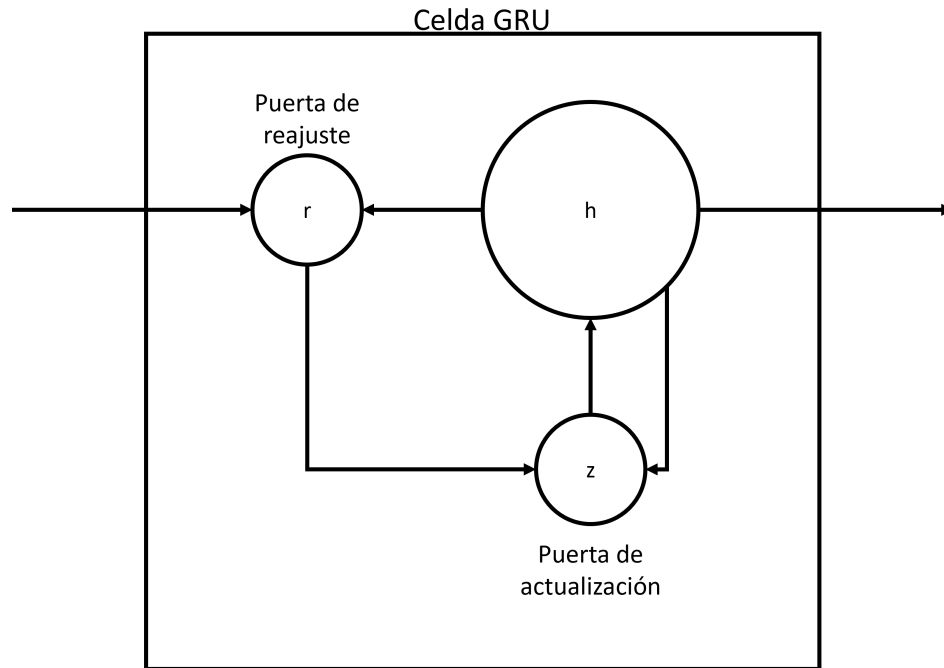


Figura 2.8: Diagrama de una neurona GRU [6].

2.9.5. Redes Neuronales Transformer

Estas redes fueron presentadas en un artículo de google en el 2017 llamado *Attention is All you Need*. Estas redes presentan capas de atención, las cuales sustituyen a las capas recurrentes y las convolucionales. Estos modelos presentan una característica de paralelización la cual hace que estas redes sean más rápidas en su entrenamiento, ya que se trata de sumas ponderadas y activaciones [30].

2.10. Cifras de mérito

Dado que los algoritmos son una parte fundamental para la predicción de los eventos epilépticos es importante determinar el rendimiento de éstos, fijando aspectos que indiquen el comportamiento para una evaluación numérica. He aquí el uso de las cifras de mérito, las cuales son valores que sirven para comparar instrumentos o sistemas en forma cuantitativa y

así evitar ambigüedades [31].

Una de las herramientas más utilizadas para la evaluación de los algoritmos en aprendizaje automático son las matrices de confusión. Estas son matrices cuadradas de tamaño $n \times n$, donde n es el número de clasificaciones que puede tomar la salida. Las columnas son etiquetadas con las clasificaciones del algoritmo y las filas con las clasificaciones reales. Una de las ventajas que presenta la matriz de confusión es que a partir de operaciones aritméticas sencillas se pueden definir nuevas métricas para la evaluación del algoritmo, las cuales son definidas a continuación [32, 33].

- **Exactitud:** Se define como la cercanía entre la clasificación predicha del algoritmo y la verdadera.
- **Precisión:** Se define como la dispersión del conjunto de clasificaciones obtenidas respecto a las clasificaciones reales.
- **Sensibilidad:** Se considera como la fracción de verdaderos positivos.
- **Especificidad:** Está determinado por la tasa de clasificaciones negativas reales.
- **Número de falsos positivos:** Se genera bajo la siguiente circunstancia: se clasifica como un positivo cuando es un negativo real. Por lo cual podemos describir como falso positivo, cuando se alerta de un evento epiléptico y este no sucede.
- **Número de falsos negativos:** Sucede cuando se clasifica un positivo real como un negativo. Bajo el enfoque de los algoritmos de predicción de eventos epilépticos, el falso negativo será cuando un ataque no está predicho por una alarma dentro del horizonte de predicción [34].

Adicionalmente desde una perspectiva técnica se van a evaluar los siguientes aspectos:

- **Tiempo de predicción:** El tiempo con el que se predice un evento epiléptico también llamado horizonte de predicción es un factor importante, de eso dependen las medidas

que se pueden tomar para disminuir los riesgos y lesiones que estas pueden causar. Dependiendo de la duración del horizonte de predicción, la sensibilidad y la especificidad varían. Al tener un lapso más corto la sensibilidad aumentará y la especificidad bajará, mientras que al aumentar el horizonte de predicción el valor de las métricas irá, al contrario.

- **Tiempo de procesamiento:** Gran parte de los métodos reportados, hasta el momento, hablan de las ventanas móviles como una métrica de evaluación, cuya duración promedio es de entre 10 y 40 segundos. Con ella se generan perfiles de tiempo caracterizables para uno o varios canales [34].

Capítulo 3

Antecedentes

En los últimos años el aprendizaje profundo en la biomedicina ha tenido un gran auge debido a su buen desempeño en la extracción de características y métodos de aprendizaje de datos complejos [35]. Por ejemplo, en el año 2017 se realizaron más publicaciones que en todos los años anteriores combinados [36]. Algunas de las aplicaciones más avanzadas del aprendizaje profundo en el área de la biomedicina recaen en la informática biomédica, entre las que se pueden mencionar el almacenamiento, análisis e interpretación de datos biológicos y fisiológicos, tales como, imágenes médicas, señales de electroencefalografía (EEG), secuencias genómicas y proteicas, que sirven para comprender tanto la salud como enfermedades humanas [35]. A continuación, se muestran algunos campos de la ingeniería biomédica en los cuales se aplica la inteligencia artificial así como las herramientas computacionales que se utilizan [35]:

- Análisis de imágenes médicas: Redes Neuronales Convolucionales (CNN's, por sus siglas en inglés), Codificadores Automáticos Apilados, Redes de Creencias Profundas (DBN's, por sus siglas en inglés), Redes Neuronales Profundas (DNN's, por sus siglas en inglés), Redes Neuronales Recurrentes (RNN's, por sus siglas en inglés).
- Secuenciación genómica y análisis de expresión génica: DNN's, DBN's, y CNN's.

- Predicción de la estructura de proteínas: DBN's, CNN's, codificadores automáticos apilados, y RNN's.

Ahora bien, en cuanto al área de estudio del trastorno de la epilepsia llamada epileptología, existen modelos computacionales basados en aprendizaje profundo que detectan las convulsiones ocasionadas por la epilepsia, y más importante aún, se han reportado que los modelos computacionales son capaces de predecir eventos epilépticos desde varios minutos antes que estos comiencen [37]. Ejemplo de ello son los siguientes trabajos que se han presentado y han reportado el mejor rendimiento en los últimos cinco años.

- **2017.** M. Hosseini, et al [38] presentaron un método en el cual utilizan dos tipos de señales bioeléctricas para poder predecir eventos epilépticos, señales electrooculográficas y electroencefalográficas. Este modelo utilizó como base de su algoritmo una red neuronal convolucional entrenada con una sola base de datos con un número limitado de pacientes, lo que les resulta en una sensibilidad del 97 %, precisión del 96 % y una tasa de falsos positivos de 0.05 por hora, todo esto para un tiempo de predicción de cinco minutos.
- **2018.** En [39] se propone un algoritmo de predicción basado en una red neuronal LSTM, con diferentes tiempos de predicción. Se plantearon periodos desde 15 minutos hasta 120 minutos, obteniendo valores superiores al 99 % en sensibilidad y especificidad, ver Tabla 1 para mayores detalles.
- **2019.** En este año se presentó un método de predicción de eventos epilépticos que demostró tener un rendimiento del 100 % en cuanto a sensibilidad, especificidad y precisión, dicho modelo está fundamentado en redes neuronales profundas y LSTM. Los autores utilizaron señales EEG de un solo canal, pertenecientes a la Universidad de Bonn [40].
- **2020.** H. Daoud, et al. [41] presentaron una red neuronal convolucional con la capacidad de predecir eventos epilépticos con una sensibilidad del 97.41 %, una especificidad

94.8 % y una precisión del 96.1 %. Utilizando como única fuente de información la base de datos del CHB-MIT, la cual consiste en señales EEG.

- **2021.** En este año los autores R. Hussein. et al [42] presentaron un método de predicción de eventos epilépticos a partir de redes neuronales convolucionales semidilatadas, entrenadas con señales EEG pertenecientes a la base de datos de CHB-MIT. Su propuesta mostró una sensibilidad y especificidad mayores al 98 %.

Sumándose a la información anterior, se presenta la Tabla 1, donde se muestra un análisis histórico de investigaciones científicas, donde se mencionan nombre del trabajo, año de la publicación, los distintos tipos de métodos que se utilizan y el desempeño que obtuvieron.

Cuadro 3.1: Análisis histórico de investigaciones orientadas a predecir eventos epilépticos.

Año	Artículo	Señal	Método	Tiempo de predicción	Sensibilidad [%]	Especificidad [%]	Precisión [%]	Falsos positivos
2017	Optimized Deep Learning for EEG Big Data and Seizure Prediction BCI via Internet of Things [38].	EOG, EEG	CNN, PCA, ICA, DSA, IoT	5 min	97	-	96	0.05 FP/h
	Classification of EEG signals for epileptic seizures using hybrid artificial neural networks based wavelet transforms and fuzzy relations [4].	EEG	LM, GD, BFGS, GCE, AG	-	-	-	99.8, 99.5, 98.8, 99.5, 99.5	-
	A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis [43].	EEG, iEEG	CNN	30 min	81.4 81.2 75	-	-	0.06 FP/h 0.16 FP/h 0.21 FP/h
	Seizure Prediction Using General Regression Neural Network [44].	EEG, iEEG	LSTM	-	29.28	-	25.62	0.58 FP/h
2018	Focal Onset Seizure Prediction Using Convolutional Networks [45].	EEG, iEEG	CNN	10 min	87.8	-	-	0.142 FP/h

Continúa en la página siguiente.

Año	Artículo	Señal	Método	Tiempo de predicción	Sensibilidad [%]	Especificidad [%]	Precisión [%]	Falsos positivos
	Convolutional Neural Network for Seizure Prediction Using Intracranial and Scalp electroencephalogram [46].	EEG, iEEG	CNN	5 min	81.48 1.2 75	-	-	0.06 FP/h 0.16 FP/h 0.21 FP/h
	A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals [39].	EEG	LSTM	15 min 30 min 60 min 20 min	99.28 99.38 99.63 99.84	99.28 99.60 99.78 99.86	-	0.11 % 0.06 % 0.03 % 0.02 %
	Epileptic Seizure Prediction Using Big Data and Deep Learning: Toward a Mobile System [47].	iEEG	DNN	27 %	69	-	-	-
2019	Efficient Epileptic Seizure Prediction Based on Deep Learning [5].	EEG	CNN, RNN	60 min	99.7	99.6	99.6	0.004 FP/h
	Epileptic Seizure Prediction With Multi-View Convolutional Neural Networks [48].	EEG	CNN	5 min	97	88	83	
	Seizure Prediction in Scalp EEG Using 3D Convolutional Neural Networks With an Image-Based Approach [49].	EEG	CNN 3D	10.5 %	85.7	-	-	0.096 FP/h
	Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals [40].	EEG	DNN, LSTM	-	100	100	100	-
2020	Epileptic seizure prediction based on local mean decomposition and deep convolutional neural network [50].	EEG	CNN, PCA	30 min 50 min	84.92 87.87	-	-	0.29 % 0.25 %
	Epileptic seizure prediction by the detection of seizure waveform from the pre-ictal phase of EEG signal [51].	EEG	-	-	91.07	97.36	99	-
	Epileptic Seizures Prediction Using Deep Learning Techniques [52].	EEG	CNN, SVM	21 min	92.7	90.8	-	-

Continúa en la página siguiente.

Año	Artículo	Señal	Método	Tiempo de predicción	Sensibilidad [%]	Especificidad [%]	Precisión [%]	Falsos positivos
	IoT based Efficient Epileptic Seizure Prediction System Using Deep Learning [41].	EEG	CNN	-	97.41	94.8	96.1	-
2021	A deep learning based ensemble learning method for epileptic seizure prediction [53].	EEG	CNN, SVM, LSTM	-	94.2	95.8	-	-
	Deep Learning for Patient-Independent Epileptic Seizure Prediction Using Scalp EEG Signals [1].	EEG	CNN	15 min 30 min 60 min	97.88 96.43 92.45	-	-	-
	Semi-dilated convolutional neural networks for epileptic seizure prediction [42].	EEG, iEEG	CNN semidilatada	-	98.9 99.78	98.75 99.6	-	0.06 FP/h 0.04 FP/h
	Deep learning based efficient epileptic seizure prediction with EEG channel optimization [54].	EEG	CNN	10 min	92.45	89.94	91.54	0.076 FP/h

EOG: Electrooculograma; iEEG: Electroencefalograma intracraneal; PCA: Análisis por componentes principales; ICA: Análisis de componentes independientes; DSA: Algoritmo de búsqueda diferencial; IoT: Internet de las cosas; LM: Algoritmo Levenberg-Marquardt; GD: Gradiente descendente; BFGS: Algoritmo de Broyden-Fletcher-Goldfard-Shanno; SCG: Gradiente conjugado escalado; AG: Algoritmos genéticos; LSTM: Redes long short-term memory; CNN 3D: CNN de tres dimensiones; FP/h: Falsos positivos por hora; además el símbolo '-' denota que no se cuenta con la información.

Analizando la Tabla 1, se puede considerar que en el estado del arte las técnicas de aprendizaje profundo más utilizadas para la predicción de eventos epilépticos son las CNN y las LSTM, donde cada una de ellas se presentó en 14 y 4 artículos de nuestra tabla, respectivamente. Por otro lado, se puede resaltar que la gran mayoría de los métodos de predicción utilizan señales EEG como información de entrada. Así mismo, la mayor parte de ellas corresponden a dos bases de datos en específico: la base de datos recabada por el Children's Hospital Boston (CHB) y el Massachusetts Institute of Technology (MIT), esta base de datos ha sido usada por un amplio número de artículos en la literatura [43], [45], [39], [5], [48], [49], [52], [53], [1], [42], [54]; y la base de datos recabada por la Universidad de Bonn, la cual es también utilizada en múltiples proyectos [4], [40].

Una gran ventaja de estas bases de datos es que son de libre acceso y permitirán comparar fácilmente los resultados obtenidos en la presente investigación y los reportados por investigaciones mencionadas en el estado del arte, que de igual forma utilizan dichas bases de datos. Lo anterior permitirá una mejor visión del aporte de esta investigación. Además, otra ventaja importante es que las señales con las que se trabajará ya se encuentran debidamente etiquetadas, lo cual permite un fácil manejo de las mismas.

Capítulo 4

Hipótesis

El utilizar las nuevas técnicas de aprendizaje profundo, como son las CNN y las LSTM, en conjunto con una buena caracterización y preprocesamiento de las señales EEG, ayudará a diseñar un método de predicción de epilépticos generalizado, el cual pudiera contar con un rendimiento entre el 70 y 80 % de sensibilidad, especificidad y precisión.

Capítulo 5

Objetivos

5.0.1. Objetivo general

Diseñar y desarrollar un clasificador de señales EEG mediante aprendizaje profundo para la predicción de eventos epilépticos.

5.0.2. Objetivos específicos

Los objetivos específicos de este proyecto son los siguientes:

- Analizar y seleccionar los parámetros que brindan más información en las señales EEG mediante transformadas que ayuden a caracterizar las señales en el dominio del tiempo, frecuencia y tiempo-frecuencia para una acertada predicción.
- Seleccionar el tipo de red neuronal a emplear para el clasificador por medio de las cifras de mérito reportadas en la literatura.
- Desarrollar el clasificador para su entrenamiento recurriendo al lenguaje de programación Python.
- Evaluar el método de predicción propuesto con base a los criterios establecidos para su divulgación.

Capítulo 6

Metodología

En este capítulo se describe el proceso empleado para la detección y predicción de eventos epilépticos utilizando técnicas de inteligencia artificial. El objetivo principal de esta metodología es proporcionar una guía detallada y sistemática para el diseño y desarrollo de algoritmos de inteligencia artificial, como el análisis de componentes principales, perceptrones multicapa y redes neuronales convolucionales, con el fin de lograr una detección y predicción precisa de eventos epilépticos.

El capítulo se divide en tres secciones principales. En la primera sección, se describe la búsqueda y análisis de bases de datos, en la segunda sección se detalla el proceso de detección de eventos epilépticos, el cual se llevó a cabo utilizando la base de datos de la Universidad de BONN [11], y en la tercera sección, se aborda el proceso de predicción de eventos epilépticos.

En la Figura 6.1 se puede observar la metodología que se siguió a gran escala para la realización de la presente tesis. Iniciando por la tarea de detección de eventos epilépticos, donde se obtuvieron dos arquitecturas propias. Posteriormente se trabajó con la parte de predicción de eventos epilépticos y finalmente la escritura de textos donde se divulga la información obtenida. Cada uno de estos subprocesos se describen en lo sucesivo.

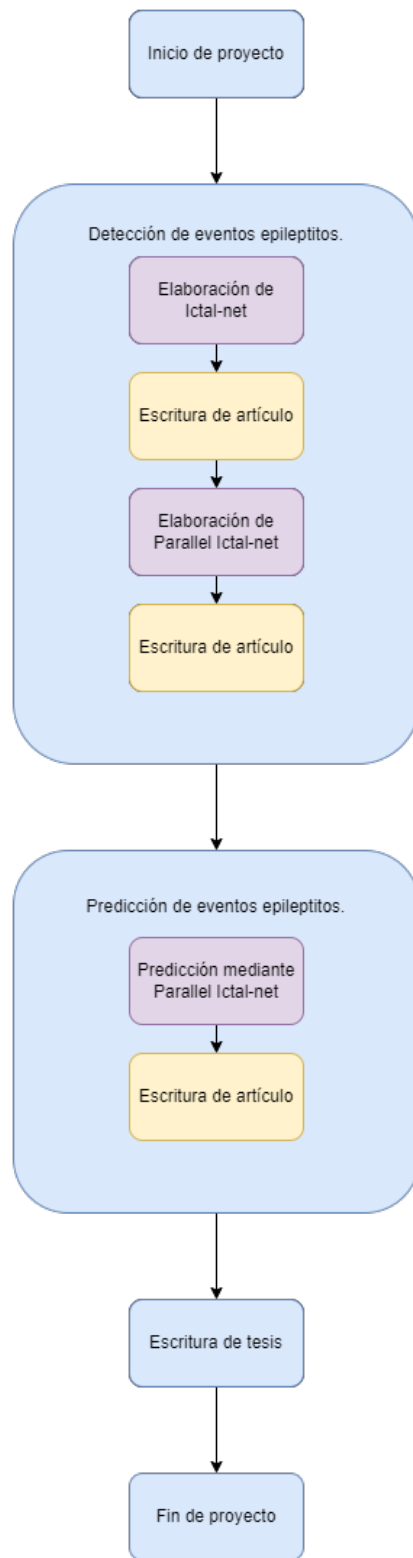


Figura 6.1: Diagrama de flujo de Metodología a gran escala.

6.1. Búsqueda y análisis de base de datos

En esta sección se abordará la metodología para la búsqueda y discriminación de las bases de datos para la elaboración de esta investigación.

6.1.1. Base de datos de la Universidad de Bonn

La base de datos de la Universidad de Bonn [11] es una de las más utilizadas para detección y clasificación de eventos epilépticos. Esta base de datos puede ser encontrada en [55] para su descarga y uso de manera libre.

Esta base de datos cuenta con cinco conjuntos de datos identificados por las letras A, B, C, D y E. Cada uno de estos conjuntos tienen 100 registros EEG de un solo canal. Las señales registradas por esta universidad fueron muestreadas con una frecuencia 173.61 Hz y filtradas de 0.53 a 40 Hz. La duración de cada registro es de 23.6 segundos.

La información guardada en esta base de datos se encuentra distribuida de la siguiente manera:

- Conjunto A: En esta carpeta se encuentra registros de cinco sujetos sanos en estado de relajación con los ojos cerrados.
- Conjunto B: Está compuesto por señales de cinco sujetos sanos en estado de relajación, pero en esta ocasión con los ojos abiertos.
- Conjunto C: Información proveniente de cinco sujetos con patología. Los registros fueron obtenidos en la formación del hipocampo del hemisferio opuesto del cerebro donde se originan los eventos epilépticos. Los registros están libres de actividad convulsiva.
- Conjunto D: Cinco sujetos con patología, sus registros fueron obtenidos en la zona epileptógena y están libres de convulsión.
- Conjunto E: Los registros pertenecientes a este subconjunto de datos presentan actividad convulsiva.

Para el análisis de esta base de datos se seleccionaron cuatro señales de manera aleatoria, a las cuales se les calculó la transformada rápida de Fourier (FFT) y se graficó su escalograma para corroborar que no presentaran ruido de línea o cualquier otro tipo de ruido por el cual debieran ser filtrados o preprocesados.

6.1.2. Base de datos de la *American Epilepsy Society*

Esta base de datos fue proporcionada por la *American Epilepsy Society* para una competencia de Kaggle en el 2014 [56]. La base de datos cuenta con señales iEEE de perros y humanos.

La base de datos cuenta con cinco registros caninos que fueron obtenidos mediante un sistema de monitores ambulatorio con 16 electrodos intracraneales con una frecuencia de muestreo de 400 Hz. Adicionalmente se cuenta con señales de dos pacientes humanos, que fueron monitoreados para la identificación de regiones del cerebro que pudieran extirpadas para prevenir futuras convulsiones. Estos registros fueron obtenidos con un número variable de electrodos, pero a una frecuencia homogénea de 5000Hz.

Cada clip de registro dura 10 minutos. Los eventos interictales en perros son segmentos extraídos de sus registros continuos una semana antes o después de cualquier convulsión. En el caso de las personas, dado que son monitoreados por menos tiempo, sus eventos interictales son extraídos de las señales continuas cuatro horas antes o después de cualquier episodio. En cuanto a los clips de periodos preictales cubren hasta una hora antes de una convulsión con un horizonte de convulsiones de cinco minutos.

La base de datos cuenta con más de 113 GB de información en archivos .mat donde se encuentran guardadas las señales iEEG.

Para cerciorarse que las señales de la presente base de datos con algún artefacto por el cual debieran de preprocesadas se realizó el mismo análisis que el seguido en la base de datos anterior. Seleccionando cuatro señales de manera aleatoria y calculando sus FFT.

Dado que esta base de datos no cuenta con un número homogéneo de canales para los registros se realizó un análisis de componentes principales realizando tres estandarizaciones

diferentes previas al análisis, donde se incluyó una normalización Min-Max, un escalonamiento Min-Max mediante la librería scikit-learn y una estandarización Z-score.

En el Anexo 1 podrá encontrar una descripción más detallada de la base de datos donde podrá encontrar el número de registros por sujetos, así como la distribución de ellos, es decir, cuantos pertenecen a un periodo preictal y cuantos pertenecen a un estado interictal.

6.1.3. Base de datos del *Boston Children's Hospital* y el *Massachusetts Institute of Technology*

Se puede observar un análisis detallado de la base de datos [57] en el Anexo 1. En donde se puede ver cuántos registros se tienen de cada sujeto, así como su duración, el número de muestras, si presenta eventos epilépticos el registro y en caso que tenga, cuántos y en qué momento empiezan. Adicionalmente se menciona si hay espacios durante los registros o registros no proporcionados para seguir la continuidad.

Al igual que con las bases de datos pasadas se seleccionaron registros de manera aleatoria para ver si contaban con algún tipo de ruido por el cual debieran ser preprocesadas.

6.2. Detección de eventos epilépticos

Como se mencionó anteriormente para la detección de eventos epilépticos se realizó una búsqueda de arquitecturas, en las cuales resaltaron dos. La primera fue denominada como Ictal-net y la segunda como Parallel Ictal-Net, esto debido a su arquitectura. El procedimiento de búsqueda es descrito en las siguientes dos subsecciones.

6.2.1. Búsqueda de Ictal-Net

En esta sección, se proporciona una descripción del proceso de investigación llevado a cabo para el desarrollo de Ictal-net. La Figura 6.2 muestra un diagrama de flujo que permite seguir de manera visual la metodología empleada, destacando algunos de los aspectos más significativos en cada uno de los pasos.

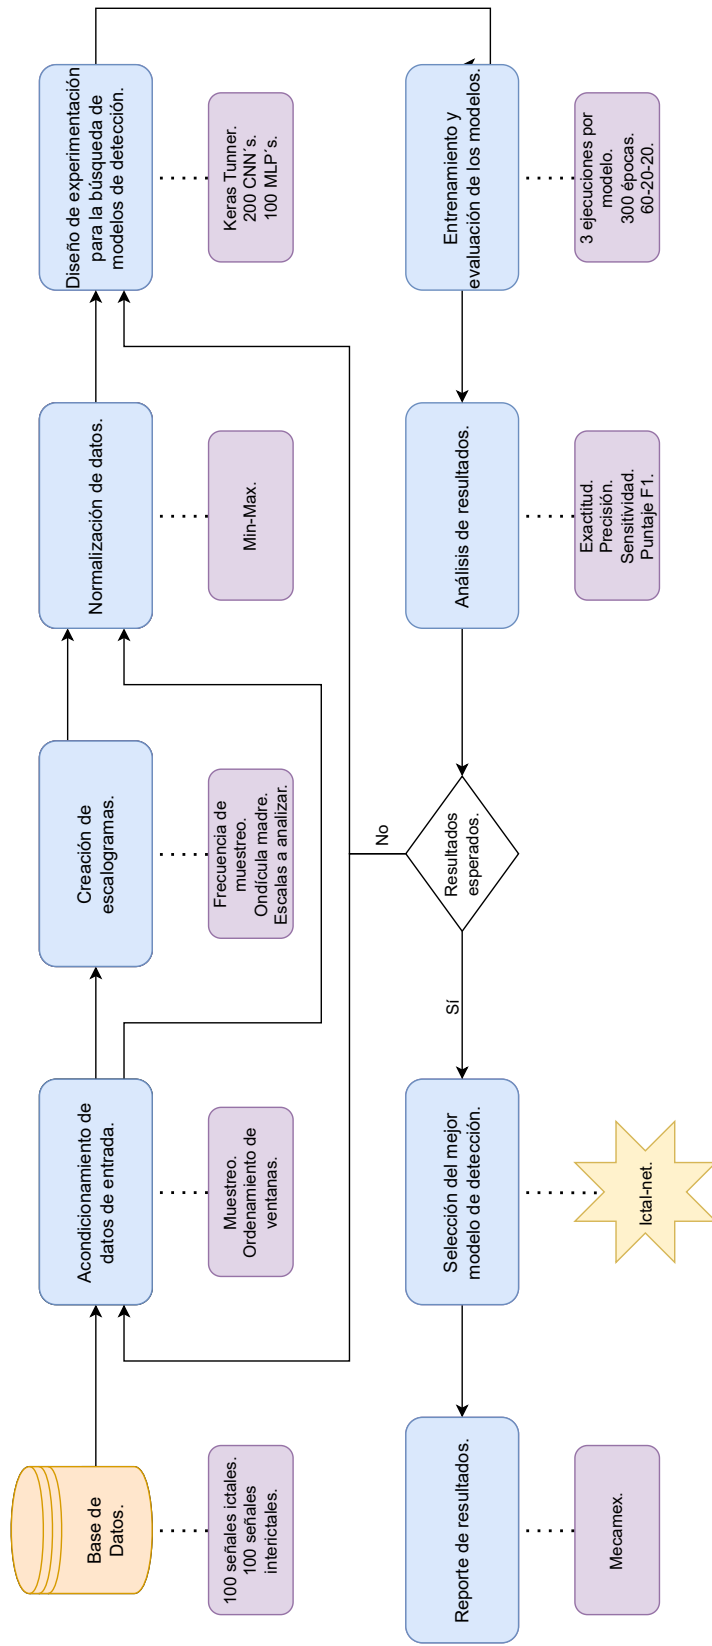


Figura 6.2: Diagrama de flujo para la búsqueda de Ictal-Net.

Acondicionamiento de los datos de entrada

La búsqueda de Ictal-Net, comenzó con el tratamiento de los datos. Dado que el propósito de Ictal-Net es realizar una clasificación entre periodos ictales e interictales solo se trabajaron con los conjuntos de datos de las carpetas D y E, de la base de datos [11], con lo cual se tenía un total de 200 señales. En el aprendizaje profundo es recomendable trabajar con bases de datos que contengan un número grande de información, por lo cual cada una de las señales contenidas en el subconjunto fue muestreada para obtener 16 ventanas de 256 muestras cada una.

Para la creación de los conjuntos de entrenamiento, validación y prueba se realizó un intercalado de las señales interictales e ictales. Cuidando que no existieran ventanas provenientes de la misma señal de origen tanto en el conjunto de entrenamiento como en el conjunto de validación o en el de prueba. Colocando 16 ventanas de periodos ictales y posteriormente 16 ventanas de periodos interictales, repitiendo este orden hasta colocar todas las señales dentro de un arreglo. En la Figura 6.3.

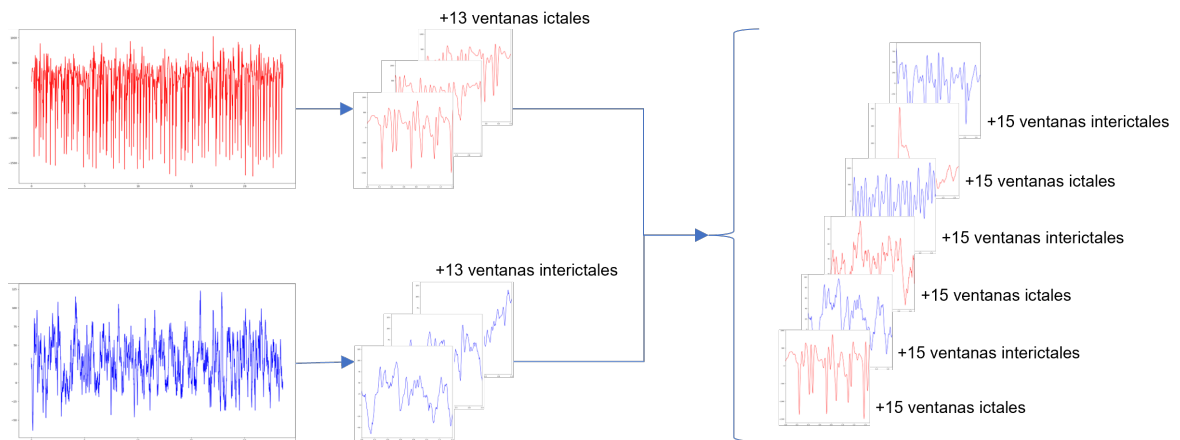


Figura 6.3: Muestro y organización de las señales ictales e interictales.

Es importante destacar la organización de las nuevas ventanas, ya que aleatorizar todas las señales provocaría cometer un sesgo temporal. Es decir, como las señales EEG están en función del tiempo no podemos entrenar las redes con ventanas que aún no pasan (el conjunto de prueba).

Ahora bien, para clasificar cada una de estas señales se optó por procesarlas en dos dominios, en el dominio del tiempo y en el dominio tiempo-frecuencia.

En el caso del dominio del tiempo las señales solo fueron normalizadas utilizando la ecuación 6.1 para posteriormente ser clasificadas mediante un MLP.

Creación de escalogramas

Una vez ordenadas todas las ventanas se procedió a crear escalogramas de cada una de las señales. Para esto se utilizó la transformada wavelet continua (CWT)

Normalización

La adecuación de la entrada para una red neuronal es de gran importancia ya que de esta forma se ayuda a la red a que tenga un mejor entrenamiento. En este caso se realizó una normalización Min-Max. La cual consiste en estandarizar los datos de entrada en un rango específico, por ejemplo, de -1 a 1. Sin embargo, para los escalogramas se decidió utilizar un rango de 0 a 1. Esta normalización se llevó a cabo realizando una función propia utilizando la Ecuación 6.1.

$$x_{normalizada} = \frac{x - X_{min}}{X_{max} - X_{min}} \quad (6.1)$$

Donde $x_{normalizada}$ representa cada uno de los valores del escalograma normalizado. Como se puede apreciar en la Ecuación 1, para calcular dicho valor, es necesario restar al valor original (x) el valor mínimo encontrado en el escalograma (x_{min}), y luego dividirlo por el rango numérico del escalograma analizado. Este rango se determina como la diferencia entre el valor máximo (x_{max}) y el valor mínimo, considerando todo el alcance del escalograma.

Diseño y compilación de Ictal-net

La metodología para el diseño de Ictal-net se centró en desarrollar y evaluar distintas arquitecturas basadas en redes neuronales convolucionales (CNN) y perceptrones multicapa (MLP), para llevar a cabo la tarea de clasificación de las señales EEG.

Para determinar la configuración óptima de la arquitectura Ictal-net, se llevaron a cabo pruebas exhaustivas utilizando diversos hiperparámetros.

En el caso de las CNN's, los hiperparámetros incluyeron el número de filtros por capa, cada uno con su correspondiente tamaño de kernel, para capturar y extraer características relevantes de las señales EEG. Además, se exploró la influencia del número de capas intermedias en el rendimiento del modelo.

Asimismo, se investigaron diferentes funciones de activación para determinar cuál proporcionaba los mejores resultados en términos de precisión de clasificación. Se implementaron técnicas de regularización, como el dropout y la normalización por lotes (Batch Normalization), para mejorar la generalización del modelo y reducir el riesgo de sobreajuste.

Además, se emplearon capas de agrupación máxima en dos dimensiones (Maxpooling2D) para reducir el costo computacional y extraer características relevantes de las representaciones convolucionales.

Con el fin de evaluar exhaustivamente la arquitectura propuesta, se realizó una amplia exploración de hiperparámetros. Estos hiperparámetros fueron ajustados y variados en una variedad de valores, como se muestra en la Tabla 1, para determinar su impacto en el rendimiento del modelo.

Cuadro 6.1: Conjunto de hiperparámetros y valores modificados durante la búsqueda de Ictal-net.

Hiperparámetro	Valores probados
Número de capas convolucionales	1, 2, 3, 4, 5
Número de filtros por capa	[30-250]
Tamaño de kernel	3×3 , 5×5
Funciones de activación	Sigmoide, ReLU
Dropout	Habilitado o deshabilitado
Normalización por lotes	Habilitada o deshabilitada
Maxpooling2D	Habilitado (2×2) o desactivado

Para los MLP's los hiperparámetros modificados fueron: el número de capas ocultas y el número de neuronas por capa. Dentro de las distintas combinaciones que se podían tener, el número máximo de capas ocultas eran 5 y el mínimo eran 2. En cuanto al número de neuronas, cada capa podía tener entre 20 y 256 neuronas. En total se probaron 100 MLP's.

Entrenamiento y evaluación de los modelos

El entrenamiento de cada una de las arquitecturas resultantes de las modificaciones de los hiperparámetros fue entrenada durante 30 épocas, mediante la validación de 60-20-20; este proceso se repitió tres veces por modelo con el fin de ver la repetibilidad de los resultados.

La evaluación de las arquitecturas se realizó calculando cuatro métricas, la exactitud, precisión, recall y puntaje F1. Para seleccionar la mejor red se promediaron las métricas obtenidas durante las tres evaluaciones y fueron comparadas y se seleccionó la que tuviera mejor rendimiento, que fue a la que se le denominó Ictal-net.

6.2.2. Búsqueda de Parallel Ictal-Net

La metodología empleada para el diseño de Parallel Ictal-net (PIN), la cual se puede visualizar en la Figura 6.4, implicó una exhaustiva búsqueda, donde se exploraron cinco conjuntos de variables relevantes. Estos conjuntos incluyeron la selección de la función wavelet madre utilizada para el análisis, considerando opciones como generalized morse wavelet (gmw), morlet, bump, complex mexican hat (cmhat) y hilbert analytic function of hermitian hat (hhhat).

Además, se evaluaron diferentes configuraciones de la frecuencia de muestreo (F_s) utilizada para el cálculo de los escalogramas, con opciones como 173.61 Hz o None (ninguna frecuencia especificada), en este caso el escalograma se calculaba como si la frecuencia de muestreo fuera de 1 Hz. También se varió el número de muestras por ventana, abarcando desde 174 muestras hasta 2083, para explorar su influencia en los resultados.

Se examinó el porcentaje de traslape entre ventanas, considerando valores nulos, un cuarto de la ventana, una tercera parte o la mitad, con el objetivo de determinar la configuración que

brindará mejores resultados para la detección. Asimismo, se evaluaron tres valores diferentes para la tasa de aprendizaje (learning rate) utilizada en el entrenamiento de la red neuronal: 0.01, 0.001 y 0.0001.

Por último, se consideró el tipo de optimizador utilizado, con opciones como Adam o SGD (Stochastic Gradient Descent), para determinar su efecto en el rendimiento general del modelo.

Todos estos valores y configuraciones mencionados anteriormente se pueden visualizar de manera más clara y organizada en la Tabla 6.2, que brinda una descripción completa de las opciones exploradas en la búsqueda de PIN.

Cuadro 6.2: Conjunto de variables modificadas durante la búsqueda de Parallel Ictal-net.

Variables	Valores probados
Ondícula madre	gmw, morlet, bump, cmhat, hhhat
Fs	173.61 Hz, None
Muestras por ventana	174,347, 521, 694, 868, 1042, 1215, 1389, 1562, 1736, 1910, 2083
Porcentaje de traslape	0, 0.25, 0.33, 0.50
Taza de aprendizaje	0.01, 0.001, 0.0001
Optimizador	Adam, SGD

Como se muestra en la Tabla 1, se consideraron un total de 28 variables, las cuales se dividieron en cinco hiperparámetros ajustables. Con el objetivo de obtener resultados confiables, todas las combinaciones posibles fueron validadas mediante la técnica de stratified 10-fold cross-validation, teniendo un total de 2880 redes neuronales a probar. A continuación, se describen de forma sucinta las diferentes etapas del proceso de búsqueda de PIN:

1. Preprocesamiento de la señal: En esta etapa, se realizaron operaciones de muestreo de las señales EEG en ventanas.
2. Cálculo de escalogramas: Se aplicó la transformada wavelet continua para obtener los escalogramas, que representan la distribución de frecuencias en función del tiempo.

Además, se llevó a cabo la normalización de los escalogramas obtenidos.

3. Pre-entrenamiento: En esta etapa, se prepararon los datos y se realizaron las configuraciones iniciales antes del entrenamiento propiamente dicho.
4. Entrenamiento: Se llevó a cabo el entrenamiento del modelo, utilizando técnicas como el transfer learning para aprovechar los conocimientos previamente adquiridos por modelos preentrenados.
5. Codificación a bloques de las CNN paralelas: Realizando las arquitecturas a probar con los diferentes números de bloques y sus características.
6. Entrenamiento de los bloques de CNN en paralelo: Se realizó el entrenamiento de los bloques utilizando las variables previamente determinadas.
7. Evaluación: Se evaluaron los resultados obtenidos, considerando métricas de desempeño relevantes para la detección de eventos epilépticos.
8. Selección de mejor modelo: Se compararon los modelos mediante las métricas de exactitud, precisión, recall y puntaje F1.
9. Estudio de ablación: Se realizó un estudio de ablación al mejor modelo, al cual se le denominó Parallel Ictal-Net (PIN), respecto a sus capas de atención.

Cada una de estas etapas se llevó a cabo de manera rigurosa y sistemática, permitiendo obtener resultados estadísticamente sustentables en la detección de eventos epilépticos. Estos pasos se pueden observar en el diagrama de flujo representado en la Figura 6.4.

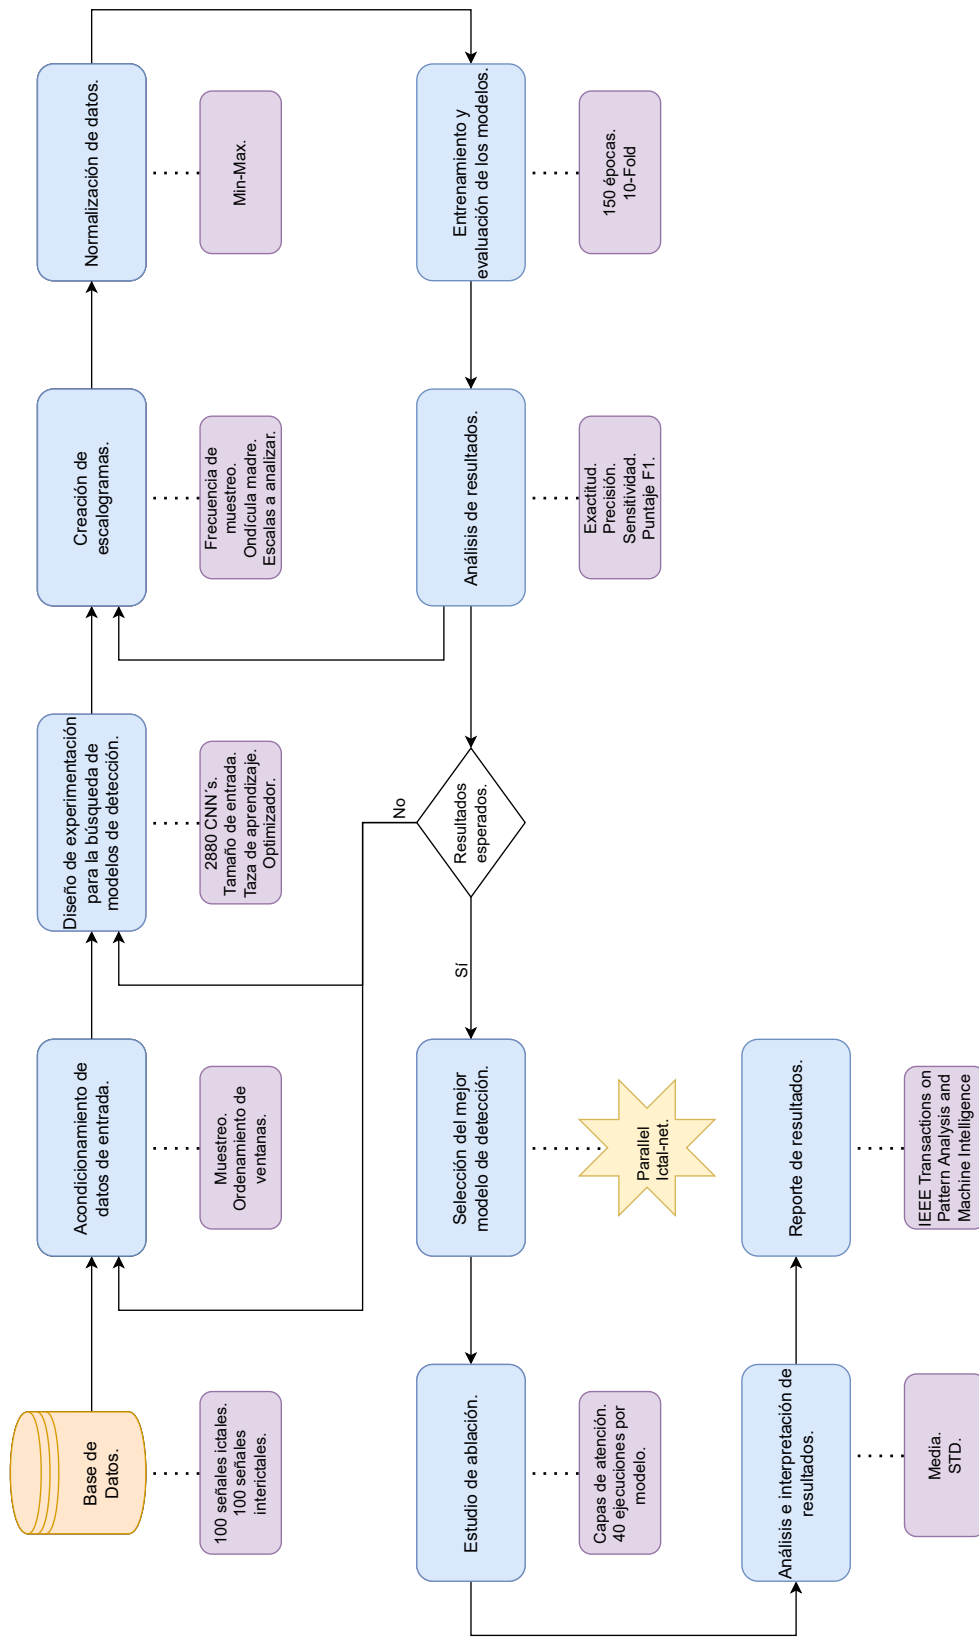


Figura 6.4: Diagrama de flujo para la búsqueda de Parallel Ictal-Net.

Preprocesamiento de las señales EEG

Ya que las señales se encuentran previamente filtradas en el repositorio, con el propósito de realizar un procesamiento se procedió a realizar el muestreo considerando el número de muestras por ventana y el porcentaje de traslape por ventana. Por ejemplo, en el caso de PIN, se utilizaron ventanas de 868 muestras con un traslape del 33 % entre ventanas. Esto resultó en un total de 7 ventanas por señal.

Posteriormente se aplicó la CWT utilizando la librería *ssqueezepy* de Python [58]. Esta librería aprovecha el uso de la tarjeta gráfica para acelerar el cálculo de la transformada, lo que permite reducir significativamente el tiempo de cómputo. Para llevar a cabo esta operación, se tuvieron dos opciones: proporcionar la frecuencia de muestreo de la señal o no proporcionarla. Sin embargo, en todos los casos se proporcionó una función wavelet madre.

Una vez obtenidos los coeficientes mediante la transformada wavelet, se calculó su valor absoluto. Dado que las dimensiones de las ventanas obtenidas eran considerablemente grandes, se realizó un proceso de redimensionamiento. Este proceso consistió en modificar los escalogramas resultantes a una dimensión de 250×250 , a excepción de aquellas ventanas que fueran de menor tamaño. El objetivo de este redimensionamiento fue reducir el número de parámetros de las redes neuronales utilizadas y evitar problemas de desbordamiento de memoria.

Posteriormente, se aplicó una normalización al escalograma obtenido utilizando la ecuación 6.1. Esta normalización permitió que los valores del escalograma se encontraran en un rango entre uno y cero, lo que facilita su procesamiento por la red neuronal.

Pre-entrenamiento

Con el objetivo de mejorar el rendimiento de las arquitecturas propuestas se implementó una etapa de pre-entrenamiento, seguida de un proceso de transferencia de aprendizaje a cada uno de los bloques convolucionales.

Para el pre-entrenamiento de los bloques convolucionales las señales que están representadas por un número n de escalogramas, deben ser reacondicionadas. El reacondicionamiento

implica separar cada una de las señales en los n escalogramas que las componen.

Como las redes CNN en paralelo se entrena con 180 señales, después del reacondicionamiento se tendrán $180n$ señales para entrenar el bloque de pre-entrenamiento. Este enfoque proporciona un mayor número de muestras para el entrenamiento.

El bloque de pre-entrenamiento consta de una capa convolucional 2D, un módulo de atención de canal eficiente, una capa de max pooling y dos neuronas con función de activación softmax en la salida. Esta arquitectura es idéntica a la de los bloques convolucionales que componen cada una de las redes probadas, como se muestra en la Figura 7.11 de la sección de resultados.

El bloque de pre-entrenamiento se entrena durante 150 épocas. Sin embargo, para evitar el sobreajuste de la red, se utiliza un callback de early stopping. Esto significa que el entrenamiento se detiene cuando la red comienza a mostrar signos de sobreajuste.

Entrenamiento general de redes

Para iniciar el entrenamiento de la red, se debe realizar la compilación de la misma. La diferencia entre cada una de las redes propuestas radica en el número de bloques convolucionales que la componen, determinado por los n escalogramas que componen la señal, así como el tamaño de entrada.

Como primer paso para el entrenamiento de la red, se llevó a cabo una etapa de transfer learning. Esto consistió en copiar los pesos de la capa convolucional obtenidos en la etapa de pre-entrenamiento y asignarlos a las capas convolucionales que forman parte de cada uno de los bloques convolucionales de la red.

Una vez que los pesos han sido asignados, se inicia el entrenamiento de la red neuronal. Este proceso consta de 150 épocas, donde tanto el valor del optimizador como el valor de la tasa de aprendizaje (learning rate) pueden variar. Es importante mencionar que el tamaño del lote (batch size) se mantiene constante en 32.

Para evitar el sobreajuste, reducir el tiempo de entrenamiento y mejorar el rendimiento de las redes, se utilizó un callback de early-stopping. Este callback detiene el entrenamiento cuando se alcanza una exactitud del 100 % en el conjunto de entrenamiento. La finalidad de

esta técnica es evitar que la red se ajuste demasiado a los datos de entrenamiento y lograr una mejor generalización.

Evaluación

La evaluación de las redes neuronales se realizó utilizando un enfoque de validación cruzada K-fold 10. Se calculan métricas de rendimiento, como la exactitud, precisión, recall y puntaje F1. Estas métricas se seleccionan por ser ampliamente utilizadas en la literatura y permiten realizar comparaciones con otros algoritmos propuestos en los últimos cinco años que aborden la misma tarea que PIN. A continuación, se presenta una descripción formal de este proceso:

Este método divide el conjunto de datos en 10 partes (folds), buscando que todos tengan el mismo tamaño y con los datos equilibrados. Posteriormente, se realizan 10 iteraciones, donde en cada iteración se utiliza un fold diferente como conjunto de prueba y los restantes nueve folds como conjunto de entrenamiento. Durante cada iteración se calculan las métricas de rendimiento, antes mencionadas, para cada red neuronal. Una vez terminadas todas las 10 iteraciones todas las métricas son promediadas obteniendo de esta manera una sola métrica de exactitud, precisión, recall y puntaje F1 por red. Siendo estas últimas las reportadas.

Selección de mejor red

La selección de la mejor red neuronal y la cual se le denominó Parallel Ictal-net, no solo consistió en una comparación de métricas. Ya que dentro de las 2880 redes probadas hubo 13 redes que se encontraron empatadas en cuanto a métricas, cabe destacar que todas ellas lo hacían superando el estado del arte. Por lo que se procedió a realizar un desempate recurriendo a otras características y métricas como:

- *Tiempo de cálculo de escalogramas.* Esta característica se consideró pensando en una posible aplicación en tiempo real, donde la eficiencia temporal es fundamental.
- *Tiempo de entrenamiento de la red neuronal.* Esta característica proporciona información sobre la eficiencia del proceso de entrenamiento y puede ser relevante en escena-

rios donde el tiempo de entrenamiento es crítico.

- *Valor L2*. Este valor puede ser indicativo de la capacidad de generalización de la red y su capacidad para evitar el sobreajuste.
- *Número de parámetros entrenables*. Esto proporciona información sobre la complejidad y las dimensiones de la red, lo cual es relevante para evaluar su capacidad de representación y su eficiencia computacional.

Estudio de ablación

Una vez seleccionada la arquitectura de red neuronal y demás variables que brindaban el mejor performance en la detección de los eventos epilépticos, se realizó un estudio de ablación. El estudio consistió en modificar la arquitectura de la red, específicamente todas las capas de atención. Esto con el objetivo de verificar que la capa de atención fuera la adecuada para realizar la tarea de detección. La capa de atención fue intercambiada por otros dos tipos de módulos de atención, *canal de atención 2D* y *atención de píxeles*. Así mismo se probó la arquitectura sin módulos de atención. Cada una de las variaciones fue probada 40 veces con un método de evaluación de 10-Fold. Lo cual ayudo a comprobar la repetibilidad de los resultados comprobando la robustez de la red diseñada. Posteriormente con las métricas obtenidas de los experimentos se calculó su media y desviación estándar para realizar una mejor comparación entre las diferentes arquitecturas.

6.3. Predicción de eventos epilépticos mediante PIN

Al haber obtenido buenos resultados para la predicción de eventos epilépticos mediante la arquitectura PIN, se consideró utilizarla para la predicción de los eventos epilépticos. Sin embargo, como la base de datos utilizada para la tarea de predicción es otra, los primeros pasos para esta metodología es distinta. El Figura 6.5 se pueden ver los cambios a nivel diagrama de flujo.

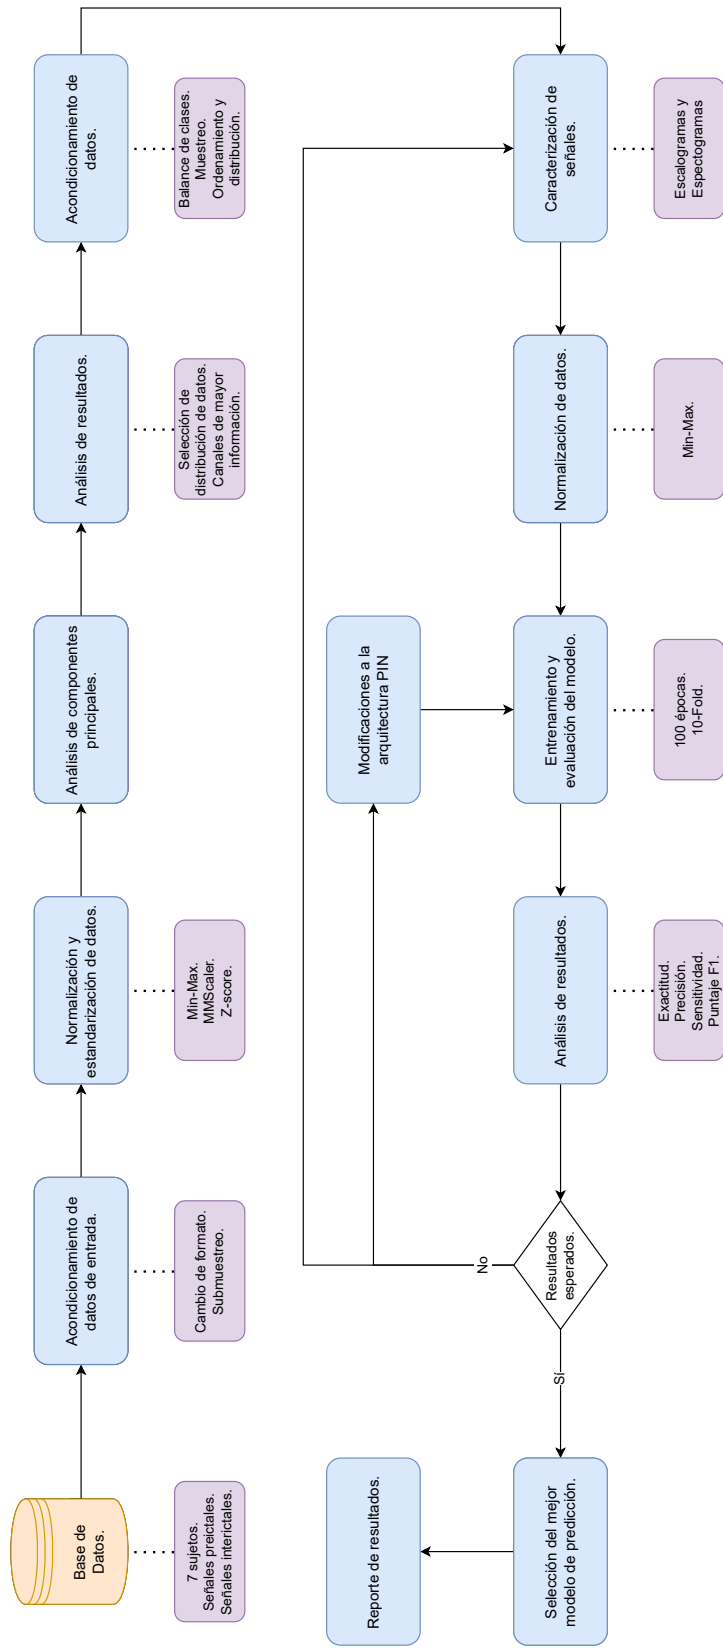


Figura 6.5: Diagrama de flujo para predecir eventos epilépticos mediante la arquitectura de PIN.

El proceso comienza con el análisis de la base de datos [56], dentro de la información que recaba, como se mencionó anteriormente, se tienen registros de origen canino y humano. Estos registros cuentan con una frecuencia de muestro distinta por lo que se realizó un proceso de muestreo para que todas las señales contaran con la misma frecuencia de muestreo.

Una vez realizado el muestreo de las señales se normalizaron y estandarizaron de tres maneras distintas, esto con el objetivo de ver como la distribución de los datos afecta los resultados del siguiente proceso que es el análisis de componentes principales.

El análisis de componentes se realizó debido al desbalance de número de canales que tienen los registros. Buscando que la arquitectura trabaje con el mismo número de canales. Primero se probó la arquitectura con un solo canal, posteriormente 4 y finalmente 8. Se tomaron estos valores según la cantidad de información brindada por los canales.

Se realizó una tabla por cada sujeto en la base de datos, las cuales se pueden observar en el Anexo 1, esto con la finalidad de realizar un análisis de la cantidad de información brindada y cuáles eran los canales que brindaban más información, así como la estandarización que era de mayor utilidad para las señales.

Ya que se seleccionó la distribución de los datos, la base de datos fue balanceada y ordenada para poder ser dividida en conjuntos de entrenamiento y de validación en pasos posteriores.

Se continuo con la caracterización de las señales, es decir, la creación de escalogramas a partir de la CWT como se hizo en la metodología para la detección de eventos epilépticos. Se normalizaron los escalogramas calculados y se entrenó el modelo de PIN con 100 épocas utilizando una validación cruzada de 10-Fold.

El modelo fue evaluado mediante la exactitud, precisión, sensibilidad y puntaje F1.

Al no tener resultados favorables en la predicción con un solo canal, se probó modificando la arquitectura para que pudiera obtener más información teniendo un mayor número de canales.

Como se aumentó el número de canales la cantidad de parámetros de la red también creció, provocando un desbordamiento en la memoria VRAM. En este sentido, se optó por agregar un bloque adicional antes de cada bloque convolucional de la arquitectura PIN. Este

bloque es un bloque de codificación, el cual es entrenado con una tarea pretexto, en este caso quitar ruido gaussiano que fue introducido a los escalogramas. Esta tarea se realizó con una red U-net cuya arquitectura fue diseñada para que el cuello de botella de la red fuera de las dimensiones de un solo escalograma. Posteriormente la primera parte de la red U-net es colocada como el bloque codificador incluyendo los pesos de la red.

Sin embargo, aún con las modificaciones realizadas a la arquitectura de PIN y el número de canales brindados los resultados nunca fueron satisfactorios.

6.4. Creación de base de datos

Para mejorar la predicción de los eventos epilépticos se realizó una nueva base de datos utilizando la base de datos [?]. Para la creación de esta base de datos se realizó un código mediante el lenguaje de programación Python, utilizando diversas librerías como numpy, statistics, pyeeg, entropy, scipy, EntropyHub, pyrqa, entre otras.

Ya que algunas de las características que se desean calcular de la señal EEG no están disponibles directamente en algunas librerías se procedió a realizar las funciones desde cero.

La primera de ellas fue para calcular la frecuencia de borde espectral. Se realiza utilizando el método de densidad espectral de potencia de Welch. Devuelve la frecuencia en la cual se alcanza un determinado percentil del espectro acumulativo de potencia.

La segunda consta de un filtro pasa banda, donde la señal a analizar es proporcionada y se le aplica un filtro tipo Butterworth de orden 2. Devolviendo la señal filtrada.

Posteriormente para caracterizar cada una de las señales se realizó una tercer función, la cual recibe como entrada la ruta de una de las señales. Cabe mencionar que estas señales ya se encuentran preprocesadas. El preprocesamiento es el que se describe en la sección **Predicción de eventos epilépticos mediante PIN**. Por lo tanto, ya están muestreadas y listas para utilizar.

Como primer paso la función carga la señal en una variable temporal, ya que será eliminada una vez que se calculen todas las características. Posteriormente calcula las siguientes características y las concatena en una lista la cual será la salida de la función:

- Media
- Desviación estándar
- Coeficiente de variación
- Mediana
- Moda
- Valor máximo
- Valor mínimo
- Primer cuartil
- Tercer cuartil
- Rango intercuartil
- Curtosis
- Asimetría
- DFA
- Parámetros de Hjorth
- Entropía de permutación
- Entropía de muestra
- Entropía aproximada
- Entropía espectral
- Dimensión fractal de Higuchi
- Densidad espectral de potencia
- Potencia relativa delta
- Potencia relativa theta
- Potencia relativa alpha
- Potencia relativa beta
- Potencia relativa gamma
- Laminaridad
- Determinismo
- Tiempo de atrapamiento
- Entropía de línea diagonal
- Media de la línea diagonal
- Tasa de recurrencia
- Frecuencia de borde espectral 25
- Frecuencia de borde espectral 50
- Frecuencia de borde espectral 75
- Amplitud de EEG en delta
- Amplitud de EEG en theta
- Amplitud de EEG en alpha
- Amplitud de EEG en beta
- Amplitud de EEG en gamma
- Exponente de Hurst

Ahora bien, dentro de la función principal se define la ruta de la carpeta que contiene todos los archivos de las señales EEG. Donde se realiza una búsqueda de todos los archivos con extensión .npy dentro de la carpeta y subcarpetas, generando una lista la cual es ordenada de manera alfabética.

Se crea una lista con el nombre de todas las características que se van a calcular, así como el tipo de señal y se guarda como encabezado del archivo CSV.

Se inicializa una lista donde se guardarán todas las características calculadas de una ventana de señal EEG y se le agregan las primeras características: el tipo de señal, es decir, la etiqueta y si la señal es de origen canino o viene de una persona. Esta información se obtiene analizando la ruta, ya que las señales se guardan individuales por sujeto y el nombre del archivo indica el tipo de señal.

Una vez teniendo las primeras características se entra a un ciclo donde se va caracterizando cada uno de los canales de la señal y la lista resultante de cada canal se va concatenando con la que contiene las primeras dos características. Al finalizar la caracterización de la ventana completa la lista es guardada en el archivo CSV. Por lo que una ventaja del código diseñado es que se pueden caracterizar señales de n canales, esto fue pensado porque los registros de señales EEG son multicanal. las características se concatenan de manera horizontal, es decir, todas las características obtenidas del análisis de una sola ventana estarán en un renglón del archivo csv. Por lo que cada renglón hace referencia a una ventana nueva.

De esta manera se va caracterizando cada una de las señales que se tienen en la carpeta compartida. En Figura 6.6 se ve el diagrama de flujo seguido para crear la base de datos y código mencionado anteriormente.

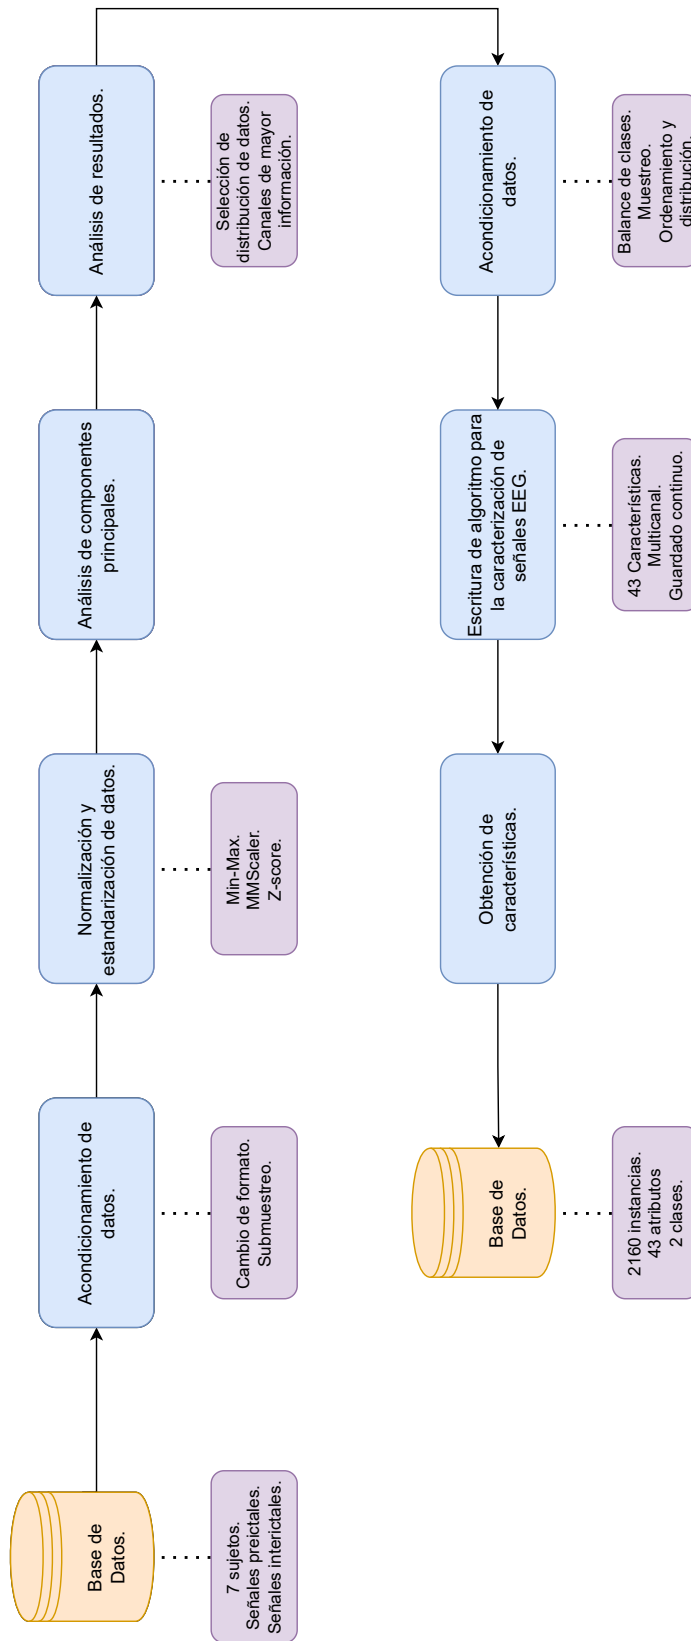


Figura 6.6: Diagrama de flujo para el desarrollo de una nueva base de datos.

6.5. Predicción de eventos epilépticos

La metodología empleada para la generación de los modelos predictivos, fundamentados en algoritmos de aprendizaje automático, es presentada en la Figura 6.7. Inicialmente, se procedió a la partición de la base de datos en dos conjuntos distintos: el conjunto de entrenamiento y el conjunto de prueba. Se asignó el 90 % del total de los datos a la porción de entrenamiento, mientras que el 10 % restante se destinó al conjunto de prueba.

Subsecuentemente, se procedió a la extracción del atributo de decisión de la base de datos, tanto en el conjunto de entrenamiento como en el de prueba, con la finalidad de disponer de vectores disyuntos que posibiliten la clasificación de las observaciones en los conjuntos respectivos.

En una fase subsiguiente, se diseñó el proceso experimental con el propósito de identificar los modelos con capacidad predictiva de eventos epilépticos. Esta meta se alcanza mediante la clasificación de períodos interictales y preictales, logrando alcanzar un rendimiento métrico en el rango del 70

Los algoritmos objeto de evaluación durante esta etapa experimental fueron: Regresión Logística, K Vecinos más Cercanos, Naive Bayes, Árbol de Decisión, Bosque Aleatorio, Gradient Boosting, Extra Trees, Light Gradient Boosting Machine, CatBoost, XGBoost, Máquina de Soporte Vectorial, AdaBoost, Análisis Discriminante Lineal, Análisis Discriminante Cuadrático y el Clasificador Ridge.

La evaluación de cada uno de los algoritmos propuestos implicó la consideración de cuatro métricas clave: exactitud, precisión, sensibilidad y puntuación F1. Esta estrategia permitió la realización de una comparación cuantitativa y objetiva entre los diferentes algoritmos evaluados.

Tras la exhaustiva evaluación y análisis de los algoritmos, se procedió a seleccionar los cinco modelos con mejor rendimiento. Estos modelos fueron sometidos a un proceso de ajuste de hiperparámetros con el fin de mejorar su capacidad de clasificación de períodos interictales y preictales. Los algoritmos ajustados fueron nuevamente sometidos a un proceso de entrenamiento de 100 épocas, empleando la técnica de validación cruzada 10-Fold.

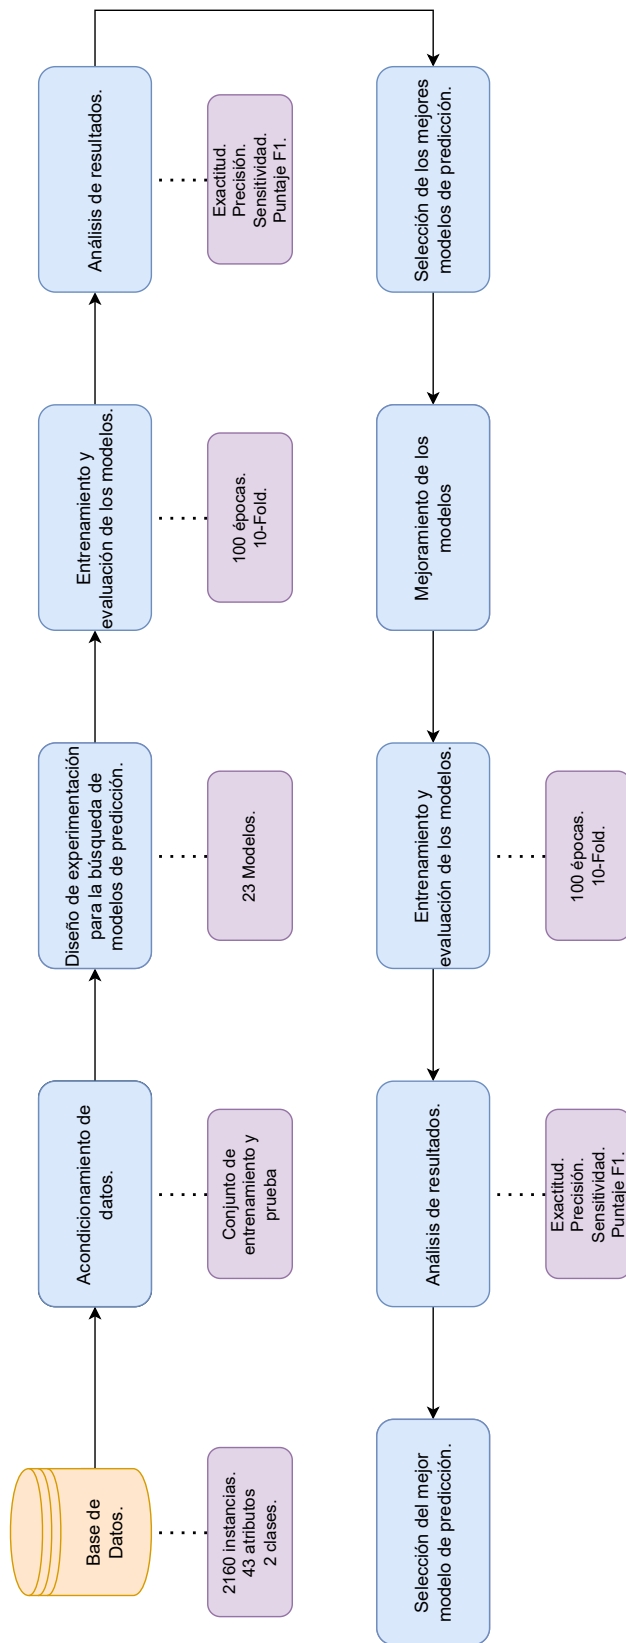


Figura 6.7: Diagrama de flujo para la búsqueda de un modelo de predicción utilizando la nueva base de datos.

Para concluir la evaluación y con el propósito de comparar el rendimiento de los algoritmos antes y después de su ajuste, tanto los modelos originales como los ajustados fueron evaluados utilizando el conjunto de prueba, que fue apartado al inicio de la metodología. De manera similar a las evaluaciones previas, se calculó cada una de las cuatro métricas, permitiendo así una comparación cuantitativa de los resultados obtenidos por los distintos modelos.

Como último paso en esta metodología, se procedió a seleccionar los tres modelos clasificadores de mejor rendimiento.

Capítulo 7

Resultados y discusión

En este capítulo se presentan los resultados obtenidos a partir de la metodología descrita en el capítulo anterior. Se comenzará describiendo los resultados de la sección de detección de eventos epilépticos, posteriormente la primera parte de la predicción de los eventos epilépticos se continuará con la generación de la base de datos y se finalizará con la segunda parte de la predicción de eventos epilépticos.

Como se mencionó en la metodología la detección de los eventos epilépticos se abordó mediante dos arquitecturas distintas, la primera de ellas fue Ictal-net y la segunda Parallel Ictal-net. A continuación, se presentan los resultados correspondientes a Ictal-net.

7.1. Detección de eventos epilépticos mediante Ictal-net

Como primeros resultados de esta sección se presenta el muestreo y la creación de los escalogramas que fueron entrada la entrada de red Ictal-net. En las Figuras 7.1 y 7.2 se muestra como de una señal completa se extrae una ventana de 256 muestras la cual pasa a ser procesada por la CWT y se obtiene como resultado un escalograma.

La Figura 7.1 corresponde a una señal de un periodo interictal, es decir, momento libre de eventos epilépticos. La señal es obtenida de la base de datos de la Universidad de Bonn. Por otro lado en la Figura 7.2 se observa una señal ictal, hay un evento epiléptico presente.

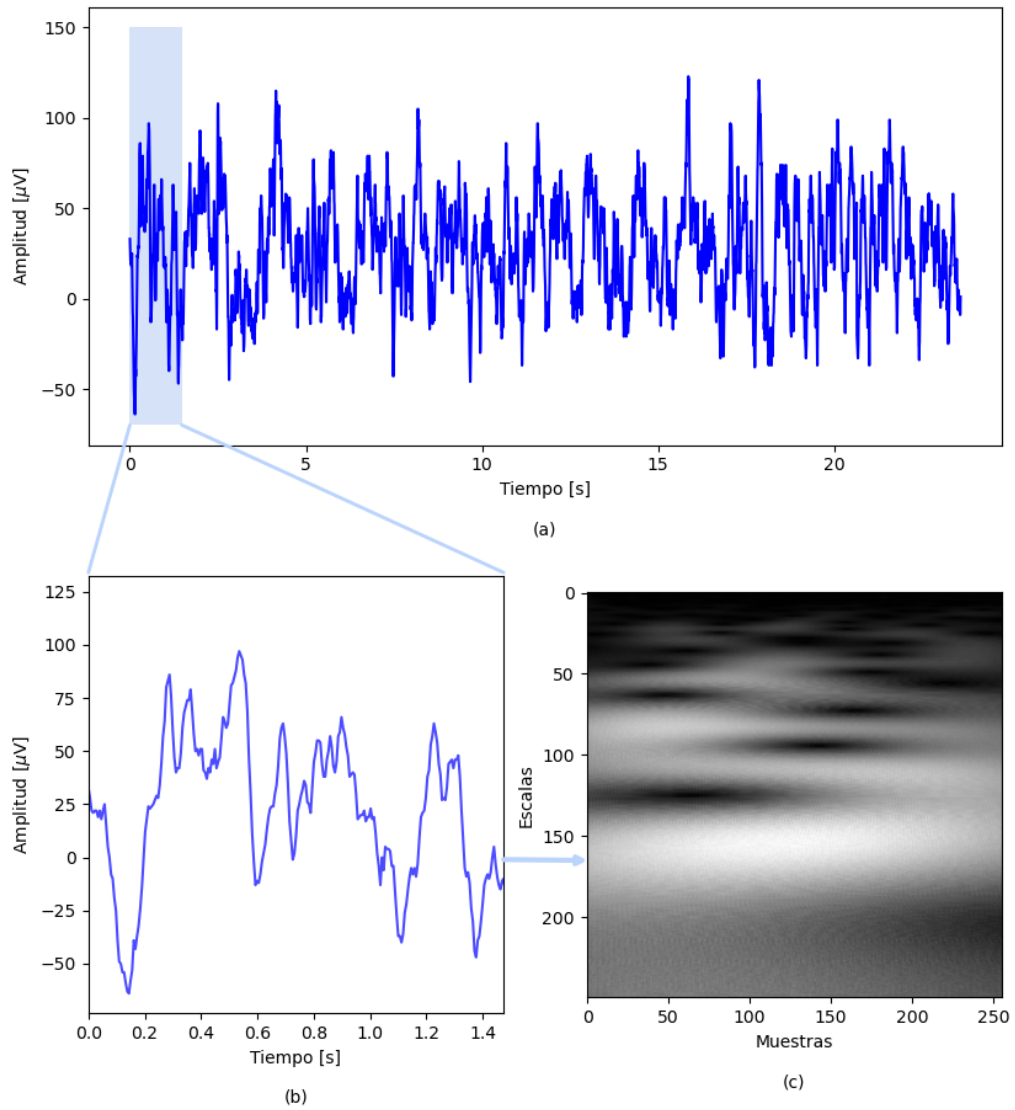


Figura 7.1: Muestreo y escalograma de señal interictal proveniente de la base de datos de la Universidad de Bonn [7].

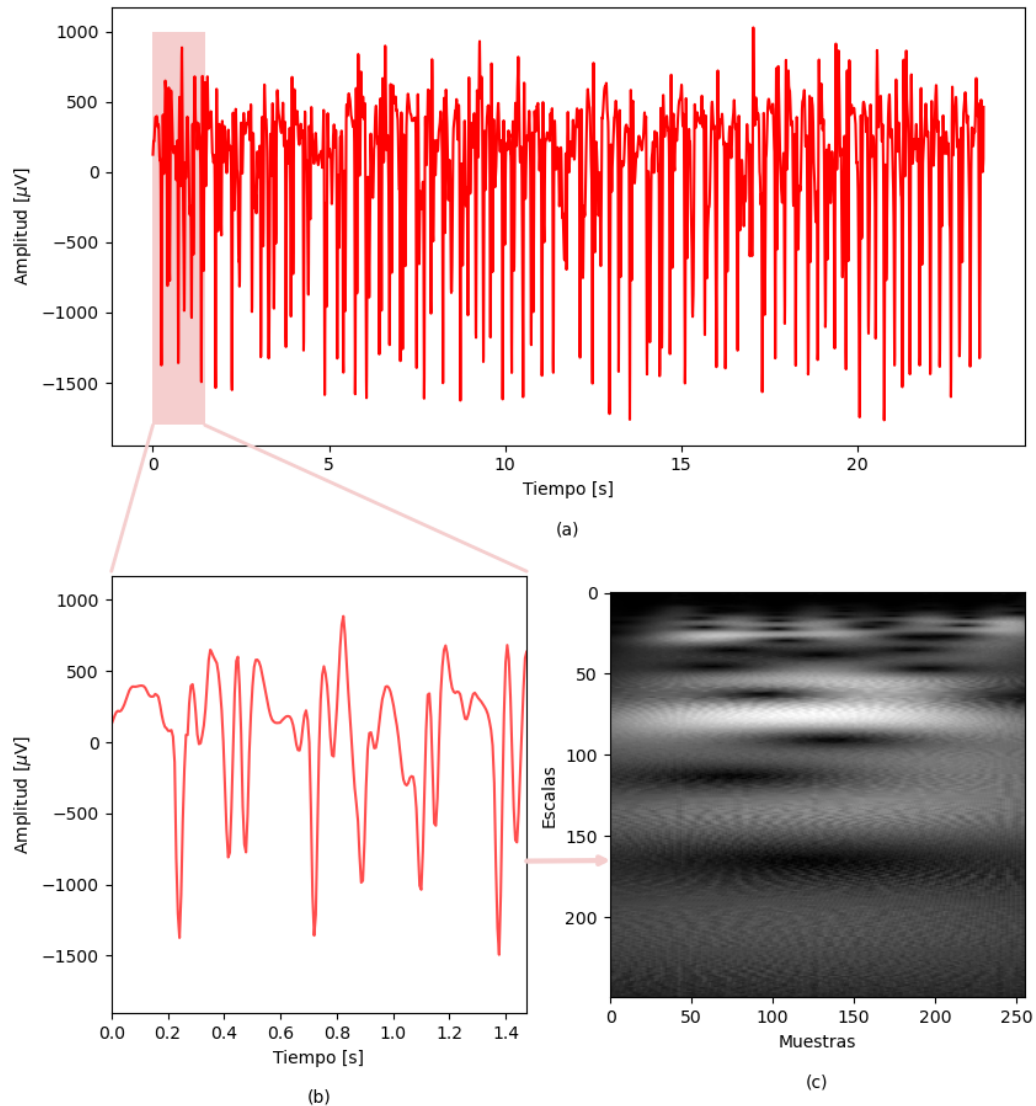


Figura 7.2: Muestreo y escalograma de señal ictal proveniente de la base de datos de la Universidad de Bonn [7].

Los escalogramas de las Figuras 7.1 y 7.2 son representaciones en escalas de grises, en este sentido cuando los escalogramas presentan pixeles de color negro nos indica ausencia de la frecuencia (escala) estudiada en la muestra de la señal (tiempo). De forma contraria

cuando el píxel es blanco existe mayor presencia de la frecuencia en ese tiempo. Por lo tanto, lo grises son valores intermedios de la presencia de las frecuencias que componen la señal.

Ahora bien, como se mencionó en la búsqueda de Ictal-net, se trabajó con las señales en el dominio del tiempo y tiempo-frecuencia. Para trabajarlas en el dominio del tiempo se trabajó con la señal cruda y se buscaba clasificar mediante un MLP. En la Figura 7.3 se muestran las precisiones alcanzadas por los distintos MLP's propuestos.

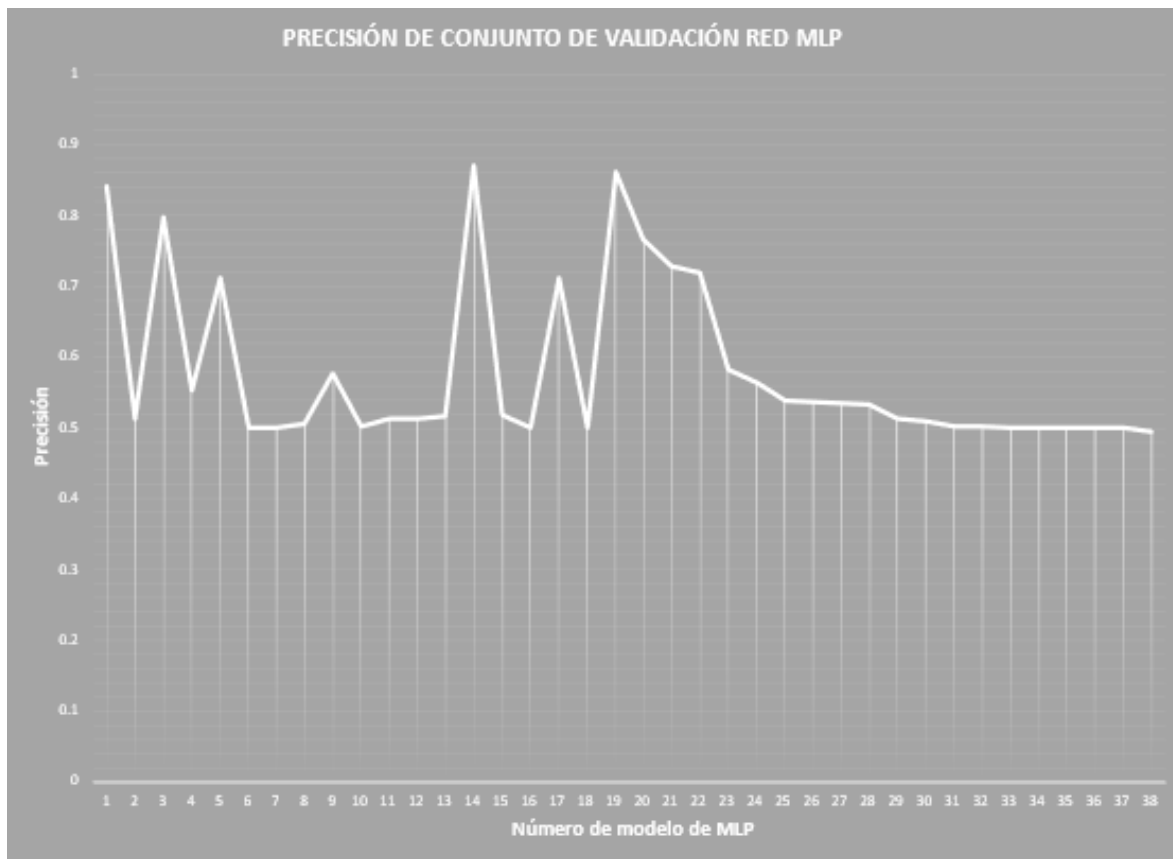


Figura 7.3: Precisiones obtenidas con distintos MLP's en la detección de eventos epilépticos.

Sin embargo, como se puede observar en Figura 7.3 las métricas alcanzadas siguiendo esta metodología no fueron las mejores, ya que se encuentran por debajo del estado del arte, teniendo una precisión máxima con un valor alrededor 87 %.

En la Figura 7.4 se pueden observar las configuraciones de las MLP's probadas y sus cifras de mérito.




Figura 7.4: Configuraciones probadas para la detección de eventos epilépticos mediante MLP.

Como se puede observar en la Figura 7.4 las líneas que componen el gráfico se presentan de dos colores (morado y rojo) las líneas de color morado son aquellas configuraciones con menor rendimiento mientras que las líneas de color rojo representan a las de mejor rendimiento, sin embargo, hay una línea de color rojo más gruesa que las demás y que parte de 150 en la coordenada número uno, es decir el número de neuronas de la primera capa, esta línea nos indica la configuración del MLP que obtuvo las mejores métricas.

El la Figura 7.5 se muestran las precisiones de las CNN's propuestas para clasificar los escalogramas calculados y determinar si la señal pertenece a un periodo ictal o interictal y de esta manera detectar eventos epilépticos. Como se obtuvieron mejores resultados que con las redes MLP se probaron más redes CNN.

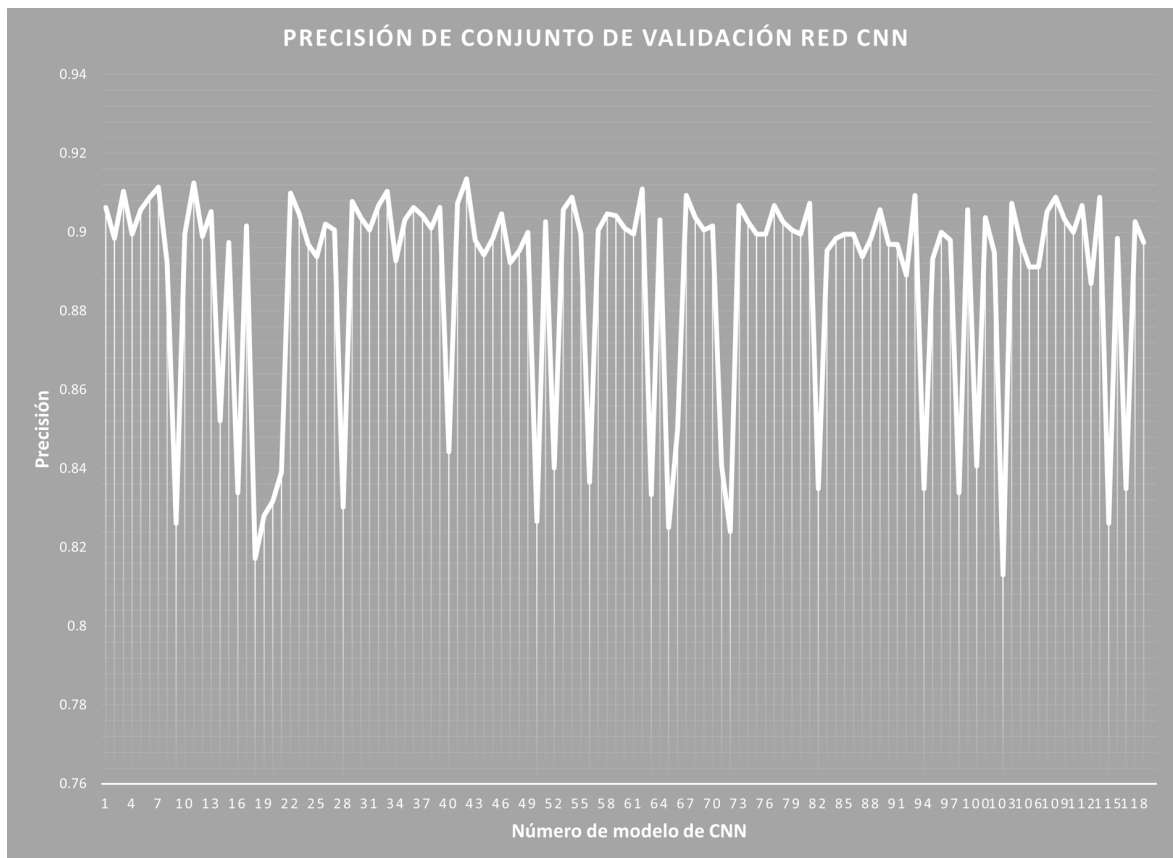


Figura 7.5: Precisiones obtenidas con distintas CNN's en la detección de eventos epilépticos.

En el caso de las CNN's las precisiones alcanzadas fueron mayores que con los MLP's,

inclusive algunos valores se encontraron dentro del estado del arte. Como se puede observar la mayoría de las redes CNN probadas se encontraban en un rango de 89 % y 92 % de precisión. Inclusive la CNN de menor rendimiento supera a la mayoría de las redes MLP

En la Figura 7.6 se muestran las configuraciones de los CNN propuestos, los colores de las líneas siguen el mismo concepto de las mostradas en la Figura 7.4, es decir, las líneas de color morado representan las CNN con menor rendimiento y las líneas de color rojos las mejor rendimiento.

A partir de las configuraciones presentadas en la Figura 7.6 al igual que con las métricas reportadas en la Figura 7.5 se determinó la arquitectura que desempeñó de mejor manera la tarea de detección de eventos epilépticos a la cual se le denominó Ictal-net y cuya arquitectura se presenta en la Figura 7.7.

En la Figura 7.7 las capas convoluciones se representan como capas de color naranja, las operaciones de normalización por lotes por capas de color amarillo, las funciones de activación de color gris, la agrupación por valores máximos de color morado, funciones de *dropout* de color lila, y las capas densas de color azul.




Figura 7.6: Configuraciones probadas para la detección de eventos epilépticos mediante CNN.




Figura 7.7: Arquitectura de la red neuronal convolucional denominada Ictal-net [7].

Como se puede ver en la Figura 7.7 la arquitectura que obtuvo las mejores métricas está compuesta por cinco capas convolucionales, cuatro capas de normalización por lotes, con funciones de activación tanto ReLU como sigmoide, dos capas de agrupamiento por máximos, dos capas de dropout una capa donde se aplanan las características calculadas por las capas convolucionales para pasarla las dos capas densas.

Las capas convolucionales cuentan con 54, 44, 64, 54 y 44 filtros cada una, trabajando con kernels de (3×3) , las agrupaciones por lotes se encuentran después de las de las capas convolucionales uno, dos, tres y cinco. Las capas de maxpooling se encuentran después de las capas convolucionales cuatro y cinco. Los dropouts tienen un valor de 0.5. La primera capa densa tiene 28 neuronas y la capa de salida cuenta con neuronas y una función de activación softmax.

En el Cuadro 7.1 se presenta la matriz de confusión donde de Ictal-net, la cual se obtuvo al evaluar la arquitectura propuesta con el conjunto de prueba. En ella se puede observar las

clasificaciones correctas por clase así con las incorrectas.

Matriz de confusión		
	Periodo interictal (1,0)	Periodo ictal (0,1)
Periodo interictal (1,0)	306	14
Periodo ictal (0,1)	25	295

Cuadro 7.1: Matriz de confusión obtenida de la evaluación de Ictal-net para la detección de eventos epilépticos.

Como se muestra en el Cuadro 7.1, la clase interictal fue clasificada de mejor manera que la clase ictal, con una diferencia de 11 muestras erróneamente clasificadas. Adicionalmente la información reportada por el Cuadro 7.1 nos ayuda a calcular las cifras de mérito y poder evaluar el rendimiento de la arquitectura cuantitativamente. Por ejemplo, en cuanto a exactitud se obtuvo un 93.90 %, la sensibilidad es de un 92.19 %, la precisión es de 95.47 % y finalmente la arquitectura obtuvo un puntaje F1 de 0.9380.

7.2. Detección de eventos epilépticos con Parallel Ictal-net

A partir de las 28 variables que se encuentran distribuidas en los cinco hiperparámetros ajustables de la arquitectura denominada PIN, se logró evaluar de un total de 2880 redes neuronales distintas, las cuales fueron evaluadas mediante validación cruzada 10 fold. Este proceso ha sido realizado con la intención de llevar a cabo una búsqueda exhaustiva con el propósito de identificar los hiperparámetros óptimos para la mencionada arquitectura.

En la Figura 7.8 se puede visualizar una gráfica de coordenadas paralelas, donde es posible realizar un seguimiento de las configuraciones realizadas para encontrar la mejor arquitec-

tura. Lo cual es definido de manera cuantitativa por las métricas comúnmente utilizadas en la literatura especializada. La primera coordenada se encuentran las cinco wavelets opciones de wavelets; le sigue la frecuencia de muestreo, la cual puede ser asignada o no para la CWT; a continuación, se muestra el número de muestras que conforman la ventana de análisis, así como el porcentaje de traslape entre estas ventanas. Posteriormente, se presenta el learning rate empleado durante el entrenamiento de la red, el tipo de optimizador utilizado y, finalmente, las cuatro métricas empleadas para evaluar el rendimiento de las arquitecturas sometidas a prueba.

De las 2880 redes o propuestas analizadas, se han identificado 135 redes que superan el estado del arte previo. Estas redes se exponen en la Figura 7.9, la cual corresponde a un acercamiento de la Figura 7.8. Estas redes se han destacado mediante una línea vertical magenta.

Tanto en la Figura 7.8 como en la 7.9, la tonalidad de las líneas que conforman la gráfica se determina a partir de los valores obtenidos en las métricas de evaluación. Se emplea un esquema de colores que va desde un tono rosa claro, representativo de las métricas más bajas reportadas, hasta un azul oscuro que denota las métricas más elevadas, siendo 1 equivalente al 100 %.

Sin embargo en la Figura 7.9 con el objetivo de mejorar la visualización de las redes de interés, aquellas que no superan el estado del arte han sido representadas con un tono grisáceo.

A partir de la Figura 7.9, se puede discernir que las redes más eficaces se han entrenado utilizando el optimizador Adam y un learning rate de 0.0001. No obstante, de las 135 combinaciones que superan el estado del arte, 13 de ellas han alcanzado un empate con un 100 % de precisión, exactitud, recall y puntuación F1. Estas 13 combinaciones se detallan en el Cuadro 7.2.




Figura 7.8: Combinación de configuraciones para la red neuronal y CWT para la búsqueda de Parallel Ictal-net.




Figura 7.9: Configuraciones que superan el estado del arte encontrado y sus cifras de mérito

En la Cuadro 7.2 se brindan mayores especificaciones acerca de las combinaciones más sobresalientes. Esto abarca la wavelet madre empleada para calcular el escalograma, la frecuencia de muestreo empleada en la CWT, el número de muestras en cada ventana, el porcentaje de traslape entre ventanas, el tiempo requerido para el cálculo y procesamiento del escalograma, el tiempo de entrenamiento de la arquitectura y, por último, el número total de parámetros presentes en la red neuronal.

Cuadro 7.2: Matriz con las configuraciones de las 13 mejores arquitecturas para la detección de eventos epilépticos.

Wavelet	Fs [Hz]	Muestras por ventana	Porcentaje de traslape [%]	Tiempo de escalogramas [s]	Tiempo de entrenamiento [s]	L2	Número de parámetros de la red
gmw	None	1042	33	12.67	236.9	0.47	7309640
bump	None	868	33	26.04	382.78	0.47	6981109
morlet	173.61	1042	25	11.59	265.73	0.49	6143871
cmhat	173.61	1042	33	24.23	515.29	0.5	8994440
bump	None	1042	0	14.65	322.52	0.51	4790902
bump	173.61	1215	0	14.93	345.51	0.51	5582102
bump	173.61	1736	25	11.27	285.61	0.51	6196313
cmhat	173.61	1389	50	19.48	427.03	0.52	9987071
morlet	173.61	1736	0	7.92	264.83	0.52	6352373
bump	None	1389	0	11.02	284.53	0.53	4787633
cmhat	None	1389	25	16.6	391.85	0.53	7990262
gmw	None	2083	25	6.01	189.41	0.53	7556333
gmw	173.61	2083	33	6.01	181.66	0.54	7556333

Dado que en las métricas las 13 opciones mostradas en el Cuadro 7.2 se encontraban empatadas se tomó como segundo criterio de selección el error cuadrático medio (L2) y como tercera característica el número de parámetros en la red neuronal. A partir de estos criterios, se ha seleccionado la segunda arquitectura presentada en el Cuadro 7.2 como la mejor.

La red neuronal que exhibió el mejor rendimiento ha sido designada como Parallel Ictal-

net (PIN). Esta red emplea la wavelet madre tipo bump para calcular los escalogramas, sin que se le asigne un valor específico de frecuencia de muestreo mediante la Transformada CWT. Las ventanas que componen la entrada para la red PIN están constituidas por 868 muestras, con un traslape del 33 % entre cada una de ellas (ver Figura 7.10. El tiempo necesario para el cálculo y procesamiento de los escalogramas fue de 26.04 segundos, mientras que el tiempo requerido para entrenar la arquitectura en los 10 ensayos fue de 382.78 segundos. Con relación a la función L2, la red obtuvo un valor de 0.47.




Figura 7.10: Entrada de Parallel Ictal-net

La Figura 7.10 exhibe la entrada de la red PIN, compuesta por 7 escalogramas de 868 muestras cada uno, evaluados en 233 escalas mediante la CWT, lo que da como resultado una entrada de dimensiones $233 \times 868 \times 7$. Es relevante destacar que estas ventanas fueron redimensionadas para que la entrada a la red PIN tenga dimensiones de $250 \times 250 \times 7$.

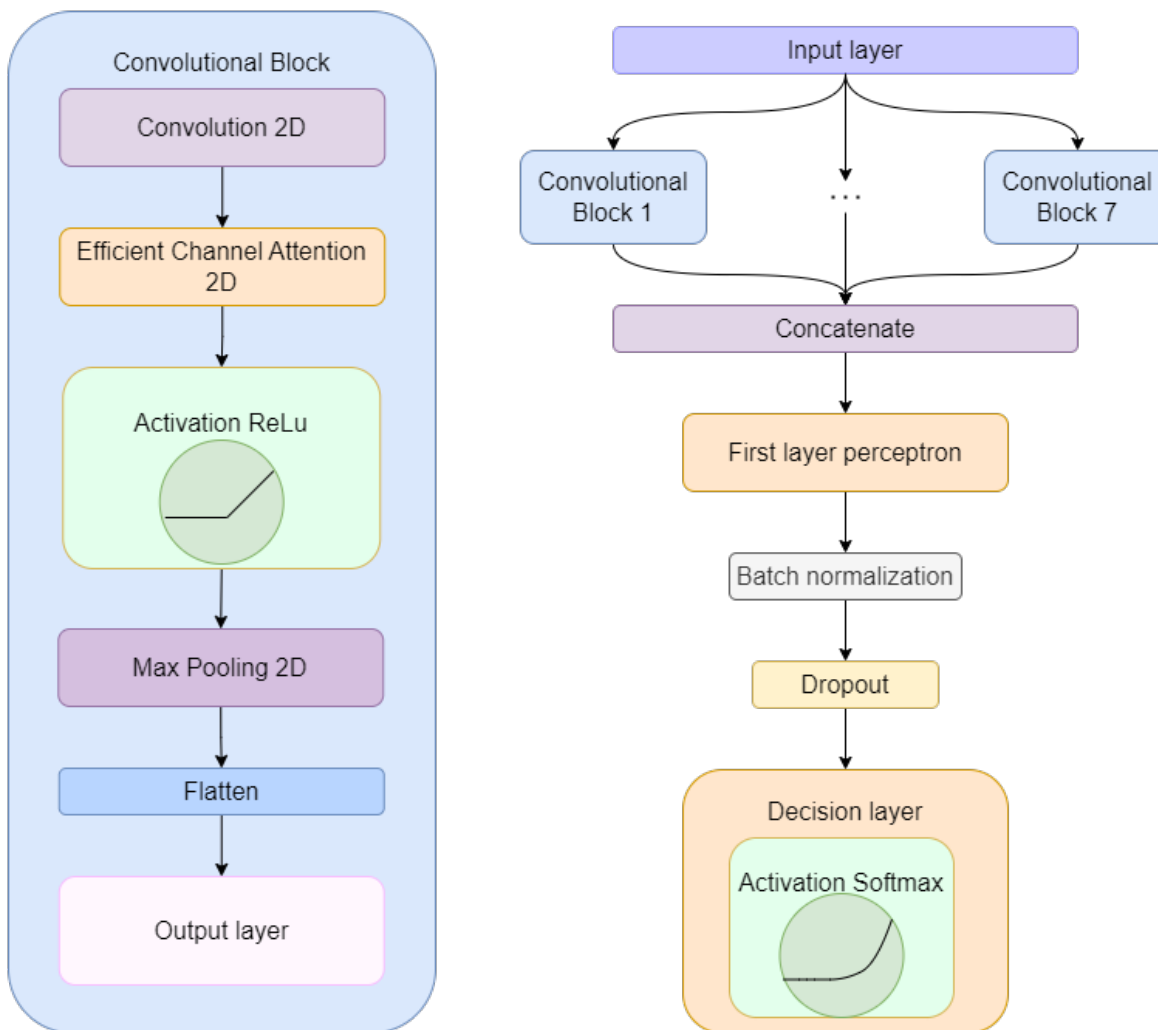


Figura 7.11: Arquitectura de Parallel Ictal-net.

Cada uno de los escalogramas que forman la entrada de la red PIN es sometido a un bloque convolucional. En este sentido, la red PIN consta de 7 bloques convolucionales, cada uno de los cuales presenta una capa convolucional 2D compuesta por 10 filtros, aplicados a kernels de dimensiones 3×3 . Posteriormente, se introduce el módulo de atención de canal

eficiente en 2D. A continuación, la información se somete a una función de activación ReLU, seguida de una capa de Max Pooling con un kernel de tamaño 2×2 . Las características extraídas se acomodan mediante una capa Flatten, para luego ser clasificadas a través de una capa densa que consta de dos neuronas en la salida y utiliza la función de activación softmax.

La salida de los 7 bloques convolucionales es concatenada para ser procesada por una capa densa compuesta por 432 neuronas, con función de activación ReLU. A continuación, se aplica una capa de normalización por lotes, seguida de un dropout del 0.7 y, para finalizar, una capa densa con dos neuronas y función de activación softmax. Esta arquitectura se encuentra representada en la Figura 7.11.

El Cuadro 7.3 presenta una comparación entre el rendimiento de la red PIN, Ictal-net y los resultados obtenidos en investigaciones previas dentro del estado del arte, considerando métricas de evaluación tales como exactitud, precisión y recall. Es importante mencionar que, aunque se calculó el puntaje F1 para ambas arquitecturas, no es factible compararlo con los demás estudios, dado que no todos ellos lo reportan.

Cuadro 7.3: Arquitecturas propuestas y estado del arte en detección de eventos epilépticos.

Clasificador	Exactitud	Precisión	Sensitividad
Parallel Ictal-net	100 %	100 %	100 %
Ictal-net [7]	93.90 %	95.47 %	92.19 %
RF [59]	97.04 %	97.00 %	97.73 %
SVM [59]	93.52 %	93.50 %	92.04 %
KNN [59]	97.96 %	98.00 %	97.35 %
DT [59]	96.67 %	96.70 %	97.73 %
MLP [59]	98.15 %	98.20 %	96.59 %
FURIA [59]	96.30 %	96.30 %	97.73 %
FLR [59]	93.15 %	93.30 %	96.21 %
FRNN [59]	98.70 %	98.70 %	98.86 %

Continúa en la siguiente página.

Clasificador	Exactitud	Precisión	Sensitividad
VQNN [59]	97.59 %	97.60 %	97.73 %
FNN [59]	96.85 %	96.90 %	98.84 %
CNN [60]	98.50 %	-	98.98 %
LSTM [61]	95.00 %	-	91.00 %
SVM 2-fold [62]	88.60 %	-	94.47 %
SVM 4-fold [62]	88.80 %	-	94.60 %
KNN 2-fold [62]	89.23 %	-	89.37 %
KNN 4-fold [62]	88.86 %	-	89.96 %
BN 2-fold [62]	91.16 %	-	91.37 %
BN 4-fold [62]	90.39 %	-	90.69 %
SVM EMD [63]	96.25 %	-	-
SVM DWT [63]	93.75 %	-	-
KNN EMD [63]	93.75 %	-	-
KNN DWT [63]	95.00 %	-	-
DT EMD [63]	97.50 %	-	-
DT DWT [63]	98.75 %	-	-
CNN GASF EEG [64]	94.50 %	-	-
CNN GADF EEG [64]	94.00 %	-	-
CNN GASF EEG potencia [64]	96.50 %	-	-
CNN GADF EEG potencia [64]	97.00 %	-	-

Los guiones indican que la métrica no es reportada por los autores de los clasificadores.

Como se puede observar en el Cuadro 7.3 el rendimiento de Ictal-net no sobresale en el estado del arte, sin embargo, el rendimiento de PIN resalta, ya que detecta los eventos epilépticos con un alto porcentaje de exactitud, precisión y sensibilidad.

7.3. Predicción de eventos epilépticos con Parallel Ictal-net

A continuación se presentan los primeros resultados obtenidos para la predicción de eventos epilépticos utilizando la base de datos proporcionada por la base de datos de la *American Epilepsy Society* en Kaggle [56].

El Cuadro 7.4 muestra la cantidad de información proporcionada por los cuatro canales con mayor relevancia definida a través de un estudio de análisis de componentes principales y las distintas maneras en las que se estandarizaron las señales EEG. En el Anexo 1 se puede ver el análisis completo de la base de datos.

Cuadro 7.4: Porcentaje de información brindada por cuatro canales y diferentes métodos de estandarización.

Sujeto	Min-max	MMScaler	Z-score
Dog_1	71.45 %	76.06 %	72.26 %
Dog_2	53.79 %	60.95 %	60.56 %
Dog_3	41.44 %	48.54 %	42.05 %
Dog_4	64.37 %	76.44 %	75.59 %
Dog_5	42.19 %	49.03 %	45.99 %
Patient_1	59.85 %	99.02 %	99.92 %
Patient_2	71.02 %	96.94 %	96.33 %

Dados los valores reflejados en el Cuadro 7.4 se puede definir que la mejor manera de estandarizar las señales EEG es mediante la función *MMScaler* de *scikit-learn*.

Posteriormente se realizaron pruebas para predecir los eventos epilépticos mediante un solo canal y la arquitectura de PIN, sin embargo los resultados no fueron favorables, ya que las mayores métricas alcanzadas no superaban ni un 55 % de rendimiento. Métricas que se ven reportadas en el Cuadro 7.5.

Cuadro 7.5: Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con escalogramas como entrada y la metodología propuesta en esta tesis.

Métrica	%
Exactitud	52.36
Precisión	52.29
Sensibilidad	52.30
Puntaje F1	52.29

Debido al bajo rendimiento de la clasificación de los escalogramas se decidió probar con espectogramas, obteniendo valores similares que con los escalogramas. Las métricas pueden verse en el Cuadro 7.6.

Cuadro 7.6: Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con espectogramas como entrada y la metodología propuesta en esta tesis.

Métrica	%
Exactitud	54.36
Precisión	54.30
Sensibilidad	54.33
Puntaje F1	54.27

Sin embargo, se encontraron metodologías en el estado del arte con sesgos temporales siguiendo dichas metodologías la arquitectura de PIN alcanzó un rendimiento superior al 90 % clasificando los escalogramas y espectogramas. Las métricas pueden visualizarse en los Cuadros 7.7 y 7.8.

Cuadro 7.7: Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con esca-logramas como entrada y la metodología encontrada en algunos proyectos del estado del arte.

Métrica	%
Exactitud	92.66
Precisión	92.50
Sensibilidad	92.57
Puntaje F1	92.53

Cuadro 7.8: Métricas obtenidas al predecir eventos epilépticos con el modelo PIN con espec-togramas como entrada y la metodología propuesta en algunos proyectos del estado del arte.

Metrica	%
Exactitud	97.00
Precisión	97.20
Sensibilidad	97.25
Puntaje F1	97.22

Aunque las métricas alcanzadas por la arquitectura siguiendo esa metodología eran altas, sin embargo, decidió omitirse ya que el objetivo del presente proyecto es realizar las predic-ciones con una metodología libre de sesgo alguno. Por lo que se decidió agregar más canales a la entrada de PIN, no obstante, el tamaño de la red crecía en gran escala, desbordando la memoria VRAM.

En la Figura 7.12 se puede observar la arquitectura de la red U-Net utilizada para el pre-entrenamiento del bloque codificador.

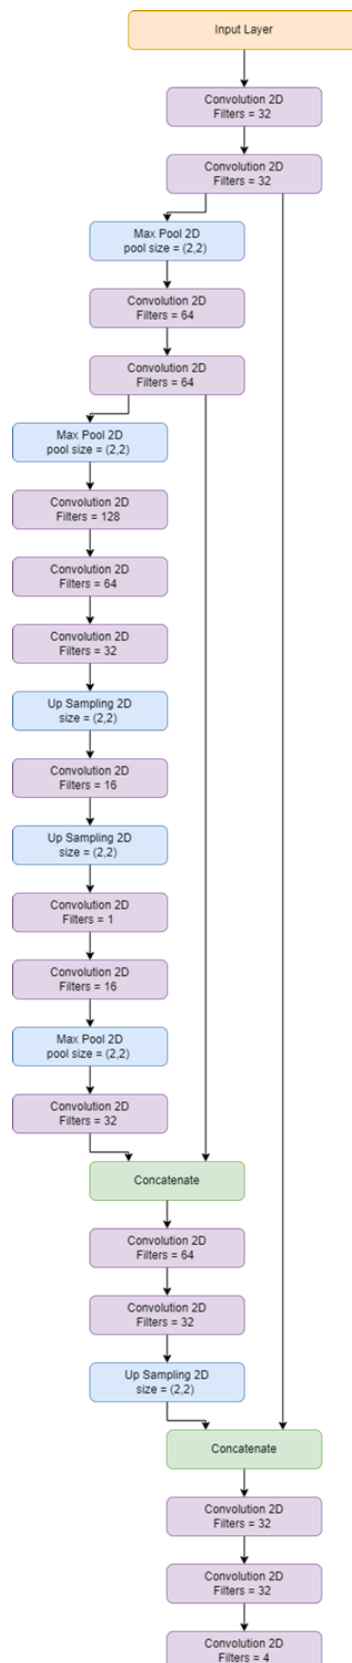


Figura 7.12: Arquitectura de U-net para tarea pretexto.

En la Figura 7.13 se puede observar la arquitectura de PIN con el bloque codificador, el cual consta de nueve capas convolucionales, dos capas de Max Pooling y dos de Up Sampling.

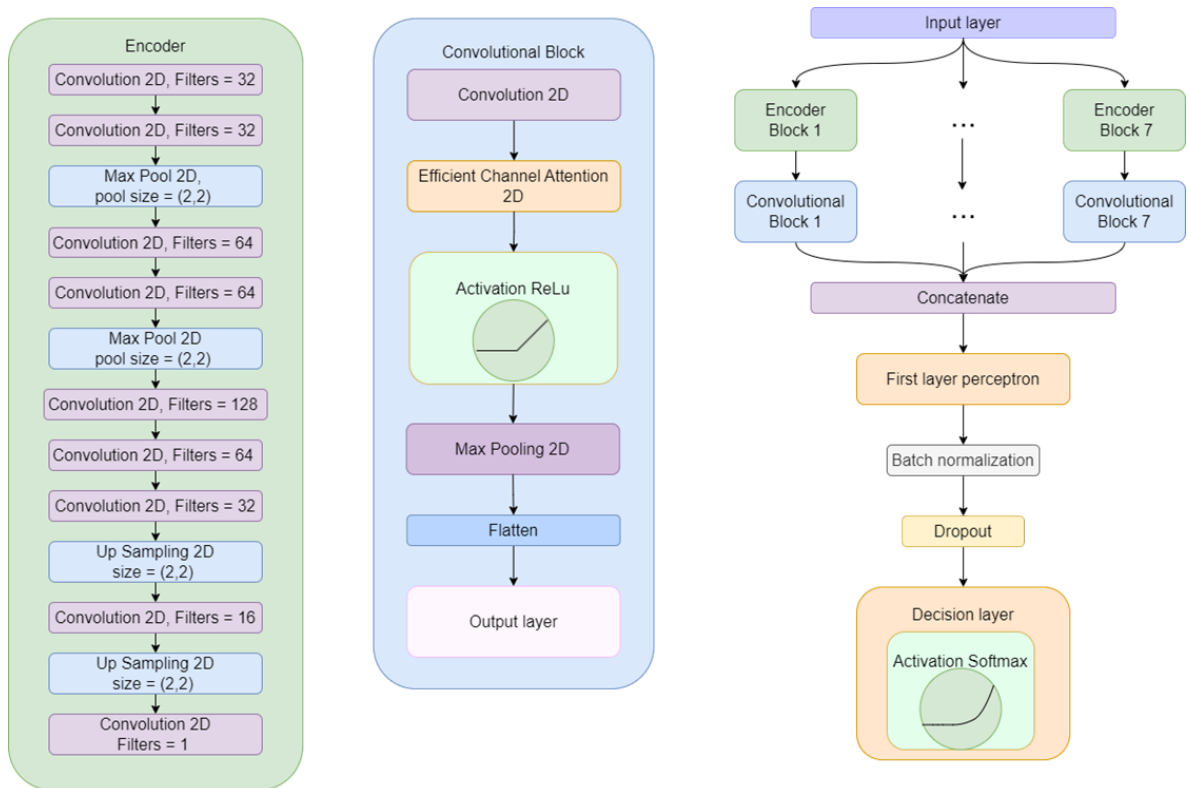


Figura 7.13: Arquitectura de Parallel Ictal-net con bloque de codificación.

Como se puede observar en la Figura 7.13 las capas convolucionales trabajan con kernels de 3×3 con 32, 32, 64, 64, 128, 64, 32, 16 y 1 filtro respectivamente. Las capas de Max Pooling y de Up Sampling trabajan con kernels de 2×2 . Cabe resaltar que la etapa codificadora se agregó antes de cada bloque convolucional de la arquitectura de PIN.

En el Cuadro 7.9 se muestran las métricas obtenidas al predecir los eventos epilépticos utilizando la arquitectura mostrada en la Figura 7.13.

Cuadro 7.9: Métricas obtenidas al predecir eventos epilépticos agregando un bloque codificador antes del convolucional es la arquitectura de PIN.

Métrica	%
Exactitud	55.82
Precisión	55.82
Sensibilidad	55.82
Puntaje F1	55.84

A partir del Cuadro 7.9 se puede concluir que la metodología seguida y la forma de caracterizar las señales no es la mejor, dado de las cifras de mérito se encuentran alrededor de un 55 %.

7.4. Generación de base de datos

Como resultado de la generación de la base de datos se obtuvo un archivo csv, el cual contiene 2160 instancias con 43 atributos y dos clases. Las etiquetas están representadas por ceros y unos, donde el cero corresponde a un periodo interictal y el uno corresponde a periodos preictales.

En el Cuadro 7.10 se presenta la primera instancia de la base de datos, la cual pertenece a un sujeto canino, el cual se encuentra denotado por el número cero y un periodo interictal.

Cuadro 7.10: Primer instancias de la base de datos generada.

Parámetro	Valor	Parámetro	Valor
Media	24.215187	DFA	0.56363777
STD	23.148808	Movilidad	0.00290336
Coefficiente de variación	0.95596236	Complejidad	384.365962
Mediana	18.296875	Actividad	1122.0779
Moda	33.65625	Permutación Entropía	2.36810876
Valor Máximo	371.5	Entropía Muestra	1.28114429
Valor Mínimo	0.00279045	Entropía Aproximada	0.501079
Primer Cuartil	8.5703125	Entropía Espectral	0.76329898
Tercer Cuartil	32.6875	HFD	0.59926755
Rango Intercuartil	24.1171875	Potencia Relativa Delta	0.31330377
Kurtosis	15.0600611	Potencia Relativa Theta	0.14876634
Potencia Relativa Beta	0.28789318	Skewness	2.7281055950
Potencia Relativa Gamma	0.83533	Potencia Relativa Alpha	0.16650367
Laminaridad	0.00764993	Amplitud de EEG en Delta	357243.179
Determinismo	0.00459491	Amplitud de EEG en Theta	256493.571
Tiempo de Captura	2.00260586	Amplitud de EEG en Gamma	194552.569
Entropía de Línea Diagonal	0.17685263	Amplitud de EEG en Beta	318552.244
Media de Línea Diagonal	2.0430622	Amplitud de EEG en Alpha	267165.996
Tasa de Recurrencia	0.00044299	Exponente Hurst	0.4693768
Frecuencia de Borde espectral 25	3.125	Sujeto	0
Frecuencia de Borde espectral 50	9.375	Etiqueta	0
Frecuencia de Borde espectral 75	15.625		

7.5. Predicción de eventos epilépticos mediante parámetros calculados en el dominio del tiempo y de la frecuencia

En esta sección se presenta la segunda parte de los resultados de predicción de eventos epilépticos. Resultados que son obtenidos al evaluar los modelos de Extra Trees, Cat Boost y XGBoost con el conjunto de entrenamiento de la base de datos generada.

Como primer resultado se presenta la Matriz de confusión del modelo de Extra Trees (ver Cuadro 7.11).

Cuadro 7.11: Matriz de confusión obtenida con el modelo de Extra Trees.

Matriz de confusión		
	Periodo interictal (0)	Periodo preictal (1)
Periodo interictal (0)	84	24
Periodo preictal (1)	27	81

A partir de la matriz mostrada en el Cuadro 7.11 se pueden calcular las cifras de mérito para evaluar el algoritmo de Extra Trees cuantitativamente. Obteniendo un 76.22 % de exactitud, una sensibilidad de 75.68 %, en cuanto a precisión un 77.78 % y un Puntaje F1 de 0.7595.

Posteriormente se muestra la matriz de confusión del algoritmo de Cat Boost (Cuadro 7.12)

7.5. PREDICCIÓN DE EVENTOS EPILÉPTICOS MEDIANTE PARÁMETROS CALCULADOS EN E

Cuadro 7.12: Matriz de confusión obtenida con el modelo Cat Boost.

Matriz de confusión		
	Periodo interictal (0)	Periodo preictal (1)
Periodo interictal (0)	88	20
Periodo preictal (1)	28	80

Respecto al algoritmo de Cat Boost y a partir de la matriz mostrada en el Cuadro 7.11 se puede determinar que la exactitud, sensibilidad, precisión y puntaje F1 son de 77.78 %, 75.86 %, 81.48 % y 0.7681 respectivamente.

Ahora bien en el Cuadro 7.13 se muestra la matriz de confusión del algoritmo XGBoost.

Cuadro 7.13: Matriz de confusión obtenida con el modelo de XGB.

Matriz de confusión		
	Periodo interictal (0)	Periodo preictal (1)
Periodo interictal (0)	81	27
Periodo preictal (1)	24	84

Evaluando los valores presentados en el Cuadro 7.13 se puede concluir que este algoritmo presenta una exactitud de 76.9 %, sensibilidad de 77.14 %, precisión de 75 % y puntaje F1 de 0.7676. Como se puede apreciar a partir de las cifras reportadas, los tres algoritmos mencionados tienen un rendimiento muy similar presentando variaciones de máximo 4 % en las métricas.

Capítulo 8

Conclusiones

La epilepsia es un trastorno neurológico que afecta a las personas que lo padecen y a sus familias, exponiéndolos a discriminación social. Una herramienta confiable de asistencia para el diagnóstico oportuno de la epilepsia ayudaría a reducir las afectaciones sociales y emocionales en los pacientes. Las señales de electroencefalografía (EEG) proporcionan indicadores fisiológicos para diagnosticar, tratar y rastrear la epilepsia, por lo que se han realizado diversos trabajos de análisis de las bases de datos disponibles públicamente como la de la Universidad de Bonn, el Hospital Pediátrico de Boston y el MIT, así como la proporcionada en una competencia de Kaggle por parte de la *American Epilepsy Society*. Sin embargo, la clasificación confiable de los estados ictales, interictales y preictales a partir de las señales EEG tomadas en la zona epiléptica sigue siendo un problema abierto.

En esta tesis se han propuesto y evaluado dos enfoques novedosos y prometedores para la detección de eventos epilépticos utilizando señales EEG. Se ha utilizado la transformada wavelet continua (CWT) para obtener características de las señales EEG y generar escalogramas, que posteriormente se utilizan como entrada para las arquitecturas propuestas; Ictal-net, una red neuronal convolucional (CNN) diseñada para reconocer patrones asociados con eventos ictales; y Parallel Ictal-net, una red que trabaja con bloques compuestos por operaciones convolucionales y capas de atención eficiente en paralelo.

El primer enfoque va dirigido a la arquitectura denominada Ictal-net y el procesamiento

de las señales EEG con transformaciones wavelet continuas. Este primer aporte nos brindó la información necesaria para determinar que las señales EEG sí pueden ser caracterizadas mediante escalogramas para la detección de eventos epilépticos, es decir, periodos ictales.

Respecto a PIN, se realizó un análisis exhaustivo de distintas configuraciones de redes neuronales para clasificar eventos ictales e interictales. Los resultados obtenidos superaron a los enfoques propuestos recientemente en la literatura revisada. Se identificaron estructuras de red que lograron detectar con certeza los estados ictales e interictales, considerando métricas de confiabilidad como precisión, recall y puntaje F1. La arquitectura de red denominada Parallel Ictal-net (PIN) fue seleccionada debido a su eficiencia y bajo error cuadrático medio (L2).

Si bien la caracterización de las señales EEG mediante escalogramas puede no ser tan robusta como para abordar problemas de predicción, resulta adecuada para la detección de eventos epilépticos. Además, se pueden complementar estas características con parámetros calculados en el dominio del tiempo y la frecuencia para obtener información adicional y abordar posibles limitaciones.

Ahora bien, es importante destacar que el manejo de las señales EEG presentan desafíos relacionados con el volumen y la complejidad de los datos, así como limitaciones en términos de hardware para procesar las señales completas debido a las altas frecuencias de muestreo. Sin embargo, el uso de escalogramas en conjunto con las redes neuronales convolucionales ha demostrado un mejor rendimiento al evitar arquitecturas excesivamente profundas.

Por otro lado, el uso de características obtenidas en los dominios del tiempo y de la frecuencia si bien lleva más tiempo su cálculo, éstas brindan más información logrando predecir un evento epiléptico.

Un aspecto importante por resaltar es que, en comparación con otros proyectos mencionados en el estado del arte, el algoritmo de predicción de eventos epilépticos se destaca por su capacidad de generalización, habiendo demostrado su efectividad tanto en perros como en personas.

Cabe destacar que todos los resultados reportados fueron obtenidos mediante una metodología seguida y estudiada rigurosamente. Cuidando el no cometer ningún tipo de sesgo

durante la investigación.

En conclusión, este trabajo ha logrado avances significativos en la clasificación de eventos ictales, interictales y preictales en señales EEG utilizando la transformada wavelet continua y características obtenidas de los dominios del tiempo y de la frecuencia. Los resultados obtenidos son prometedores y sientan bases sólidas para futuras investigaciones en el campo de la epileptología. Se espera que este enfoque pueda contribuir al desarrollo de herramientas de asistencia confiables para el diagnóstico y tratamiento oportuno de la epilepsia, mejorando así la calidad de vida de los pacientes y sus familias.

Bibliografía

- [1] T. Dissanayake, T. Fernando, S. Denman, S. Sridharan, and C. Fookes, “Deep Learning for Patient-Independent Epileptic Seizure Prediction Using Scalp EEG Signals,” *IEEE Sensors Journal*, vol. 21, no. 7, pp. 9377–9388, 04 2021.
- [2] H. Ocak, “Automatic detection of epileptic seizures in eeg using discrete wavelet transform and approximate entropy,” *Expert Systems with Applications*, vol. 36, no. 2, Part 1, pp. 2027–2036, 2009. [En línea]. Disponible: <https://www.sciencedirect.com/science/article/pii/S0957417407006203>
- [3] K. Polat and S. Güneş, “Classification of epileptiform eeg using a hybrid system based on decision tree classifier and fast fourier transform,” *Applied Mathematics and Computation*, vol. 187, no. 2, pp. 1017–1026, 2007. [En línea]. Disponible: <https://www.sciencedirect.com/science/article/pii/S0096300306012380>
- [4] O. Kocadagli and R. Langari, “Classification of EEG signals for epileptic seizures using hybrid artificial neural networks based wavelet transforms and fuzzy relations,” *Expert Systems with Applications*, vol. 88, pp. 419–434, 12 2017.
- [5] H. Daoud and M. A. Bayoumi, “Efficient Epileptic Seizure Prediction Based on Deep Learning,” *IEEE Transactions on Biomedical Circuits and Systems*, vol. 13, no. 5, pp. 804–813, 2019.
- [6] M. T. Jones, “Arquitecturas de aprendizaje profundo – IBM Developer,” 2017. [En línea]. Disponible: <https://developer.ibm.com/es/technologies/artificial-intelligence/articles/cc-machine-learning-deep-learning-architectures/>

- [7] G. Hernández-Nava, S. Salazar-Colores, C. Ortiz Echeverri, S. Leyva López, and J. M. Ramos Arreguin, *Ictal-net: Un diseño de CNN para la clasificación de escalogramas de electroencefalogramas con crisis convulsivas.*, 11 2022, pp. 27–38.
- [8] OPS, ILAE, and IBE, *El abordaje de la epilepsia desde el sector de la salud pública 2018*, 2018.
- [9] I. M. del Seguro Social, “Hasta siete de cada 10 derechohabientes con epilepsia logran el control de su enfermedad: Imss — sitio web .ªcercando el imss al ciudadano”, 2020. [En línea]. Disponible: <http://www.imss.gob.mx/prensa/archivo/202002/072>
- [10] OMS, “Epilepsia.” [En línea]. Disponible: <https://www.who.int/es/news-room/fact-sheets/detail/epilepsy>
- [11] D. Rai, M. P. Kerr, S. McManus, V. Jordanova, G. Lewis, and T. S. Brugha, “Epilepsy and psychiatric comorbidity: A nationally representative population-based study,” *Epilepsia*, vol. 53, no. 6, pp. 1095–1103, 2012.
- [12] J. F. Téllez-Zenteno, R. Nguyen, and L. Hernández-Ronquillo, “Lesiones, accidentes y mortalidad en epilepsia: Una revisión de sus prevalencias, factores de riesgo y prevención,” *Revista de investigación clínica*, pp. 466–479, 2010. [En línea]. Disponible: <https://www.medigraphic.com/pdfs/revinvcli/nn-2010/nn1051.pdf>
- [13] R. S. Fisher, C. Acevedo, A. Arzimanoglou, A. Bogacz, J. Helen Cross, C. E. Elger, J. Engel Jr, L. Forsgren, J. A. French, M. Glynn, D. C. Hesdorffer, B. Lee, G. W. Mathern, S. L. Mosh, E. Perucca, I. E. Scheffer, orn Tomson, M. Watanabe, and S. Wiebe, “A practical clinical definition of epilepsy,” *Epilepsia*, vol. 55, no. 4, pp. 475–482, 2014.
- [14] J. M. Almira and M. Aguilar-Domingo, *Neuromatemáticas: el lenguaje eléctrico del cerebro*. Madrid, UNKNOWN: Editorial CSIC Consejo Superior de Investigaciones Científicas, 2016. [En línea]. Disponible: <http://ebookcentral.proquest.com/lib/uamsp/detail.action?docID=4794808>

- [15] P. Boonyakitanont, A. Lek-Uthai, K. Chomtho, and J. Songsiri, “A review of feature extraction and performance evaluation in epileptic seizure detection using eeg,” *Biomedical Signal Processing and Control*, vol. 57, p. 101702, 2020.
- [16] U. R. Acharya, Y. Hagiwara, S. N. Deshpande, S. Suren, J. E. W. Koh, S. L. Oh, N. Arunkumar, E. J. Ciaccio, and C. M. Lim, “Characterization of focal eeg signals: a review,” *Future Generation Computer Systems*, vol. 91, pp. 290–299, 2019.
- [17] A. Aarabi, R. Fazel-Rezai, and Y. Aghakhani, “Eeg seizure prediction: measures and challenges,” in *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE, 2009, pp. 1864–1867.
- [18] J. P. Mueller and L. Massaron, *Machine learning for dummies*. John Wiley & Sons, 2016.
- [19] A. B. Rué, J. C. Roma, T. L. Bagén, and U. O. de Catalunya, *Deep learning: principios y fundamentos*, ser. Manual. Tecnología. UOC, 2019. [En línea]. Disponible: <https://books.google.com.mx/books?id=RKhhzQEACAAJ>
- [20] I. Mackie, S. Abramsky, C. Hankin, A. Pitts, S. S. Skiena, D. Durham, and U. M. Hinchey, *Undergraduate Topics in Computer Science*. Springer, 2010. [En línea]. Disponible: <http://www.springer.com/series/7592>
- [21] R. López García *et al.*, “Aprendizaje auto-supervisado para análisis de imágenes en dominios no convencionales: Apoyo a la diagnosis de covid-19,” B.S. thesis, 2021.
- [22] T. Chen, S. Kornblith, M. Norouzi, and G. E. Hinton, “A simple framework for contrastive learning of visual representations,” *CoRR*, vol. abs/2002.05709, 2020. [En línea]. Disponible: <https://arxiv.org/abs/2002.05709>
- [23] M. Caron, I. Misra, J. Mairal, P. Goyal, P. Bojanowski, and A. Joulin, “Unsupervised learning of visual features by contrasting cluster assignments,” *CoRR*, vol. abs/2006.09882, 2020. [En línea]. Disponible: <https://arxiv.org/abs/2006.09882>

- [24] J.-B. Grill, F. Strub, F. Alché, C. Tallec, P. H. Richemond, E. Buchatskaya, C. Doersch, B. Á. Pires, Z. D. Guo, M. G. Azar, B. Piot, K. Kavukcuoglu, R. Munos, and M. Valko, “Bootstrap your own latent: A new approach to self-supervised learning,” *CoRR*, vol. abs/2006.07733, 2020. [En línea]. Disponible: <https://arxiv.org/abs/2006.07733>
- [25] M. A. A. Fernández, *Inteligencia artificial para programadores con prisa*. Universo de Letras, 2022. [En línea]. Disponible: <https://books.google.com.mx/books?id=ieFYEAAAQBAJ>
- [26] E. S. Olivas, *Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques: Algorithms, Methods, and Techniques*. IGI Global, 2009.
- [27] S. Kulkarni, G. Harman, and W. I. O. Service), *An Elementary Introduction to Statistical Learning Theory*, ser. Wiley Series in Probability and Statistics. Hoboken, N.J.: Wiley, 2011.
- [28] SmartPanel, “¿Qué es el Deep Learning?” 04 2010. [En línea]. Disponible: <https://www.smartpanel.com/que-es-deep-learning/>
- [29] D. Calvo, “Red Neuronal Recurrente - RNN,” 12 2018. [En línea]. Disponible: <https://www.diegocalvo.es/red-neuronal-recurrente/>
- [30] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, “Attention is all you need,” in *Advances in neural information processing systems*, 2017, pp. 5998–6008.
- [31] C. Muñoz Gamboa, M. Cadena Méndez, E. Hernández Matos, and E. Sacristán Rock, *Fundamentos de la instrumentación biomédica*. Universidad Autónoma Metropolitana, 2001.
- [32] P. Recuero de los Santos Blog, “Machine Learning a tu alcance: La matriz de confusión - Think Big Empresas,” 2018. [En línea]. Disponible: <https://empresas.blogthinkbig.com/ml-a-tu-alcance-matriz-confusion/>

- [33] “Glossary of Terms,” *Machine Learning*, vol. 30, no. 2/3, pp. 271–274, 1998. [En línea]. Disponible: <http://link.springer.com/10.1023/A:1017181826899>
- [34] F. Mormann, R. G. Andrzejak, C. E. Elger, and K. Lehnertz, “Seizure prediction: The long and winding road,” pp. 314–333, 2007.
- [35] C. Cao, F. Liu, H. Tan, D. Song, W. Shu, W. Li, Y. Zhou, X. Bo, and Z. Xie, “Deep Learning and Its Applications in Biomedicine,” pp. 17–32, 02 2018.
- [36] O. Faust, Y. Hagiwara, T. J. Hong, O. S. Lih, and U. R. Acharya, “Deep learning for healthcare applications based on physiological signals: A review,” pp. 1–13, 07 2018.
- [37] S. An, C. Kang, and H. W. Lee, “Artificial Intelligence and Computational Approaches for Epilepsy,” *Journal of Epilepsy Research*, vol. 10, no. 1, pp. 8–17, 06 2020.
- [38] M.-P. Hosseini, D. Pompili, K. Elisevich, and H. Soltanian-Zadeh, “Optimized Deep Learning for EEG Big Data and Seizure Prediction BCI via Internet of Things,” *IEEE Transactions on Big Data*, vol. 3, no. 4, pp. 392–404, 11 2017.
- [39] K. Tsiouris, V. C. Pezoulas, M. Zervakis, S. Konitsiotis, D. D. Koutsouris, and D. I. Fotiadis, “A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals,” *Computers in Biology and Medicine*, vol. 99, pp. 24–37, 08 2018.
- [40] R. Hussein, H. Palangi, R. K. Ward, and Z. J. Wang, “Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals,” *Clinical Neurophysiology*, vol. 130, no. 1, pp. 25–37, 01 2019.
- [41] H. Daoud, P. Williams, and M. Bayoumi, “IoT based Efficient Epileptic Seizure Prediction System Using Deep Learning,” in *IEEE World Forum on Internet of Things, WF-IoT 2020 - Symposium Proceedings*. Institute of Electrical and Electronics Engineers Inc., 06 2020.

- [42] R. Hussein, S. Lee, R. Ward, and M. J. McKeown, “Semi-dilated convolutional neural networks for epileptic seizure prediction,” *Neural Networks*, vol. 139, pp. 212–222, 07 2021.
- [43] N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, and O. Kavehei, “A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis,” *arXiv preprint arXiv:1707.01976*, 07 2017. [En línea]. Disponible: <http://arxiv.org/abs/1707.01976>
- [44] R. E. d. S. Pinto, “Seizure prediction based on long short term memory networks,” Ph.D. dissertation, Universidade de Coimbra, 2017.
- [45] H. Khan, L. Marcuse, M. Fields, K. Swann, and B. Yener, “Focal onset seizure prediction using convolutional networks,” *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 9, pp. 2109–2118, 09 2018.
- [46] N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, S. Ippolito, and O. Kavehei, “Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram,” *Neural Networks*, vol. 105, pp. 104–111, 2018. [En línea]. Disponible: <https://www.sciencedirect.com/science/article/pii/S0893608018301485>
- [47] I. Kiral-Kornek, S. Roy, E. Nurse, B. Mashford, P. Karoly, T. Carroll, D. Payne, S. Saha, S. Baldassano, T. O’Brien, D. Grayden, M. Cook, D. Freestone, and S. Harrer, “Epileptic Seizure Prediction Using Big Data and Deep Learning: Toward a Mobile System,” *EBioMedicine*, vol. 27, pp. 103–111, 2018. [En línea]. Disponible: <https://doi.org/10.1016/j.ebiom.2017.11.032>
- [48] C. L. Liu, B. Xiao, W. H. Hsaio, and V. S. Tseng, “Epileptic Seizure Prediction with Multi-View Convolutional Neural Networks,” *IEEE Access*, vol. 7, pp. 170 352–170 361, 2019.

- [49] A. R. Ozcan and S. Erturk, “Seizure Prediction in Scalp EEG Using 3D Convolutional Neural Networks with an Image-Based Approach,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 27, no. 11, pp. 2284–2293, 2019.
- [50] Z. Yu, W. Nie, W. Zhou, F. Xu, S. Yuan, Y. Leng, and Q. Yuan, “Epileptic seizure prediction based on local mean decomposition and deep convolutional neural network,” *Journal of Supercomputing*, vol. 76, no. 5, pp. 3462–3476, 2020. [En línea]. Disponible: <https://doi.org/10.1007/s11227-018-2600-6>
- [51] K. Das, D. Daschakladar, P. P. Roy, A. Chatterjee, and S. P. Saha, “Epileptic seizure prediction by the detection of seizure waveform from the pre-ictal phase of EEG signal,” *Biomedical Signal Processing and Control*, vol. 57, p. 101720, 03 2020.
- [52] S. Muhammad Usman, S. Khalid, and M. H. Aslam, “Epileptic Seizures Prediction Using Deep Learning Techniques,” *IEEE Access*, vol. 8, pp. 39 998–40 007, 2020.
- [53] S. Muhammad Usman, S. Khalid, and S. Bashir, “A deep learning based ensemble learning method for epileptic seizure prediction,” *Computers in Biology and Medicine*, vol. 136, p. 104710, 09 2021.
- [54] R. Jana and I. Mukherjee, “Deep learning based efficient epileptic seizure prediction with EEG channel optimization,” *Biomedical Signal Processing and Control*, vol. 68, p. 102767, 07 2021.
- [55] U. Bonn, “Ukb — eeg data download.” [En línea]. Disponible: <https://www.ukbonn.de/epileptologie/arbeitsgruppen/ag-lehnertz-neurophysik/downloads/>
- [56] A. E. Society, “American epilepsy society seizure prediction challenge — kaggle,” 2014. [En línea]. Disponible: <https://www.kaggle.com/competitions/seizure-prediction/data>
- [57] A. H. Shoeb, “Application of machine learning to epileptic seizure onset detection and treatment,” Ph.D. dissertation, Massachusetts Institute of Technology, 2009.

- [58] J. Muradeli, “Overlordgolddragon/sssqueezeepy: Qol, cleanups, fixes,” 1 2022. [En línea]. Disponible: <https://doi.org/10.5281/zenodo.5080508>
- [59] Aayesha, M. B. Qureshi, M. Afzaal, M. S. Qureshi, and M. Fayaz, “Machine learning-based eeg signals classification model for epileptic seizure detection,” *Multimedia Tools and Applications*, vol. 80, pp. 17 849–17 877, 2021. [En línea]. Disponible: <https://doi.org/10.1007/s11042-021-10597-6>
- [60] Ömer Türk and M. S. Özerdem, “Epilepsy detection by using scalogram based convolutional neural network from eeg signals,” *Brain Sciences*, vol. 9, 2019. [En línea]. Disponible: <https://www.mdpi.com/2076-3425/9/5/115>
- [61] K. Shekokar, S. Dour, and G. Ahmad, “Epileptic seizure classification using lstm,” 2021, pp. 591–594.
- [62] R. S. S. Kumari and R. Abirami, “Automatic detection and classification of epileptic seizure using radial basis function and power spectral density,” 2019, pp. 6–9.
- [63] M. Bekbalanova, A. Zhunis, and Z. Duisebekov, “Epileptic seizure prediction in eeg signals using emd and dwt,” 2019, pp. 1–4.
- [64] A. Shankar, S. Dandapat, and S. Barma, “Classification of epileptic seizure from eeg signal based on hilbert vibration decomposition and deep learning,” *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 2802–2805, 2021.

Anexo 1

Análisis de componentes principales por sujeto de la base de datos proporcionada por la *American Epilepsy Society*

En el presente anexo se presentan las tablas obtenidas del análisis de componentes principales por sujeto. La primer tabla corresponde al sujeto denominado Dog_1, posteriormente se presenta Dog_2, Dog_3, Dog_4, Dog_5, Patient_1 y finalmente Patient_2. Las tablas contienen la cantidad de información proporcionada por cada canal por cada método de normalización utilizado. También se muestra la sumatoria de la información de los primeros cuatro canales que brindan mayor información, posteriormente los 8 que brindan más información y finalmente si se tomaran 12 canales. Cada grupo de canales se encuentra resaltado por un color en específico, los primeros cuatro con amarillo, seguidos de un color azul y finalmente color naranja.

Cuadro Anexo 1.1: PCA con diferentes métodos de normalización sujeto uno 'Dog_1'

Sujeto	Canal	PCA_minmax	PCS_MMScaler	PCA_SS	Información por
Dog_01	1	37.18	35.48	32.14	4 Canales
	2	14.25	18.82	21.09	71.45 76.06 72.26
	3	11.90	13.42	12.53	8 Canales
	4	8.12	8.35	6.50	90.39 91.88 89.75
	5	6.40	5.60	5.71	12 Canales
	6	5.31	4.10	4.93	97.32 97.95 97.31
	7	4.03	3.71	3.87	
	8	3.20	2.40	0.01	
	9	2.34	0.01	3.00	
	10	2.03	1.92	2.68	
	11	0.36	1.68	1.93	
	12	1.36	1.50	1.75	
	13	1.20	0.43	0.58	
	14	0.97	0.97	1.00	
	15	0.63	0.78	1.10	
	16	0.71	0.84	1.21	

Las celdas de color indican los primeros cuatro canales que brindan más información.

Las celdas de color indican las siguientes cuatro canales que brindan mayor información.

Las celdas de color indican el tercer conjunto de canales que brindan mayor información.

Los valores en negritas indican la mayor información brindada por número de canales.

Cuadro Anexo 1.2: PCA con diferentes métodos de normalización sujeto dos 'Dog_2'

Sujeto	Canal	PCA_minmax	PCS_MMScaler	PCA_SS	Información por
Dog_02	1	19.05	25.46	24.52	4 Canales
	2	13.85	15.77	15.42	53.79 60.95 60.56
	3	11.04	12.04	13.27	8 Canales
	4	9.85	7.69	0.01	79.08 84.71 83.75
	5	0.79	7.31	7.35	12 Canales
	6	1.18	6.60	6.81	94.40 96.76 96.05
	7	1.60	5.64	6.24	
	8	2.04	0.01	5.76	
	9	2.43	0.61	0.82	
	10	2.99	1.14	1.39	
	11	7.15	1.49	1.73	
	12	6.51	2.26	2.18	
	13	4.64	2.60	4.38	
	14	6.03	4.21	2.96	
	15	5.61	3.70	3.80	
	16	5.25	3.49	3.37	

Las celdas de color ■ indican los primeros cuatro canales que brindan más información.

Las celdas de color ■ indican las siguientes cuatro canales que brindan mayor información.

Las celdas de color ■ indican el tercer conjunto de canales que brindan mayor información.

Los valores en negritas indican la mayor información brindada por número de canales.

Cuadro Anexo 1.3: PCA con diferentes métodos de normalización sujeto tres 'Dog_3'

Sujeto	Canal	PCA_minmax	PCS_MMScaler	PCA_SS	Información por
Dog_03	1	14.03	15.84	13.55	4 Canales
	2	10.41	11.87	0.00	41.44 48.54 42.05
	3	8.90	10.79	11.15	8 Canales
	4	8.10	10.04	9.19	67.63 77.08 67.54
	5	7.72	0.00	8.16	12 Canales
	6	2.69	0.63	7.41	86.54 96.03 88.18
	7	3.18	1.10	3.42	
	8	6.64	2.25	4.07	
	9	3.60	3.19	4.32	
	10	3.99	4.32	4.62	
	11	4.05	8.35	5.03	
	12	6.01	5.49	6.21	
	13	5.82	5.94	6.09	
	14	5.28	7.09	5.47	
	15	4.67	6.70	5.53	
	16	4.90	6.39	5.78	

Las celdas de color indican los primeros cuatro canales que brindan más información.

Las celdas de color indican las siguientes cuatro canales que brindan mayor información.

Las celdas de color indican el tercer conjunto de canales que brindan mayor información.

Los valores en negritas indican la mayor información brindada por número de canales.

Cuadro Anexo 1.4: PCA con diferentes métodos de normalización sujeto cuatro 'Dog_4'

Sujeto	Canal	PCA_minmax	PCS_MMScaler	PCA_SS	Información por
Dog_04	1	22.46	33.34	33.57	4 Canales
	2	20.27	24.67	24.07	64.37 76.44 75.59
	3	11.94	11.05	10.54	8 Canales
	4	9.71	7.38	7.41	86.57 92.24 91.88
	5	7.27	6.31	6.86	12 Canales
	6	6.60	3.97	3.83	95.94 98.19 97.75
	7	4.84	2.79	2.94	
	8	3.49	2.74	2.66	
	9	3.25	0.00	0.00	
	10	2.57	2.09	1.99	
	11	0.64	0.43	1.69	
	12	0.77	0.52	0.60	
	13	1.20	0.85	0.74	
	14	1.90	1.44	0.91	
	15	1.65	1.24	1.12	
	16	1.45	1.18	1.07	

Las celdas de color indican los primeros cuatro canales que brindan más información.

Las celdas de color indican las siguientes cuatro canales que brindan mayor información.

Las celdas de color indican el tercer conjunto de canales que brindan mayor información.

Los valores en negritas indican la mayor información brindada por número de canales.

Cuadro Anexo 1.5: PCA con diferentes métodos de normalización sujeto cinco 'Dog_5'

Sujeto	Canal	PCA_minmax	PCS_MMScaler	PCA_SS	Información por
Dog_05	1	12.65	14.36	14.90	4 Canales
	2	10.87	12.77	12.21	42.19 49.03 45.99
	3	10.10	11.99	0.52	8 Canales
	4	8.58	0.47	10.95	68.80 76.63 72.95
	5	7.73	9.91	3.00	12 Canales
	6	2.82	2.16	7.93	88.66 94.53 92.61
	7	6.73	7.88	7.30	
	8	6.30	7.20	7.46	
	9	5.85	2.84	3.87	
	10	5.50	6.41	4.08	
	11	4.12	6.10	6.25	
	12	4.96	5.45	5.95	
	13	4.86	4.72	4.90	
	14	4.41	3.69	5.49	
	15	4.54	4.04	5.19	

Las celdas de color indican los primeros cuatro canales que brindan más información.

Las celdas de color indican las siguientes cuatro canales que brindan mayor información.

Las celdas de color indican el tercer conjunto de canales que brindan mayor información.

Los valores en negritas indican la mayor información brindada por número de canales.

Cuadro Anexo 1.6: PCA con diferentes métodos de normalización sujeto seis 'Patient_1'

Sujeto	Canal	PCA_minmax	PCS_MMScaler	PCA_SS	Información por
Patient_01	1	22.65	99.56	99.56	4 Canales
	2	14.91	0.25	0.25	59.85 99.92 99.92
	3	11.85	0.08	0.08	8 Canales
	4	10.44	0.03	0.03	80.76 99.97 99.97
	5	6.11	0.02	0.02	12 Canales
	6	1.56	0.01	0.01	94.34 99.99 99.99
	7	1.74	0.01	0.01	
	8	5.55	0.01	0.01	
	9	4.96	0.01	0.01	
	10	2.36	0.01	0.01	
	11	3.04	0.00	0.00	
	12	2.88	0.00	0.00	
	13	3.56	0.00	0.00	
	14	4.29	0.00	0.00	
	15	4.10	0.00	0.00	

Las celdas de color indican los primeros cuatro canales que brindan más información.

Las celdas de color indican las siguientes cuatro canales que brindan mayor información.

Las celdas de color indican el tercer conjunto de canales que brindan mayor información.

Los valores en negritas indican la mayor información brindada por número de canales.

Cuadro Anexo 1.7: PCA con diferentes métodos de normalización sujeto siete 'Patient_2'

Sujeto	Canal	PCA_minmax	PCS_MMScaler	PCA_SS	Información por
Patient_02	1	39.33	89.13	90.19	4 Canales
	2	15.14	4.51	2.86	71.02 96.94 96.33
	3	9.86	2.26	2.08	8 Canales
	4	6.69	1.05	1.21	88.58 98.94 98.53
	5	6.29	0.67	0.78	12 Canales
	6	4.45	0.61	0.58	95.61 99.68 99.47
	7	3.35	0.41	0.46	
	8	3.47	0.32	0.37	
	9	2.36	0.28	0.30	
	10	1.76	0.20	0.27	
	11	1.50	0.15	0.20	
	12	1.41	0.11	0.16	
	13	1.20	0.09	0.13	
	14	0.79	0.06	0.09	
	15	0.73	0.05	0.08	
	16	0.60	0.03	0.07	
	17	0.38	0.03	0.05	
	18	0.20	0.00	0.03	
	19	0.18	0.00	0.00	
	20	0.12	0.01	0.00	
	21	0.08	0.02	0.01	
	22	0.06	0.01	0.01	
	23	0.02	0.01	0.02	
	24	0.03	0.01	0.02	

Las celdas de color indican los primeros cuatro canales que brindan más información.

Las celdas de color indican las siguientes cuatro canales que brindan mayor información.

Las celdas de color indican el tercer conjunto de canales que brindan mayor información.

Los valores en negritas indican la mayor información brindada por número de canales.

Anexo 2

Análisis de la base de datos CHB-MIT

En este anexo se presenta una serie de tablas resultado de un análisis profundo de la base de datos proporcionada por el CHB y el MIT [57]. El análisis consistió en el abrir cada uno de los registros proporcionados en la base de datos, para adquirir la hora en la que comenzó el registro, la hora en la que finalizó, la duración del registro en segundos, la cantidad de muestras que contiene, si el registro contiene eventos epilépticos y en caso de ser positiva la respuesta cuantos contiene, el tiempo en el cual inició cada uno de ellos, el segundo en el que termino el periodo ictal, número de segundos que dura el evento epiléptico y el total de muestras ictales que contiene el registro. En algunos casos existen registros inexistentes entre los proporcionados en la base de datos, estos registros se marcan en color rojo dentro de las tablas. Cabe destacar que se realizo una tabla por sujeto.

Cuadro Anexo 2.1: Información proporcionada en la base de datos del MIT-CHB para el sujeto 1.

Archivo	Inicio		Fin		Duración de		Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	inicio [s]			fin [s]	[s]	[s]	Ictales	Ictales	
chb01_01.edf	11:42:54	12:42:54	12:42:54	12:42:54	3.600,00	921.600,00	0	0	0	0	0	0	0,00	0,00
chb01_02.edf	12:42:57	13:42:57	13:42:57	13:42:57	3.600,00	921.600,00	0	0	0	0	0	0	0,00	0,00
chb01_03.edf	13:43:04	14:43:04	14:43:04	14:43:04	3.600,00	921.600,00	1	2996	3036	40	10.240,00	10.240,00		
chb01_04.edf	14:43:12	15:43:12	15:43:12	15:43:12	3.600,00	921.600,00	1	1467	1494	27	6.912,00	6.912,00		
chb01_05.edf	15:43:19	16:43:19	16:43:19	16:43:19	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_06.edf	16:43:26	17:43:26	17:43:26	17:43:26	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_07.edf	17:43:33	18:43:33	18:43:33	18:43:33	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_08.edf	18:43:40	19:43:40	19:43:40	19:43:40	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_09.edf	19:43:56	20:43:56	20:43:56	20:43:56	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_10.edf	20:44:07	21:44:07	21:44:07	21:44:07	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_11.edf	21:44:14	22:44:14	22:44:14	22:44:14	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_12.edf	22:44:22	23:44:22	23:44:22	23:44:22	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_13.edf	23:44:29	0:44:29	0:44:29	0:44:29	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_14.edf	0:44:37	1:44:37	1:44:37	1:44:37	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb01_15.edf	1:44:44	2:44:44	2:44:44	2:44:44	3.600,00	921.600,00	1	1732	1772	40	10.240,00	10.240,00		
chb01_16.edf	2:44:51	3:44:51	3:44:51	3:44:51	3.600,00	921.600,00	1	1015	1066	51	13.056,00	13.056,00		

Tabla Anexo 2.1 contia de página anterior

Archivo	Inicio	Fin	Duración de registro [s]	Muestras	Núm de eventos	Tiempo	Tiempo inicio [s]	fin [s]	Duración [s]	Muestras Ictales
	[hrs]	[hrs]								
chb01_17.edf	3:44:59	4:44:59	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_18.edf	4:45:06	5:45:06	3.600,00	921.600,00	1	1720	1810	90	23.040,00	
chb01_19.edf	5:45:13	6:45:13	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_20.edf	6:45:20	7:29:43	2.663,00	681.728,00	0	0	0	0	0	0,00
chb01_21.edf	7:33:46	8:33:46	3.600,00	921.600,00	1	327	420	93	23.808,00	
chb01_22.edf	8:33:49	9:33:49	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_23.edf	9:33:58	10:33:58	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_24.edf	10:34:06	11:34:06	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_25.edf	11:34:14	12:34:14	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_26.edf	12:34:22	13:13:07	2.325,00	595.200,00	1	1862	1963	101	25.856,00	
chb01_27.edf	13:13:21	13:23:21	600,00	153.600,00	0	0	0	0	0	0,00
chb01_28.edf										
chb01_29.edf	13:24:08	14:24:08	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_30.edf	14:24:15	15:24:15	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_31.edf	15:24:24	16:24:24	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_32.edf	16:24:32	17:24:32	3.600,00	921.600,00	0	0	0	0	0	0,00
chb01_33.edf	17:24:39	18:24:39	3.600,00	921.600,00	0	0	0	0	0	0,00

Tabla Anexo 2.1 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb01_34.edf	18:24:46	19:24:46	3.600,00	921.600,00	0	0	0	0	0,00
chb01_35.edf									
chb01_36.edf	22:14:43	23:14:43	3.600,00	921.600,00	0	0	0	0	0,00
chb01_37.edf	23:14:46	0:14:46	3.600,00	921.600,00	0	0	0	0	0,00
chb01_38.edf	0:14:53	1:14:53	3.600,00	921.600,00	0	0	0	0	0,00
chb01_39.edf	1:15:01	2:15:01	3.600,00	921.600,00	0	0	0	0	0,00
chb01_40.edf	2:15:08	3:15:08	3.600,00	921.600,00	0	0	0	0	0,00
chb01_41.edf	3:15:15	4:15:15	3.600,00	921.600,00	0	0	0	0	0,00
chb01_42.edf	4:15:22	5:15:22	3.600,00	921.600,00	0	0	0	0	0,00
chb01_43.edf	5:15:29	6:15:29	3.600,00	921.600,00	0	0	0	0	0,00
chb01_44.edf									
chb01_45.edf									
chb01_46.edf	8:15:51	9:15:51	3.600,00	921.600,00	0	0	0	0	0,00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.2: Información proporcionada en la base de datos del MIT-CHB para el sujeto 2.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	Ictales	Ictales
chb02_01.edf	15:29:39	16:29:39	16:29:39	16:29:39	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_02.edf	17:29:49	18:29:49	18:29:49	18:29:49	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_03.edf	18:29:56	19:29:56	19:29:56	19:29:56	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_04.edf	19:30:03	20:30:03	20:30:03	20:30:03	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_05.edf	20:30:10	21:30:10	21:30:10	21:30:10	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_06.edf	21:30:18	22:30:18	22:30:18	22:30:18	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_07.edf	22:30:25	23:30:25	23:30:25	23:30:25	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_08.edf	23:30:33	0:30:33	0:30:33	0:30:33	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_09.edf	0:30:40	1:30:40	1:30:40	1:30:40	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_10.edf	1:30:47	2:30:47	2:30:47	2:30:47	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_11.edf	2:30:55	3:30:55	3:30:55	3:30:55	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_12.edf	3:31:02	4:31:02	4:31:02	4:31:02	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_13.edf	4:31:09	5:31:09	5:31:09	5:31:09	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_14.edf	5:31:17	6:31:17	6:31:17	6:31:17	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_15.edf	8:31:38	9:31:38	9:31:38	9:31:38	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb02_16.edf	9:31:46	9:47:45	9:47:45	9:47:45	959,00	245.504,00	1	130	212	82	20.992,00	82	20.992,00

Tabla Anexo 2.2 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb02_16+.edf	10:50:23	11:50:23	3.600,00	921.600,00	1	2972	3053	81	20.736,00
chb02_17.edf	11:50:31	12:50:31	3.600,00	921.600,00	0	0	0	0	0,00
chb02_18.edf	12:50:38	13:50:38	3.600,00	921.600,00	0	0	0	0	0,00
chb02_19.edf	13:50:45	14:50:45	3.600,00	921.600,00	1	3369	3378	9	2.304,00
chb02_20.edf	14:50:53	15:50:53	3.600,00	921.600,00	0	0	0	0	0,00
chb02_21.edf	15:51:00	16:51:00	3.600,00	921.600,00	0	0	0	0	0,00
chb02_22.edf	16:51:08	17:51:08	3.600,00	921.600,00	0	0	0	0	0,00
chb02_23.edf	19:02:27	20:02:27	3.600,00	921.600,00	0	0	0	0	0,00
chb02_24.edf	20:02:40	21:02:40	3.600,00	921.600,00	0	0	0	0	0,00
chb02_25.edf	21:02:48	22:02:48	3.600,00	921.600,00	0	0	0	0	0,00
chb02_26.edf	22:02:55	23:02:55	3.600,00	921.600,00	0	0	0	0	0,00
chb02_27.edf	23:03:03	0:03:03	3.600,00	921.600,00	0	0	0	0	0,00
chb02_28.edf	0:03:10	1:03:10	3.600,00	921.600,00	0	0	0	0	0,00
chb02_29.edf	1:03:18	2:03:18	3.600,00	921.600,00	0	0	0	0	0,00
chb02_30.edf	2:03:25	3:03:25	3.600,00	921.600,00	0	0	0	0	0,00
chb02_31.edf	3:03:33	4:03:33	3.600,00	921.600,00	0	0	0	0	0,00
chb02_32.edf	4:03:40	5:03:40	3.600,00	921.600,00	0	0	0	0	0,00

Tabla Anexo 2.2 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb02_33.edf	5:03:47	6:03:47	3.600,00	921.600,00	0	0	0	0	0,00
chb02_34.edf	6:03:55	7:03:55	3.600,00	921.600,00	0	0	0	0	0,00
chb02_35.edf	7:04:02	8:04:02	3.600,00	921.600,00	0	0	0	0	0,00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.3: Información proporcionada en la base de datos del MIT-CHB para el sujeto 3.

Archivo	Inicio		Fin		Duración de		Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	inicio [s]			fin [s]	[s]	[s]	Ictales	Ictales	
chb03_01.edf	13:23:36	14:23:36	14:23:36	14:23:36	3.600,00	921.600,00	1	362	414	52	13.312,00	13.312,00		
chb03_02.edf	14:23:39	15:23:39	15:23:39	15:23:39	3.600,00	921.600,00	1	731	796	65	16.640,00	16.640,00		
chb03_03.edf	15:23:47	16:23:47	16:23:47	16:23:47	3.600,00	921.600,00	1	432	501	69	17.664,00	17.664,00		
chb03_04.edf	16:23:54	17:23:54	17:23:54	17:23:54	3.600,00	921.600,00	1	2162	2214	52	13.312,00	13.312,00		
chb03_05.edf	17:24:01	18:24:01	18:24:01	18:24:01	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_06.edf	18:24:08	19:24:08	19:24:08	19:24:08	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_07.edf	19:24:15	20:24:15	20:24:15	20:24:15	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_08.edf	20:24:22	21:24:22	21:24:22	21:24:22	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_09.edf	21:24:30	22:24:30	22:24:30	22:24:30	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_10.edf	22:24:37	23:24:37	23:24:37	23:24:37	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_11.edf	23:24:44	0:24:44	0:24:44	0:24:44	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_12.edf	0:24:51	1:24:51	1:24:51	1:24:51	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_13.edf	1:24:59	2:24:59	2:24:59	2:24:59	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_14.edf	2:25:06	3:25:06	3:25:06	3:25:06	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_15.edf	3:25:13	4:25:13	4:25:13	4:25:13	3.600,00	921.600,00	0	0	0	0	0,00	0,00		
chb03_16.edf	4:25:20	5:25:20	5:25:20	5:25:20	3.600,00	921.600,00	0	0	0	0	0,00	0,00		

Tabla Anexo 2.3 contia de página anterior

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	Ictales	Ictales
chb03_17.edf	5:25:27	6:25:27	6:25:27	6:25:27	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_18.edf	6:25:34	7:25:34	7:25:34	7:25:34	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_19.edf	7:25:42	8:25:42	8:25:42	8:25:42	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_20.edf	8:25:51	9:25:57	9:25:57	9:25:57	3.606,00	923.136,00	0	0	0	0	0	0	0,00
chb03_21.edf	12:38:31	13:38:31	13:38:31	13:38:31	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_22.edf	13:38:38	14:38:38	14:38:38	14:38:38	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_23.edf	14:38:45	15:38:45	15:38:45	15:38:45	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_24.edf	16:39:05	17:39:05	17:39:05	17:39:05	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_25.edf	15:38:57	16:38:57	16:38:57	16:38:57	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_26.edf	17:39:12	18:39:12	18:39:12	18:39:12	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_27.edf	18:39:20	19:39:20	19:39:20	19:39:20	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_28.edf	19:39:27	20:39:27	20:39:27	20:39:27	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_29.edf	20:39:34	21:39:34	21:39:34	21:39:34	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_30.edf	21:39:42	22:39:42	22:39:42	22:39:42	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_31.edf	16:50:17	17:50:17	17:50:17	17:50:17	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_32.edf	17:50:25	18:50:25	18:50:25	18:50:25	3.600,00	921.600,00	0	0	0	0	0	0	0,00
chb03_33.edf	18:50:32	19:50:32	19:50:32	19:50:32	3.600,00	921.600,00	0	0	0	0	0	0	0,00

Tabla Anexo 2.3 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb03_34.edf	1:51:23	2:51:23	3.600,00	921.600,00	1	1982	2029	47	12.032,00
chb03_35.edf	2:51:30	3:51:30	3.600,00	921.600,00	1	2592	2656	64	16.384,00
chb03_36.edf	4:51:45	5:51:45	3.600,00	921.600,00	1	1725	1778	53	13.568,00
chb03_37.edf	21:15:28	22:15:28	3.600,00	921.600,00	0	0	0	0	0,00
chb03_38.edf	22:15:35	23:15:35	3.600,00	921.600,00	0	0	0	0	0,00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.4: Información proporcionada en la base de datos del MIT-CHB para el sujeto 4.

Archivo	Inicio		Fin		Duración de		Muestras		Núm de		Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	registro [s]	inicio [s]	fin [s]	eventos	inicio [s]	fin [s]	[s]	[s]	Ictales	Ictales	
chb04_01.edf	18:01:25				-64.885,00	-16.610.560,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_02.edf	22:02:15		2:02:15		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_03.edf	2:02:23		6:02:23		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_04.edf	6:02:30		10:02:30		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_05.edf	10:02:37		12:41:33		9.536,00	2.441.216,00	1	7804	7853	7853	49	12.544,00				
chb04_06.edf	12:45:50		16:45:50		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_07.edf	16:45:53		18:50:49		7.496,00	1.918.976,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_08.edf	18:53:30		22:53:30		14.400,00	3.686.400,00	1	6446	6557	6557	111	28.416,00				
chb04_09.edf	22:53:33		2:53:33		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_10.edf	2:53:41		6:53:41		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_11.edf	6:53:48		8:14:20		4.832,00	1.236.992,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_12.edf	8:16:27		12:16:47		14.420,00	3.691.520,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_13.edf	12:17:31		16:17:29		14.398,00	3.685.888,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_14.edf	16:18:02		20:18:20		14.418,00	3.691.008,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_15.edf	20:19:43		0:19:43		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00
chb04_16.edf	0:19:51		4:19:51		14.400,00	3.686.400,00	0	0	0	0	0	0	0	0	0,00	0,00

Tabla Anexo 2.4 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras Ictales
						inicio [s]	fin [s]		
chb04_17.edf	4:19:59	8:08:51	13.732,00	3.515.392,00	0	0	0	0	0,00
chb04_18.edf	8:11:11	12:11:36	14.425,00	3.692.800,00	0	0	0	0	0,00
chb04_19.edf	12:41:24	16:41:24	14.400,00	3.686.400,00	0	0	0	0	0,00
chb04_20.edf			0,00	0,00	0	0	0	0	0,00
chb04_21.edf	20:41:40	0:41:40	14.400,00	3.686.400,00	0	0	0	0	0,00
chb04_22.edf	0:41:48	4:41:48	14.400,00	3.686.400,00	0	0	0	0	0,00
chb04_23.edf	4:41:55	11:41:48	25.193,00	6.449.408,00	0	0	0	0	0,00
chb04_24.edf	7:41:42	11:41:48	14.406,00	3.687.936,00	0	0	0	0	0,00
chb04_25.edf	11:46:02	15:46:02	14.400,00	3.686.400,00	0	0	0	0	0,00
chb04_26.edf	15:46:10	19:46:10	14.400,00	3.686.400,00	0	0	0	0	0,00
chb04_27.edf	19:46:17	23:46:44	14.427,00	3.693.312,00	0	0	0	0	0,00
chb04_28.edf	0:04:47	4:05:10	14.423,00	3.692.288,00	2	1679	1781	102	26.112,00
chb04_29.edf	4:06:56	8:06:59	14.403,00	3.687.168,00	0	0	0	0	0,00
chb04_30.edf	8:07:45	12:07:45	14.400,00	3.686.400,00	0	0	0	0	0,00
chb04_31.edf	12:07:53	16:07:53	14.400,00	3.686.400,00	0	0	0	0	0,00
chb04_32.edf	16:08:00	20:08:00	14.400,00	3.686.400,00	0	0	0	0	0,00
						3782	3898	116	29.696,00

Tabla Anexo 2.4 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras	
						inicio [s]	fin [s]		Ictales	Ictales
chb04_33.edf	20:08:08	0:08:08	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_34.edf	0:08:16	4:08:16	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_35.edf	4:08:24	8:08:24	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_36.edf	8:08:31	12:08:31	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_37.edf	12:08:39	13:42:12	5.613,00	1.436.928,00	0	0	0	0	0	0,00
chb04_38.edf	14:37:59	18:37:59	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_39.edf	18:38:02	22:38:02	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_40.edf	22:38:10	2:38:10	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_41.edf	2:38:18	6:38:18	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb04_42.edf	6:38:25	8:15:28	5.823,00	1.490.688,00	0	0	0	0	0	0,00
chb04_43.edf	8:17:50	12:17:50	14.400,00	3.686.400,00	0	0	0	0	0	0,00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.5: Información proporcionada en la base de datos del MIT-CHB para el sujeto 5.

Archivo	Inicio		Fin		Duración de		Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	inicio [s]			fin [s]	[s]	[s]	Ictales	Ictales	
chb05_01.edf	17:20:05	18:20:15	3.610,00	924.160,00	0	0	0	0	0	0	0	0,00	0,00	
chb05_02.edf	18:20:57	19:20:57	3.600,00	921.600,00	0	0	0	0	0	0	0	0,00	0,00	
chb05_03.edf	19:21:04	20:21:04	3.600,00	921.600,00	0	0	0	0	0	0	0	0,00	0,00	
chb05_04.edf	20:21:11	21:21:11	3.600,00	921.600,00	0	0	0	0	0	0	0	0,00	0,00	
chb05_05.edf	21:21:19	22:21:19	3.600,00	921.600,00	0	0	0	0	0	0	0	0,00	0,00	
chb05_06.edf	22:21:25	23:21:25	3.600,00	921.600,00	1	417	532	115	29.440,00					
chb05_07.edf	23:21:32	0:21:32	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_08.edf	0:21:39	1:21:39	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_09.edf	1:21:46	2:21:46	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_10.edf	2:21:53	3:21:53	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_11.edf	3:22:01	4:22:01	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_12.edf	4:22:08	5:22:08	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_13.edf	5:22:15	6:22:15	3.600,00	921.600,00	1	1086	1196	110	28.160,00					
chb05_14.edf	6:22:21	7:22:21	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_15.edf	7:22:28	8:22:28	3.600,00	921.600,00	0	0	0	0	0,00					
chb05_16.edf	8:22:35	9:22:35	3.600,00	921.600,00	1	2317	2413	96	24.576,00					

Tabla Anexo 2.5 contia de página anterior

Archivo	Inicio	Fin	Duración de registro [s]	Muestras	Núm de eventos	Tiempo	Tiempo	Duración	Muestras
	[hrs]	[hrs]				inicio [s]	fin [s]		
chb05_17.edf	9:22:42	10:22:42	3.600,00	921.600,00	1	2451	2571	120	30.720,00
chb05_18.edf	10:22:50	11:22:50	3.600,00	921.600,00	0	0	0	0	0,00
chb05_19.edf	11:22:57	12:22:57	3.600,00	921.600,00	0	0	0	0	0,00
chb05_20.edf	12:23:04	13:23:04	3.600,00	921.600,00	0	0	0	0	0,00
chb05_21.edf	13:23:11	14:23:11	3.600,00	921.600,00	0	0	0	0	0,00
chb05_22.edf	14:23:17	15:23:17	3.600,00	921.600,00	1	2348	2465	117	29.952,00
chb05_23.edf	15:23:24	16:23:24	3.600,00	921.600,00	0	0	0	0	0,00
chb05_24.edf	16:23:31	17:23:31	3.600,00	921.600,00	0	0	0	0	0,00
chb05_25.edf	17:23:38	18:23:38	3.600,00	921.600,00	0	0	0	0	0,00
chb05_26.edf	18:23:46	19:23:46	3.600,00	921.600,00	0	0	0	0	0,00
chb05_27.edf	19:23:53	20:23:53	3.600,00	921.600,00	0	0	0	0	0,00
chb05_28.edf	20:24:00	21:24:00	3.600,00	921.600,00	0	0	0	0	0,00
chb05_29.edf	21:24:07	22:24:07	3.600,00	921.600,00	0	0	0	0	0,00
chb05_30.edf	22:24:14	23:24:14	3.600,00	921.600,00	0	0	0	0	0,00
chb05_31.edf	23:24:21	0:24:21	3.600,00	921.600,00	0	0	0	0	0,00
chb05_32.edf	0:24:28	1:24:28	3.600,00	921.600,00	0	0	0	0	0,00
chb05_33.edf	1:24:35	2:24:35	3.600,00	921.600,00	0	0	0	0	0,00

Tabla Anexo 2.5 contia de página anterior

Archivo	Inicio	Fin	Duración de registro [s]	Muestras	Núm de eventos	Tiempo	Tiempo	Duración	Muestras
	[hrs]	[hrs]				inicio [s]	fin [s]		
chb05_34.edf	2:24:42	3:24:42	3.600,00	921.600,00	0	0	0	0	0,00
chb05_35.edf	3:24:49	4:24:49	3.600,00	921.600,00	0	0	0	0	0,00
chb05_36.edf	4:24:56	5:24:56	3.600,00	921.600,00	0	0	0	0	0,00
chb05_37.edf	5:25:03	6:25:03	3.600,00	921.600,00	0	0	0	0	0,00
chb05_38.edf	6:25:10	7:25:10	3.600,00	921.600,00	0	0	0	0	0,00
chb05_39.edf	7:25:17	8:25:17	3.600,00	921.600,00	0	0	0	0	0,00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.6: Información proporcionada en la base de datos del MIT-CHB para el sujeto 6.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]		Ictales	Ictales
chb06_01.edf	19:08:32	23:08:59	14,427,00	3,693,312,00	3	1724	1738	14	3,584,00			
chb06_02.edf	23:09:34	3:09:34	14,400,00	3,686,400,00	0	0	0	0	0,00			
chb06_03.edf	3:09:42	7:09:42	14,400,00	3,686,400,00	0	0	0	0	0,00			
chb06_04.edf	7:09:51	10:50:52	13,261,00	3,394,816,00	2	327	347	20	5,120,00			
chb06_05.edf	10:51:20	14:51:20	14,400,00	3,686,400,00	0	0	0	0	0,00			
chb06_06.edf	14:51:23	18:51:23	14,400,00	3,686,400,00	0	0	0	0	0,00			
chb06_07.edf	18:51:31	22:51:31	14,400,00	3,686,400,00	0	0	0	0	0,00			
chb06_08.edf	22:51:39	2:51:39	14,400,00	3,686,400,00	0	0	0	0	0,00			
chb06_09.edf	2:51:47	6:51:47	14,400,00	3,686,400,00	1	12500	12516	16	4,096,00			
chb06_10.edf	6:51:54	10:51:54	14,400,00	3,686,400,00	1	10833	10845	12	3,072,00			
chb06_11.edf					0	0	0	0	0			
chb06_12.edf	14:52:10	18:52:10	14,400,00	3,686,400,00	0	0	0	0	0,00			
chb06_13.edf	18:52:20	22:52:20	14,400,00	3,686,400,00	1	506	519	13	3,328,00			

Tabla Anexo 2.6 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras	
									Ictales	Muestras
chb06_14.edf	22:52:35	2:52:35	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb06_15.edf	2:52:43	6:52:43	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb06_16.edf	6:52:51	7:43:21	3.030,00	775.680,00	0	0	0	0	0	0,00
chb06_17.edf	7:45:51	11:45:51	14.400,00	3.686.400,00	0	0	0	0	0	0,00
chb06_18.edf	11:45:55	13:58:03	7.928,00	2.029.568,00	1	7799	7811	12	12	3.072,00
chb06_19.edf					0	0	0	0	0	0,00
chb06_....edf					0	0	0	0	0	0,00
chb06_23.edf					0	0	0	0	0	0,00
chb06_24.edf	8:23:24	12:23:24	14.400,00	3.686.400,00	1	9387	9403	16	16	4.096,00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.7: Información proporcionada en la base de datos del MIT-CHB para el sujeto 7.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Tiempo		Muestras Ictales
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	
chb07_01.edf	16:58:28	20:58:39	14,411.00	3,689,216.00	0	0	0	0	0	0	0.00	
chb07_02.edf	21:00:13	1:00:13	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_03.edf	1:00:21	5:00:21	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_04.edf	5:00:29	9:00:29	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_05.edf	9:00:36	13:00:36	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_06.edf	13:00:44	14:22:44	4,920.00	1,259,520.00	0	0	0	0	0	0	0.00	
chb07_07.edf	14:23:26	15:41:06	4,660.00	1,192,960.00	0	0	0	0	0	0	0.00	
chb07_08.edf	15:45:54	19:45:54	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_09.edf	19:45:58	23:45:58	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_10.edf	23:46:06	3:46:06	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_11.edf	3:46:13	7:46:13	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_12.edf	7:46:22	11:46:22	14,400.00	3,686,400.00	1	4920	5006	86	22,016.00			
chb07_13.edf	11:46:29	12:48:35	3,726.00	953,856.00	1	3285	3381	96	24,576.00			
chb07_14.edf	12:48:54	16:48:54	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_15.edf	16:48:58	20:48:58	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb07_16.edf	20:49:06	0:49:06	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	

Tabla Anexo 2.7 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras Ictales
						inicio [s]	fin [s]		
chb07_17.edf	0:49:19	4:49:19	14,400.00	3,686,400.00	0	0	0	0	0.00
chb07_18.edf	4:49:28	8:10:28	12,060.00	3,087,360.00	0	0	0	0	0.00
chb07_19.edf	8:10:28	12:12:43	14,535.00	3,720,960.00	1	13688	13831	143	36,608.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.8: Información proporcionada en la base de datos del MIT-CHB para el sujeto 8.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]		Ictales	Ictales
chb08_01.edf							0	0	0	0	0	0.00
chb08_02.edf	12:28:57	13:28:57	13:28:57	13:28:57	3,600.00	921,600.00	1	2670	2841	171	43,776.00	
chb08_03.edf	13:28:59	14:28:59	14:28:59	14:28:59	3,600.00	921,600.00	0	0	0	0	0.00	
chb08_04.edf	14:29:07	15:29:07	15:29:07	15:29:07	3,600.00	921,600.00	0	0	0	0	0.00	
chb08_05.edf	15:29:14	16:29:14	16:29:14	16:29:14	3,600.00	921,600.00	1	2856	3046	190	48,640.00	
chb08_06.edf							0	0	0	0	0	
chb08_....edf							0	0	0	0	0	
chb08_09.edf							0	0	0	0	0	
chb08_10.edf	19:36:54	20:36:54	20:36:54	20:36:54	3,600.00	921,600.00	0	0	0	0	0.00	
chb08_11.edf	20:37:01	21:37:01	21:37:01	21:37:01	3,600.00	921,600.00	1	2988	3122	134	34,304.00	
chb08_12.edf	21:37:08	22:37:08	22:37:08	22:37:08	3,600.00	921,600.00	0	0	0	0	0.00	
chb08_13.edf	22:37:16	23:37:16	23:37:16	23:37:16	3,600.00	921,600.00	1	2417	2577	160	40,960.00	
chb08_14.edf	23:37:23	0:37:23	0:37:23	0:37:23	3,600.00	921,600.00	0	0	0	0	0.00	
chb08_15.edf	0:37:31	1:37:31	1:37:31	1:37:31	3,600.00	921,600.00	0	0	0	0	0.00	
chb08_16.edf	1:37:38	2:37:38	2:37:38	2:37:38	3,600.00	921,600.00	0	0	0	0	0.00	
chb08_17.edf	2:37:46	3:37:46	3:37:46	3:37:46	3,600.00	921,600.00	0	0	0	0	0.00	

Tabla Anexo 2.8 contia de página anterior

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]		Ictales	Ictales
chb08_18.edf	3:37:53	4:37:53	3,600.00	921,600.00	0	0	0	0	0	0	0	0.00
chb08_19.edf	4:38:01	5:38:01	3,600.00	921,600.00	0	0	0	0	0	0	0	0.00
chb08_20.edf	5:38:08	6:38:08	3,600.00	921,600.00	0	0	0	0	0	0	0	0.00
chb08_21.edf	6:38:16	7:38:16	3,600.00	921,600.00	1	2083	2347	264	67,584.00			
chb08_22.edf	7:38:23	8:38:23	3,600.00	921,600.00	0	0	0	0	0	0	0	0.00
chb08_23.edf	8:38:31	9:38:31	3,600.00	921,600.00	0	0	0	0	0	0	0	0.00
chb08_24.edf	9:38:38	10:38:38	3,600.00	921,600.00	0	0	0	0	0	0	0	0.00
chb08_25.edf					0	0	0	0	0	0	0	0.00
chb08_....edf					0	0	0	0	0	0	0	0.00
chb08_28.edf					0	0	0	0	0	0	0	0.00
chb08_29.edf	13:51:25	14:51:48	3,623.00	927,488.00	0	0	0	0	0	0	0	0.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.9: Información proporcionada en la base de datos del MIT-CHB para el sujeto 9.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Tiempo		Muestras Ictales
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	
chb09_01.edf	17:59:37	20:13:20	8,023.00	2,053,888.00	0	0	0	0	0	0	0.00	
chb09_02.edf	20:14:28	0:14:27	14,399.00	3,686,144.00	0	0	0	0	0	0	0.00	
chb09_03.edf	0:20:27	4:20:27	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb09_04.edf	4:20:30	8:20:45	14,415.00	3,690,240.00	0	0	0	0	0	0	0.00	
chb09_05.edf	8:21:34	12:21:34	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb09_06.edf	12:21:42	16:21:41	14,399.00	3,686,144.00	1	12231	12295	64	16,384.00			
chb09_07.edf	16:22:09	20:22:09	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb09_08.edf	20:22:17	0:22:17	14,400.00	3,686,400.00	2	2951	3030	79	20,224.00			
chb09_09.edf	0:22:25	4:22:25	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb09_10.edf	4:22:33	8:22:33	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb09_11.edf	8:22:40	12:22:40	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb09_12.edf	12:22:47	16:22:47	14,400.00	3,686,400.00	0	0	0	0	0	0	0.00	
chb09_13.edf	16:23:00	20:23:05	14,405.00	3,687,680.00	0	0	0	0	0	0	0.00	
chb09_14.edf	20:23:54	0:24:05	14,411.00	3,689,216.00	0	0	0	0	0	0	0.00	
chb09_15.edf	0:26:59	4:27:20	14,421.00	3,691,776.00	0	0	0	0	0	0	0.00	

Tabla Anexo 2.9 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb09_16.edf	4:28:46	8:15:17	13,591.00	3,479,296.00	0	0	0	0	0.00
chb09_17.edf	8:16:09	8:32:23	974.00	249,344.00	0	0	0	0	0.00
chb09_18.edf	8:34:42	12:34:42	14,400.00	3,686,400.00	0	0	0	0	0.00
chb09_19.edf	12:34:46	14:09:46	5,700.00	1,459,200.00	1	5299	5361	62	15,872.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.10: Información proporcionada en la base de datos del MIT-CHB para el sujeto 10.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras		
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]		Ictales	Totales	
chb10_01.edf	17:52:43	19:53:03	19:53:03	19:53:03	7,220.00	1,848,320.00	0	0	0	0	0	0.00	0.00
chb10_02.edf	19:53:45	21:53:45	21:53:45	21:53:45	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_03.edf	21:53:52	23:53:52	23:53:52	23:53:52	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_04.edf	23:54:00	1:54:00	1:54:00	1:54:00	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_05.edf	1:54:07	3:54:07	3:54:07	3:54:07	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_06.edf	3:54:15	5:54:15	5:54:15	5:54:15	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_07.edf	5:54:23	7:54:23	7:54:23	7:54:23	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_08.edf	7:54:30	9:54:30	9:54:30	9:54:30	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_....edf							0	0	0	0	0	0	0
chb10_12.edf	15:55:00	17:55:00	17:55:00	17:55:00	7,200.00	1,843,200.00	1	6313	6348	35	8,960.00		
chb10_13.edf	17:55:08	19:55:08	19:55:08	19:55:08	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_14.edf	19:55:15	21:55:15	21:55:15	21:55:15	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_15.edf	21:55:23	23:55:23	23:55:23	23:55:23	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_16.edf	23:55:30	1:55:30	1:55:30	1:55:30	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_17.edf	1:55:37	3:55:37	3:55:37	3:55:37	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00
chb10_18.edf	3:55:45	5:55:45	5:55:45	5:55:45	7,200.00	1,843,200.00	0	0	0	0	0	0.00	0.00

Tabla Anexo 2.10 contía de página anterior

Archivo	Inicio		Fin [hrs]	Duración de registro [s]		Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras	
	[hrs]	[hrs]		inicio [s]	fin [s]			Ictales	Ictales			
chb10_19.edf	5:55:52	7:55:52	7:55:52	7,200.00	1,843,200.00	0	0	0	0	0	0	0.00
chb10_20.edf	7:56:00	9:56:12	9:56:12	7,212.00	1,846,272.00	1	6888	6958	6958	70	17,920.00	17,920.00
chb10_21.edf	9:58:35	11:58:35	11:58:35	7,200.00	1,843,200.00	0	0	0	0	0	0	0.00
chb10_22.edf	11:58:43	13:58:43	13:58:43	7,200.00	1,843,200.00	0	0	0	0	0	0	0.00
chb10_....edf						0	0	0	0	0	0	0.00
chb10_27.edf	22:02:08	0:02:26	0:02:26	7,218.00	1,847,808.00	1	2382	2447	2447	65	16,640.00	16,640.00
chb10_28.edf	0:03:04	2:03:04	2:03:04	7,200.00	1,843,200.00	0	0	0	0	0	0	0.00
chb10_29.edf						0	0	0	0	0	0	0.00
chb10_30.edf	4:03:19	6:03:32	6:03:32	7,213.00	1,846,528.00	1	3021	3079	3079	58	14,848.00	14,848.00
chb10_31.edf	6:04:00	8:04:21	8:04:21	7,221.00	1,848,576.00	1	3801	3877	3877	76	19,456.00	19,456.00
chb10_....edf						0	0	0	0	0	0	0.00
chb10_38.edf	14:33:05	16:33:05	16:33:05	7,200.00	1,843,200.00	1	4618	4707	4707	89	22,784.00	22,784.00
chb10_....edf						0	0	0	0	0	0	0.00
chb10_89.edf	16:21:55	18:21:55	18:21:55	7,200.00	1,843,200.00	1	1383	1437	1437	54	13,824.00	13,824.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.11: Información proporcionada en la base de datos del MIT-CHB para el sujeto 11.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración		Muestras Ictales
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	
chb11_01.edf	14:19:16	15:19:14	14:19:16	15:19:14	3,598.00	921,088.00	0	0	0	0	0	0.00
chb11_02.edf	15:19:43	16:19:43	15:19:43	16:19:43	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_03.edf	16:19:50	17:19:50	16:19:50	17:19:50	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_04.edf	17:19:57	18:19:57	17:19:57	18:19:57	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_05.edf	18:20:03	19:20:03	18:20:03	19:20:03	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_06.edf	19:20:10	20:20:10	19:20:10	20:20:10	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_07.edf	20:20:17	21:20:17	20:20:17	21:20:17	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_08.edf	21:20:24	22:20:24	21:20:24	22:20:24	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_09.edf	22:20:31	23:20:31	22:20:31	23:20:31	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_10.edf	23:20:37	0:20:37	23:20:37	0:20:37	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_11.edf	0:20:44	1:20:44	0:20:44	1:20:44	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_12.edf	1:20:51	2:20:51	1:20:51	2:20:51	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_13.edf	2:20:58	3:20:58	2:20:58	3:20:58	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_14.edf	3:21:04	4:21:04	3:21:04	4:21:04	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_15.edf	4:21:11	5:21:11	4:21:11	5:21:11	3,600.00	921,600.00	0	0	0	0	0	0.00
chb11_16.edf	5:21:18	6:21:18	5:21:18	6:21:18	3,600.00	921,600.00	0	0	0	0	0	0.00

Tabla Anexo 2.11 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras Ictales
						inicio [s]	fin [s]		
chb11_17.edf	6:21:25	7:21:25	3,600.00	921,600.00	0	0	0	0	0.00
chb11_18.edf	7:21:32	8:21:32	3,600.00	921,600.00	0	0	0	0	0.00
chb11_19.edf	8:21:39	9:21:39	3,600.00	921,600.00	0	0	0	0	0.00
chb11_....edf					0	0	0	0	0
chb11_24.edf	13:22:16	14:22:16	3,600.00	921,600.00	0	0	0	0	0.00
chb11_25.edf	14:22:23	15:22:23	3,600.00	921,600.00	0	0	0	0	0.00
chb11_26.edf	16:22:36	16:22:29	-7.00	-1,792.00	0	0	0	0	0.00
chb11_27.edf	16:22:36	17:22:36	3,600.00	921,600.00	0	0	0	0	0.00
chb11_....edf					0	0	0	0	0
chb11_53.edf	17:37:03	18:37:03	3,600.00	921,600.00	0	0	0	0	0.00
chb11_54.edf	18:37:10	19:37:10	3,600.00	921,600.00	0	0	0	0	0.00
chb11_55.edf	19:37:17	20:37:17	3,600.00	921,600.00	0	0	0	0	0.00
chb11_56.edf	20:37:51	21:37:51	3,600.00	921,600.00	0	0	0	0	0.00
chb11_57.edf					0	0	0	0	0
chb11_58.edf	22:38:05	23:38:05	3,600.00	921,600.00	0	0	0	0	0.00
chb11_59.edf					0	0	0	0	0
chb11_60.edf	0:38:19	1:38:19	3,600.00	921,600.00	0	0	0	0	0.00

Tabla Anexo 2.11 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb11_61.edf	1:38:26	2:38:26	3,600.00	921,600.00	0	0	0	0	0.00
chb11_62.edf	2:38:32	3:38:32	3,600.00	921,600.00	0	0	0	0	0.00
chb11_63.edf	3:38:39	4:38:39	3,600.00	921,600.00	0	0	0	0	0.00
chb11_.....edf					0	0	0	0	
chb11_82.edf	21:47:24	22:47:24	3,600.00	921,600.00	1	298	320	22	5,632.00
chb11_.....edf					0	0	0	0	
chb11_92.edf	7:48:31	8:48:31	3,600.00	921,600.00	1	2695	2727	32	8,192.00
chb11_.....edf					0	0	0	0	
chb11_99.edf	14:49:19	15:36:58	2,859.00	731,904.00	1	1454	2206	752	192,512.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.12: Información proporcionada en la base de datos del MIT-CHB para el sujeto 12.

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb12_....edf					0	0	0	0	
chb12_06.edf	22:44:34	23:44:40	3,606.00	923,136.00	2	1665	1726	61	15,616.00
chb12_07.edf					0	0	0	0	
chb12_08.edf	00:46:38	01:46:38	3,600.00	921,600.00	4	1426	1439	13	3,328.00
chb12_09.edf	01:46:45	02:46:57	3,612.00	924,672.00	2	1591	1614	23	5,888.00
chb12_10.edf	02:47:45	03:47:56	3,611.00	924,416.00	2	1657	1977	320	81,920.00
chb12_11.edf	03:48:28	04:28:59	2,431.00	622,336.00	1	2798	2824	26	6,656.00
chb12_....edf					0	0	0	0	
chb12_19.edf	08:57:21	09:57:21	3,600.00	921,600.00	0	3082	3114	32	8,192.00
chb12_20.edf	09:57:27	10:57:27	3,600.00	921,600.00	0	3503	3535	32	8,192.00
					2	593	625	32	8,192.00
					1	811	856	45	11,520.00
					1	1085	1122	37	9,472.00

Tabla Anexo 2.12 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb12_21.edf	10:57:35	11:57:35	3,600.00	921,600.00	0	0	0	0	0.00
chb12_22.edf					0	0	0	0	
chb12_23.edf	12:06:43	13:06:43	3,600.00	921,600.00	3	425	522	97	24,832.00
chb12_24.edf	13:06:45	14:06:45	3,600.00	921,600.00	0	630	670	40	10,240.00
chb12_24.edf	13:06:45	14:06:45	3,600.00	921,600.00	0	0	0	0	0.00
chb12_....edf					0	0	0	0	
chb12_27.edf	16:07:06	17:07:06	3,600.00	921,600.00	6	1728	1753	25	6,400.00
chb12_28.edf	17:07:12	18:07:12	3,600.00	921,600.00	1	181	215	34	8,704.00
						107	146	39	9,984.00
						554	592	38	9,728.00
						1163	1199	36	9,216.00

Tabla Anexo 2.12 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb12_29.edf	18:07:19	19:07:43	3,624.00	927,744.00	6	1401	1447	46	11,776.00
chb12_32.edf	21:09:45	22:09:45	3,600.00	921,600.00	0	0	0	0	0.00
chb12_33.edf	22:09:51	23:09:51	3,600.00	921,600.00	2	2185	2206	21	5,376.00
chb12_34.edf	23:09:58	24:09:58	3,600.00	921,600.00	0	0	0	0	0.00
chb12_35.edf	00:10:04	01:10:04	3,600.00	921,600.00	0	0	0	0	0.00
chb12_36.edf	01:10:11	02:10:11	3,600.00	921,600.00	1	653	680	27	6,912.00
chb12_37.edf	02:10:17	03:10:33	3,616.00	925,696.00	0	0	0	0	0.00
chb12_38.edf	03:11:04	04:11:04	3,600.00	921,600.00	5	1548	1576	28	7,168.00
						2798	2821	23	5,888.00
						2966	3009	43	11,008.00
						3146	3201	55	14,080.00
						3364	3410	46	11,776.00
chb12_39.edf	04:11:10	05:11:10	3,600.00	921,600.00	0	0	0	0	0.00

Tabla Anexo 2.12 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb12_40.edf	05:11:17	06:11:17	3,600.00	921,600.00	0	0	0	0	0.00
chb12_41.edf	06:11:24	07:11:24	3,600.00	921,600.00	0	0	0	0	0.00
chb12_42.edf	07:11:30	08:11:30	3,600.00	921,600.00	5	699	1170	750	13,056.00
						945	1676	973	7,168.00
						2213	2236	29	7,424.00
								25	6,400.00
								23	5,888.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Tabla Anexo 2.13 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb13_18.edf	8:14:20	9:14:20	3,600.00	921,600.00	0	0	0	0	0.00
chb13_19.edf	9:14:25	10:14:25	3,600.00	921,600.00	1	2077	2121	44	11,264.00
chb13_20.edf					0	0	0	0	
chb13_21.edf	11:14:59	12:14:59	3,600.00	921,600.00	1	934	1004	70	17,920.00
chb13_22.edf	12:15:06	13:15:06	3,600.00	921,600.00	0	0	0	0	0.00
chb13_23.edf					0	0	0	0	
chb13_24.edf	14:15:19	15:15:19	3,600.00	921,600.00	0	0	0	0	0.00
chb13_....edf					0	0	0	0	
chb13_30.edf	20:16:00	21:16:00	3,600.00	921,600.00	0	0	0	0	0.00
chb13_....edf					0	0	0	0	
chb13_36.edf	2:17:23	3:17:23	3,600.00	921,600.00	0	0	0	0	0.00
chb13_37.edf	3:17:30	4:17:30	3,600.00	921,600.00	0	0	0	0	0.00
chb13_38.edf	4:17:37	5:17:37	3,600.00	921,600.00	0	0	0	0	0.00
chb13_39.edf	5:17:44	6:17:44	3,600.00	921,600.00	0	0	0	0	0.00
chb13_40.edf	6:17:50	7:17:50	3,600.00	921,600.00	2	142	173	31	7,936.00
chb13_....edf					0	530	594	64	16,384.00
chb13_....edf					0	0	0	0	

Tabla Anexo 2.13 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb13_47.edf	13:18:37	14:18:37	3,600.00	921,600.00	0	0	0	0	0.00
chb13_48.edf					0	0	0	0	
chb13_55.edf	21:20:07	22:20:07	3,600.00	921,600.00	2	458	478	20	5,120.00
chb13_56.edf	22:20:14	23:20:14	3,600.00	921,600.00	0	2436	2454	18	4,608.00
chb13_57.edf					0	0	0	0	0.00
chb13_58.edf	0:20:28	1:20:28	3,600.00	921,600.00	1	2474	2491	17	4,352.00
chb13_59.edf	1:20:34	2:20:34	3,600.00	921,600.00	1	3339	3401	62	15,872.00
chb13_60.edf	2:20:41	3:20:41	3,600.00	921,600.00	1	638	660	22	5,632.00
chb13_61.edf					0	0	0	0	
chb13_62.edf	4:20:55	5:20:55	3,600.00	921,600.00	3	851	916	65	16,640.00
						1626	1691	65	16,640.00
						2664	2721	57	14,592.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.14: Información proporcionada en la base de datos del MIT-CHB para el sujeto 14.

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb14_01.edf	14:34:50	15:34:50	3,600.00	921,600.00	0	0	0	0	0.00
chb14_02.edf	15:34:53	16:34:53	3,600.00	921,600.00	0	0	0	0	0.00
chb14_03.edf	16:35:00	17:35:00	3,600.00	921,600.00	1	1986	2000	14	3,584.00
chb14_04.edf	17:35:07	18:35:07	3,600.00	921,600.00	2	1372	1392	20	5,120.00
chb14_05.edf	17:35:07	18:35:07	3,600.00	921,600.00	2	2817	2839	22	5,632.00
chb14_05.edf					0	0	0	0	
chb14_06.edf	19:35:21	20:35:21	3,600.00	921,600.00	1	1911	1925	14	3,584.00
chb14_07.edf	20:35:28	21:35:28	3,600.00	921,600.00	0	0	0	0	0.00
chb14_08.edf					0	0	0	0	
chb14_11.edf	0:35:55	1:35:55	3,600.00	921,600.00	1	1838	1879	41	10,496.00
chb14_12.edf	1:36:02	2:36:02	3,600.00	921,600.00	0	0	0	0	0.00
chb14_13.edf	2:36:09	3:36:09	3,600.00	921,600.00	0	0	0	0	0.00
chb14_14.edf	3:36:16	4:36:16	3,600.00	921,600.00	0	0	0	0	0.00
chb14_15.edf					0	0	0	0	
chb14_16.edf	5:36:29	6:36:29	3,600.00	921,600.00	0	0	0	0	0.00
chb14_17.edf	6:36:36	7:36:36	3,600.00	921,600.00	1	3239	3259	20	5,120.00

Tabla Anexo 2.14 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb14_18.edf	7:36:43	7:36:43	0.00	0.00	1	1039	1061	22	5,632.00
chb14_19.edf	8:36:50	9:36:50	3,600.00	921,600.00	0	0	0	0	0.00
chb14_20.edf	9:36:57	10:36:57	3,600.00	921,600.00	0	0	0	0	0.00
chb14_21.edf					0	0	0	0	
chb14_22.edf	11:37:11	12:37:11	3,600.00	921,600.00	0	0	0	0	0.00
chb14_23.edf					0	0	0	0	
chb14_24.edf	13:37:25	14:37:25	3,600.00	921,600.00	0	0	0	0	0.00
chb14_25.edf	14:37:31	15:37:31	3,600.00	921,600.00	0	0	0	0	0.00
chb14_26.edf	15:37:38	16:37:38	3,600.00	921,600.00	0	0	0	0	0.00
chb14_27.edf	16:37:45	17:37:45	3,600.00	921,600.00	1	2833	2849	16	4,096.00
chb14_28.edf					0	0	0	0	
chb14_29.edf	18:37:59	19:37:59	3,600.00	921,600.00	0	0	0	0	0.00
chb14_30.edf	19:38:06	20:38:06	3,600.00	921,600.00	0	0	0	0	0.00
chb14_31.edf					0	0	0	0	
chb14_32.edf	21:38:19	22:38:19	3,600.00	921,600.00	0	0	0	0	0.00
chb14_....edf					0	0	0	0	
chb14_37.edf	2:38:53	3:38:53	3,600.00	921,600.00	0	0	0	0	0.00

Tabla Anexo 2.14 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb14_38.edf					0	0	0	0	
chb14_39.edf	4:39:07	5:39:07	3,600.00	921,600.00	0	0	0	0	0.00
chb14_...edf					0	0	0	0	
chb14_42.edf	7:39:28	8:39:28	3,600.00	921,600.00	0	0	0	0	0.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.15: Información proporcionada en la base de datos del MIT-CHB para el sujeto 15.

Archivo	Inicio		Fin		Duración de registro [s]		Muestras		Núm de eventos		Tiempo inicio [s]		Tiempo fin [s]		Duración [s]		Muestras Ictales	
	[hrs]	[hrs]	[hrs]	[hrs]	[hrs]	[s]	[s]	[s]	[s]	[s]	[s]	[s]	[s]	[s]	[s]	[s]	[s]	[s]
chb15_01.edf	18:23:13	19:23:15	3,602.00	922,112.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_02.edf	19:23:43	20:23:43	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_03.edf	20:23:50	21:23:50	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_04.edf	21:23:57	22:23:57	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_05.edf	22:24:03	23:24:03	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_06.edf	23:24:10	0:24:10	3,600.00	921,600.00	1	272	397	125	32,000.00	0	0	0	0	0	0	0	0.00	0.00
chb15_07.edf	0:24:17	1:24:17	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_08.edf	1:24:24	2:24:24	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_09.edf	2:24:31	3:24:31	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_10.edf	3:24:38	4:24:38	3,600.00	921,600.00	1	1082	1113	31	7,936.00	0	0	0	0	0	0	0	0.00	0.00
chb15_11.edf	4:24:45	5:24:45	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_12.edf	5:24:52	6:24:52	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_13.edf	6:24:59	7:24:59	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_14.edf	7:25:06	8:25:06	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00
chb15_15.edf	8:25:13	9:25:13	3,600.00	921,600.00	1	1591	1748	157	40,192.00	0	0	0	0	0	0	0	0.00	0.00
chb15_16.edf	9:25:20	10:25:20	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0	0	0	0	0.00	0.00

Tabla Anexo 2.15 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb15_17.edf	10:25:27	11:25:27	3,600.00	921,600.00	1	1925	1960	35	8,960.00
chb15_18.edf					0	0	0	0	
chb15_19.edf	12:25:41	13:25:41	3,600.00	921,600.00	0	0	0	0	0.00
chb15_20.edf	13:25:48	14:25:48	3,600.00	921,600.00	1	607	662	55	14,080.00
chb15_21.edf					0	0	0	0	
chb15_22.edf	15:26:02	16:26:02	3,600.00	921,600.00	1	760	965	205	52,480.00
chb15_....edf					0	0	0	0	
chb15_26.edf	19:27:44	20:27:44	3,600.00	921,600.00	0	0	0	0	0.00
chb15_27.edf					0	0	0	0	
chb15_28.edf	21:27:58	22:27:58	3,600.00	921,600.00	1	876	1066	190	48,640.00
chb15_29.edf	22:28:05	23:28:05	3,600.00	921,600.00	0	0	0	0	0.00
chb15_30.edf	23:28:12	0:28:12	3,600.00	921,600.00	0	0	0	0	0.00
chb15_31.edf	0:28:18	1:28:18	3,600.00	921,600.00	1	1751	1871	120	30,720.00
chb15_32.edf	1:28:25	2:28:25	3,600.00	921,600.00	0	0	0	0	0.00
chb15_33.edf	2:28:32	3:28:32	3,600.00	921,600.00	0	0	0	0	0.00
chb15_34.edf					0	0	0	0	
chb15_35.edf	4:28:46	5:28:46	3,600.00	921,600.00	0	0	0	0	0.00

Tabla Anexo 2.15 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb15_36.edf					0	0	0	0	
chb15_37.edf	6:29:00	7:29:00	3,600.00	921,600.00	0	0	0	0	0.00
chb15_....edf					0	0	0	0	
chb15_40.edf	9:29:21	10:29:21	3,600.00	921,600.00	3	834	894	60	15,360.00
						2378	2497	119	30,464.00
						3362	3425	63	16,128.00
chb15_....edf					0	0	0	0	
chb15_45.edf	14:30:00	15:30:00	3,600.00	921,600.00	0	0	0	0	0.00
chb15_46.edf	15:30:07	16:30:07	3,600.00	921,600.00	1	1108	1248	140	35,840.00
chb15_....edf					0	0	0	0	
chb15_49.edf	18:38:05	19:38:30	3,625.00	928,000.00	0	0	0	0	0.00
chb15_50.edf	19:38:56	20:38:56	3,600.00	921,600.00	0	0	0	0	0.00
chb15_51.edf	20:39:03	21:39:03	3,600.00	921,600.00	0	0	0	0	0.00
chb15_52.edf	21:39:10	22:39:19	3,609.00	923,904.00	1	778	846	68	17,408.00
chb15_53.edf					0	0	0	0	
					263	318	318	55	14,080.00
					843	1020	1020	177	45,312.00

Tabla Anexo 2.15 contía de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb15_54.edf	23:39:54	0:39:54	3,600.00	921,600.00	5	1524	1595	71	18,176.00
chb15_61.edf	6:41:03	7:41:03	3,600.00	921,600.00	0	0	0	0	0.00
chb15_62.edf	7:41:10	8:41:10	3,600.00	921,600.00	1	751	859	108	27,648.00
chb15_63.edf	8:41:17	9:41:17	3,600.00	921,600.00	0	0	0	0	0.00
chb15_...edf					0	0	0	0	

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.16: Información proporcionada en la base de datos del MIT-CHB para el sujeto 16.

Archivo	Inicio		Fin		Duración de		Muestras	Núm de		Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	eventos		inicio [s]	fin [s]	[s]	[s]	Ictales	Ictales		
chb16_01.edf	16:39:42	17:39:42	17:39:42	17:39:42	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_02.edf	17:39:45	18:39:45	18:39:45	18:39:45	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_03.edf	18:39:52	19:39:52	19:39:52	19:39:52	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_04.edf	19:39:58	20:39:58	20:39:58	20:39:58	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_05.edf	20:40:05	21:40:05	21:40:05	21:40:05	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_06.edf	21:40:12	22:40:12	22:40:12	22:40:12	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_07.edf	22:40:19	23:40:19	23:40:19	23:40:19	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_08.edf	23:40:26	24:40:26	24:40:26	24:40:26	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_09.edf	00:40:33	01:40:33	01:40:33	01:40:33	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_10.edf	01:40:40	02:40:40	02:40:40	02:40:40	3,600.00	921,600.00	1	2290	2299	2299	9	2,304.00			
chb16_11.edf	02:40:47	03:40:47	03:40:47	03:40:47	3,600.00	921,600.00	1	1120	1129	1129	9	2,304.00			
chb16_12.edf	03:40:54	04:40:54	04:40:54	04:40:54	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_13.edf	04:41:01	05:41:01	05:41:01	05:41:01	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_14.edf	05:41:08	06:41:08	06:41:08	06:41:08	3,600.00	921,600.00	1	1854	1868	1868	14	3,584.00			
chb16_15.edf	06:41:15	07:41:15	07:41:15	07:41:15	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00
chb16_16.edf	07:41:22	08:41:22	08:41:22	08:41:22	3,600.00	921,600.00	1	1214	1220	1220	6	1,536.00			

Tabla Anexo 2.16 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb16_17.edf	08:41:29	09:41:29	3,600.00	921,600.00	4	227	236	9	2,304.00
						1694	1700	6	1,536.00
						2162	2170	8	2,048.00
						3290	3298	8	2,048.00
chb16_18.edf	09:41:36	10:41:36	3,600.00	921,600.00	2	627	635	8	2,048.00
chb16_19.edf	10:41:43	11:41:43	3,600.00	921,600.00	0	1909	1916	7	1,792.00
						0	0	0	0.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.17: Información proporcionada en la base de datos del MIT-CHB para el sujeto 17.

Archivo	Inicio		Fin		Duración de registro [s]		Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	fin [s]			inicio [s]	fin [s]	[s]	[s]	Ictales	Ictales
chb17a_03.edf	19:47:38	20:47:38	20:47:38	20:47:38	3,600.00	921,600.00	1	2282	2372	90	23,040.00			
chb17a_04.edf	20:47:45	21:47:45	21:47:45	21:47:45	3,600.00	921,600.00	1	3025	3140	115	29,440.00			
chb17a_05.edf	21:47:52	22:47:52	22:47:52	22:47:52	3,600.00	921,600.00	0	0	0	0	0.00			
chb17a_06.edf	22:47:59	23:47:59	23:47:59	23:47:59	3,600.00	921,600.00	0	0	0	0	0.00			
chb17a_07.edf	0:48:39	1:48:39	1:48:39	1:48:39	3,600.00	921,600.00	0	0	0	0	0.00			
chb17b_57.edf	1:59:21	2:59:21	2:59:21	2:59:21	3,600.00	921,600.00	0	0	0	0	0.00			
chb17b_58.edf	2:59:28	3:59:28	3:59:28	3:59:28	3,600.00	921,600.00	0	0	0	0	0.00			
chb17b_59.edf	3:59:35	4:59:35	4:59:35	4:59:35	3,600.00	921,600.00	0	0	0	0	0.00			
chb17b_60.edf	4:59:41	5:59:41	5:59:41	5:59:41	3,600.00	921,600.00	0	0	0	0	0.00			
chb17b_63.edf	8:00:02	9:00:26	9:00:26	9:00:26	3,624.00	927,744.00	1	3136	3224	88	22,528.00			
chb17b_67.edf	11:40:36	12:40:36	12:40:36	12:40:36	3,600.00	921,600.00	0	0	0	0	0.00			

Tabla Anexo 2.17 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb17b_68.edf	12:40:43	13:40:43	3,600.00	921,600.00	0	0	0	0	0.00
chb17b_69.edf	13:40:50	13:40:43	-7.00	-1,792.00	0	0	0	0	0.00
chb17c_01.edf									
chb17c_02.edf	22:53:46	23:53:46	3,600.00	921,600.00	0	0	0	0	0.00
chb17c_03.edf	23:53:53	0:53:53	3,600.00	921,600.00	0	0	0	0	0.00
chb17c_04.edf	0:54:00	1:54:00	3,600.00	921,600.00	0	0	0	0	0.00
chb17c_05.edf	1:54:06	2:54:06	3,600.00	921,600.00	0	0	0	0	0.00
chb17c_06.edf	2:54:13	3:54:13	3,600.00	921,600.00	0	0	0	0	0.00
chb17c_07.edf	3:54:20	4:54:20	3,600.00	921,600.00	0	0	0	0	0.00
chb17c_08.edf	4:54:27	5:54:27	3,600.00	921,600.00	0	0	0	0	0.00
chb17c_....edf									
chb17c_13.edf	9:59:42	10:59:42	3,600.00	921,600.00	0	0	0	0	0.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.18: Información proporcionada en la base de datos del MIT-CHB para el sujeto 18.

Archivo	Inicio		Fin		Duración de		Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	inicio [s]			fin [s]	[s]	[s]	Ictales	Ictales	
chb18_01.edf	17:53:23	18:53:34	3,611.00	924,416.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_02.edf	18:54:57	19:54:57	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_03.edf	19:55:04	20:55:04	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_04.edf	20:55:11	21:55:11	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_05.edf	21:55:18	22:55:18	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_06.edf	22:55:25	23:55:25	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_07.edf	23:55:32	0:55:32	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_08.edf	0:55:38	1:55:38	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_09.edf	1:55:45	2:55:45	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_10.edf	2:55:52	3:55:52	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_11.edf	3:55:59	4:55:59	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_12.edf	4:56:06	5:56:06	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_13.edf	5:56:13	6:56:13	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_14.edf	6:56:19	7:56:19	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_15.edf	7:56:26	8:56:26	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00
chb18_16.edf	8:56:33	9:56:33	3,600.00	921,600.00	0	0	0	0	0	0	0	0	0.00	0.00

Tabla Anexo 2.18 contia de página anterior

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	Ictales	Ictales
chb18_17.edf	9:56:40	10:56:40	10:56:40	10:56:40	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_18.edf	16:57:30	17:57:30	17:57:30	17:57:30	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_19.edf	17:57:37	18:57:37	18:57:37	18:57:37	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_20.edf	18:57:44	19:57:44	19:57:44	19:57:44	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_21.edf	19:57:50	20:57:05	20:57:05	20:57:05	3,555.00	910,080.00	0	0	0	0	0	0	0.00
chb18_22.edf	20:57:57	21:57:57	21:57:57	21:57:57	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_23.edf	23:58:18	0:58:18	0:58:18	0:58:18	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_24.edf	0:58:25	1:58:25	1:58:25	1:58:25	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_25.edf	1:58:31	2:58:31	2:58:31	2:58:31	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_26.edf	2:58:38	3:58:38	3:58:38	3:58:38	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_27.edf	3:58:45	4:58:45	4:58:45	4:58:45	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_28.edf	4:58:52	5:58:52	5:58:52	5:58:52	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb18_29.edf	5:58:59	6:58:59	6:58:59	6:58:59	3,600.00	921,600.00	1	3477	3527	50	12,800.00	12,800.00	
chb18_30.edf	6:59:06	7:59:06	7:59:06	7:59:06	3,600.00	921,600.00	1	541	571	30	7,680.00	7,680.00	
chb18_31.edf	10:00:32	10:38:26	10:38:26	10:38:26	2,274.00	582,144.00	1	2087	2155	68	17,408.00	17,408.00	
chb18_32.edf	11:38:42	12:38:42	12:38:42	12:38:42	3,600.00	921,600.00	1	1908	1963	55	14,080.00	14,080.00	
chb18_33.edf	15:39:10	16:39:10	16:39:10	16:39:10	3,600.00	921,600.00	0	0	0	0	0	0	0.00

Tabla Anexo 2.18 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb18_34.edf	19:40:40	20:40:40	3,600.00	921,600.00	0	0	0	0	0.00
chb18_35.edf	8:42:06	9:42:06	3,600.00	921,600.00	1	2196	2264	68	17,408.00
chb18_36.edf	8:45:57	9:45:57	3,600.00	921,600.00	1	463	509	46	11,776.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.19: Información proporcionada en la base de datos del MIT-CHB para el sujeto 19.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración		Muestras Ictales
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	
chb19_01.edf	17:36:30	17:36:30	18:36:30	18:36:30	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_02.edf	18:36:32	18:36:32	19:36:32	19:36:32	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_03.edf	19:36:40	19:36:40	20:36:40	20:36:40	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_04.edf	20:36:46	20:36:46	21:36:46	21:36:46	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_05.edf	21:36:53	21:36:53	22:36:53	22:36:53	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_06.edf	22:37:00	22:37:00	23:37:00	23:37:00	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_07.edf	23:37:07	23:37:07	24:37:07	24:37:07	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_08.edf	00:37:14	00:37:14	01:37:14	01:37:14	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_09.edf	01:37:20	01:37:20	02:37:20	02:37:20	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_10.edf	02:37:27	02:37:27	03:37:27	03:37:27	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_11.edf	03:37:34	03:37:34	04:37:34	04:37:34	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_12.edf	04:37:41	04:37:41	05:37:41	05:37:41	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_13.edf	05:37:47	05:37:47	06:37:47	06:37:47	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_14.edf	06:37:54	06:37:54	07:37:54	07:37:54	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_15.edf	07:38:01	07:38:01	08:38:01	08:38:01	3,600.00	921,600.00	0	0	0	0	0	0.00
chb19_16.edf	08:38:08	08:38:08	09:38:08	09:38:08	3,600.00	921,600.00	0	0	0	0	0	0.00

Tabla Anexo 2.19 contía de página anterior

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras		
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]		Ictales	Ictales	
chb19_17.edf	12:38:35	13:38:35	13:38:35	13:38:35	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_18.edf	13:38:42	14:38:42	14:38:42	14:38:42	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_19.edf	14:38:48	15:38:48	15:38:48	15:38:48	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_20.edf	15:38:55	16:38:55	16:38:55	16:38:55	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_21.edf	16:39:02	17:39:02	17:39:02	17:39:02	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_22.edf	22:39:42	23:39:42	23:39:42	23:39:42	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_23.edf	23:39:49	24:39:49	24:39:49	24:39:49	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_24.edf	00:39:56	01:39:56	01:39:56	01:39:56	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_25.edf	01:40:02	02:40:02	02:40:02	02:40:02	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_26.edf	04:40:23	05:40:23	05:40:23	05:40:23	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_27.edf	03:03:38	04:03:38	04:03:38	04:03:38	3,600.00	921,600.00	0	0	0	0	0	0.00	0.00
chb19_28.edf	01:09:35	02:09:47	02:09:47	02:09:47	3,612.00	924,672.00	1	299	377	78	19,968.00		
chb19_29.edf	07:11:12	08:11:12	08:11:12	08:11:12	3,600.00	921,600.00	1	2964	3041	77	19,712.00		
chb19_30.edf	11:12:51	12:08:25	12:08:25	12:08:25	3,334.00	853,504.00	1	3159	3240	81	20,736.00		

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.20: Información proporcionada en la base de datos del MIT-CHB para el sujeto 20.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración [s]	Muestras Ictales
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]		
chb20_01.edf	16:55:08	17:55:14	17:55:14	17:55:14	3,606.00	923,136.00	0	0	0	0	0.00
chb20_02.edf	17:55:44	18:55:44	18:55:44	18:55:44	3,600.00	921,600.00	0	0	0	0	0.00
chb20_03.edf	18:55:51	19:55:51	19:55:51	19:55:51	3,600.00	921,600.00	0	0	0	0	0.00
chb20_04.edf	19:55:59	20:55:59	20:55:59	20:55:59	3,600.00	921,600.00	0	0	0	0	0.00
chb20_05.edf	20:56:06	21:56:06	21:56:06	21:56:06	3,600.00	921,600.00	0	0	0	0	0.00
chb20_06.edf	21:56:13	22:56:13	22:56:13	22:56:13	3,600.00	921,600.00	0	0	0	0	0.00
chb20_07.edf	22:56:19	23:56:19	23:56:19	23:56:19	3,600.00	921,600.00	0	0	0	0	0.00
chb20_08.edf	23:56:26	0:56:26	0:56:26	0:56:26	3,600.00	921,600.00	0	0	0	0	0.00
chb20_....edf											
chb20_11.edf	2:56:46	3:56:46	3:56:46	3:56:46	3,600.00	921,600.00	0	0	0	0	0.00
chb20_12.edf	3:56:53	4:56:53	4:56:53	4:56:53	3,600.00	921,600.00	1	94	123	29	7,424.00
chb20_13.edf	4:57:00	5:57:00	5:57:00	5:57:00	3,600.00	921,600.00	2	1440	1470	30	7,680.00
chb20_14.edf	5:57:07	6:57:07	6:57:07	6:57:07	3,600.00	921,600.00	1	1971	2009	38	9,728.00
chb20_15.edf	6:57:14	7:57:14	7:57:14	7:57:14	3,600.00	921,600.00	2	390	425	35	8,960.00
								1689	1738	49	12,544.00

Tabla Anexo 2.20 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras	
										Ictales
chb20_16.edf	7:57:20	8:55:09	3,469.00	888,064.00	1	2226	2261	35	8,960.00	
chb20_17.edf	8:55:24	9:55:24	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_21.edf	12:51:27	13:51:45	3,618.00	926,208.00	0	0	0	0	0.00	
chb20_22.edf	13:53:06	14:05:28	742.00	189,952.00	0	0	0	0	0.00	
chb20_23.edf	14:11:44	15:01:08	2,964.00	758,784.00	0	0	0	0	0.00	
chb20_24.edf			0.00	0.00	0	0	0	0	0.00	
chb20_25.edf	16:05:20	17:05:20	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_26.edf	17:05:27	18:05:27	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_27.edf	18:05:33	19:05:33	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_28.edf	19:05:40	20:05:40	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_29.edf	20:05:47	21:05:47	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_30.edf	21:05:54	22:05:54	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_31.edf	22:06:01	23:06:01	3,600.00	921,600.00	0	0	0	0	0.00	
chb20_34.edf	1:06:21	2:06:21	3,600.00	921,600.00	0	0	0	0	0.00	

Tabla Anexo 2.20 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb20_59.edf	0:44:04	1:44:04	3,600.00	921,600.00	0	0	0	0	0.00
chb20_60.edf	1:44:11	2:44:11	3,600.00	921,600.00	0	0	0	0	0.00
chb20_61.edf									
chb20_68.edf	9:45:07	10:21:14	2,167.00	554,752.00	1	1393	1432	39	9,984.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.21: Información proporcionada en la base de datos del MIT-CHB para el sujeto 21.

Archivo	Inicio		Fin		Duración de		Muestras	Núm de eventos	Tiempo		Duración		Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]	registro [s]	inicio [s]			fin [s]	[s]	[s]	Ictales	Ictales	
chb21_01.edf	17:56:45	18:56:45	18:56:45	18:56:45	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_02.edf	18:56:49	19:56:49	19:56:49	19:56:49	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_03.edf	19:56:57	20:56:57	20:56:57	20:56:57	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_04.edf	20:57:04	21:57:04	21:57:04	21:57:04	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_05.edf	21:57:11	22:57:11	22:57:11	22:57:11	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_06.edf	22:57:18	23:57:18	23:57:18	23:57:18	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_07.edf	23:57:24	0:57:24	0:57:24	0:57:24	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_08.edf	0:57:31	1:57:31	1:57:31	1:57:31	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_09.edf	1:57:38	2:57:38	2:57:38	2:57:38	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_10.edf	2:57:45	3:57:45	3:57:45	3:57:45	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_11.edf	3:57:52	4:57:52	4:57:52	4:57:52	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_12.edf	4:57:59	5:57:59	5:57:59	5:57:59	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_13.edf	5:58:06	6:58:06	6:58:06	6:58:06	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_14.edf	6:58:13	7:58:13	7:58:13	7:58:13	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_15.edf	7:58:20	8:58:20	8:58:20	8:58:20	3,600.00	921,600.00	0	0	0	0	0	0	0.00	0.00
chb21_16.edf	8:58:27	9:58:26	9:58:26	9:58:26	3,599.00	921,344.00	0	0	0	0	0	0	0.00	0.00

Tabla Anexo 2.21 contia de página anterior

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Tiempo fin [s]	Duración [s]	Muestras	
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]			Ictales	Ictales
chb21_17.edf	9:58:59	10:58:59	10:58:59	10:58:59	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_18.edf	10:59:06	11:59:06	11:59:06	11:59:06	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_19.edf	11:59:13	12:59:13	12:59:13	12:59:13	3,600.00	921,600.00	1	1288	1344	56	14,336.00	14,336.00	
chb21_20.edf	12:59:20	13:49:10	13:49:10	13:49:10	2,990.00	765,440.00	1	2627	2677	50	12,800.00	12,800.00	
chb21_21.edf	15:49:35	16:49:35	16:49:35	16:49:35	3,600.00	921,600.00	1	2003	2084	81	20,736.00	20,736.00	
chb21_22.edf	16:49:42	17:49:42	17:49:42	17:49:42	3,600.00	921,600.00	1	2553	2565	12	3,072.00	3,072.00	
chb21_23.edf	18:36:01	19:36:01	19:36:01	19:36:01	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_24.edf	20:36:11	21:36:11	21:36:11	21:36:11	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_25.edf	22:36:25	23:36:25	23:36:25	23:36:25	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_26.edf	23:36:32	0:36:32	0:36:32	0:36:32	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_27.edf	0:36:39	1:36:39	1:36:39	1:36:39	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_28.edf	1:36:46	2:36:46	2:36:46	2:36:46	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_29.edf	8:37:34	9:37:34	9:37:34	9:37:34	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_30.edf	13:38:08	14:38:08	14:38:08	14:38:08	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_31.edf	22:39:10	23:39:10	23:39:10	23:39:10	3,600.00	921,600.00	0	0	0	0	0	0	0.00
chb21_32.edf	23:39:17	0:39:17	0:39:17	0:39:17	3,600.00	921,600.00	0	0	0	0	0	0	0.00

Tabla Anexo 2.21 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb21_33.edf	0:39:24	1:39:24	3,600.00	921,600.00	0	0	0	0	0.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.22: Información proporcionada en la base de datos del MIT-CHB para el sujeto 22.

Archivo	Inicio		Fin		Duración de registro [s]	Muestras	Núm de eventos	Tiempo		Duración		Muestras Ictales
	[hrs]	[hrs]	[hrs]	[hrs]				inicio [s]	fin [s]	[s]	[s]	
chb22_01.edf	22:38:09	22:38:09	23:38:09	23:38:09	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_02.edf	23:38:12	23:38:12	0:38:12	0:38:12	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_03.edf	0:38:18	0:38:18	1:38:18	1:38:18	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_04.edf	1:38:25	1:38:25	2:38:25	2:38:25	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_05.edf	2:38:32	2:38:32	3:38:32	3:38:32	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_06.edf	3:38:39	3:38:39	4:38:39	4:38:39	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_07.edf	4:38:45	4:38:45	5:38:45	5:38:45	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_08.edf	5:38:52	5:38:52	6:38:52	6:38:52	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_09.edf	6:38:59	6:38:59	7:38:59	7:38:59	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_10.edf	7:39:05	7:39:05	8:39:05	8:39:05	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_11.edf	8:39:12	8:39:12	9:39:23	9:39:23	3,611.00	924,416.00	0	0	0	0	0	0.00
chb22_....edf												
chb22_15.edf	12:44:29	12:44:29	13:44:29	13:44:29	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_16.edf	13:44:36	13:44:36	14:44:36	14:44:36	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_17.edf	14:44:42	14:44:42	15:44:42	15:44:42	3,600.00	921,600.00	0	0	0	0	0	0.00
chb22_18.edf	15:44:49	15:44:49	16:44:49	16:44:49	3,600.00	921,600.00	0	0	0	0	0	0.00

Tabla Anexo 2.22 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb22_54.edf	4:03:46	5:03:46	3,600.00	921,600.00	0	0	0	0	0.00
chb22_....edf									
chb22_77.edf	1:33:40	2:33:40	3,600.00	921,600.00	0	0	0	0	0.00

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Cuadro Anexo 2.23: Información proporcionada en la base de datos del MIT-CHB para el sujeto 23.

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
chb23_....edf									
chb23_06.edf	8:57:57	11:02:43	7,486.00	1,916,416.00	1	3962	4075	113	28,928.00
chb23_07.edf	11:03:16	11:45:56	2,560.00	655,360.00	0	0	0	0	0.00
chb23_08.edf	11:48:05	14:40:27	10,342.00	2,647,552.00	2	325	345	20	5,120.00
						5104	5151	47	12,032.00
chb23_09.edf	14:40:47	18:41:13	14,426.00	3,693,056.00	4	2589	2660	71	18,176.00
						6885	6947	62	15,872.00
						8505	8532	27	6,912.00
chb23_10.edf	18:41:40	22:41:40	14,400.00	3,686,400.00	0	0	0	0	0.00
chb23_....edf									
chb23_16.edf	13:46:32	17:46:32	14,400.00	3,686,400.00	0	0	0	0	0.00
chb23_17.edf	17:46:42	21:16:29	12,587.00	3,222,272.00	0	0	0	0	0.00
chb23_18.edf									
chb23_19.edf	2:28:28	6:28:28	14,400.00	3,686,400.00	0	0	0	0	0.00
chb23_20.edf	6:28:36	7:52:05	5,009.00	1,282,304.00	0	0	0	0	0.00

Tabla Anexo 2.23 contia de página anterior

Archivo	Inicio [hrs]	Fin [hrs]	Duración de registro [s]	Muestras	Núm de eventos	Tiempo inicio [s]	Tiempo fin [s]	Duración [s]	Muestras Ictales
---------	-----------------	--------------	-----------------------------	----------	-------------------	----------------------	-------------------	-----------------	---------------------

Las celdas resaltadas en color rojo son registros no porcionados en la base de datos

Anexo 3

Registro de protocolo

En el presente anexo, se presentará documentación que avale el registro del protocolo así como la aprobación del comité de ética para llevar a cabo la investigación presentada en esta tesis.



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
DIRECCIÓN DE INVESTIGACIÓN Y POSGRADO

REGISTRO DEL PROTOCOLO DE INVESTIGACIÓN
DEL ESTUDIANTE DE POSGRADO

Los 2 Espacios oscuros exclusivos para la Dirección	No. Registro de Proyecto*: Fecha de Registro*:	13226 16-05-2022
	Fecha de inicio de proyecto:	03/01/2022
	Fecha de término de proyecto:	30/06/2023
1. DATOS DEL SOLICITANTE		
No. de expediente:	309232	
Apellido Paterno	Apellido Materno	Nombre(s)
HERNANDEZ	NAVA	GERARDO
Dirección:		
Calle y número	Colonia	
Camino Viejo a Mixcoac #24	San Bartolo Ameyalco	
Estado	Teléfono (incluir lada)	
9	5586764600	
2. DATOS DEL PROYECTO		
Facultad:	INGENIERÍA	
Programa:	MAESTRIA EN CIENCIAS EN INTELIGENCIA ARTIFICIAL	
Tema específico del proyecto:	Predicción de eventos epilépticos mediante técnicas de aprendizaje profundo usando señales EEG.	
 RAMOS ARREGUIN JUAN MANUEL Director de tesis	 TOVAC ARRIAGA SAUL Coordinador de programa	 HERNANDEZ NAVA GERARDO Alumno
Dr. Juan Carlos Jáuregui Correa Jefe de División de Investigación y Posgrado de la Fac. de Ing.	 Dr. Manuel Toledano Ayala Director de Fac. Ing.	 Dra. Ma. Guadalupe Flavia Loarca Piña Directora de Investigación y Posgrado UAQ

Anexo 3 Manual de procedimientos Administrativos de Posgrado de la Facultad de Ingeniería

Figura Anexo 3.1: Constancia de registro del protocolo.



Universidad Autónoma de Querétaro
Facultad de Ingeniería
División de Investigación y Posgrado



C. U., mayo 13, 2022
Acta 295/2021

Dra. Ma. Guadalupe Flavia Loarca Piña
Directora de Investigación y Posgrado UAQ.
PRESENTE:

Con relación a su protocolo y registro en título de tema de tesis: **"PREDICCIÓN DE EVENTOS EPILÉPTICOS MEDIANTE TÉCNICAS DE APRENDIZAJE PROFUNDO USANDO SEÑALES EEG."** de (a) alumno (a) HERNANDEZ NAVA GERARDO con número de expediente 309232, del programa Maestría en Ciencias en Inteligencia Artificial con el (a) Dr. (a) RAMOS ARREGUIN JUAN MANUEL como Director (a) de la Tesis, enviado al H. Consejo de Posgrado e Investigación para su autorización, le informo el acuerdo que quedó asentado en el acta 295 de sesión ordinaria, celebrada el día 01 de diciembre de 2021.

SE ACEPTA PROTOCOLO Y REGISTRO DE TÍTULO DE TESIS.

Sin otro particular, me es grato enviarle un cordial saludo.

Atentamente
"El Ingenio para crear, no para destruir"

Dr. Manuel Toledano Ayala
Director de la Facultad de Ingeniería.

MTA*asg

Figura Anexo 3.2: Autorización del protocolo por parte del H. Consejo de Posgrado e Investigación.



C. U., 6 de abril de 2022

Gerardo Hernández Nava
Estudiante de Maestría en Ciencias en Inteligencia Artificial
Expediente 309232

Presente

El Comité de Ética Aplicada para la Investigación de la Facultad de Ingeniería ha revisado el protocolo del trabajo de tesis:

CEAIFI-035-2022-TP

Predicción de eventos epilépticos mediante técnicas de aprendizaje profundo usando señales EEG

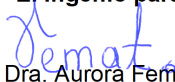
Con apego a los lineamientos éticos de beneficencia, no maleficencia, justicia y autonomía, este comité ha dado el siguiente dictamen:

Aprobado éticamente

El presente dictamen tiene vigencia de un año a partir de su fecha de emisión.

Sirva esta carta para los fines académicos que al interesado convengan.

Atentamente
“El Ingenio para Crear, No para Destruir”


Dra. Aurora Femat Díaz
Presidente del CEAIFI
afemat@uaq.mx

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
CERRO DE LAS CAMPANAS S/N, COL. LAS CAMPANAS
FACULTAD DE INGENIERÍA
C.P. 76010 QUERÉTARO, QRO. TEL. 192 12 00 EXT. 6023

Figura Anexo 3.3: Constancia de aprobación por parte del comite de ética.

Anexo 4

Productos de la maestría

Este anexo esta dirigido a presentar las publicación relacionas con el tema de investigación así como algunos reconocimientos recibidos.

Diseño y Planeación Mecatrónica, Capítulo 3, pp. 27 - 38.
 ISBN: 978-607-9394-25-7
 Asociación Mexicana de Mecatrónica A.C., 2022



Ictal-net: un Diseño de CNN para la Clasificación de Escalogramas de Electroencefalogramas con Crisis Convulsivas

Hernández Nava Gerardo, Salazar Colores Sebastián, Ortiz Echeverri César Javier,
 Leyva López Sheila y Ramos-Arreguín Juan Manuel[✉]

Universidad Autónoma de Querétaro, Facultad de Ingeniería
[✉]juan.ramos@uaq.mx

Resumen

La epilepsia es una enfermedad neurológica caracterizada por convulsiones de manera recurrente y aleatoria, que afecta a alrededor de 70 millones de personas en todo el mundo. Actualmente, en la epileptología, área que trata con la clasificación, detección y predicción de eventos epilépticos, se ha trabajado con la aplicación de técnicas de inteligencia artificial, como el aprendizaje profundo. Sin embargo, en tareas como la clasificación aún existe un margen de mejora en términos de exactitud, precisión, sensibilidad y puntaje F1. Por ello en este trabajo se presenta Ictal-net, una red neuronal convolucional propuesta para la clasificación periodos ictales (estados convulsivos) e interictales (estados libres de convulsiones) en señales de electroencefalografía. El objetivo de la red propuesta es detectar ataques epilépticos, para lo cual fueron caracterizadas señales de EEG mediante escalogramas obtenidos de la transformada wavelet continua. En este trabajo se utilizaron registros provenientes de la Universidad de Bonn, Alemania. Ictal-net obtuvo un 93.9% de exactitud, 95.47% en precisión, sensibilidad del 92.19% y un puntaje F1 de 93.8%, cifras que se encuentran entre las mejores reportadas en la literatura.

Palabras clave: Epilepsia, Clasificación, Escalogramas, Electroencefalograma, Transformada Wavelet Continua, Red Neuronal Convolucional.

1. Introducción

En la última definición clínica operativa publicada por la Liga Internacional Contra la Epilepsia (ILAE, por sus siglas en inglés) en 2014 se menciona que la epilepsia es una enfermedad cerebral que se define por cualquiera de las siguientes circunstancias: por la presencia de al menos dos crisis no provocadas con una separación entre ellas mayor a 24 horas, una crisis no provocada con una probabilidad mínima del 60% de presentar nuevas crisis durante los siguientes 10 años, o bien, tener un diagnóstico de un síndrome de epilepsia [1]. Se considera que este trastorno neurológico crónico no transmisible afecta alrededor de 70 millones de personas en el mundo, siendo una de las enfermedades neurológicas más comunes a nivel mundial, sin distinción de edad o sexo [2]. Esta enfermedad es caracterizada por convulsiones no provocadas que se presentan de forma recurrente y aleatoria.

Las personas que padecen esta enfermedad muchas veces se ven limitadas en sus actividades en la vida diaria, llegando a padecer de discriminación social y laboral [1] [13] [3], lo cual ha inspirado a la realización de este proyecto. Anteriormente, se han realizado trabajos relacionados con la clasificación, detección y predicción de eventos epilépticos, buscando ayudar a las personas que padecen esta enfermedad, mediante algoritmos de Inteligencia Artificial, específicamente, aprendizaje profundo.

Una de las partes clave en el desarrollo de dichos algoritmos, son los datos de entrada. Una de las señales fisiológicas fundamental en el diagnóstico, tratamiento y seguimiento de la epilepsia es el



Figura Anexo 4.2: Reconocimiento por presentación oral del artículo denominado Ictal-net: Un diseño de CNN para la clasificación de escalogramas de electroencefalogramas con crisis convulsivas.



Figura Anexo 4.3: Reconocimiento por el artículo: *Ictal-net: Un diseño de CNN para la clasificación de escalogramas de electroencefalogramas con crisis convulsivas*.

Article

Parallel Ictal-net, a Parallel CNN Architecture with Efficient Channel Attention for Seizure Detection

Gerardo Hernández-Nava ¹, Sebastián Salazar-Colores^{2*}, Eduardo Cabal-Yepez ³ and Juan-Manuel Ramos-Arreguín ⁴

¹ Faculty of Engineering, Autonomous University of Querétaro, Santiago de Querétaro, Querétaro, CO 76140; gerardohn.uam@gmail.com

² Research Department, Centro de Investigaciones en Óptica A.C., León, Guanajuato, CO 37150; sebastian.salazar@cio.mx

³ Multidisciplinary Studies Department, Campus Yuriria, University of Guanajuato, Yuriria, Guanajuato, CO 38954; educabal@ugto.mx

⁴ Faculty of Engineering, Autonomous University of Querétaro, Santiago de Querétaro, Querétaro, CO 76140; jsistdig@yahoo.com.mx

* Correspondence: sebastian.salazar@cio.mx;

Abstract: Around 70 million people worldwide suffer epilepsy, a neurological disorder characterized by non-induced convulsions occurring in irregular and arbitrary periods. Amid an epileptic seizure, transient signs appear because of extreme abnormal neural events. Epilepsy restricts people and affects the life of families. Therefore, reliable aiding tools for timely diagnosis of this disease are beneficial to eradicate social and emotional distress on patients. Several works have performed the classification of the Bonn University dataset, which contain 5 collection of EEG signals; however, not many of them focus on the subsets D and E, which correspond to EEG registers of the ictal and interictal events, acquired from the epileptogenic zone. Therefore, in this work, the Parallel Ictal-net (PIN) neural network architecture is introduced, which utilizes the scalograms obtained from the continuous wavelet transform, to perform a high-accuracy classification of EEG signals, into ictal or interictal states. Obtained results demonstrate the proposed-PIN efficacy on recognizing between ictal and interictal events with remarkable certainty, which is validated through computing the accuracy, precision, recall and F1 score, of the put forward technique, reaching around 99% of confidence for all of them, surpassing previous approaches in related literature.

Keywords: CNN, CWT, Efficient channel attention, Seizure detection.

Citation: To be added by editorial staff during production.

Academic Editor: Firstname
Lastname

Received: date
Revised: date
Accepted: date
Published: date



Copyright: © 2023 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

More than 70 million people worldwide have epilepsy, a non transmissible, chronic neurological disorder, which does not distinguish age, sex, or race. Epilepsy is characterized by non-induced convulsions occurring in an intermittent and random way. In 2014, the International League Against Epilepsy (ILAE) designated epilepsy as a brain disease characterized by any of the following conditions: occurrence of at least two non-provoked seizures, within 24 hours apart, one non-provoked crisis with a minimal probability of 60% on suffering new seizures through the following 10 years or having an epilepsy-syndrome diagnosis [1].

During an epileptic seizure, transient indicators or symptoms appear because of excessive or simultaneous abnormal neural activity. The symptoms may include temporal disorientation, absent lapses, loss of consciousness, psychic symptoms (e.g., dread, anxiety, and déjà vu) as well as sudden and uncontrollable muscular-contraction movements of the body extremities. Suffering from this disease restricts people in

Anexo 5

Actividades Extracurriculares

Además de las investigaciones que implico este proyecto. Se estuvieron trabajando en diferentes investigaciones externas, de las cuales se escribieron diversos artículos y se presentaron posters en congresos nacionales e internacionales. En esta sección se presentarán los artículos escritos, los reconocimientos obtenidos entre otros documentos.



Plantilla latex para protocolo de tesis de posgrado en la Facultad de Ingeniería, Universidad Autónoma de Querétaro

Estudiante:
Ing. Arya Stark

Director:
Dr. Syrio Forel

Codirector:
Dr. Jaqen H'ghar

20 de octubre de 2022



Figura Anexo 5.1: Plantilla para protocolo de tesis, dirigido a alumnos de la facultad de ingeniería, en Latex.

Diseño y Planeación Mecatrónica, Capítulo 19, pp. 262 - 271.
 ISBN: 978-607-9394-25-7
 Asociación Mexicana de Mecatrónica A.C., 2022



Aprendizaje Automático para la Detección del Daño Pulmonar a través de Parámetros Clínicos

Leyva López Sheila¹, [✉]Salazar Colores Sebastián², Hernández Nava Gerardo¹ y Pedraza Ortega Jesús-Carlos¹.

¹ Universidad Autónoma de Querétaro, Facultad de Ingeniería, Querétaro, Querétaro, México.

² Centro de Investigaciones en Óptica, León, Guanajuato, México.
[✉]sebastian.salazar@cio.mx

Resumen

El aprendizaje automático es un campo de la inteligencia artificial especializado en la tarea de clasificación a partir de patrones extraídos de datos. En los últimos años sus aplicaciones en medicina han tenido un éxito sin precedentes. Enfermedades como la fibrosis pulmonar idiopática requieren un correcto diagnóstico temprano para favorecer la calidad de vida del paciente. Esta enfermedad ha sido diagnosticada mayormente desde el enfoque de visión artificial. Sin embargo, no siempre es posible proveer imágenes médicas a estos sistemas de visión. En esta investigación se presentan los resultados de realizar una exploración en la tarea de clasificación del daño pulmonar sobre únicamente parámetros clínicos: edad y sexo del paciente, su relación con el tabaco, y el resultado de su capacidad vital forzada. Tres populares paradigmas de inteligencia artificial fueron desarrollados y analizados: una red neuronal artificial, bosques aleatorios, y regresión logística. Bajo las métricas de exactitud, sensibilidad y puntaje-F1 se muestra que bosques aleatorios obtuvo el puntaje más alto para esta tarea con 92%, 93% y 94%, respectivamente.

Palabras clave: Fibrosis Pulmonar, Capacidad Vital Forzada, Redes Neuronales Artificiales, Árboles Aleatorios, Regresión Logística.

1. Introducción

La fibrosis pulmonar idiopática (FPI) es una enfermedad crónica, progresiva y limitante que principalmente se caracteriza por una tos persistente que evoluciona a lo largo de meses, y en la mayoría de los casos le precede un cuadro respiratorio agudo [1]. Hasta el día de hoy, la FPI no tiene cura. Sin embargo, un diagnóstico certero podría ayudar a reducir el riesgo de muerte del paciente e incluso mejorar su esperanza y calidad de vida, dado que el promedio de supervivencia después de presentar los primeros síntomas se ubica entre los 3 y 5 años.

Utilizada para detectar FPI, la prueba de función pulmonar (PFP) es una evaluación para conocer el funcionamiento de los pulmones, es decir, conocer si los pulmones están realizando su función de inspiración y expiración de aire, correctamente [2]. Dicha evaluación puede incluir espirometrías, pruebas de volumen pulmonar, oximetría, pruebas de fracción de óxido nítrico espirado y/o pruebas de gases en sangre arterial [3], [4]. Una de las pruebas de función pulmonar más reconocida y estandarizada es la espirometría. La cual es no invasiva, y mediante la medición de flujos y volúmenes de aire exhalado e inspirado ayuda a identificar si existen obstrucciones al flujo respiratorio. Dentro de esta prueba se manejan dos principales parámetros fisiológicos: volumen espiratorio forzado en el primer segundo (FEV₁) y capacidad vital forzada (CVF), esta última se refiere al volumen máximo de aire exhalado de manera forzada por la boca después una inspiración máxima [5]. Específicamente, se considera que la CVF es normal cuando es mayor al 80% de su valor teórico [6] y suele disminuir en pacientes con fibrosis pulmonar idiopática.



Figura Anexo 5.3: Reconocimiento por la aportación al 21° Congreso Nacional de Mecatrónica con el artículo *Aprendizaje Automático para la Detección del Daño Pulmonar a través de Parámetros Clínicos*.



Análisis de Modelos de Segmentación de Atrofia Peripapilar Alfa y Beta en Imágenes de Fondo de Ojo

Anguiano Almejo Javier¹, Hernández Nava Gerardo¹ y Alfonso Francia Gendry¹

¹Universidad Autónoma de Querétaro
 Anguiano_javier@outlook.com

Resumen

La atrofia peripapilar (APP) es un hallazgo clínico que refleja la atrofia de la capa de la retina y el epitelio pigmentario de la retina. La extensión y el desarrollo de la APP son factores de evaluación médica de interés para los especialistas de la visión, ya que se relacionan estrechamente con la gravedad de diversas enfermedades y afecciones oculares, lo cual destaca la importancia de separar el área APP de las imágenes retinianas. Esta es una tarea desafiante debido a que las áreas de APP son irregulares y no uniformes con cambios graduales en sus límites. En este trabajo se comparan los modelos: Segnet, Segnet Mobilenet, Segnet Vgg, Segnet Resnet50, Unet, Unet Vgg, Unet Resnet50, Unet Mobilenet, Unet Mini, FCN 8, FCN 8 Vgg, FCN 8 Mobilenet, FCN 32, FCN 32 Vgg y FCN 32 Mobilenet; mediante puntaje f1, intersección sobre la unión, sensibilidad y precisión. Se utiliza una muestra de 300 del conjunto de datos ORIGA, que contiene imágenes de fondo de ojo de pacientes sanos y con glaucoma. Como resultado se observó que las redes MobileNet obtuvieron métricas superiores al resto, entre ellas se destacó Unet Mobilenet.

Palabras clave: Atrofia Peripapilar, Segmentación, Aprendizaje Profundo, Visión Artificial, Glaucoma, Redes Neuronales.

1. Introducción

El análisis automatizado de imágenes biomédicas es un área de gran interés en la inteligencia artificial (IA), dada su relevancia en el apoyo al diagnóstico de enfermedades. La oftalmología es un área de la medicina, donde se han incorporado técnicas de IA para agilizar el trabajo de los médicos. El estudio de fotografías de fondo de ojo es una de ellas, ya que, a partir de estas, es posible determinar enfermedades como glaucoma, hipertensión, retinopatía diabética y degeneración macular [1].

En el análisis de imágenes de fondo de ojo, se pueden examinar diferentes estructuras morfológicas, entre las que se encuentran: el disco óptico, nervio neuro retiniano, capas de fibras nerviosas retinianas, atrofia peripapilar (APP) y hemorragias retinianas o del disco óptico [2]. Estudios clínicos ha demostrado que la APP presenta una fuerte correlación con el diagnóstico de glaucoma [3]. La APP es un biomarcador que se expresa como un adelgazamiento y degeneración del tejido coriorretiniano alrededor del nervio óptico [4]. El área de APP se puede presentar como una estructura de medialuna o de circunferencia completa en la periferia del nervio óptico con bordes irregulares. Esta suele estar conformada por dos tipos: la zona alfa y la zona beta [5].

La zona alfa, se caracteriza por una región de hiper e hipopigmentación irregular del epitelio pigmentario de la retina (EPR) y generalmente se encuentra en pacientes con miopía [6]. La zona beta se expresa con mayor frecuencia en pacientes con glaucoma, que tiene como característico



Figura Anexo 5.5: Reconocimiento por la aportación al 21° Congreso Nacional de Mecatrónica con el artículo *Análisis de Modelos de Segmentación de Atrofia Peripapilar Alfa y Beta en Imágenes de Fondo de Ojo*.

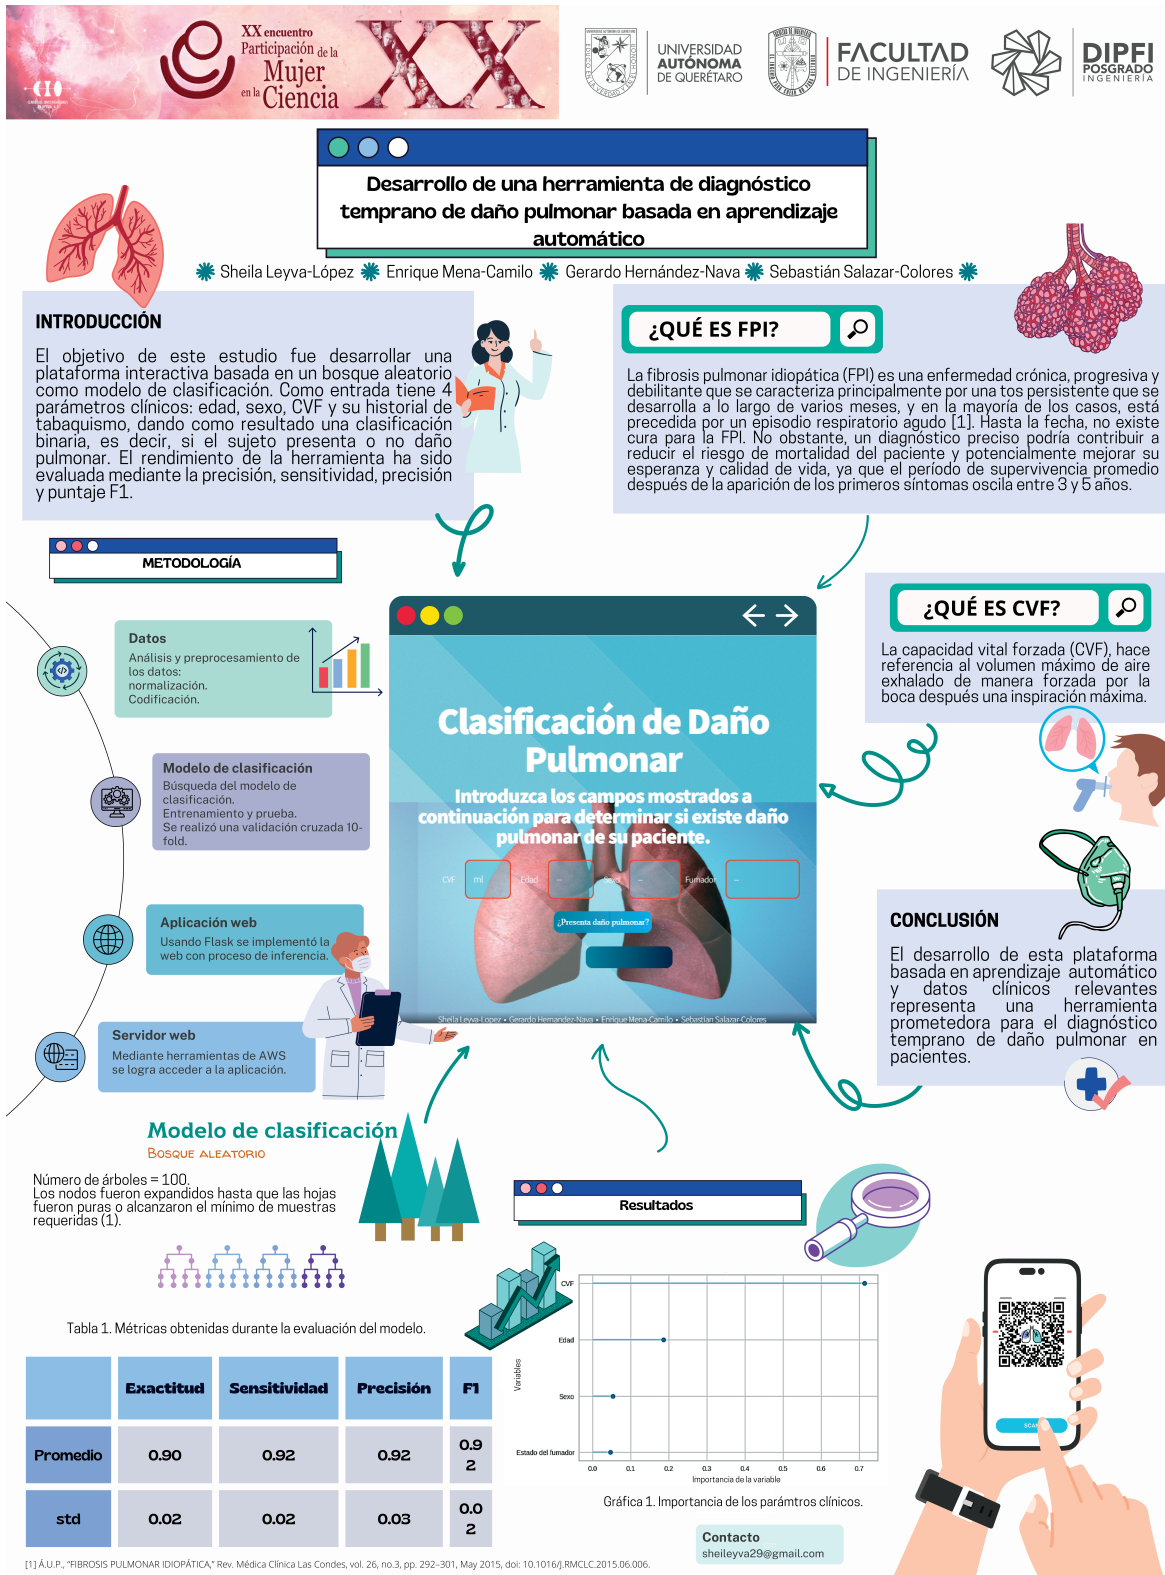


Figura Anexo 5.6: Póster realizado para presentar en un congreso del Centro de Investigaciones en Óptica.

INVESTIGACIONES Y DESARROLLOS TECNOLÓGICOS EN MÉXICO CENTRO DE INVESTIGACIONES EN ÓPTICA, A. C.

DESARROLLO DE UNA HERRAMIENTA DE DIAGNÓSTICO TEMPRANO DE DAÑO PULMONAR BASADA EN APRENDIZAJE AUTOMÁTICO

Sheila Leyva-López¹, Enrique Mena-Camilo¹, Gerardo Hernández-Nava¹, Sebastián Salaza-Colores²

¹Universidad Autónoma de Querétaro, ²Centro de Investigaciones en Óptica.
sheileyva29@gmail.com

RESUMEN

El objetivo de este estudio ha sido desarrollar una plataforma interactiva basada en técnicas de aprendizaje automático para la predicción de daño pulmonar. Se utilizaron parámetros clínicos de 176 pacientes, incluyendo información sobre su edad, sexo, capacidad vital forzada y su historial de tabaquismo. Se ha utilizado el algoritmo de bosques aleatorios para entrenar el modelo y se ha evaluado su rendimiento mediante métricas de exactitud, precisión, sensibilidad y puntaje F1. La plataforma interactiva ha sido desarrollada para permitir que los usuarios introduzcan los parámetros clínicos relevantes y obtengan una clasificación de si tienen o no daño pulmonar. Esta plataforma resulta ser de fácil uso y permite la interacción con los datos de manera visual e intuitiva. El modelo de predicción, que se ha entrenado utilizando el algoritmo de bosques aleatorios, ha demostrado un alto rendimiento en la identificación de daño pulmonar, obteniendo una exactitud del 90% y el resto de las métricas (precisión, sensibilidad y puntaje F1) con 92%. El desarrollo de esta plataforma interactiva basada en técnicas de aprendizaje automático y datos clínicos relevantes representa una herramienta prometedora para el diagnóstico temprano de daño pulmonar en pacientes. La inclusión de los parámetros clínicos relevantes ha permitido una evaluación precisa y personalizada del riesgo de daño pulmonar.

INTRODUCCIÓN

La fibrosis pulmonar idiopática (FPI) es una enfermedad crónica y progresiva que afecta gravemente la salud. Su principal manifestación es una tos persistente que se desarrolla a lo largo de varios meses y, en la mayoría de los casos, se presenta después de un episodio respiratorio agudo [1]. Lamentablemente, hasta la fecha, no existe una cura para esta enfermedad. No obstante, es crucial contar con un diagnóstico preciso que pueda reducir el riesgo de mortalidad del paciente y, al mismo tiempo, mejorar su esperanza y calidad de vida. Cabe destacar que el promedio de supervivencia después de la aparición de los primeros síntomas varía entre 3 y 5 años.

La evaluación de la función pulmonar (PFP) es una prueba utilizada en la detección de la FPI. Esta prueba permite evaluar el correcto funcionamiento de los pulmones, determinando si la inspiración y la expiración del aire se están llevando a cabo de manera adecuada [2]. Se realizan varios exámenes dentro de esta evaluación, como la espirometría, las pruebas de volumen pulmonar, la oximetría, el análisis de la fracción de óxido nítrico espirado y las pruebas de gases en sangre arterial [3], [4].

La espirometría es una de las pruebas de función pulmonar más reconocidas y estandarizadas. Esta prueba permite detectar posibles obstrucciones en el flujo respiratorio mediante la medición precisa de los flujos y volúmenes de aire inhalado y exhalado. Se toman en cuenta dos parámetros fisiológicos fundamentales en la espirometría: el volumen espiratorio forzado en el primer segundo (FEV1) y la capacidad vital forzada (CVF). La CVF se refiere al volumen máximo de aire exhalado de manera forzada por la boca después de una inhalación profunda [5]. Se considera que la CVF es normal cuando supera el 80% de su valor teórico [6]. Sin embargo, en pacientes con fibrosis pulmonar idiopática, suele disminuir.

Por otra parte, el aprendizaje automático (ML, por sus siglas en inglés), una rama de la inteligencia artificial (IA), se caracteriza por su capacidad de analizar grandes cantidades de datos, extrayendo patrones y predicciones a partir de ellos. Una aplicación clave del ML es la clasificación, que consiste en asignar etiquetas a conjuntos de características o señales basándose en patrones

Figura Anexo 5.7: Artículo *Desarrollo de una herramienta de diagnóstico temprano de daño pulmonar basada en aprendizaje automático.*



Figura Anexo 5.8: Página web para realizada para la clasificación de Daño pulmonar presentada en un congreso del Centro de Investigaciones en Óptica.



Figura Anexo 5.9: Reconocimiento por la participación en el XX encuentro Participación de la Mujer en la Ciencia

2023 IEEE Conference on Artificial Intelligence

Improving Idiopathic Pulmonary Fibrosis Damage Prediction with Segmented Images in a Deep Learning Model

Sheila Leyva-López¹, Gerardo Hernández-Nava¹, Enrique Mena-Camilo¹, Sebastián Salazar-Colores²

¹Autonomous University of Queretaro, ²Centro de Investigaciones en Óptica

Main Objective

The main objective of this work is to improve the prediction of lung damage caused by IPF by implementing a UNet semantic segmentation module. This is a preprocessing block for the network proposed in [3], which is an end-to-end multi-modal learning-based approach that predicts the decline of FVC in patients with IPF, using CT images and demographic information in CNN frameworks with a stacked attention layer.

What is IPF?

Idiopathic Pulmonary Fibrosis (IPF) is a chronic, progressive, and debilitating disease that is primarily characterized by persistent coughing that evolves over several months, often preceded by an acute respiratory illness [1]. To date, IPF remains an incurable disease. However, an accurate and timely diagnosis can significantly contribute to reducing the mortality associated with this pathology and improving the life expectancy and quality of life of affected patients. It is worth noting that, after the onset of the first symptoms, the average survival interval ranges between 2 and 5 years [1] [2].

What is FVC?

Forced Vital Capacity (FVC) refers to the maximum volume of air forcibly exhaled through the mouth after maximal inspiration.

RESULTS

$$LLL_m = \log\left(P + \frac{1}{N+K}\right) \quad (1)$$

where:
LLL_m is the Laplace Log-Likelihood. **P** stands for the number of correct predictions made by the model on the test dataset. **N** is the size of the test dataset. **K** is the number of classes or possible values.

f-encoder	Experimental	RMSE			LLL _m		
		Mean	Std	Difference from guided image	Mean	Std	Difference from guided image
ResNet34	Fibro-CoSAet	184.79	21.45	-0.28	6.73	0.31	0.57
	Replicated Model	184.62	20.76	-0.37	6.71	0.25	0.32
	Guided Image	185.31	21.42	-	6.69	0.25	-

Note:
 The evaluations and calculated metrics were obtained using the 5-Fold technique, this implies that an 80% training and 20% testing data split was performed on the datasets used, with this process being repeated 5 times while varying the elements in the sets

METHODOLOGY

Segmentation Module

- A central slice of the CT scan is randomly selected, omitting 15% of the initial and final slices.
- Images are converted to PNG format with dimensions of 256 × 256 × 1 in order to optimize the use of graphic computing memory.

UNet

- Subsequently, the image is processed by a UNet that uses the DenseNet121 network architecture as the encoder.
- As a result of the evaluation of the input in the previous model, a mask is obtained, where the lungs of the CT slice are segmented.

Prediction Model

Different encoder functions are tested within the Fig. 1 model, including EfficientNet, ResNet, and ResNeXt, with their respective variations.

Evaluation metrics

Finally, the LLL_m and RMSE metrics, which are indicators of the reliability of the predictions, are calculated to perform a quantitative comparison between the experiments.

Figure 1. Implementation of the segmentation module to the Fibro-CoSAet model

CONCLUSION

Based on the results obtained, which indicate a favorable difference when using a guided image at the input of the prediction model, it can be concluded that the inclusion of additional data, such as masks obtained through segmentation models, improves the input data to models and thus obtains precise and reliable results in predicting idiopathic pulmonary fibrosis damage. These can be used as preprocessing modules for future work.

Proven f-encoders

- EfficientNet B0
- EfficientNet B1
- EfficientNet B2
- EfficientNet B3
- EfficientNet B4
- ResNet 18
- ResNet 34
- ResNet 50
- ResNet 101
- ResNet 152
- ResNext 50
- ResNext 101

REFERENCES

[1] A. Sánchez, J. Acosta, and M. Molina-Molina, "Idiopathic pulmonary fibrosis," *Medicina Clínica (English Edition)*, vol. 148, no. 4, pp. 170-175, 2017. (Online). Available: <https://doi.org/10.1016/j.medcli.2016.11.035>

[2] S. C. Kim, S. H. Kim, P. S. Park, and B. Kim, "Idiopathic pulmonary fibrosis: Current and future treatment," *The Clinical Respiratory Journal*, vol. 16, no. 2, pp. 84-90, 2021. (Online). Available: <https://doi.org/10.1111/crj.13466>

[3] A. Nish, E. M. Moshier, M. A. Islam, and S. Saha, "Idiopathic pulmonary fibrosis prognosis prediction using a convolutional self-attention network," *Physica in Medicina & Biologia*, vol. 66, no. 22, 2021. (Online). Available: <https://doi.org/10.1088/1361-6560/ab2562>

[4] Y. Tian, "Lung function decline prediction using improved efficientnet," 2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP), pp. 924-927, 2022. (Online). Available: <https://doi.org/10.1109/ICSP5964.2022.9779391>

[5] T. Chai and B. Q. Guo, "Mean square error (mse) or mean absolute error (mae)? arguments about avoiding errors in the literature," *Genes*, vol. 12, no. 1, pp. 1247-1250, 2021. (Online). Available: <https://doi.org/10.3390/genes12011247>

[6] S. C. Kim, "Idiopathic pulmonary fibrosis prognosis," *Open Source Imaging Consortium (OSIC) 2020*, Virtual, October 2020. (Online). Available: <https://www.kaggle.com/computer-graphics/pulmonary-fibrosis-prognosis-overview>

[7] H. H. Kim, "Code-dataset121: lung of segmentation," *Kaggle*, 2020. Virtual, October 2022. (Online). Available: <https://www.kaggle.com/code/hulya/unsupervised-dense-net121-lung-of-segmentation/notebook>

RELATED WORK

Scan me

ABOUT US

Scan me

Figura Anexo 5.10: Póster presentado en el congreso IEEE CAI 2023.

Improving Idiopathic Pulmonary Fibrosis Damage Prediction with Segmented Images in a Deep Learning Model

1st Sheila Leyva-López
Faculty of Engineering
Autonomous University of Queretaro
Queretaro, Mexico
0000-0003-3634-8351

2nd Gerardo Hernández-Nava
Faculty of Engineering
Autonomous University of Queretaro
Queretaro, Mexico
0000-0002-8685-1003

3rd Enrique Mena-Camilo
Faculty of Engineering
Autonomous University of Queretaro
Queretaro, Mexico
0000-0001-8353-9017

4th Sebastián Salazar-Colores
Centro de Investigaciones en Óptica
León, México
0000-0002-6353-0864

Abstract—This work introduces a semantic segmentation model, UNet, as a preprocessing module to an algorithm predicting lung damage caused by Idiopathic Pulmonary Fibrosis. By modifying the model input through the incorporation of a guide image (a segmentation result) into the original image, we observed an improved performance of eight out of twelve tested backbones in the prediction model, with an improvement of up to 0.57 in the LLL_m metric. This study underscores the significance of data preprocessing in deep learning models' performance. The inclusion of additional data, such as segmented images, can significantly enhance a model's ability to perform specific tasks, emphasizing the need for careful data preprocessing to obtain precise and reliable results when implementing deep learning models for lung damage prediction.

Index Terms—Segmentation, Deep Learning, Idiopathic Pulmonary Fibrosis, Computed Tomography.

I. INTRODUCTION

Idiopathic Pulmonary Fibrosis (IPF) is a chronic, progressive, and debilitating disease that is primarily characterized by persistent coughing that evolves over several months, often preceded by an acute respiratory illness [1]. To date, IPF remains an incurable disease. However, an accurate and timely diagnosis can significantly contribute to reducing the mortality associated with this pathology and improving the life expectancy and quality of life of affected patients. It is worth noting that, after the onset of the first symptoms, the average survival interval ranges between 2 and 5 years [1] [2].

The main objective of this work is to improve the prediction of lung damage caused by IPF by implementing a UNet semantic segmentation module. This is a preprocessing block for the network proposed in [3], which is an end-to-end multimodal learning-based approach that predicts the decline of forced vital capacity (FVC) in patients with IPF, using Computed Tomography (CT) images and demographic information in convolutional neural network (CNN) frameworks with a stacked attention layer.

To evaluate the models, two main metrics are considered, Laplace Log-Likelihood (LLL_m) (Equation 1), which measures a model's ability to correctly predict the classes or values of a test dataset, using logarithmic probability as a measure of error. One advantage of this metric is that it avoids problems of overfitting and underestimating the model's accuracy. Moreover, it is especially useful when working with small or imbalanced datasets [4]. The root mean squared error ($RMSE$) (Equation 2) is also used, which evaluates the accuracy of a regression model. $RMSE$ measures the average squared difference between the actual values and the predicted values by the model [5].

$$LLL_m = \log\left(P + \frac{1}{N + K}\right) \quad (1)$$

where:

LLL_m es la Laplace Log-Likelihood. P stands for the number of correct predictions made by the model on the test dataset. N is the size of the test dataset. K is the number of classes or possible values.

$$RMSE = \sqrt{\frac{\sum(y - y_{pred})^2}{n}} \quad (2)$$

where:

n represents the number of observations in the dataset. y is the true value of the response variable. y_{pred} is the predicted value of the response variable.

II. DATABASE

The database provided in [6] comprises 176 training subjects and 5 test subjects. However, for this study, we decided to only utilize the training set as the remaining subjects are unlabeled. The segmentation of this training set is described in the methodology section. The main objective is to predict the last three forced vital capacity (FVC) measurements, as well

Figura Anexo 5.11: Artículo *Improving Idiopathic Pulmonary Fibrosis Damage Prediction with Segmented Images in a Deep Learning Model*.



Classification of COVID-19 Mortality Risk: A Neural Network-Based Approach Using Mexican Healthcare Sector Data

Enrique Mena-Camilo¹(✉) , Gerardo Hernández-Nava¹ ,
Sheila Leyva-López¹ , and Sebastián Salazar-Colores²

¹ Facultad de Ingeniería, Universidad Autónoma de Querétaro,
Santiago de Querétaro, 76010 Querétaro, Mexico
enriquemece97@gmail.com

² Centro de Investigaciones en Óptica, 37150 León, Guanajuato, Mexico

Abstract. This study focuses on the use of neural networks and clinical data collected by the Mexican Ministry of Health to classify the risk of death from COVID-19. A multi-layer perceptron neural network model was designed, achieving remarkable results with an accuracy of 96.28%, sensitivity of 99.23%, and an F1 score of 0.9773. The model was optimized through meticulous exploration of various network configurations and performance enhancement techniques. The results showcase the efficacy of neural networks in predicting the risk of death, allowing healthcare professionals to prioritize treatment and allocate resources more efficiently. The value of artificial intelligence in the fight against the pandemic is emphasized, along with its potential application in diverse geographical and healthcare contexts. This work contributes to the advancement of predictive models and encourages further research in the fields of epidemiology and artificial intelligence to combat COVID-19.

Keywords: COVID-19 · Artificial Neural Network · Multi-Layer Perceptron · Mortality Risk

1 Introduction

The COVID-19 pandemic, has posed an unprecedented global health challenge. The World Health Organization (WHO) reports that as of June 2023, the virus has caused the death of over 6.9 million people worldwide, with the actual number possibly exceeding 20 million [13, 15]. Despite the declaration of the national emergency as concluded, the number of infections and fatalities continues to rise. In just June 2023, WHO reports 1 million new cases and 5,700 deaths [14], while the Mexican Government during the same period reports 14,820 new cases and 143 deaths [4].

The pandemic has highlighted the need for more sophisticated data processing techniques to handle the vast amount of generated information. Artificial

© The Author(s), under exclusive license to Springer Nature Switzerland AG 2024
J. de J. A. Flores Cuautle et al. (Eds.): CNIB 2023, IFMBE Proceedings 96, pp. 112–119, 2024.
https://doi.org/10.1007/978-3-031-46933-6_12

Figura Anexo 5.12: Artículo *Classification of COVID-19 Mortality Risk: A Neural Network-Based Approach Using Mexican Health Setor Data.*



Figura Anexo 5.13: Reconocimiento por la participación en el 46° Congreso Nacional de Ingeniería Biomédica con el artículo *Classification of COVID-19 Mortality Risk: A Neural Network-Based Approach Using Mexican Health Setor Data*.