

---

Aplicación de algoritmos de aprendizaje automático, con énfasis en aprendizaje supervisado, para la identificación y categorización de segmentos de interés en señales bioeléctricas para el estudio de la epilepsia - Fase V

---

Javier Alejandro Pérez Marín





UNIVERSIDAD DEL VALLE DE GUATEMALA  
Facultad de Ingeniería



**Aplicación de algoritmos de aprendizaje automático, con  
énfasis en aprendizaje supervisado, para la identificación y  
categorización de segmentos de interés en señales bioeléctricas  
para el estudio de la epilepsia - Fase V**

Trabajo de graduación presentado por Javier Alejandro Pérez Marín  
para optar al grado académico de Licenciado en Ingeniería Mecatrónica

Guatemala,

2024



UNIVERSIDAD DEL VALLE DE GUATEMALA  
Facultad de Ingeniería




**Aplicación de algoritmos de aprendizaje automático, con  
énfasis en aprendizaje supervisado, para la identificación y  
categorización de segmentos de interés en señales bioeléctricas  
para el estudio de la epilepsia - Fase V**

Trabajo de graduación presentado por Javier Alejandro Pérez Marín  
para optar al grado académico de Licenciado en Ingeniería Mecatrónica


Guatemala,

2024


Vo.Bo.:

(f)   
M. Sc. Carlos Esquit

Tribunal Examinador:

(f)   
M.Sc. Carlos Esquit

(f)   
M. Sc. Miguel Enrique Zea Arenales

(f)   
Ing. Kurt Emmanuel Kellner

Fecha de aprobación: Guatemala, 13 de febrero de 2025.

A mis padres, Oscar y Karol, por creer en mis sueños, apoyarme y ser parte de ellos. Por su esfuerzo incansable, por siempre buscar lo mejor para nosotros, por siempre pensar en los 4 y por enseñarme que la unión familiar y el amor incondicional son la base de todo logro. Su ejemplo me ha mostrado que, aun en medio de las adversidades, la fe en Dios y el compromiso se transforman en fuerza para seguir adelante. En cada paso de mi camino, he llevado su sabiduría y su entrega, recordándome que cada sacrificio y cada pequeño triunfo han cimentado en mí los valores que hoy me definen.

A Dani, mi hermana, siempre has sido una parte fundamental en mi vida. Siempre quiero estar para la súper diseñadora y hermana que eres, acompañándote en cada paso y celebrando cada uno de tus logros. Tu cariño, tus risas y tus constantes ánimos han iluminado mi camino. Eres una persona increíblemente capaz y te animo a seguir esforzándote, confiada en que lograrás todo lo que te propongas. Gracias por estar siempre presente y por aportar esa alegría que tanto me ha impulsado a avanzar.

Esta tesis no solo representa el cierre de mi carrera universitaria, sino también la oportunidad de decirles que, hoy, somos ingenieros y lo hemos logrado, a pesar de la incertidumbre que nos acompañó al inicio y con una inmensa alegría y gratitud al llegar a este fin. Este trabajo es un tributo a sus enseñanzas, a sus sacrificios, a esos abrazos que siempre estuvieron ahí para reconfortarme y a la luz que han encendido en mí, impulsándome a nunca dejar de soñar.

A mi familia, en especial a mis abuelitos, tíos, tías y primos, gracias por su aliento, cariño y apoyo, que hicieron de estos 5 años una experiencia aún mejor. Sus palabras de ánimo y su constante presencia me motivaron a superar cada desafío y a celebrar cada logro. Este éxito es también de ustedes, que con su cariño y ejemplo dejan una huella imborrable en mi camino.

A mi novia, por tu apoyo constante, compañía, cariño y tus palabras de aliento que me han acompañado a lo largo de estos cinco años. Tu compañía ha sido una parte invaluable de este camino, aportando fuerza en los momentos difíciles y haciendo más significativos los logros alcanzados. Porque no se trata solo del viaje, sino de la compañía que enriquece cada paso del camino.

A todos mis amigos y amigas de la UVG, en especial a Cerón, Gerardo y Alba. Sin duda, repetiría estos 5 años las veces que me lo pidieran, si ustedes estuvieran allí. Gracias por cada curso y “sufrimiento” compartido, gracias por cada risa y consejo, gracias por estar. Sigamos soñando en grande, porque son ingenieros capaces, y quiero estar allí para aplaudir cuando logren sus metas y para abrazarlos en los momentos en que las cosas no salgan como esperaban, pero siempre con la frente en alto y con ganas de seguir adelante.

A mi asesor, Dr. Luis Alberto Rivera, con toda mi admiración y agradecimiento, un verdadero ejemplo de persona y docente. Su constante acompañamiento, gran conocimiento y la confianza que ha depositado en mí me han motivado a lo largo de este trabajo y me han dejado un aprendizaje invaluable para el futuro en el ámbito de la investigación. Gracias por confiar en mí y siempre impulsarme a dar lo mejor de mí. Dios le siga bendiciendo.

A todos mis docentes y mentores de la universidad, les extiendo mi más sincero agradecimiento por su dedicación, compromiso y el incansable afán de compartir su conocimiento. Cada clase, cada consejo y cada reto me han enriquecido, impulsándome a crecer y aprender. De manera especial, quiero agradecer a M.Sc. Miguel Zea, cuyo gran apoyo y orientación en este trabajo fueron de mucha ayuda. Gracias a todos y todas por iluminar la trayectoria de sus estudiantes y ser una fuente de inspiración.

Finalmente, más no menos importante, agradezco a Dios por ser mi luz y guía en cada paso de este camino. Agradezco a las personas que apoyan el programa de becas de la UVG, cuyo compromiso y generosidad han hecho posible que este sueño se materialice. También extiendo mi gratitud a todas aquellas personas que, sin ser nombradas, tienen un lugar muy especial en mi corazón. Gracias por su fe, su amor y por creer en mí.

---

*Que cada día cuente para hacer realidad nuestros sueños*

---

<b>Prefacio</b>	<b>IV</b>
<b>Lista de figuras</b>	<b>IX</b>
<b>Lista de cuadros</b>	<b>X</b>
<b>Resumen</b>	<b>XI</b>
<b>Abstract</b>	<b>XII</b>
<b>1. Introducción</b>	<b>1</b>
<b>2. Antecedentes</b>	<b>2</b>
2.1. Contexto general de la epilepsia . . . . .	2
2.2. Estado del arte en el uso del aprendizaje automático para la epilepsia . . . . .	3
2.3. Evolución línea de investigación en Universidad del Valle de Guatemala . . . . .	4
<b>3. Justificación</b>	<b>7</b>
<b>4. Objetivos</b>	<b>8</b>
4.1. Objetivo general . . . . .	8
4.2. Objetivos específicos . . . . .	8
<b>5. Alcance</b>	<b>9</b>
<b>6. Marco teórico</b>	<b>10</b>
6.1. Cerebro humano . . . . .	10
6.1.1. Actividad eléctrica del cerebro . . . . .	11
6.1.2. Ritmos normales . . . . .	12
6.2. Epilepsia . . . . .	13
6.2.1. Anomalías epileptiformes . . . . .	14
6.2.2. Fases de una crisis epiléptica . . . . .	16
6.2.3. Tipos de crisis epilépticas . . . . .	16
6.3. Análisis de señales EEG . . . . .	17

6.3.1.	Montajes . . . . .	18
6.3.2.	Análisis en el dominio de la frecuencia . . . . .	19
6.3.3.	Análisis en el dominio del tiempo . . . . .	19
6.4.	Algoritmos de aprendizaje automático . . . . .	20
6.4.1.	Aprendizaje supervisado . . . . .	21
6.4.2.	Aprendizaje no supervisado . . . . .	22
6.4.3.	Aprendizaje reforzado . . . . .	22
6.5.	Aprendizaje profundo . . . . .	22
6.5.1.	Entrenamiento de redes neuronales profundas . . . . .	24
6.5.2.	Tipos de redes neuronales profundas . . . . .	26
<b>7.</b>	<b>Obtención y recolección de datos</b>	<b>29</b>
7.1.	Propuesta de recolección de datos estandarizada . . . . .	29
7.2.	Centros especializados . . . . .	32
7.3.	Bases de datos médicas . . . . .	32
7.3.1.	<i>Siena Scalp EEG Database</i> . . . . .	32
7.3.2.	<i>CHB-MIT Scalp EEG Database</i> . . . . .	33
7.3.3.	<i>The Temple University Hospital EEG Data Corpus (TUH)</i> . . . . .	33
7.3.4.	Otras bases de datos disponibles . . . . .	35
7.3.5.	Selección base de datos de TUH . . . . .	35
<b>8.</b>	<b>Procesamiento de estudios</b>	<b>36</b>
8.1.	Selección de estudios . . . . .	36
8.1.1.	Descripción del conjunto de datos . . . . .	36
8.1.2.	Descarga de estudios de base de datos . . . . .	38
8.2.	Definición de parámetros de HUMANA . . . . .	38
8.3.	Migración de estudios a MATLAB . . . . .	39
8.3.1.	Selección de tipo de referencia . . . . .	39
8.3.2.	Lectura en memoria de estudios . . . . .	39
8.3.3.	Lectura optimizada de estudios . . . . .	41
<b>9.</b>	<b>Redes neuronales profundas: justificación y métodos generales</b>	<b>43</b>
9.1.	Justificación del enfoque de redes neuronales profundas . . . . .	43
9.2.	Implementación y validación de red LSTM . . . . .	44
9.2.1.	Estructura de la red . . . . .	44
9.2.2.	Opciones de entrenamiento . . . . .	45
9.2.3.	Proceso de entrenamiento y resultados . . . . .	45
9.3.	Implementación y validación de red TCN . . . . .	47
9.3.1.	Estructura de la red . . . . .	47
9.3.2.	Opciones de entrenamiento . . . . .	49
9.3.3.	Proceso de entrenamiento y resultados . . . . .	49
<b>10.</b>	<b>Implementación de redes EEGnet</b>	<b>51</b>
10.1.	Implementación de redes LSTM EEGnet . . . . .	51
10.1.1.	Estructuras trabajadas . . . . .	51
10.1.2.	Resumen resultados LSTM EEGnet . . . . .	53
10.2.	Implementación de redes TCN EEGnet . . . . .	54
10.2.1.	Estructuras y resultados . . . . .	54

10.3. Discusión redes EEGnet . . . . .	56
<b>11. Herramienta <i>Epileptic EEG Analysis Toolbox</i></b>	<b>58</b>
11.1. Migración a MATLAB 2024 . . . . .	58
11.1.1. Evaluación de dependencias para la migración . . . . .	58
11.1.2. Manejo de herramienta como proyecto y cambios necesarios . . . . .	59
11.2. Mejoras y nuevas implementaciones en herramienta . . . . .	60
11.2.1. Implementación de <i>Widget Toolbox</i> . . . . .	60
11.2.2. Protocolo cierre de ventana principal . . . . .	61
11.2.3. Actualización a función <code>openedf</code> . . . . .	61
11.2.4. Implementación de montajes de EEG en herramienta . . . . .	62
<b>12. Conclusiones</b>	<b>66</b>
<b>13. Recomendaciones</b>	<b>68</b>
<b>14. Bibliografía</b>	<b>69</b>
<b>15. Anexos</b>	<b>73</b>
15.1. Documentación general . . . . .	73
15.2. Repositorio GitHub . . . . .	73
15.3. Listado de etiquetas disponibles en conjunto de datos TUH SEIZ . . . . .	74
<b>16. Glosario</b>	<b>75</b>

---

## Lista de figuras

---

1.	Última iteración de herramienta - Anotaciones . . . . .	6
2.	Lóbulos del cerebro y su ubicación . . . . .	11
3.	A) Vista lateral IS 10-20 y B) Vista superior IS 10-20 . . . . .	12
4.	Ejemplos de actividad base en EGG con su espectro de frecuencia . . . . .	13
5.	Ejemplos de EEG reales de anomalías epileptiformes . . . . .	15
6.	Clasificación de crisis epilépticas ILAE 2017 . . . . .	17
7.	Ejemplos de tipos de montajes . . . . .	18
8.	Tipos de aprendizaje automático . . . . .	20
9.	Aprendizaje profundo y sus áreas . . . . .	23
10.	Perceptrón multicapa básico generalizado . . . . .	23
11.	Efecto del momentum en SGD . . . . .	25
12.	Red neuronal recurrente (RNN) simplificada . . . . .	27
13.	CNN simplificada para imágenes RGB clasificación multiclase . . . . .	28
14.	Interés en el aprendizaje profundo . . . . .	28
15.	Equipo disponible para recolección de datos . . . . .	30
16.	Montaje bipolar de doble banana . . . . .	37
17.	Distribución estudios con referencia ar y le en SEIZ TUH . . . . .	40
18.	Flujo de trabajo con <code>datastore</code> . . . . .	41
19.	Flujo de trabajo aprendizaje de máquina tradicional y profundo . . . . .	44
20.	Arquitectura de red LSTM utilizada en el experimento . . . . .	45
21.	Progreso del entrenamiento de la red LSTM . . . . .	46
22.	Matriz de confusión de la red LSTM . . . . .	47
23.	Arquitectura de red TCN utilizada en el experimento . . . . .	48
24.	Progreso del entrenamiento de la red TCN . . . . .	50
25.	Matriz de confusión de la red TCN . . . . .	50
26.	Estructura de red BiLSTM EEGnet . . . . .	52
27.	Estructura de red LSTM EEGnet profunda . . . . .	52
28.	Estructura de red LSTM EEGnet con <code>modwt</code> . . . . .	52
29.	Estructura de red LSTM EEGnet con <code>cwt</code> . . . . .	52

30.	Arquitectura de red TCN utilizada en el experimento . . . . .	55
31.	Ejemplos de entrenamiento y matriz de confusión para las redes entrenadas .	57
32.	Análisis archivos de proyectos tras cambios en migración . . . . .	60
33.	Modificaciones campo para ingresar contraseña . . . . .	60
34.	Error al cerrar ventanas secundarias . . . . .	61
35.	Alerta al cerrar ventana principal . . . . .	61
36.	Modificaciones ventana de análisis . . . . .	63
37.	Nueva ventana de anotaciones por montaje . . . . .	63
38.	Selección automática de canales estándar . . . . .	63
39.	Montaje bipolar doble banana generado automáticamente con su cursor . . .	64
40.	Ventana generada al identificarse eventos de convulsión . . . . .	64
41.	Montaje aislado de evento de convulsión generado . . . . .	65
42.	Ventana generada al no identificarse eventos de convulsión . . . . .	65

---

## Lista de cuadros

---

1.	Trabajos relacionados al estudio de la epilepsia mediante ML . . . . .	3
2.	Ejemplos de arquitecturas en modelos de DL para EEG . . . . .	4
3.	Electrodos disponibles en casco . . . . .	30
4.	Ejemplo de etiquetado en estudios EEG . . . . .	37
5.	Ejemplo de etiquetado en estudios EEG . . . . .	37
6.	Especificaciones ordenador utilizado . . . . .	41
7.	Resumen resultados con LSTM EEGnet . . . . .	53
8.	Resumen resultados con TCN EEGnet . . . . .	56
9.	Listado de etiquetas disponibles en base de datos TUH SEIZ . . . . .	74

El presente trabajo se enfocó en la implementación y evaluación de algoritmos de aprendizaje automático con énfasis en aprendizaje supervisado para el análisis de señales EEG de pacientes con epilepsia, como parte de la línea de investigación desarrollada en conjunto con HUMANA en la Universidad del Valle de Guatemala. Los objetivos principales incluyeron la exploración de redes neuronales profundas (LSTM y TCN) para preservar la secuencialidad de las señales y la detección de segmentos de interés, así como la actualización de la herramienta *Epileptic EEG Analysis Toolbox*.

Para ello, se emplearon estudios de la base de datos de *The Temple University Hospital* (TUH), ampliando significativamente la diversidad y cantidad de señales analizadas. Se evaluaron múltiples configuraciones de redes neuronales, logrando una precisión consistente superior al 81 % en la clasificación de eventos de convulsión y no convulsión. Las redes TCN destacaron por su eficiencia en tiempo de entrenamiento y su capacidad para capturar dependencias temporales mediante convoluciones causales y dilatadas, mientras que las redes LSTM ofrecieron un rendimiento competitivo, aunque con mayores demandas computacionales.

Asimismo, se implementaron mejoras en la herramienta *Epileptic EEG Analysis Toolbox*, incorporando nuevas funcionalidades como montajes automatizados, generación de anotaciones basadas en redes neuronales y optimización del código para garantizar un mejor desempeño. Estas actualizaciones permiten una interacción más intuitiva para los médicos y sientan las bases para futuras exploraciones de algoritmos de aprendizaje profundo.

Este trabajo representa un avance significativo en el análisis de señales EEG mediante aprendizaje profundo, estableciendo un marco de referencia para la integración de estas técnicas como herramientas clínicas y proporcionando recomendaciones para superar las limitaciones computacionales identificadas.

The present study focused on the implementation and evaluation of machine learning algorithms, with an emphasis on supervised learning, for the analysis of EEG signals from epilepsy patients. This work is part of the research line developed in collaboration with HUMANA at *Universidad del Valle de Guatemala*. The primary objectives included the exploration of deep neural networks (LSTM and TCN) to preserve the sequential nature of the signals and detect segments of interest, as well as the enhancement of the *Epileptic EEG Analysis Toolbox*.

To achieve these goals, data from *The Temple University Hospital* (TUH) database were utilized, significantly increasing the diversity and volume of analyzed signals. Multiple neural network configurations were evaluated, achieving consistent accuracy rates exceeding 81 % in the classification of seizure and non-seizure events. TCN networks demonstrated superior efficiency in training time and the ability to capture temporal dependencies through causal and dilated convolutions, whereas LSTM networks delivered competitive performance albeit with higher computational demands.

Furthermore, improvements to the *Epileptic EEG Analysis Toolbox* were implemented, including new functionalities such as automated montages, annotation generation based on neural networks, and code optimization to ensure enhanced performance. These updates provide a more intuitive interface for clinicians and lay the groundwork for future explorations of deep learning algorithms.

This study represents a significant advancement in EEG signal analysis using deep learning, establishing a reference framework for integrating these techniques into clinical tools and offering recommendations to address the identified computational limitations.

La epilepsia es una enfermedad neurológica que afecta a millones de personas en todo el mundo. Aunque los avances en la investigación han permitido que muchos pacientes mejoren su calidad de vida con tratamientos adecuados, el diagnóstico y tratamiento de esta afección siguen siendo un desafío. Los electroencefalogramas (EEG) son una herramienta fundamental para la evaluación de pacientes con epilepsia, pero el análisis de estos estudios es un proceso manual que requiere tiempo y experiencia por parte de los médicos especialistas. Esto resalta la necesidad de desarrollar herramientas automatizadas que faciliten y optimicen el análisis de señales bioeléctricas, como los EEG.

En este contexto, la aplicación de algoritmos de aprendizaje automático se ha convertido en una estrategia prometedora para la identificación y categorización de segmentos de interés en señales bioeléctricas. Este trabajo de graduación, enfocado en técnicas de aprendizaje supervisado, tuvo como objetivo avanzar en el desarrollo de una herramienta capaz de procesar y analizar EEG de manera eficiente. Esto se logró mediante la implementación de algoritmos de aprendizaje automático para la identificación de patrones asociados con episodios epilépticos. Este trabajo se desarrolló como la quinta fase de la línea de investigación en la Universidad del Valle de Guatemala, en la que se ha trabajado previamente en la creación y optimización de la herramienta *Epileptic EEG Analysis Toolbox*.

El objetivo principal de esta investigación fue identificar y categorizar segmentos de interés en señales bioeléctricas, esto mediante algoritmos de aprendizaje automático supervisado. Para alcanzar este objetivo, se plantearon varios objetivos específicos, como la obtención de nuevas señales bioeléctricas, la investigación de características de las señales y algoritmos, la optimización del proceso de detección de segmentos de interés y la actualización de la herramienta de software existente.

### 2.1. Contexto general de la epilepsia

La epilepsia es una enfermedad neurológica prevalente en todo el mundo, afectando a más de cincuenta millones de personas para el año 2019 [1]. Gracias a los avances en la investigación de esta afección, se han logrado resultados prometedores. Para el año en mención, aproximadamente una cuarta parte de los casos de epilepsia eran prevenibles, y al menos el 70 % de los pacientes estudiados podían reanudar sus actividades diarias con el tratamiento adecuado.

Este padecimiento es considerado un problema de salud pública, no solo por su relevancia médica, sino también por su profundo impacto social. A lo largo de la historia, esta enfermedad ha sido una causa de discriminación y estigmatización, afectando el bienestar social y psicológico de quienes la padecen, además de conllevar altos costos económicos [2]. Estas dificultades resaltan la importancia de contar con métodos de diagnóstico eficaces y accesibles, que contribuyan a una mejor comprensión y manejo de la epilepsia.

Sin embargo, uno de los grandes desafíos para un diagnóstico adecuado de esta enfermedad es la interpretación de los electroencefalogramas (EEG), estudios esenciales que registran la actividad eléctrica cerebral. Actualmente, este proceso sigue siendo en gran medida manual y depende de la experiencia del especialista, lo que implica una considerable inversión de tiempo y recursos. Esto ha impulsado la exploración de tecnologías avanzadas, como el aprendizaje automático, que ofrecen soluciones para mejorar la detección y análisis de patrones en el EEG, y así transformar el diagnóstico de la epilepsia.

## 2.2. Estado del arte en el uso del aprendizaje automático para la epilepsia

Siddiqui señala que, la detección de convulsiones y obtención de conocimiento relacionado con el cerebro es una tarea compleja [3]. Sin embargo, en las últimas tres décadas, con la ayuda del aprendizaje automático (*machine learning*, ML), se ha logrado automatizar y mejorar la precisión de estos procesos. Permitiendo a investigadores obtener resultados importantes en la segmentación clasificada de EEG, siendo esto novedoso pues como anteriormente se discutía, el análisis de estos es actualmente un proceso manual que depende en gran medida de la pericia de los médicos, quienes en ocasiones deben de analizar hasta 72 horas de un estudio [4].

Como se observa en el Cuadro 1, se han tenido distintos acercamientos mediante diferentes algoritmos (clasificadores), como distintas maneras de representar los EEG (características) obteniéndose resultados prometedores que en su mayoría superan el 80 % de rendimiento. Esto ha motivado a múltiples investigadores a seguir explorando este campo. Con el aumento de bases de datos extensas de EEG, el campo ha expandido su enfoque hacia el aprendizaje profundo (*Deep Learning*, DL).

Clasificador(es)	Característica(s)	Rendimiento (%)
<i>SVM</i>	<i>Vector</i>	96
<i>Random forest</i>	<i>Time and frequency</i>	93.8
<i>ANN</i>	<i>Line length</i>	99.6
<i>Burst detection algo</i>	<i>Line length</i>	84.27, 84.85.7
<i>Normalization</i>	<i>Line length</i>	52
<i>ELM and BPNN</i>	<i>SE</i>	95.6
<i>SVM and ELM</i>	<i>AE and SE</i>	95.58
<i>SVM</i>	<i>DWT</i>	94.8
<i>GMM</i>	<i>Spectral, hybrid, temporal</i>	87.58
<i>Random forest</i>	<i>PCA, STF, Moving Max</i>	97.12, 99.29, 0.77/h
<i>Random forest and k-NN</i>	<i>Spectral power</i>	80.87, 47.45, 2.5/h, 56.23
<i>Boosting</i>	<i>Stockwell</i>	94.26, 96.34
<i>SVM, MLP, KNN, Naïve bayes</i>	<i>Energy</i>	98.75
<i>Random forest</i>	<i>Entropy and DWT</i>	98.45
<i>SVM</i>	<i>Time-Frequency</i>	90.62, 99.32
<i>Random forest</i>	<i>Time-domain</i>	96.94
<i>SVM, LDA, QDA, LC, PC, DT, KNN, UDC, PARZEN</i>	<i>Time-frequency</i>	84, 85
<i>SVM</i>	<i>DWT</i>	86.83
<i>SVM and neural network</i>	<i>DWT and CWT</i>	99.1
<i>ELM</i>	<i>Time-frequency</i>	97.73, 0.37/h
<i>SVM</i>	<i>DWT</i>	99.38
<i>LS-SVM</i>	<i>FFT and DWT</i>	100
<i>SVM and Naïve bayes</i>	<i>Entropy, RMS, variance, energy</i>	96.55, 95.63, 95.7
<i>LS-SVM</i>	<i>8 types of Entropies</i>	100, 99.4, 99.5
<i>ANN</i>	<i>Spectral power</i>	86
<i>KNN and GHE</i>	-	100
<i>Random forest</i>	<i>DWT</i>	99.74, 0.21/h
<i>Random forest</i>	<i>STFT, mean, energy and std dev</i>	96.7
<i>Random forest, SVM, KNN, and Adaboost</i>	<i>28 statistical and time-frequency features</i>	97.6, 94.4, 96.1, 92.9, 98.8, 0.96
<i>ANN, KNN, SVM, and Random forest</i>	<i>Mean, std dev, power, skewness, kurtosis, absolute mean</i>	100
<i>SVM</i>	<i>Energy</i>	99.5
<i>SVM and Random forest</i>	<i>10-time and frequency</i>	0.98
<i>LS-SVM</i>	<i>DCT, SVD, IMF, DCT-DWT</i>	91.36
<i>SysFor and Forest CERN</i>	<i>9 statistical features</i>	100
<i>Random forest</i>	<i>L1-penalized robust regression (L1PRR)</i>	100
<i>SVM, NB, KNN, random forest, logistic model Trees (LMT)</i>	<i>15-features</i>	97.40, 97.40, 97.50
<i>Random forest</i>	<i>IMF</i>	98.4, 98.6, 96.4
<i>ANN</i>	<i>Time-frequency</i>	100
<i>Decision forest-Random forest, Boosting</i>	<i>9 statistical features</i>	96.67, 74.36, 84.06

**Cuadro 1.** Trabajos relacionados al estudio de la epilepsia mediante ML

Nota. Obtenido de [3].

El aprendizaje profundo, una rama del aprendizaje automático, ha demostrado un gran potencial en áreas relacionadas, como el análisis de electrocardiogramas y el procesamiento de imágenes médicas [5]. Una de sus principales ventajas, es la capacidad de extraer patrones complejos directamente de los datos sin procesar, lo que permite obtener resultados más precisos y construir modelos que se adaptan mejor a la naturaleza de los datos. En el contexto de los EEG, esto significa que los modelos pueden aprender por su cuenta características relevantes para la detección de convulsiones, sin requerir que el investigador seleccione manualmente dichas características. Como se muestra en el Cuadro 2, estos modelos han alcanzado hasta un 89 % de precisión en tareas de clasificación de EEG, lo que subraya su efectividad en el reconocimiento de patrones complejos.

Arquitectura	Precisión (%)
SAE 3 capas ocultas, 1 capa densa	54
Híbrida 1 capa convolucional, 1 capa RNN, 2 capas densas	73
Híbrida 2 capas convolucionales, 1 capa RNN, 1 capa densa	75
CNN 5 capas convolucionales, 1 capa densa	81
MLPNN 4 capas ocultas	82
RNN 2 capas LSTM, 1 capa densa	87
CNN 2 capas convolucionales, 2 capas densas	87
CNN 2 capas convolucionales, 1 capa densa	88
DBN (3 capas RBM's), 1 capa densa	89

**Cuadro 2.** *Ejemplos de arquitecturas en modelos de DL para EEG*  
Nota. Obtenido de [5].

### 2.3. Evolución línea de investigación en Universidad del Valle de Guatemala

La línea de investigación sobre el uso de algoritmos de aprendizaje automático en el análisis de EEG para la detección de crisis epilépticas en UVG comenzó en 2020, impulsada por el trabajo de María Angulo y Luis Rivera en colaboración con el Centro de Epilepsia y Neurocirugía Funcional (HUMANA) [6]. Desde entonces, esta iniciativa ha buscado desarrollar una herramienta innovadora que facilite el análisis automatizado de señales EEG, optimizando el diagnóstico de la epilepsia mediante el uso de técnicas avanzadas de aprendizaje automático.

En el trabajo realizado por Angulo se propuso desarrollar y aplicar algoritmos de aprendizaje automático a EEG de pacientes con epilepsia. Esto mediante una interfaz implementada en MATLAB, demostrando la factibilidad de caracterizar segmentos de EEG mediante el uso de redes neuronales artificiales (ANN, por sus siglas en inglés) y máquinas de vectores de soporte (SVM, por sus siglas en inglés) con una precisión superior al 95 %. Al vez, María Pineda [7] implementó una base de datos con *phpMyAdmin* y *MySQL* para almacenar los estudios de los pacientes. Ambas resaltaron la importancia de ampliar el conjunto de señales disponibles para explorar otras técnicas de caracterización y algoritmos de aprendizaje automático no supervisado para la mejora de la herramienta.

En el año 2021, José David Vela retomó la línea de investigación con el objetivo de im-

plementar el reconocimiento y anotación de episodios ictales (fase activa de una convulsión) en EEG [8]. Para lo cual, implementó una SVM de tiempo continuo con kernel gaussiano logrando una exactitud de  $96.7\% \pm 3.81\%$ . Esta mejora incluyó la implementación de una sección para el entrenamiento de un algoritmo de aprendizaje automático específico, para su posterior utilización en la clasificación de las señales con la nueva categoría implementada. Destacó el uso de características mediante transformadas *Wavelet* para la reducción de tiempo computacional y extendió nuevamente la necesidad de contar con más datos por parte de HUMANA para la validación de la herramienta.

Posteriormente, en el año 2022, Camila Lemus retomó la recomendación de [6] para implementar algoritmos de aprendizaje automático no supervisado [9]. En primera instancia, se centró en validar la herramienta existente utilizando bases de datos de EEG y electrocardiograma (ECG), reafirmando la precisión de las ANN para la segmentación ( $99.6\% \pm 0.61\%$ ) y la eficiencia de la extracción de vectores de características en términos de tiempo computacional. Introdujo el uso del algoritmo de agrupamiento (*clustering*) k-means de aprendizaje no supervisado, demostrando ser eficiente en términos de tiempo computacional pero no logrando una precisión superior al  $85.51\%$ . Se enfatizó nuevamente la necesidad de contar con más datos para el entrenamiento de modelos de aprendizaje, tanto supervisados como no supervisados, y de explorar la combinación de características junto con algoritmos eficientes en tiempo computacional.

Entre los años 2020 y 2022, se tuvieron avances significativos en la herramienta y exploración de algoritmos de aprendizaje automático. Por ende, resulta crucial comprender el estado actual de la herramienta hasta el año pasado, considerando las contribuciones de Cristhofer Patzán y Diego Méndez, quienes validaron y optimizaron la herramienta buscando que esta quede formalmente funcional al lograrse un entrenamiento adecuado de los algoritmos.

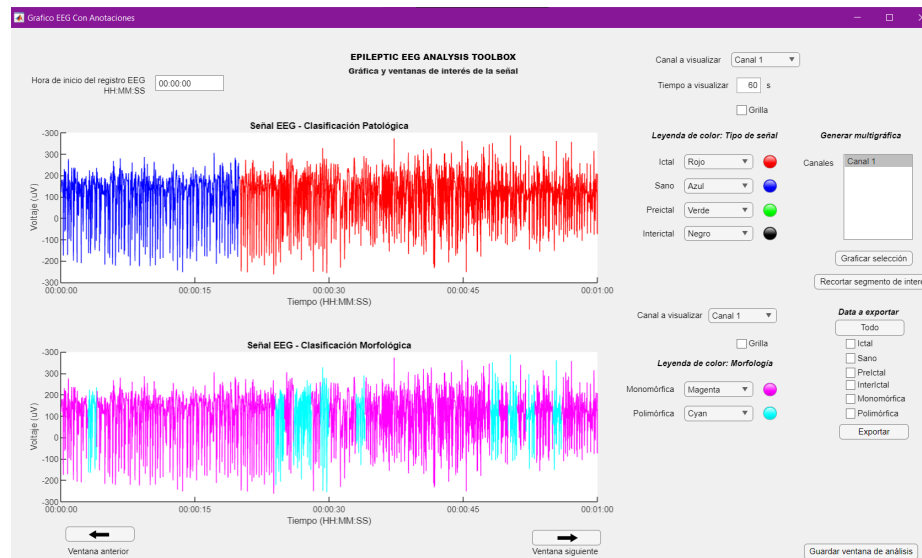
La última revisión por Patzán [10] se enfocó en aplicar algoritmos de aprendizaje automático a una muestra más amplia de señales bioeléctricas, como EEG y electromiografía (EMG), con el fin de mejorar la detección de segmentos relevantes en el estudio de la epilepsia. Validó el rendimiento de estos algoritmos mediante análisis estadístico y actualizó la interfaz de la herramienta para abordar tiempos computacionales deficientes. Resaltó la importancia de una muestra equitativa de datos para evitar sesgos en los algoritmos de clasificación. Además, determinó que los algoritmos que emplean transformadas wavelets tiempo-frecuencia ofrecen mejores resultados tanto en clasificación como tiempo computacional. Como resultado, la última versión de la herramienta ha sido optimizada en términos de tiempo computacional y algoritmos de detección de segmentos de interés en señales. Se sugiere explorar el algoritmo *Chamaleon* y continuar la recopilación de datos de HUMANA para el entrenamiento de los algoritmos.

El algoritmo *Chamaleon*, como indica Shehadeh [11], es un algoritmo que se basa en el comportamiento de los camaleones cuando buscan a su presa y por ello su nombre completo es *Chameleon Swarm Algorithm (CSA)*. Este busca resolver problemas de optimización numérica global con bajo costo computacional, lo cual es posible pues se emplea una población de agentes (camaleones) distribuidos para recorrer el plano del problema y conforme se acerca alguno de estos a un dato “presa”, este permanece cerca de la región del plano para agrupar de manera óptima por cercanía. Por lo que, la exploración de este algoritmo puede resultar adecuada para la segmentación de las señales bioeléctricas por su estabilidad, bajos tiempos computacionales y adaptabilidad a distintos problemas de agrupamiento.

Méndez [12] se enfocó en validar y migrar la herramienta para su implementación en HUMANA. Definió los requerimientos mínimos de *hardware* y validó el funcionamiento de esta en distintos ordenadores. En conjunto con las mejoras de [10], implementó algoritmos más eficientes para el control de la base de datos y el despliegue de resultados en la herramienta. Estas acciones en conjunto, permitieron la validación de la herramienta para su migración segura y funcional a HUMANA. Se recomendó la exploración de algoritmos que permitan reducir aún más tiempos computacionales y proporcionar más información al usuario, a la vez que se sugiere evaluar posibles mejoras basándose en el programa BWAnalysis.

El programa BWAnalysis es de los programas más avanzados disponibles para el análisis de EEG. Este permite segmentar las señales en ventanas de tiempo definido por el usuario, obtener características básicas (i.e., amplitud, frecuencia, etc.) y complejas (i.e. FFT, espectro de frecuencias, etc.) de las señales, sincronización del video del estudio con las señales y trazado de los segmentos de interés para la elaboración de informes [13]. Por lo que, resulta importante tener en cuenta la funcionalidad y características de este programa, pues la herramienta que se desarrolla dentro de esta línea de investigación busca optimizar los procesos ya familiarizados con los doctores.

La última actualización de la herramienta *Epileptic EEG Analysis Toolbox* para el estudio de la epilepsia mostró avances significativos haciéndola más intuitiva y optimizada para un menor consumo de recursos computacionales (ver Figura 1). Esto se logró mediante la validación y mejora de los algoritmos de aprendizaje automático, junto con las optimizaciones en la interfaz, tanto para el despliegue de resultados como para el uso de recursos. Esta iteración acerca la herramienta a su implementación formal en HUMANA, aunque todavía existen limitaciones por abordar antes de su adopción definitiva. Se requiere un mayor equilibrio en los datos, con una proporción equitativa entre pacientes sanos y con epilepsia, para un entrenamiento eficaz de los algoritmos. También es importante explorar algoritmos de aprendizaje automático innovadores, optimizar aún más los tiempos computacionales y mejorar el despliegue de resultados. Por último, validar la herramienta en un entorno médico real es crucial para comprobar su eficacia en la práctica.



**Figura 1.** Última iteración de herramienta - Anotaciones  
Nota. Obtenida de: [10].

Según datos de HUMANA [4], alrededor de 325,000 personas en Guatemala padecen epilepsia, y aproximadamente el 30 % de estos casos son de difícil control. El impacto de la epilepsia va más allá de la salud, afectando la vida social y profesional de quienes la padecen. Se han reportado casos de niños expulsados de escuelas tras sufrir un ataque epiléptico y trabajadores despedidos por la misma razón [2]. Además, el deficiente acceso a la salud en el país implica que no hay suficientes herramientas para facilitar el diagnóstico de la epilepsia, lo que obliga a los pacientes a afrontar altos costos para obtener tratamientos adecuados (e.g., EEG  $\sim$  US\$100 [14]). Ante este escenario, es fundamental la investigación sobre la epilepsia y el desarrollo de herramientas en el país, tanto para su estudio como para su tratamiento, con el fin de mejorar la calidad de vida de quienes la padecen y reducir el estigma asociado a la enfermedad.

El trabajo reciente en la herramienta *Epileptic EEG Analysis Toolbox* ha demostrado avances significativos en términos de mejora de algoritmos de aprendizaje automático, optimización de tiempos computacionales y actualización de la interfaz de usuario. Sin embargo, estas deben ser continuadas para lograr una implementación efectiva de la herramienta.

Para avanzar en esta línea de investigación, se requiere una muestra de datos mayor y equitativa para el entrenamiento de los algoritmos de aprendizaje automático, asegurando una representación equilibrada entre pacientes sanos y aquellos con epilepsia. Por ello, parte de este trabajo de graduación consistió en la recolección de más datos de HUMANA, bases de datos médicas e investigación de otros centros especializados en el estudio de la epilepsia. Este enfoque permitió reunir un conjunto de datos más amplio y diverso, lo cual fue fundamental para entrenar y validar los algoritmos de aprendizaje automático de manera efectiva.

Además, este trabajo buscó optimizar los procesos de análisis y detección de eventos en las señales EEG mediante la implementación de aprendizaje profundo con las redes LSTM y TCN, adaptadas para clasificar eventos de convulsión y no convulsión. Estas mejoras, junto con la actualización de la herramienta *Epileptic EEG Analysis Toolbox*, buscan no sólo avanzar en el análisis automatizado de señales EEG, sino también facilitar su adopción en entornos médicos, contribuyendo a un diagnóstico más accesible y eficiente.

### 4.1. Objetivo general

Identificar y categorizar segmentos de interés en señales bioeléctricas para el estudio de la epilepsia, mediante la implementación de algoritmos de aprendizaje automático, con énfasis en técnicas de aprendizaje supervisado.

### 4.2. Objetivos específicos

- Obtener señales bioeléctricas adicionales a las de fases anteriores, de pacientes con epilepsia en centros de estudios especializados como HUMANA.
- Investigar y evaluar características de las señales bioeléctricas, así como algoritmos de aprendizaje automático, con un enfoque en técnicas de aprendizaje supervisado, para mejorar el rendimiento de los clasificadores en la identificación y categorización de dichas señales.
- Optimizar el proceso de detección de segmentos de interés en las señales y la generación automática de anotaciones relevantes, según los parámetros de HUMANA.
- Realizar análisis estadísticos para evaluar el rendimiento de los algoritmos y determinar las características más efectivas para describir las señales bioeléctricas.
- Actualizar la herramienta de software para el estudio de la epilepsia desarrollada en fases anteriores, incorporando las mejoras en los algoritmos de clasificación y detección de segmentos de interés en las señales bioeléctricas.

El presente trabajo de graduación abarcó la mejora y optimización de la herramienta *Epileptic EEG Analysis Toolbox* para el análisis de señales EEG en el contexto del estudio de la epilepsia. Esto incluyó la recolección y procesamiento de señales EEG provenientes de múltiples fuentes, con un énfasis particular en la base de datos de *The Temple University Hospital* (TUH), trabajada bajo los estándares establecidos por HUMANA.

El enfoque principal se centró en la implementación de algoritmos de aprendizaje profundo, representando una desviación significativa de las metodologías tradicionales utilizadas en fases anteriores. Las redes neuronales profundas, específicamente las arquitecturas LSTM y TCN, se entrenaron directamente con señales EEG crudas, eliminando la necesidad de procesos manuales de extracción de características. Este enfoque permitió explorar nuevas posibilidades para la detección y clasificación de eventos de convulsión y no convulsión, demostrando la viabilidad de estas técnicas en el análisis de señales EEG.

Asimismo, se realizaron actualizaciones en la herramienta enfocadas en mejorar su funcionalidad y usabilidad para los médicos. Entre las mejoras destacan la incorporación de elementos gráficos que facilitan la interacción, la visualización de señales mediante montajes automatizados, y la generación de anotaciones basadas en redes neuronales. Además, se migró la herramienta a las últimas recomendaciones de MATLAB en su versión 2024B, garantizando su compatibilidad y continuidad futura.

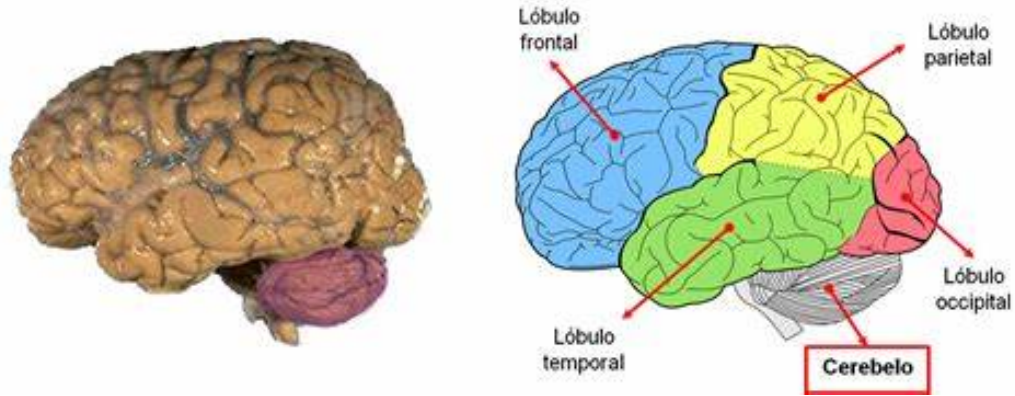
El alcance de este trabajo no incluyó la implementación de un sistema completamente integrado en entornos clínicos reales, pero avanzó significativamente en la preparación de la herramienta para futuras aplicaciones. Aunque se lograron avances importantes en la clasificación de eventos epilépticos y en la optimización mediante aprendizaje profundo, los recursos computacionales representaron una de las principales limitantes para alcanzar mayores niveles de precisión en los modelos.

## 6.1. Cerebro humano

El cerebro humano es el órgano rector y más complejo del cuerpo humano, permitiendo la realización de movimientos motores y el procesamiento del entorno para la adquisición de aprendizajes o la respuesta a estímulos [15]. Se compone de dos hemisferios, derecho e izquierdo, que trabajan en conjunto en procesos como la memoria, el cálculo y el procesamiento sensorial. Sin embargo, cada hemisferio también desempeña funciones específicas:

- Hemisferio izquierdo: en general, se ocupa del aprendizaje y procesamiento de información.
  - Pensamiento numérico, verbal y simbólico.
  - Expresión hablada y escrita.
  - Lectura.
- Hemisferio derecho:
  - Imaginación y creatividad, inclusive habilidades musicales.
  - Control de las emociones y sentimientos.
  - Pensamiento intuitivo.
  - Funciones espaciales.

Además, el cerebro humano está dividido en diferentes regiones llamadas lóbulos (ver Figura 2), cada uno de los cuales desempeña funciones específicas. Estos lóbulos incluyen el frontal, parietal, temporal y occipital, cada uno de los cuales tiene características y funciones distintas. A continuación, se explorará en detalle la función de cada lóbulo [15].



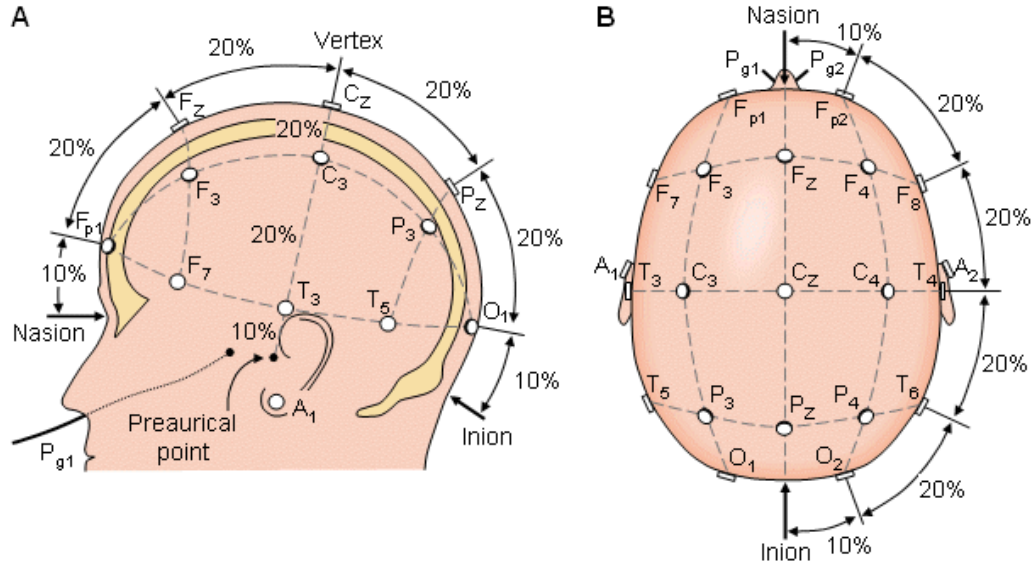
**Figura 2.** *Lóbulos del cerebro y su ubicación*  
 Nota. Obtenida de [15].

- Lóbulo frontal: responsable del control motor, la planificación, la toma de decisiones y la personalidad.
- Lóbulo parietal: se encarga del procesamiento sensorial, la percepción espacial y la integración de información.
- Lóbulo temporal: relacionado con la audición, la memoria y el procesamiento del lenguaje.
- Lóbulo occipital: principalmente asociado con la visión y el procesamiento visual.

### 6.1.1. Actividad eléctrica del cerebro

En 1929, Hans Berger acuñó por primera vez el término “electroencefalograma (EEG)” para referirse al registro de la actividad eléctrica del cerebro captada a través de electrodos colocados en el cuero cabelludo [16]. Estas señales eléctricas son generadas por las células piramidales de la corteza cerebral, conocidas como neuronas, las cuales actúan como diminutos dipolos eléctricos con polaridad dependiente de su estado (inhibitorio o excitatorio).

Dado el interés en comprender el funcionamiento del cerebro, los EEG se han vuelto indispensables para la evaluación de pacientes con trastornos del sistema nervioso, como epilepsias y convulsiones. Para estandarizar el procedimiento y facilitar la comparación de resultados entre diferentes pacientes, se ha desarrollado un sistema de colocación de electrodos conocido como el estándar IS 10-20 (ver Figura 3). Este estándar, ampliamente utilizado en la práctica clínica, define la ubicación de los electrodos en relación con puntos anatómicos específicos en el cuero cabelludo, lo que permite una interpretación más precisa de los registros de EEG [17].



**Figura 3.** A) Vista lateral IS 10-20 y B) Vista superior IS 10-20

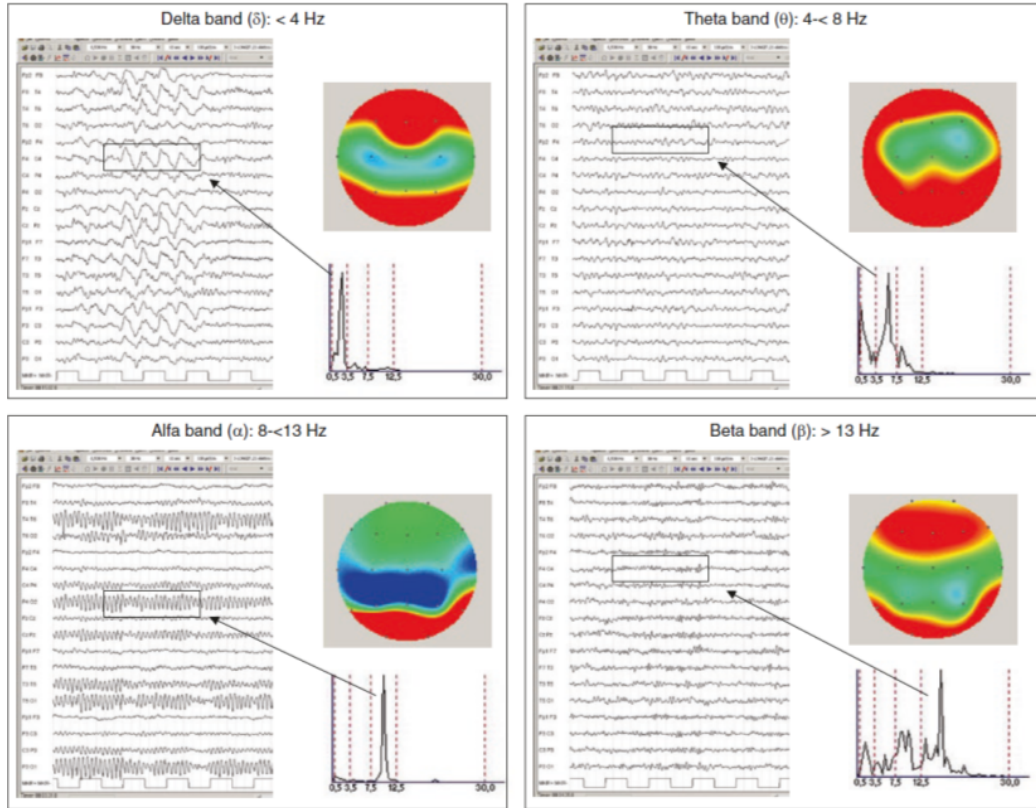
Nota. F = Frontal, C = Central, P = Parietal, T = Temporal, O = Occipital, A = Auricular, Z = plano sagital, Impares = hemisferio izquierdo y Pares = hemisferio derecho. Obtenida de [18].

### 6.1.2. Ritmos normales

Debido a la estandarización, se ha podido determinar artefactos fisiológicos en los EEG (como el ruido debido al latido del corazón, la respiración y el movimiento muscular) y, en especial, se han identificado los ritmos normales en un EEG (ver Figura 4) [2]. Estos, también conocidos como actividad base, se clasifican de la siguiente manera:

- Delta ( $\delta$ ): señal en el rango de frecuencias de 0.5 a 4 Hz y una amplitud alta entre 100 a 200  $\mu$ V [17]. Es dominante durante el sueño profundo (etapas 3 y 4) y debe prestarse atención a la región en que se identifique pues movimientos musculares pueden producir este tipo de ritmo. En un adulto no debe presentarse este ritmo estando despierto, en niños es aceptable ya que refleja madurez de la corteza cerebral.
- Theta ( $\theta$ ): señal en el rango de frecuencias de 4 a 8 Hz y una amplitud  $>30$   $\mu$ V [17]. Este es predominante cuando el sujeto se encuentra dormido, en especial si presenta sueño con movimiento ocular rápido (MOR). Es identificable en la región de los lóbulos temporales, se puede clasificar como  $\theta$  baja (4 a 6 Hz), asociada con vigilia disminuida con somnolencia alta, y theta alta (6 a 8 Hz), relacionada con la memoria de trabajo activa. En adultos, este ritmo no debe presentarse estando despierto, en niños es aceptable la presencia hasta la adolescencia.
- Alpha ( $\alpha$ ): señal en el rango de frecuencias de 8 a 13 Hz y una amplitud baja entre 30 a 50  $\mu$ V (mayor en el hemisferio derecho) [17]. Este es dominante durante la relajación en estado de vigilia con los ojos cerrados y es atenuado al abrir los ojos o por esfuerzo mental. Indica la activación cortical y se observa en las regiones occipitales y frontales, pudiéndose propagar a la región parietal y temporal posterior.

- Beta ( $\beta$ ): señal en el rango de frecuencias de 13 a 30 Hz y una amplitud  $>30 \mu\text{V}$  [17]. Este es dominante en un estado de vigilia con los ojos abiertos y es notorio en actividad mental. Se localiza principalmente en la región frontal (fronto-central) y puede verse afectada por sedantes o drogas hipnóticas.
- Gamma ( $\gamma$ ): señal en el rango de frecuencias de 30 a 50 Hz [17]. Es predominante durante la actividad mental superior, como la interpretación de objetos para formar una imagen coherente. Indica la percepción y la conciencia del individuo, y no está presente en sujetos sedados.



**Figura 4.** Ejemplos de actividad base en EGG con su espectro de frecuencia  
Nota. Obtenida de [19].

## 6.2. Epilepsia

La epilepsia, una condición crónica con múltiples causas, se manifiesta comúnmente a través de crisis recurrentes, desencadenadas por descargas excesivas de las neuronas cerebrales, que pueden presentarse con síntomas físicos o conductuales (manifestaciones clínicas) o ser identificadas mediante estudios (paraclínicas) [2]. Esta enfermedad neurológica es altamente prevalente a nivel mundial, afectando a más de cincuenta millones de personas para el año 2019 y, a nivel Guatemala, alrededor de 325,000 personas la padecen, siendo aproximadamente el 30 % de estos casos de difícil control [1][4].

Según indica [20], el término “epilepsia” no se refiere a una sola condición, sino a múltiples patologías que pueden manifestarse con crisis epilépticas. Estos síndromes epilépticos se clasifican según el grupo etario del paciente, que incluye neonatal-lactante, preescolar y escolar, así como epilepsias generalizadas idiopáticas y de edad variable. Hasta el año 2022, se habían identificado 41 patologías epilépticas distintas, cada una con sus propias características epileptiformes durante las diferentes fases de una crisis epiléptica.

Entonces, las epilepsias conllevan una predisposición a experimentar crisis epilépticas recurrentes, y se diagnostican cuando una persona ha experimentado dos o más de estas crisis. Estas crisis pueden manifestarse con una variedad de síntomas, desde sensaciones subjetivas extrañas o difíciles de describir hasta fenómenos auditivos, visuales, motores o sensaciones de hormigueo. Dichos síntomas pueden aparecer de forma aislada y autolimitada, lo que significa que pueden presentarse de manera independiente y limitarse a un período breve de tiempo sin progresar a una crisis completa. Además, las crisis pueden presentarse con sacudidas de una (o más) extremidad o de la mitad de la cara sin que haya pérdida de la conciencia, o con una pérdida brusca de la misma, seguida de caída al suelo y contracciones musculares seguidas de sacudidas rítmicas [2].

### 6.2.1. Anomalías epileptiformes

Las descargas eléctricas características de las crisis epilépticas siguen patrones identificables por su frecuencias y evolución en el espacio-tiempo [19]. Por lo que, es importante definir cómo estas se cuantifican e identifican por su forma.


Para la cuantificación de las descargas eléctricas se emplea el siguiente criterio, según su aparición:

- Abundantes:  $\geq 1/10$  s
- Frecuentes:  $< 1/10$  s a  $\geq 1/\text{min}$
- Ocasionales:  $< 1/\text{min}$  a  $\geq 1/\text{h}$
- Raras:  $< 1/\text{h}$

Mientras que, para la clasificación por su forma, se sigue el glosario de la IFCN 2017 (ver Figura 5) [19]. En este se establecen las siguientes formas y sus características:

- Onda aguda (*Spike*): onda transitoria con pico puntiagudo, es distinguible de la actividad de fondo y con una duración de 20 a 70 ms. La amplitud es variable, pero típicamente es de 50  $\mu\text{V}$ . Esta puede ser monofásica o multifásica, con un componente negativo dominante.
- Polipunta (*Polyspike complex*): secuencia de dos o más ondas agudas.
- Punta-onda (*Sharp Wave*): transitorio epiléptico claramente distinguible de la actividad de fondo, con pico puntiagudo y una duración de 70 a 200 ms. Por lo general, tiene una amplitud variable (100-200  $\mu\text{V}$ ) y un componente negativo dominante.

- Onda aguda - onda lenta (*Spike and Slow Wave complex*): patrón epiléptico claramente distinguible de la actividad de fondo. Este puede ser único o múltiple, consiste en una onda aguda y una onda lenta asociada.
- Polipunta - onda lenta (*Polyspikes and slow wave complex*): patrón epiléptico que consiste en dos o más ondas agudas asociadas con una o más ondas lentas.
- Punta-onda - onda lenta (*Sharp and slow wave complex*): patrón epiléptico claramente distinguible de la actividad de fondo. Este puede ser único o múltiple, consiste en una punta-onda y una onda lenta asociada.



**Figura 5.** Ejemplos de EEG reales de anomalías epiléptiformes

Nota. a) Onda aguda. b) Polipunta. c) Punta-onda. d) Onda aguda - onda lenta. e) Polipunta - onda lenta. f) Punta-onda - onda lenta. Obtenida de [19].

### 6.2.2. Fases de una crisis epiléptica

Una crisis epiléptica se caracteriza por una serie de fases distintas, cada una con sus propias características y síntomas. Comprender estas fases es crucial tanto para quienes padecen epilepsia como para el estudio del paciente, ya que puede ayudar a reconocer los signos de una crisis [2]. Las fases de una crisis epiléptica son:

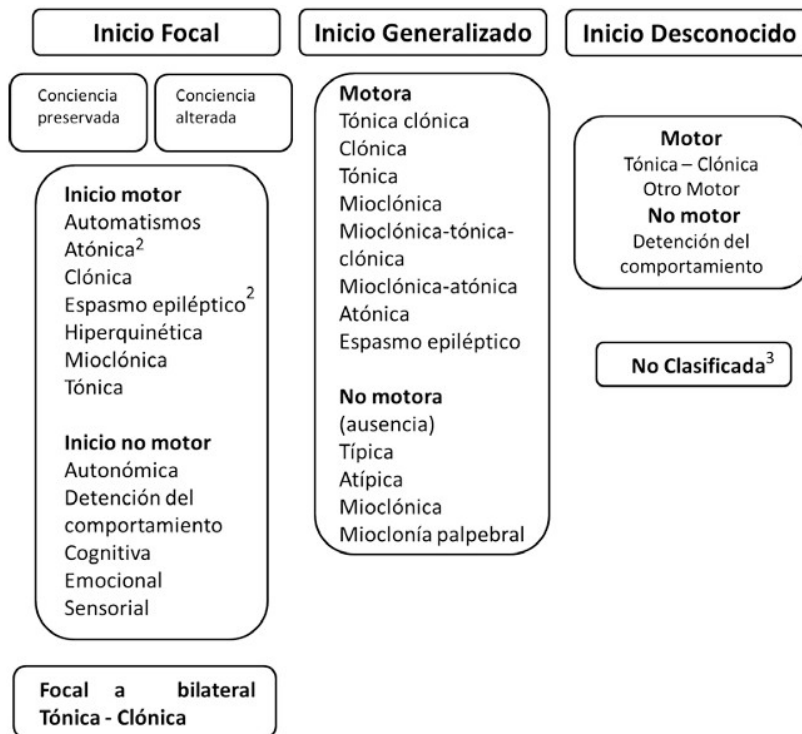
- Fase aura: es la primera etapa de una crisis epiléptica, también conocida como fase preictal. Ocurre justo antes de la fase ictal y puede durar desde unos segundos hasta una hora. Durante esta fase, el paciente puede experimentar síntomas como fatiga, cambios visuales, sensación de desconexión de la realidad y alucinaciones sensoriales. Los movimientos involuntarios breves, como los espasmos musculares, pueden ocurrir. Esta fase es causada por una alteración en la actividad cerebral que comienza poco antes de la fase más notable de la crisis, siendo esto notorio en el EEG al tenerse anomalías epileptiformes mezcladas con los ritmos normales [2].
- Fase ictal: es la fase más evidente de una crisis epiléptica. Durante esta fase, puede experimentar alteraciones en la conciencia, movimientos involuntarios o ambos. Los movimientos involuntarios pueden implicar todo el cuerpo o una parte del mismo. La fase ictal generalmente dura desde unos segundos hasta unos minutos y puede ser convulsiva o no convulsiva. Estos síntomas se corresponden con los patrones vistos en el electroencefalograma (EEG) durante esta fase, que muestran una actividad eléctrica errática con anomalías epileptiformes continuas [2].
- Fase postictal: ocurre después de la fase ictal de una crisis. Durante esta etapa, puede experimentar una variedad de síntomas, como fatiga extrema, confusión y parálisis temporal de una extremidad. La duración y la intensidad de los síntomas postictales pueden variar. Estos síntomas pueden correlacionarse con los cambios en el EEG durante la fase ictal y pueden durar desde varias horas hasta días, siendo notorias ciertas anomalías epileptiformes ocasionales mezcladas con los ritmos normales [2].

### 6.2.3. Tipos de crisis epilépticas

Las crisis epilépticas se clasifican según su origen, presencia de síntomas motores y afectación de la conciencia. Por ello, en el año 2017, la Liga Internacional Contra La Epilepsia (ILAE, por sus siglas en inglés) publica su última revisión para la clasificación operacional de los tipos de crisis [21]. En la cual establecieron (ver Figura 6 para conocer sus subdivisiones):

- Crisis focales: estas comienzan en una región específica del cerebro y pueden permanecer focalizadas o propagarse para afectar otras áreas (bilateral Tónico-Clónica). Su clasificación depende de síntomas motores y alteraciones a la conciencia, dependiendo de la ubicación y extensión de la actividad epiléptica.
- Crisis generalizadas: estas involucran ambos hemisferios cerebrales simultáneamente desde el inicio y su clasificación depende únicamente de síntomas motores, pues generalmente estas presentan conciencia alterada.

- Crisis de inicio desconocido: en este tipo de crisis, no se puede determinar si la actividad epiléptica comienza focal o generalizada debido a la falta de información sobre el inicio del evento. Su clasificación se basa en síntomas motores, pero es importante determinar la naturaleza de la crisis para una adecuada clasificación



**Figura 6.** *Clasificación de crisis epilépticas ILAE 2017*  
 Nota. Obtenida de [21].

### 6.3. Análisis de señales EEG

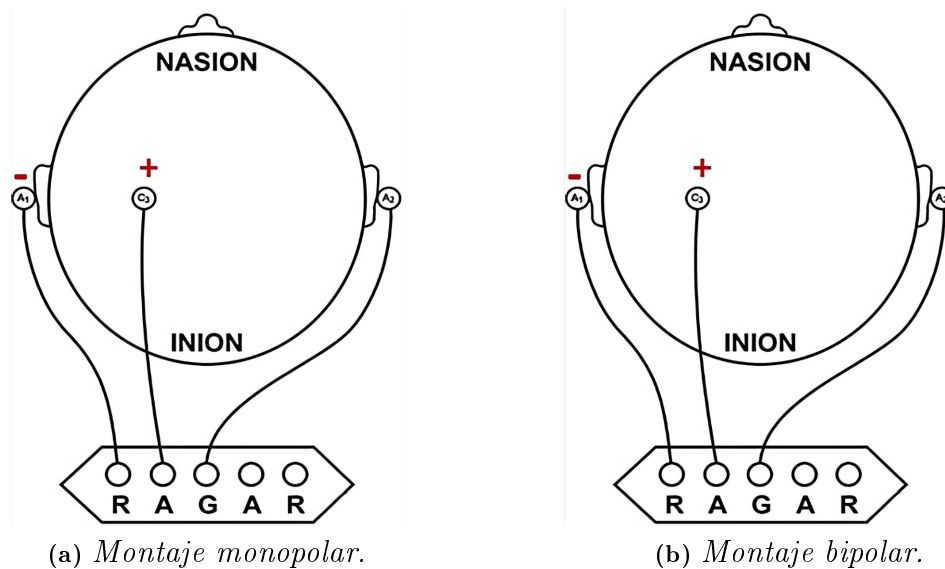
El análisis de los distintos canales de un EEG es fundamental para obtener información relevante de cada momento registrado durante el estudio. Para lograrlo, es crucial contar con una visualización adecuada de los valores, que puede lograrse mediante los montajes. Posteriormente, al explorar diversas técnicas de análisis disponibles, podemos identificar segmentos de interés para detectar crisis epilépticas. Esta detección permite a los médicos no solo definir el tipo de epilepsia, sino también el síndrome asociado a la epilepsia en cuestión.

### 6.3.1. Montajes

Los montajes se refieren al registro gráfico de varios canales en una secuencia establecida, siendo los de 16 canales los más comunes, aunque también se utilizan montajes de 8 o hasta 32 canales, estos últimos principalmente en investigaciones médicas debido a su costo [2]. Entre los montajes disponibles se encuentran la referencia común (activa o inactiva), la referencia común promedio, la derivación de fuente y la derivación bipolar. Destacan especialmente dos tipos de montajes: el montaje de referencia común, también conocido como montaje monopolar, y el montaje bipolar [19].

El montaje monopolar, o de referencia común, utiliza un electrodo de referencia para los canales de interés (ver Figura 7a). Generalmente, este electrodo de referencia se coloca en el oído del hemisferio que se está analizando. Esto permite una comparación relativa entre la actividad eléctrica de diferentes áreas del cerebro. Sin embargo, puede introducir artefactos (ruido) debido a la actividad eléctrica muscular o a interferencias externas, lo que puede dificultar la interpretación precisa de los datos.

Por otro lado, el montaje bipolar utiliza dos electrodos adyacentes para cada canal de registro, lo que permite una medición más directa de la diferencia de potencial entre dos áreas específicas del cerebro (ver Figura 7b). Esto reduce la sensibilidad a artefactos comunes en el montaje monopolar y puede proporcionar una mayor resolución espacial. Sin embargo, el montaje bipolar puede requerir una mayor cantidad de electrodos y puede ser más difícil de interpretar para algunos tipos de análisis.



**Figura 7.** Ejemplos de tipos de montajes

Nota. R - referencia, A - electrodo activo (*active*), G - tierra (*ground*). Obtenida de [22].

### 6.3.2. Análisis en el dominio de la frecuencia

El análisis de señales en el dominio de la frecuencia, o análisis espectral, es una técnica ampliamente utilizada en diversos campos científicos y es la base de muchos procesos comunes como la resonancia magnética. Esta técnica implica una transformación del EEG desde el dominio del tiempo (muestras en el tiempo) al dominio de la frecuencia (muestras para cada frecuencia). La mayor ventaja de esta técnica es resumir la información contenida en grandes tiempos a unos pocos valores. Sin embargo, al ser un análisis estadístico, el resultado será una información promedio sobre la estructura de la señal del EEG y no evidenciará patrones de señal muy cortos o señales de baja potencia [19].

Para llevar a cabo este tipo de análisis, resulta necesario obtener el espectro de frecuencias de uno o más canales (ver Figura 4). Con este espectro, es posible resumir características interesantes del dominio de frecuencia, tales como la potencia absoluta y relativa en las diferentes bandas, la frecuencia de potencia máxima, la frecuencia mediana, la frecuencia de borde espectral y la frecuencia dominante principal. Estas características pueden utilizarse por sí solas o en combinación entre sí para definir nuevas variables, a menudo llamadas índices. Una ventaja de estos índices es que representan características complejas de la señal de una manera comprensible y son menos sensibles al ruido que contamina los electrodos [19].

### 6.3.3. Análisis en el dominio del tiempo

El análisis de señales en el dominio del tiempo implica realizar mediciones y/o cálculos directamente sobre la señal original del EEG, sin ninguna transformación como en el caso del análisis espectral.

Existen varios parámetros de los EEG en el dominio del tiempo, y en este contexto se menciona uno de los parámetros que es más utilizado:

- Cruces por cero: este parámetro se define como el número de veces que la señal de EEG cruza la línea base. Sin embargo, es importante tener en cuenta que este parámetro no siempre representa el ritmo de la señal del EEG, ya que a menudo el ritmo de interés está enmascarado por el ritmo normal [19].

En cuanto a la visualización de la evolución de los datos en el tiempo, existen varias técnicas, entre las que se incluyen los histogramas y tendencias, así como el análisis de wavelet. Los histogramas y tendencias son métodos simples y eficientes para mostrar la evolución temporal de un parámetro de interés (e.g., amplitud), mientras que el análisis de wavelet ofrece una representación tiempo-frecuencia más detallada, aunque a menudo pierde la visión general global que proporcionan los histogramas y tendencias [19].

Además de estos parámetros, otros aspectos relevantes del análisis en el dominio del tiempo incluyen las estadísticas básicas: valor medio, la mediana, la varianza, la desviación estándar, la asimetría y la curtosis de la señal de EEG [19].

## 6.4. Algoritmos de aprendizaje automático

El aprendizaje automático (ML) es un campo interdisciplinario de la inteligencia artificial (IA) que busca desarrollar algoritmos que permitan a las computadoras aprender y mejorar automáticamente a partir de la experiencia. A diferencia de los métodos tradicionales de programación, donde se especifican todas las reglas, el aprendizaje automático permite que los sistemas informáticos descubran patrones en los datos para realizar tareas específicas. Este enfoque es especialmente útil en situaciones donde los datos son complejos o cambian con el tiempo, ya que los algoritmos pueden adaptarse y mejorar continuamente su rendimiento en función de la retroalimentación recibida [23].

Por lo anterior, los algoritmos de aprendizaje automático han emergido como herramientas poderosas en el análisis de EEG, especialmente cuando se combinan con técnicas de análisis en dominio de la frecuencia y tiempo. En el análisis de EEG en el dominio de la frecuencia, estos algoritmos pueden identificar patrones complejos y características relevantes en las señales EEG, lo que permite una mejor comprensión de las diferentes frecuencias presentes y su relación con los estados mentales [3].

Por otro lado, en el análisis en el dominio del tiempo, los algoritmos de aprendizaje automático pueden extraer características temporales de las señales EEG, como la duración de los eventos, la amplitud de los picos, y la frecuencia (cantidad) de aparición de ciertos patrones. Estas características temporales son cruciales para la detección de eventos específicos, como las convulsiones epilépticas [3].

Para llevar a cabo estas tareas en el análisis de EEG, se utilizan diversos algoritmos de aprendizaje automático, cada uno diseñado para abordar diferentes aspectos de la señales [3]. Estos algoritmos se clasifican en tres categorías principales: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje reforzado (ver Figura 8).



**Figura 8.** *Tipos de aprendizaje automático*  
Nota. Obtenida de [24].

### 6.4.1. Aprendizaje supervisado

En este tipo de aprendizaje, el algoritmo recibe un conjunto de datos etiquetados que incluyen entradas y sus salidas deseadas. Su objetivo es aprender una función que mapee las entradas a las salidas correctas. Básicamente, como se detalla en la Ecuación (1), este tipo de algoritmos desarrollan una función ( $\mathbf{f}$ ) que permita realizar inferencias de la salida ( $\mathbf{y}$ ) debido a su entrada ( $\mathbf{x}$ ) esto mediante el aprendizaje de parámetros ( $\phi$ ) [25].

$$y = f[x, \phi] \quad (1)$$

Estos algoritmos son capaces de realizar tareas de regresión y de clasificación, donde la principal diferencia recae en que la salida ( $\mathbf{y}$ ) es continua (e.g., 10.5) para las tareas de regresión y discreta para las de clasificación (e.g., “bueno”). Según el tipo de tarea que se desea realizar, así se debe de seleccionar el algoritmo.

Algunos algoritmos de aprendizaje supervisado son:

- De clasificación
  - Máquinas de vectores de soporte (SVM): utiliza un hiperplano que separa los datos de cada una de las clases. Cuando los datos no presentan un comportamiento lineal, permiten la utilización de kernels (funciones no lineales) para transformar los datos a un espacio de mayor dimensión y así presenten un comportamiento lineal [24].
  - Árboles de decisión: tal como su nombre lo indica, estos replican la estructura de un árbol, donde los datos ingresan por el tronco y luego pasan a ser clasificados por las condiciones de cada rama que lleva a cada categoría. Estos pueden llegar a tener tantas ramificaciones como categorías que se busque clasificar [24].
  - Redes neuronales: estas se inspiran en el funcionamiento de las neuronas del cerebro humano, las cuales cuentan con una unidad básica llamada perceptrón que cumple con la Ecuación (1). Cada unidad básica, se interconecta con el resto que se tengan y es así que forman la red neuronal. Luego, cada unidad básica y conexión entre ellas contiene sus parámetros, los cuales mediante un entrenamiento se ajustan para lograr la clasificación en cada una de las categorías (salidas de la red) [25].
- De regresión [24]
  - Regresión lineal: ajuste estadístico mediante una función lineal de la siguiente forma  $y = \phi_0 + \phi_1 x$ .
  - Regresión no lineal: ajuste estadístico mediante una función no lineal de la forma  $y = \phi_0 + \phi_1 x + \phi_2 x^2 + \dots + \phi_n x^n$ .
  - Máquinas de vectores de soporte (SVM): funcionan de la misma manera que las de clasificación, con la diferencia que ahora el hiperplano busca ajustarse al comportamiento de los datos.

### 6.4.2. Aprendizaje no supervisado

En este tipo de aprendizaje, el algoritmo recibe un conjunto de datos sin etiquetar y debe encontrar patrones o estructuras interesantes en los datos [3]. No se le proporciona ninguna retroalimentación correcta o incorrecta. Algunos ejemplos de algoritmos de aprendizaje no supervisado incluyen:

- *K-Means clustering*
- Análisis de componentes principales (PCA)
- Algoritmos de agrupamiento jerárquico
- Mapas autoorganizados (SOM)

### 6.4.3. Aprendizaje reforzado

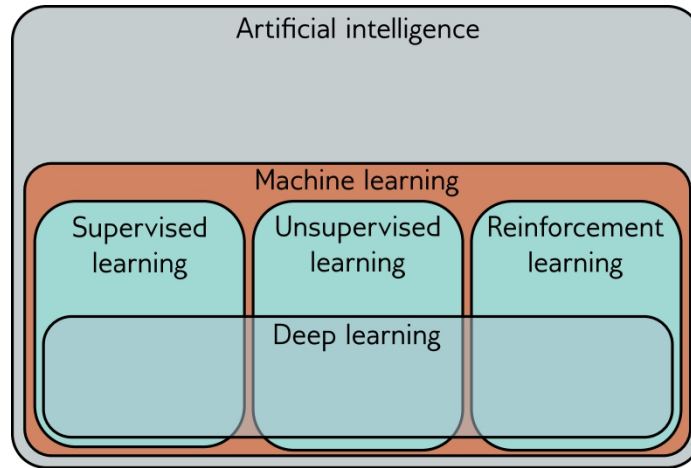
En este tipo de aprendizaje, el algoritmo aprende a través de la interacción con un entorno. Recibe retroalimentación en forma de recompensas o penalizaciones en función de las acciones que toma. El objetivo es aprender una política que maximice la recompensa acumulada a lo largo del tiempo [3]. Algunos algoritmos de aprendizaje reforzado son, los siguientes:

- *Q-Learning*
- Aprendizaje profundo Q
- Política de gradiente suave (PG)
- *Actor-Critic*

## 6.5. Aprendizaje profundo


En los últimos años, el campo del aprendizaje automático ha experimentado un notable auge, impulsado por avances en el procesamiento de grandes volúmenes de datos, capacidades computacionales y el desarrollo de nuevas técnicas (aprendizaje profundo/*Deep Learning*). Esto ha permitido un progreso significativo en diversas áreas, donde la capacidad de estos algoritmos para adaptarse y mejorar con el tiempo ha resultado particularmente útil [25].

El aprendizaje profundo es una evolución del aprendizaje automático que integra las tres áreas principales de este campo (supervisado, no supervisado y por refuerzo) en un solo enfoque (ver Figura 9). Esto se logra mediante la implementación de redes neuronales profundas, que se adaptan según la funcionalidad buscada (i.e., clasificación o regresión) y el tipo de datos disponibles (e.g., imágenes, señales o texto).



**Figura 9.** *Aprendizaje profundo y sus áreas*  
 Nota. Obtenida de [25].

El concepto de red neuronal profunda se basa en la definición dada anteriormente en la sección de aprendizaje supervisado (6.4.1), y en el teorema de aproximación universal. El cual, establece que cualquier función continua es aproximable por una red neuronal de una capa (perceptrón multicapa, MLP), siempre y cuando esta tenga las suficientes neuronas en su capa oculta para representar la función (ver Figura 10).



**Figura 10.** *Perceptrón multicapa básico generalizado*

Entonces, una red neuronal profunda es la interconexión lineal de dos o más capas ocultas con sus neuronas de entrada y salida. Esta interconexión de capas ocultas, permite que este tipo de redes neuronales interpreten de mejor manera los datos, por lo que han ganado popularidad pues son capaces de aprender de los datos (aprender de la experiencia) sin la necesidad de proporcionarle características representativas de estos. A la vez que, se han optimizado sus algoritmos de entrenamiento para procesar grandes cantidades de datos, así llegando a superar capacidades humanas (e.g., predicción de enfermedades) y proporcionando nuevas herramientas (e.g., editores de fotos con IA).

### 6.5.1. Entrenamiento de redes neuronales profundas

El entrenamiento de una red neuronal profunda se puede visualizar desde la perspectiva de un problema de optimización numérica, donde se busca minimizar la función de pérdida de la red ajustando sus parámetros ( $\phi$ , Ecuación (1)). A pesar de esta perspectiva simple, este problema de optimización puede llegar a involucrar de cientos a millones de parámetros, por consiguiente, plantea retos significativos para los enfoques de resolución tradicionales.

#### Función de pérdida

La función de pérdida o de costo mide la discrepancia entre las predicciones del modelo ( $\mathbf{f}[x_i, \phi]$ ) y el valor o clase real ( $\mathbf{y}_i$ ). Esta función actúa como una guía para el entrenamiento del modelo, ajustando los parámetros de la red de manera que las predicciones sean lo más precisas posible [25].

La elección de la función de pérdida es crucial, ya que debe adaptarse al tipo de problema<sup>1</sup>: en particular, si el modelo realiza una tarea de clasificación binaria o de clasificación multiclase. En el caso de clasificación binaria, donde solo hay dos posibles clases (e.g., ictal/no ictal), se suelen utilizar funciones de pérdida como la entropía cruzada binaria, que mide la probabilidad de que el modelo clasifique correctamente en cada caso [25].

Por otro lado, en problemas de clasificación multiclase, donde existen múltiples clases posibles (e.g., clasificar diferentes tipos de crisis epilépticas), se utiliza una versión generalizada de la entropía cruzada. Esta función considera todas las clases posibles en cada predicción y evalúa la probabilidad asignada a la clase correcta [25].

Es importante distinguir entre estos tipos de problemas porque la función de pérdida debe reflejar la estructura del conjunto de clases. De esta manera, la función de pérdida no solo mide el error, sino que también guía al modelo para lograr una clasificación precisa según el tipo de problema.

#### Algoritmos de optimización

Como se expuso anteriormente, los métodos tradicionales para resolver este problema de optimización pueden tornarse ineficientes en redes profundas debido a la gran cantidad de parámetros. Por ello, se han desarrollado algoritmos de optimización específicos que permiten ajustar los parámetros de la red de manera más efectiva. Entre los más utilizados se encuentran el descenso de gradiente estocástico (SGD) con momentum y adam, mediante los cuales se ha alcanzado el estado del arte en múltiples modelos.

---

<sup>1</sup>Se omite problema de regresión, pues no se presenta un caso de este tipo en este trabajo. Consulte: [medium.com/analytics-vidhya/a-comprehensive-guide-to-loss-functions-part-1-regression-ff8b847675d6](https://medium.com/analytics-vidhya/a-comprehensive-guide-to-loss-functions-part-1-regression-ff8b847675d6)

**Descenso de gradiente estocástico con momentum (SGDM):** el descenso de gradiente estocástico (SGD) es un método de optimización que ajusta los parámetros de la red en función de un pequeño subconjunto de datos (*minibatch*) en cada paso (iteración), en lugar de utilizar el conjunto completo. Aunque esto acelera el entrenamiento, puede generar oscilaciones en el proceso de convergencia, dificultando la llegada a un mínimo global [25].

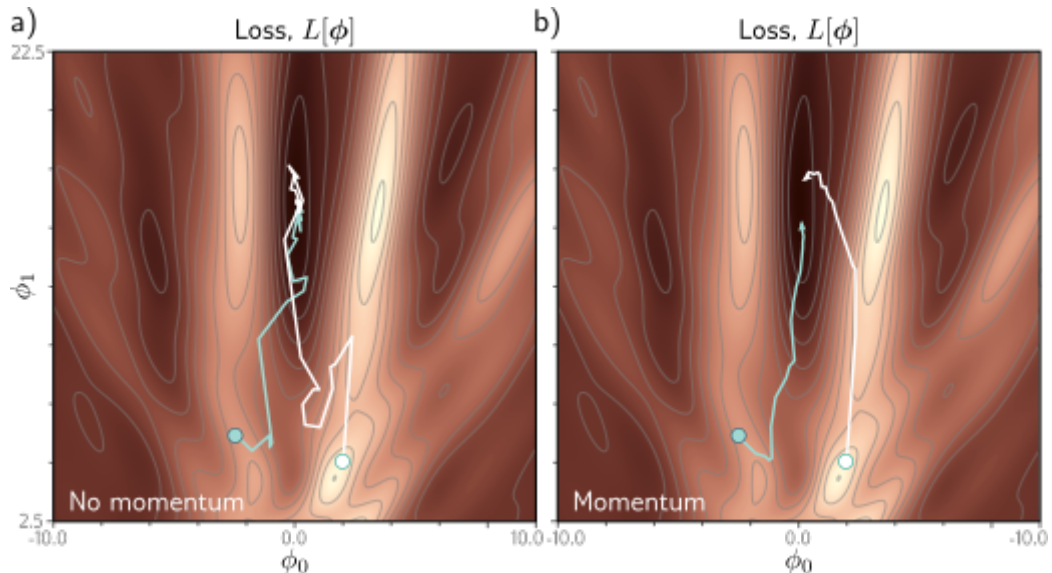
Para reducir estas oscilaciones, se incorpora el concepto de momentum o momento, que añade una fracción del gradiente de la iteración anterior al cálculo actual. La actualización del parámetro en SGDM se define como:

$$\theta_{\ell+1} = \theta_{\ell} - \alpha \nabla E(\theta_{\ell}) + \gamma(\theta_{\ell} - \theta_{\ell-1}), \quad (2)$$

donde:

- $\alpha$  es la tasa de aprendizaje, que controla la magnitud del ajuste en cada paso.
- $\nabla E(\theta_{\ell})$  es el gradiente de la función de pérdida respecto a los parámetros de la red en el paso ( $\theta_{\ell}$ ).
- $\gamma$  es el valor de momentum, que determina cuánto del gradiente de la iteración previa influirá en la actualización actual.

El parámetro de momentum ayuda a suavizar el trayecto de optimización, permitiendo que el modelo progrese más rápido en direcciones donde el gradiente se mantiene consistente y se reducen las oscilaciones (ver Figura 11).



**Figura 11.** Efecto del momentum en SGD

Nota. a) SGD sin momentum, b) SGD con momentum. Obtenida de [25].

**Adam (*adaptive moment estimation*):** adam es una mejora sobre SGD que incorpora tanto momentum como una adaptación automática de la tasa de aprendizaje para cada parámetro. Utiliza momentos de primer y segundo orden del gradiente, es decir, el promedio y la varianza acumulados, respectivamente, para ajustar dinámicamente la función de pérdida [26].

Adam realiza la siguiente secuencia en cada iteración:

1. Cálculo del promedio acumulado del gradiente:

$$m_\ell = \beta_1 m_{\ell-1} + (1 - \beta_1) \nabla E(\theta_\ell),$$

donde:

- $m_\ell$  es el promedio acumulado de los gradientes de los parámetros.
- $\beta_1$  es el factor de decaimiento que controla cuánto influye el gradiente actual en el promedio.

2. Cálculo del promedio acumulado del cuadrado del gradiente:

$$v_\ell = \beta_2 v_{\ell-1} + (1 - \beta_2) [\nabla E(\theta_\ell)]^2,$$

donde:

- $v_\ell$  es el promedio acumulado del cuadrado de los gradientes de los parámetros.
- $\beta_2$  es el factor de decaimiento que controla cuánto influye el gradiente actual en el promedio.

Finalmente, la actualización de los parámetros en adam se define como:

$$\theta_{\ell+1} = \theta_\ell - \frac{\alpha \cdot m_\ell}{\sqrt{v_\ell} + \epsilon}, \quad (3)$$

donde:

- $\epsilon$  es un pequeño valor constante para evitar divisiones por cero.

Adam es especialmente útil en redes profundas, ya que adapta automáticamente la magnitud del ajuste para cada parámetro según la variación de su gradiente, permitiendo una convergencia más estable y rápida en muchos casos [25].

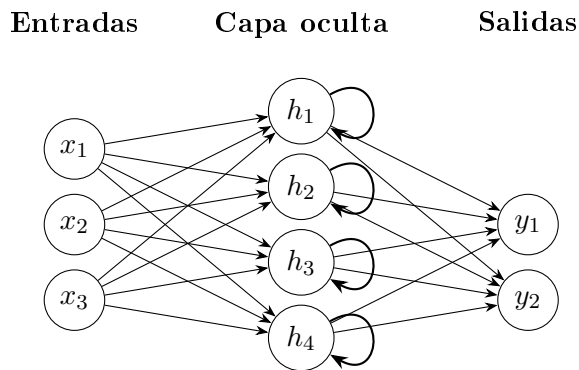
### 6.5.2. Tipos de redes neuronales profundas

En el campo del aprendizaje profundo, existen múltiples arquitecturas de redes neuronales diseñadas para abordar problemas específicos. Dos tipos de redes son particularmente relevantes en el análisis de señales temporales y secuenciales, como los electroencefalogramas (EEG): las redes neuronales recurrentes (RNN) y las redes neuronales convolucionales (CNN).

## Redes neuronales recurrentes

Las redes neuronales recurrentes (RNN, por sus siglas en inglés) están diseñadas para procesar datos secuenciales, lo cual las hace ideales para tareas en las que el orden de los datos y la dependencia temporal son importantes, como el análisis de EEG, la predicción de series temporales y el procesamiento de lenguaje natural. En una RNN, las conexiones entre las neuronas forman un ciclo que permite que la información persista a lo largo de las capas (ver Figura 12), creando una especie de “memoria” de corto plazo. Esta “memoria” permite que las RNN capten relaciones dependientes en el tiempo, facilitando el reconocimiento de patrones que evolucionan a lo largo de una secuencia [27].

Las RNN, sin embargo, presentan ciertos desafíos, como el desvanecimiento del gradiente, que limita su capacidad para capturar dependencias de largo plazo en secuencias largas. Este problema ha llevado al desarrollo de variantes de RNN que buscan mejorar la retención de información y mitigar esta dificultad, como lo son las LSTM, GRU, entre otras.




**Figura 12.** Red neuronal recurrente (RNN) simplificada

## Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN) son ampliamente utilizadas en el procesamiento de imágenes (ver Figura 13), pero también se han adaptado para analizar datos secuenciales y temporales, como los EEG. Las CNN aplican filtros (o convoluciones) que extraen características locales de los datos, lo que permite detectar patrones repetitivos y estructuras en diferentes segmentos de la secuencia [25]. En el contexto de señales EEG, las CNN pueden capturar patrones específicos en intervalos de tiempo fijos, lo cual resulta útil para identificar eventos de interés dentro de la señal.

Una de las ventajas de las CNN es su capacidad para realizar estos análisis de manera paralela y eficiente, aprovechando la naturaleza estructurada de las convoluciones. Además, al no depender de conexiones cíclicas, como en las RNN, las CNN pueden procesar secuencias más largas con menos problemas de gradientes desvanecidos y tiempo de inferencia.




**Figura 13.** *CNN simplificada para imágenes RGB clasificación multiclase*

## Otros tipos de redes neuronales

Además de las RNN y CNN, existen otras arquitecturas de redes neuronales profundas, como las redes generativas antagónicas (GAN), los transformadores (*transformers*) y los *autoencoders* [25]. Las GAN han revolucionado el campo de la generación de datos sintéticos, siendo útiles en aplicaciones como la generación de imágenes realistas. Por su parte, los transformadores han mostrado gran eficacia en el procesamiento de secuencias largas, como en tareas de modelado de lenguaje natural. Finalmente, los *autoencoders* se utilizan frecuentemente para la reducción de dimensionalidad y la extracción de características relevantes en datos complejos.

Es importante mencionar que este campo está en constante evolución, con mejoras frecuentes a arquitecturas existentes y la introducción de nuevas variantes. Desde el año 2012, el interés en este enfoque ha experimentado un crecimiento notable, como se muestra en la Figura 14. Aunque no se profundiza en estas arquitecturas adicionales, representan direcciones prometedoras para futuras investigaciones en el análisis de patrones en grandes conjuntos de datos.



**Figura 14.** *Interés en el aprendizaje profundo*  
Nota. Obtenida de [28].

---

## Obtención y recolección de datos

---

En este capítulo se describe el proceso de recolección de electroencefalogramas para este trabajo de graduación. Se incluyen las bases de datos investigadas, los centros especializados en epilepsia considerados para colaboración, y otras alternativas evaluadas. Este proceso representa un avance significativo tanto para este proyecto de graduación como para la línea de investigación.

### 7.1. Propuesta de recolección de datos estandarizada

Teniendo en cuenta el equipo disponible en la UVG para la recolección de señales bioeléctricas, se evaluó como primer alternativa la implementación de un proceso de recolección estandarizado. Para ello, se inició con la evaluación de los equipos BIOPAC modelos MP36 y MP41, los cuales son interfaces certificadas ISO 9001:2015 para la adquisición de señales de bioeléctricas para fines de investigación (ver Figura 15a).

Se determinó que el modelo MP36 era apto para la recolección de electroencefalogramas, ya que es compatible con el casco de electrodos de la empresa Electro-Cap disponible en UVG (ver Figura 15b). Este casco cumple con el estándar 10/20, es compatible con los montajes monopolar y bipolar, dispone los canales que se presentan en el Cuadro 3 y se ajusta a pacientes mayores de 5 años de edad.



(a) Pruebas con BIOPAC MP41



(b) Casco de electrodos en UVG

**Figura 15.** Equipo disponible para recolección de datos  
 Nota. Figura 15b obtenida de [29].

Conector blanco	Conector rojo	Color de cable
Fp1	Fp2	Café
F3	F4	Rojo
C3	C4	Naranja
P3	P4	Amarillo
01	02	Verde
F7	F8	Azul
T3	T4	Violeta
T5	T6	Gris
Gnd	Cz	Blanco
Fz	Pz	Negro

**Cuadro 3.** Electrodo disponibles en casco  
 Nota. Obtenido de [29].

Dado que este proceso de recolección requeriría la participación de personas ajenas a la investigación, se procedió a elaborar un consentimiento informado con la siguiente estructura:

- Sobre la investigación: contexto del estudio, proporcionando el nombre, lugar, fecha y encargados de la investigación.
- Propósito y objetivo del estudio.
- Procedimiento para sesiones de medición: detalles sobre la realización del electroencefalograma básico y el trato que recibirá.
- Uso y confidencialidad de los datos: limitaciones del uso de la información recopilada, destinada únicamente para fines académicos y científicos.
- Consideraciones asociadas a la participación: indicación de que el estudio no presenta riesgos para la salud del paciente, más allá de una posible irritación en la piel por la colocación de los electrodos.
- Beneficios asociados a la participación: información sobre la contribución del participante al desarrollo de la herramienta *Epileptic EEG Analysis Toolbox*.
- Condiciones de participación voluntaria.
- Declaración de consentimiento de participación.
- Declaración del encargado de la investigación.
- Firma de participante e información de investigadores.

El documento completo de consentimiento informado se encuentra en la documentación de este trabajo de graduación en la carpeta “Documentos/Consentimiento Informado” (ver Anexos 15.1). La elaboración de este documento tenía como objetivo informar y solicitar la autorización de los pacientes para su participación en la investigación. Sin embargo, tras evaluar la seguridad de realizar mediciones a pacientes con y sin epilepsia, se determinó que existía un riesgo significativo al hacerlo sin supervisión médica especializada. Este proceso requeriría el apoyo y/o capacitación de personal médico para monitorear y manejar posibles complicaciones durante las sesiones de medición, lo cual excedía los alcances de esta investigación. Por lo tanto, se optó por realizar una investigación exhaustiva de bases de datos médicas disponibles y de centros especializados en epilepsia, como HUMANA, para obtener los datos necesarios de manera segura y confiable.

## 7.2. Centros especializados

Con el objetivo de expandir las posibilidades de obtención de datos, se investigaron centros especializados en neurología y epilepsia que podrían ser considerados en fases futuras del proyecto. Estos centros, ubicados en diversos países, cuentan con la experiencia clínica y los recursos necesarios para proporcionar estudios electroencefalográficos valiosos.

Sin embargo, no se establecieron colaboraciones formales con estos centros en esta fase del proyecto, ya que se contó con la disponibilidad de bases de datos accesibles y adecuadas para el desarrollo de los algoritmos de aprendizaje automático, como se detalla en la siguiente sección.

Algunos de los centros identificados incluyen:

- Instituto Nacional de Neurología y Neurocirugía de México “Manuel Velasco Suárez”.
- Centro Aura de México.
- Consejo Nacional de Investigaciones Científicas y Técnicas - Hospital El Cruce - Universidad Nacional Arturo Jauretche (Argentina).

La información completa sobre estos centros, incluyendo datos de contacto y detalles adicionales, queda documentada y disponible como un recurso para futuras fases en la carpeta “Documentos/Información Centros” (ver Anexos 15.1).

## 7.3. Bases de datos médicas

Como indica Obeid [30], aunque cada año se realizan cientos a miles de electroencefalogramas en todo el mundo, las bases de datos disponibles para el desarrollo de algoritmos especializados en su análisis son limitadas. Ante esta limitación que afectó las fases anteriores de esta línea de investigación, se llevó a cabo una búsqueda exhaustiva de bases de datos estandarizadas.

Esta búsqueda tuvo como objetivo obtener un conjunto de datos más robusto y diverso, en concordancia con el primer objetivo específico de este trabajo. Para la selección de bases de datos disponibles, se priorizó que estas fueran de libre acceso y que contuvieran anotaciones de utilidad para el desarrollo de algoritmos de aprendizaje supervisado.

### 7.3.1. *Siena Scalp EEG Database*

Esta base de datos consiste en registros de 14 pacientes monitoreados mediante la técnica de EEG con video (Video-EEG) en la Unidad de Neurología de la Universidad de Siena. Los pacientes tienen un rango de edad entre 20 y 71 años, de los cuales 9 son hombres y 5 son mujeres. Cada EEG fue recolectado a una frecuencia de muestreo de 512 Hz bajo el estándar 10/20 [31].

En cuanto a las etiquetas que contiene cada señal en forma de región de interés, es importante resaltar que esta base de datos contiene 6 tipos de etiqueta para identificar diferentes tipos de crisis, según la clasificación de la ILAE (ver Figura 6):

- IAS: crisis de conciencia alterada de inicio focal.
- WIAS: crisis de conciencia preservada de inicio focal.
- FBTC: crisis focal a bilateral tónica - clónica.
- T: crisis en lóbulo temporal <sup>1</sup>.
- R: crisis en lóbulo derecho <sup>1</sup>.
- L: crisis en lóbulo izquierdo <sup>1</sup>.

Esta base de datos es valiosa, ya que permite profundizar en el desarrollo de algoritmos de clasificación multiclase y algoritmos de procesamiento de video.

Acceso directo a la base de datos: [doi.org/10.13026/5d4a-j060](https://doi.org/10.13026/5d4a-j060)

### **7.3.2. *CHB-MIT Scalp EEG Database***

Esta base de datos contiene 664 registros de EEG de 22 pacientes pediátricos del *Children's Hospital Boston*, monitoreados durante varios días sin estar bajo medicación anticonvulsiva. Los pacientes tienen un rango de edad entre 1.5 y 22 años, de los cuales 17 son mujeres y 5 son hombres. Cada estudio fue recolectado a una frecuencia de 256 Hz con una resolución de 16 bits. Los registros incluyen al menos 23 canales que cumplen con el estándar 10/20 y contienen etiquetas de tipo región de interés para los estudios que presentan convulsiones [32].

Esta base de datos es de gran importancia, ya que es una de las pocas que proporciona estudios de pacientes pediátricos. Esto ha permitido a los investigadores profundizar en aplicaciones adaptadas a la madurez del cerebro humano, como se menciona en la Sección 6.1.2.

Acceso directo a la base de datos: [doi.org/10.13026/C2K01R](https://doi.org/10.13026/C2K01R)

### **7.3.3. *The Temple University Hospital EEG Data Corpus (TUH)***

Esta es la base de datos más grande disponible públicamente, cuenta con los registros completos para cada estudio y se estima que contiene más de 60,000 EEG recolectados en el *Temple University Hospital Philadelphia* desde el año 2002 [30]. Esta base de datos, además de proporcionar una gran cantidad de estudios, también proporcionan herramientas de software para su análisis, e inclusive algunas han sido adoptadas por empresas como MATLAB con la función `edfread()`.

---

<sup>1</sup>Indica el lóbulo de ocurrencia de la crisis, complementa las primeras 3 etiquetas.

Cuenta con un repositorio (*corpus*) principal que se divide en 6 repositorios secundarios, cada uno con un enfoque específico:

- **TUH EEG Corpus (TUEG: v2.0.1)**: repositorio principal, contiene 69,625 EDF (EEG) de los cuales el 95 % se encuentran bajo el estándar 10/20 y la frecuencia de muestreo está en el rango de 250 a 1024 Hz. No se encuentra etiquetado.
  - **TUH Abnormal EEG Corpus (TUAB: v3.0.1)**: contiene 2,993 EDF clasificados como normales o anormales. Donde según su clasificación, se encuentran separados por carpetas y su objetivo es el entrenamiento de algoritmos tipo secuencia a etiqueta.
  - **TUH EEG Artifact Corpus (TUAR: v3.0.1)**: contiene 310 EDF anotados para la detección de artefactos relacionados con el movimiento ocular, masticación, escalofríos, movimiento muscular y ruido debido a electrodos. Su objetivo es el entrenamiento de algoritmos que identifiquen y/o eliminen este tipo de artefactos.
  - **TUH EEG Epilepsy Corpus (TUEP: v2.0.1)**: contiene 100 EDF correspondientes a pacientes con epilepsia y 100 EDF correspondientes a pacientes sin epilepsia. El objetivo es el entrenamiento de algoritmos que puedan determinar si un paciente padece o no de epilepsia.
  - **TUH EEG Events Corpus (TUEV: v2.0.1)**: contiene 518 EDF anotados para la identificación de las onda aguda - onda lenta, descargas periódicas epileptiformes generalizadas o lateralizadas, movimientos oculares, artefactos y ruido de fondo (ver Sección 6.2.1). Su objetivo es servir para entrenar algoritmos que asocien la forma de las ondas, que son de interés médico en el diagnóstico de la epilepsia.
  - **TUH EEG Seizure Corpus (TUSZ: v2.0.3)**: incluye 7,361 EDF anotados manualmente para la detección de períodos de convulsión (fase ictal) y todas las anotaciones de los subconjuntos ya mencionados. Cada estudio contiene dos archivos de etiquetas: uno que indica el fragmento de tiempo y el canal donde se da una crisis o artefacto, y otro que señala únicamente el período de tiempo donde existe convulsión aplicable para todos los canales. El objetivo de este repositorio, es el entrenamiento de algoritmos tipo secuencia a secuencia, capaces de reconocer períodos de convulsión en un estudio en general o por canales.
  - **TUH EEG Slowing Corpus (TUSL: v2.0.1)**: contiene 300 EDF anotados para la detección de comportamientos lentos, de fondo complejo o de convulsión. Las etiquetas proporcionadas por estudio aplican para todos los canales y conforman un conjunto equilibrado de clases (100 estudios por clase). Este subconjunto ha sido de utilidad para evaluar algoritmos de clasificación existentes, para evaluar la respuesta ante sucesos poco comunes dentro de un EEG.

Con lo expuesto, esta base de datos es un recurso de gran valor para esta línea de investigación, debido a su gran volumen de datos, la variedad de anotaciones y las herramientas de software que proporciona. Para gestionar el acceso a esta base de datos y explorar sus repositorios, consulte: [isip.piconepress.com/projects/nedc/html/tuh\\_eeg/](http://isip.piconepress.com/projects/nedc/html/tuh_eeg/).

### 7.3.4. Otras bases de datos disponibles

El avance en esta línea de investigación depende en gran medida de la cantidad de electroencefalogramas disponibles para el entrenamiento y la validación de algoritmos de aprendizaje automático. Como señala Obeid [30]: “grandes cantidades de EEG permitirán alcanzar el estado del arte en algoritmos de aprendizaje automático para descubrir nuevos diagnósticos y validar prácticas clínicas”. A continuación, se presenta un listado de otras bases de datos que pueden ser exploradas para su posible utilidad:

- *The Bonn EEG Time Series*: [doi.org/10.34810/data490](https://doi.org/10.34810/data490).
- *EEG/fMRI Naturalistic Viewing Dataset*: [doi.org/10.1101/2022.11.23.517540](https://doi.org/10.1101/2022.11.23.517540).
- *Simultaneous EEG-fMRI Dataset*: [doi.org/10.17632/crhybxpdy6.2](https://doi.org/10.17632/crhybxpdy6.2)
- *Epileptic EEG Dataset*: [doi.org/10.17632/5pc2j46cbc.1](https://doi.org/10.17632/5pc2j46cbc.1)
- *EEG Dataset of Epileptic Seizure Patients*: [dx.doi.org/10.21227/hd6x-jr97](https://dx.doi.org/10.21227/hd6x-jr97)
- *Dataset of neonatal EEG recordings with seizures annotations*: [zenodo.org/records/4940267](https://zenodo.org/records/4940267)
- *AES Seizure Prediction Challenge database*: [kaggle.com/c/seizure-prediction/data](https://kaggle.com/c/seizure-prediction/data)
- *OpenNEURO Epilepsy Datasets*: [doi.org/10.1038/s41597-019-0104-8](https://doi.org/10.1038/s41597-019-0104-8)

### 7.3.5. Selección base de datos de TUH

Tras evaluar la implementación de un proceso de recolección estandarizado, explorar las bases de datos disponibles y considerar la posible colaboración con centros especializados en epilepsia, se decidió gestionar el acceso a la base de datos *The Temple University Hospital* (TUH). Esta decisión se basó en la necesidad de contar con un conjunto de datos amplio y detallado, algo que esta base de datos ofrece gracias a su gran cantidad de estudios y anotaciones. En los siguientes capítulos, se evidencia el gran valor de la base de datos para esta línea de investigación.

Este capítulo describe los estudios utilizados y las técnicas aplicadas para su procesamiento. Asimismo, se aborda el tercer objetivo específico de este trabajo, con un enfoque particular en la definición de los parámetros establecidos por HUMANA para el procesamiento de los estudios.

Para una mejor comprensión de este estudio, consultar `Prototipo_Data_TUH.m` en el repositorio de esta fase de investigación (ver Anexo 15.2).

## 8.1. Selección de estudios

Como se menciona en la Sección 7.3.3, la base de datos de TUH ofrece distintos repositorios para diversas funcionalidades. Teniendo en cuenta el trabajo de las fases anteriores, se priorizó la clasificación de periodos ictales o de convulsión, por lo que se seleccionó el subconjunto “*TUH EEG Seizure Corpus*” (SEIZ TUH) [33].

### 8.1.1. Descripción del conjunto de datos

Este conjunto de estudios se encuentra dividido en dos carpetas principales:

- DOCS: proporciona los listados de los electrodos disponibles según el tipo de montaje utilizado y un cuadro que resume todas las posibles etiquetas que se pueden encontrar en los estudios.
  - Montajes disponibles: todos los estudios son compatibles con el montaje TCP bipolar de doble banana (ver Figura 16). Es importante tener en cuenta que algunos



### 8.1.2. Descarga de estudios de base de datos

Para realizar la descarga de los estudios desde la base de datos, es fundamental haber gestionado previamente el acceso a esta, como se detalla en la Sección 7.3.3. La base de datos se encuentra alojada en un servidor Apache, y [30] recomienda utilizar la herramienta `rsync` para este procedimiento debido a su capacidad para mantener sincronizadas las copias locales con las actualizaciones del servidor.

El método preferido para descargar los estudios es el siguiente:

- Para usuarios de Linux y MacOS: `rsync` está disponible de manera nativa en estas plataformas dentro de su terminal y es ideal para realizar las descargas.
- Para usuarios de Windows: se recomienda instalar MobaXterm, que incluye soporte para `rsync`, permitiendo realizar las descargas de manera similar a Linux y MacOS.

Además, es necesario contar con:

- Las credenciales de acceso al servidor proporcionadas por TUH.
- La ruta específica dentro del servidor donde se encuentran los estudios a descargar.
- Espacio de almacenamiento suficiente en el equipo local para las descargas.

En la documentación de esta línea de investigación, en la carpeta “Documentos/Manuales” (ver Anexos 15.1), se proporciona una guía detallada para configurar `rsync`, instalar MobaXterm en sistemas Windows y ejecutar los comandos necesarios para descargar y mantener sincronizada la base de datos con el servidor de TUH.

## 8.2. Definición de parámetros de HUMANA

Una vez descargados los estudios y antes de proceder con su procesamiento para la implementación de los algoritmos, se definieron los parámetros utilizados por HUMANA para el análisis de los estudios electroencefalográficos. Este paso fue realizado en concordancia con el tercer objetivo específico de este trabajo, asegurando que el procesamiento de los datos cumpla con los estándares y criterios establecidos por este centro.

Basándose en los estudios proporcionados por HUMANA y de su libro titulado “Epilepsias, Enfoque Multidisciplinario” [2], se identificaron los siguientes parámetros clave:

- Distribución estandarizada de electrodos 10-20: como primer criterio, se estableció que los estudios debían cumplir con esta distribución de electrodos (ver Sección 6.1.1).
- Montaje bipolar para el análisis: HUMANA no realiza un análisis canal por canal, sino que organiza los estudios como un montaje bipolar. Este enfoque les permite comparar directamente la actividad entre canales y entre hemisferios del cerebro, facilitando la identificación de patrones relevantes para el diagnóstico.

## 8.3. Migración de estudios a MATLAB

La primera tarea para iniciar la exploración de algoritmos con los nuevos datos consistió en desarrollar un proceso de lectura eficiente para manejar la gran cantidad de archivos disponibles. Este proceso no solo debía optimizar la carga de datos, sino también garantizar que los estudios cumplieran con los parámetros establecidos por HUMANA y fueran adaptados para su posterior procesamiento mediante algoritmos de aprendizaje automático.

### 8.3.1. Selección de tipo de referencia

El punto de partida para esta tarea fue definir con qué tipo de referencia se iba a trabajar, ya que, como se expuso anteriormente, el conjunto de datos SEIZ TUH contiene estudios con referencia promedio (ar) y referencia de oídos (le). Si bien ambas referencias tienen sus ventajas particulares, trabajar con ambas mezcladas no era una opción viable, ya que ello podría introducir inconsistencias en los datos y dificultar la interpretación mediante los algoritmos de aprendizaje automático [35].

La referencia promedio (ar) presenta ventajas significativas en estudios electroencefalográficos. Distribuye el potencial de referencia entre todos los electrodos, lo cual reduce posibles sesgos asociados a una única ubicación y minimiza la influencia de ruidos locales en los puntos de referencia [35]. Esto es especialmente relevante para estudios con algoritmos de aprendizaje automático, ya que asegura una mayor homogeneidad en las señales procesadas.

Por otro lado, la referencia de oídos (le) es más común en configuraciones clínicas, y su simplicidad puede ser adecuada para aplicaciones rápidas. Sin embargo, su dependencia de una ubicación fija puede hacerla más susceptible a interferencias externas y artefactos, especialmente si los electrodos de referencia no están correctamente posicionados [35].

Dado que el objetivo principal de este trabajo era maximizar la calidad y consistencia de los datos para el entrenamiento de los modelos, se optó por utilizar exclusivamente los estudios con referencia promedio (ar). Esta decisión no solo garantiza una mayor uniformidad en los datos, sino que también se alinea con los hallazgos de [35], donde se destaca que la referencia promedio tiende a ser más adecuada para análisis automatizados debido a su robustez frente al ruido y los artefactos. Además, esta elección no perjudica la cantidad de estudios a utilizar, ya que el conjunto contiene una mayor proporción de estudios con referencia ar en comparación con le (ver Figura 17).

### 8.3.2. Lectura en memoria de estudios

En una primera iteración, se consideró la posibilidad de realizar una lectura conjunta de todos los estudios en memoria. Esto implicaba leer y procesar más de 5,000 estudios con referencia ar de manera simultánea. Para implementar este enfoque, se siguió el Algoritmo 1, que emplea la función `dir` para delimitar los archivos a leer. Posteriormente, mediante un ciclo `for`, se realiza el proceso de lectura utilizando las funciones `edfinfo` y `edfread`. Para el procesamiento de etiquetas asociadas, se emplearon funciones específicas para la lectura de tablas.




Figura 17. Distribución estudios con referencia ar y le en SEIZ TUH

**Entrada:** Rutas de acceso a los estudios obtenidas con `dir`.  
**Salida:** Estudios procesados en montaje bipolar junto a su vector de etiquetas.

```

1 para cada estudio hacer
2   inicio
3     Definir chnl_list ← lista de canales de interés para montaje bipolar.
4     Obtener relPath, relName ← ruta y nombre del archivo de etiquetas del
      estudio.
5     Formatear edfName ← nombre del archivo EDF correspondiente al estudio.
6     Leer etiquetas lbl_data ← tabla desde relPath, relName.
7     Leer header del EEG edf_hdr ← edfinfo(relPath, edfName).
8     Leer señales EEG seleccionadas edf_data ← edfread(relPath,
      edfName, SelectedSignals=chnl_list).
9     Calcular frecuencia de muestreo (edf_Fs) y número de muestras
      (edf_samples).
10    Crear montaje bipolar edf_montage ← combinaciones de los canales de
      edf_data.
11   fin
12   si se requiere resampling al EEG entonces
13     Definir nueva frecuencia Fs_new;                               %Generalmente a 256 Hz
14     Calcular fracción de conversión (P, Q) ← rat(Fs_new/edf_Fs).
15     Aplicar resampling a edf_montage.
16     Actualizar variables de frecuencia (edf_Fs, edf_samples).
17   fin
18   Inicializar vector de etiquetas (etiquetas) ← “bckg”.
19   para cada etiqueta en lbl_data hacer
20     si la etiqueta es “seiz” entonces
21       Obtener tiempos de inicio (strt_lbl) y fin (stop_lbl).
22       Convertir tiempos a índices (strt_idx, stop_idx).
23       Actualizar vector de etiquetas para strt_idx:stop_idx como “seiz”.
24     fin
25   fin
26 fin

```

Algoritmo 1. Lectura y procesamiento de estudios en memoria

No obstante, a pesar de los esfuerzos realizados para optimizar el uso de memoria, no fue posible cargar todos los estudios simultáneamente. Esto debido a las longitudes variables de los archivos y al volumen de datos procesados, lo que superó la capacidad de memoria RAM disponible en el equipo utilizado (ver Cuadro 6). Lo que destacó la necesidad de adoptar un enfoque alternativo que permitiera un procesamiento eficiente y adaptado a las limitaciones de memoria.

Característica	Especificación
Procesador	Intel Core i7-12700H (14 núcleos, 20 hilos, hasta 4.7 GHz)
Memoria RAM	32 GB DDR4 (3200 MT/s)
Tarjeta Gráfica	NVIDIA GeForce RTX 3070 Ti (8 GB GDDR6)
Sistema Operativo	Windows 11 Home 64-bit

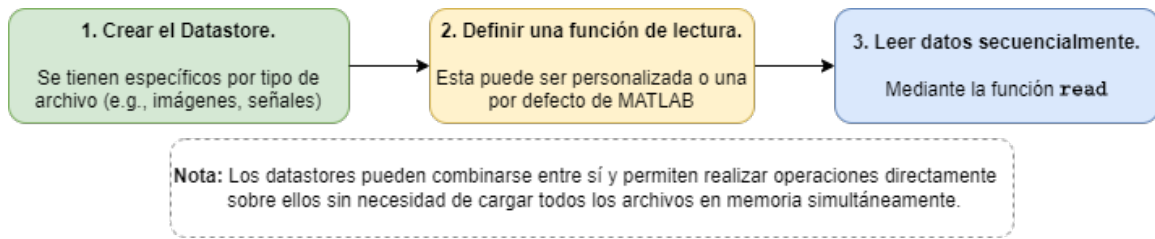
**Cuadro 6.** *Especificaciones ordenador utilizado*

### 8.3.3. Lectura optimizada de estudios

Para superar las limitaciones de memoria identificadas en la lectura simultánea de todos los estudios, se implementó una solución basada en la funcionalidad de `datastore` de MATLAB. Esta herramienta permite manejar grandes conjuntos de datos de manera eficiente, accediendo secuencialmente a cada archivo sin necesidad de cargar todos los estudios en memoria al mismo tiempo, como se ilustra en la Figura 18. Este enfoque asegura un procesamiento fluido y escalable para conjuntos de datos extensos como el de SEIZ TUH.

La implementación de esta solución requirió la definición de tres funciones de lectura personalizadas: una para la lectura de los estudios, otra para las etiquetas, y una tercera para el procesamiento conjunto de los estudios y sus etiquetas. Estas funciones personalizadas se diseñaron para replicar los procedimientos realizados en la sección anterior, a la vez que se mantienen las funcionalidades características de los `datastore`.

El procedimiento completo se presenta en el Algoritmo 2, el cual detalla los pasos seguidos para evaluar cada estudio de manera independiente, optimizando el uso de memoria y cumpliendo con los parámetros de HUMANA. Asimismo, también se aplican funcionalidades para facilitar la implementación de los algoritmos de aprendizaje automático, como la normalización en el rango  $[-1, 1]$  y centro en cero para las señales. Esta normalización no solo asegura consistencia en las señales, sino que también prepara los datos para su uso en algoritmos de aprendizaje automático como se discute en el siguiente capítulo.



**Figura 18.** *Flujo de trabajo con `datastore`*

```

Entrada: Rutas de acceso a los estudios y sus archivos de etiquetas.1
Salida: Datastore combinado y transformado para procesamiento.

% Definir funciones de lectura personalizadas.
1 Función readTUHEDF(edf_filename)
    % Para lectura de los archivos .edf y realización de montaje.
2     Seleccionar los canales de interés (chnl_list).
3     Leer los datos del archivo .edf (edfinfo y edfread).
4     Obtener frecuencia de muestreo (edf_Fs) y muestras (edf_samples).
5     Generar montaje bipolar a partir de los canales seleccionados.
6     Realizar resampling a 256 Hz si la frecuencia no coincide.
7     devolver Montaje bipolar, frecuencia de muestreo, cantidad de muestras.
8 fin
9 Función read_lbl(csv_filename)
    % Para lectura de los archivos .csv de etiquetas.
10    Configurar opciones de importación para las etiquetas (detectImportOptions).
11    Seleccionar columnas de interés (start_time, stop_time, label).
12    Leer tabla de etiquetas (readtable).
13    devolver Tabla con tiempos y etiquetas.
14 fin
15 Función getlbls(data, ventana, modo)
    % Para procesamiento de las señales y sus etiquetas.
16    Normalizar las señales con centro en cero (normalize).
17    Generar un vector de etiquetas por muestra del estudio.
18    Aplicar rescaling al rango [-1, 1].
19    Según modo, retornar:
20        1: Fragmentos de señales y etiquetas de ancho igual a ventana.
21        2: Una ventana aleatoria de la señal y sus etiquetas de ancho igual a ventana.
22        3: Señales y etiquetas completas.
23    devolver Señales y etiquetas procesadas.
24 fin

    % Crear y configurar el datastore.
25 Crear un signalDatastore para las señales con función de lectura readTUHEDF.
26 Crear un fileDatastore para las etiquetas con función de lectura read_lbl.
27 Combinar ambos datastores (combine).
28 Transformar el datastore combinado (transform) utilizando la función getlbls.

    % Ejemplo de lectura con un ciclo for.
29 para cada elemento en datastore hacer
30     Leer un elemento del datastore (read).
31     Procesar el estudio y las etiquetas asociadas.
32 fin

```

**Algoritmo 2.** *Lectura y procesamiento de estudios con datastores*

<sup>1</sup>Palabras en inglés hacen mención a funciones específicas de MATLAB.

---

## Redes neuronales profundas: justificación y métodos generales


---

En los últimos años, las redes neuronales profundas han revolucionado diversos campos, demostrando su capacidad para resolver problemas complejos y superar las limitaciones de enfoques convencionales. Este capítulo aborda la transición del aprendizaje automático tradicional hacia el enfoque de redes neuronales profundas, en concordancia con los objetivos específicos del 2 al 4 de este trabajo. Asimismo, se presentan los aspectos necesarios para su implementación en MATLAB, estableciendo las bases para los experimentos y análisis realizados en capítulos posteriores.

### 9.1. Justificación del enfoque de redes neuronales profundas

En fases anteriores de esta línea de investigación, los esfuerzos se concentraron en identificar las características que mejor representarían los EEG en sus diferentes segmentos de interés: ictal y no ictal. Sin embargo, la precisión de los algoritmos desarrollados depende directamente de la calidad de estas características y de su capacidad para generalizar y representar adecuadamente nuevos estudios. Además, este enfoque de extracción de características implica una pérdida de la información secuencial inherente a los estudios, lo que limita su capacidad para capturar patrones temporales complejos presentes en los EEG.

Como se detalla en [36], el comportamiento no estacionario natural de los EEG convierte el proceso manual de extracción de características en una tarea sobredemandante, teóricamente compleja y, en muchos casos, poco satisfactoria. En este contexto, el enfoque de aprendizaje profundo ha ganado popularidad en los últimos años, ya que permite que el algoritmo extraiga automáticamente las características más útiles para la clasificación, aprovechando la información secuencial y los patrones temporales (ver Figura 19). Además, son especialmente robustos frente a datos ruidosos o de alta dimensionalidad, lo que resulta útil en el análisis de EEG.



**Figura 19.** *Flujo de trabajo aprendizaje de máquina tradicional y profundo*  
 Nota. Obtenida de [37].

## 9.2. Implementación y validación de red LSTM

Las redes neuronales de memoria a largo-corto plazo (*long short-term memory*, LSTM) son una variante de las redes neuronales recurrentes diseñadas para resolver problemas relacionados con la dependencia a largo plazo en secuencias. Estas redes han demostrado ser efectivas en la clasificación de secuencias temporales, como las señales EEG, gracias a su capacidad para retener información relevante durante períodos prolongados.

Con el objetivo de evaluar su posible implementación en esta fase de la investigación, se llevó a cabo una primera experimentación utilizando una red LSTM para la clasificación de señales multicanal provenientes de un acelerómetro colocado en una persona. En este escenario, la tarea de la red consistió en diferenciar entre varias actividades realizadas por el individuo, como caminar, estar de pie, sentarse, correr o bailar.


### 9.2.1. Estructura de la red

La red utilizada en este experimento está diseñada específicamente para procesar señales multicanal secuenciales y consta de cuatro capas principales, cada una con una función específica dentro del modelo:

- Capa de entrada secuencial (`sequenceInputLayer`): esta capa acepta secuencias de entrada con tres canales por cada paso de tiempo, correspondientes a los tres ejes del acelerómetro ( $x, y, z$ ).
- Capa LSTM (`lstmLayer`): una capa de memoria a largo-corto plazo con 200 unidades, configurada en modo de salida secuencial (`OutputMode='sequence'`). Esta capa es responsable de capturar patrones temporales a lo largo de la secuencia.
  - Las unidades ocultas hacen mención a la cantidad de información que la capa retiene entre iteraciones, es decir, la memoria de la capa.
  - Salida secuencial hace mención a que por cada muestra que recibe, devuelve una muestra también.
- Capa densa (`fullyConnectedLayer`): reduce la salida de la capa LSTM a 5 unidades, representando las 5 clases de las actividades: caminar, estar de pie, sentarse, correr y bailar.

- Capa softmax (`softmaxLayer`): transforma las salidas de la capa densa en probabilidades, asignando una puntuación a cada clase.

El diagrama de la Figura 20 ilustra la arquitectura de la red utilizada en este experimento.



**Figura 20.** Arquitectura de red LSTM utilizada en el experimento

### 9.2.2. Opciones de entrenamiento

Para entrenar la red LSTM descrita anteriormente, se definieron las siguientes opciones de entrenamiento utilizando la función `trainingOptions` de MATLAB. Este enfoque permite especificar los hiperparámetros necesarios para optimizar el rendimiento del modelo, controlando los aspectos del proceso de entrenamiento.

- **Optimizador: `adam`**, este optimizador contribuye a una convergencia más rápida y estable.
- **Número máximo de épocas (`epoch`): 60**, este parámetro define el número de veces que el modelo revisa el conjunto de datos completo.
- **Umbral del gradiente: 2**, para evitar problemas de gradientes explosivos (que tienden a infinito), se definió un umbral para recortar los gradientes en valores altos, limitando así la magnitud máxima de los mismos.
- **`Verbose` y `Plots`**: estos parámetros hacen referencia a si se desea imprimir en consola el progreso del entrenamiento y graficarlo respectivamente.

Las opciones de entrenamiento se establecieron de la siguiente manera en MATLAB:

```
options = trainingOptions('adam','MaxEpochs',60,'GradientThreshold',2, ...
                          'Verbose',0,'Plots','training-progress');
```

### 9.2.3. Proceso de entrenamiento y resultados


Una de las principales ventajas de MATLAB para el desarrollo de redes neuronales profundas radica en la facilidad con la que se puede entrenar un modelo mediante una función específica. En este experimento, se utilizó la función `trainNetwork`, que permite realizar el proceso de entrenamiento de manera eficiente al integrar automáticamente las capas definidas, los hiperparámetros configurados y los datos de entrenamiento (`XTrain` y `YTrain`).

El entrenamiento se inicia en MATLAB de la siguiente manera:

```
net = trainNetwork(XTrain, YTrain, layers, options);
```

Es importante mencionar que MATLAB ha marcado esta función como no recomendada para nuevos desarrollos, dado que se han introducido funciones más robustas y flexibles como `trainnet`. Sin embargo, en este caso se ilustra su uso como un primer ejemplo de implementación, en la siguiente sección se presenta el caso con la función `trainnet`.

Mientras se entrena la red, se genera un gráfico que detalla el progreso del modelo, mostrando tanto la pérdida (*loss*) como la precisión (*accuracy*) en cada época (ver Figura 21). Conforme avanzan las iteraciones, la pérdida se reduce y la precisión incrementa, reflejando el aprendizaje progresivo de la red. En este experimento, la red alcanzó una precisión del 99.98 % en el conjunto de validación, lo que demuestra la efectividad de las LSTM para clasificar correctamente secuencias de múltiples canales aprendiendo patrones propios de las señales.



**Figura 21.** Progreso del entrenamiento de la red LSTM

Además, se incluye la matriz de confusión generada, como se muestra en la Figura 22. Este gráfico es esencial en el análisis de modelos de clasificación, ya que proporciona un desglose detallado de las predicciones realizadas por el modelo frente a las etiquetas reales de los datos. Cada celda en la matriz indica el número o porcentaje de muestras en las que una clase específica fue predicha como otra.

En particular, estas se pueden interpretar por:

- Filas y columnas: corresponden a las clases reales y clases predichas respectivamente.
- La diagonal principal: muestra el número o porcentaje de predicciones correctas, es decir, aquellas en las que la clase predicha coincide con la clase verdadera.
- Las celdas fuera de la diagonal principal: representan errores de clasificación, mostrando las clases en las que el modelo cometió confusiones.

Esta representación permite identificar patrones de error, como confusiones frecuentes entre clases similares o aquellas que podrían requerir un mayor refinamiento en el modelo o en los datos de entrenamiento. Por ejemplo, en este caso, puede destacarse cómo el modelo logra clasificar correctamente la mayoría de los ejemplos (diagonal principal en azul) y en el caso de la clase de correr se evidencia la confusión del modelo con la clase de bailar.

Clase Real	Dancing	6302				2
	Running	18	8048			2
	Sitting			12368	1	
	Standing				13999	1
	Walking					13147
		Dancing	Running	Sitting	Standing	Walking
		Clase Predicha				

**Figura 22.** *Matriz de confusión de la red LSTM*

### 9.3. Implementación y validación de red TCN

Las redes neuronales convolucionales temporales (*temporal convolutional networks*, TCN) son una variante de las redes convolucionales diseñadas para trabajar con datos secuenciales. Estas redes combinan la potencia de las convoluciones con la capacidad de modelar dependencias temporales, lo que las convierte en una opción efectiva para tareas de clasificación de secuencias temporales e igualando las capacidades de las redes recurrentes en esta tarea.

Con el objetivo de evaluar su implementación en esta fase de la investigación, se realizó un experimento utilizando una red TCN también para la clasificación de señales multicanal provenientes de un acelerómetro colocado en una persona. Similar al experimento con la LSTM, la tarea de la red fue diferenciar entre diversas actividades realizadas por el individuo: caminar, estar de pie, sentarse, correr o bailar.

#### 9.3.1. Estructura de la red

La red TCN utilizada en este experimento está diseñada específicamente para procesar señales multicanal secuenciales y consta de la siguiente estructura:

- Capa de entrada secuencial (`sequenceInputLayer`): esta capa acepta secuencias de

entrada con tres canales por cada paso de tiempo, correspondientes a los tres ejes del acelerómetro ( $x, y, z$ ).

- 4 bloques residuales: este bloque consiste en dos capas de convolución causal y dilatada por un mismo factor, seguidas por capas de normalización de capa, una función de activación y una capa de *dropout*. También, se suma la entrada del bloque a la salida (conexión residual), donde inicialmente se incluye una convolución de  $1 \times 1$  en la entrada para igualar el número de canales (filtros) entre la entrada y la salida del bloque.
- Capa densa (**fullyConnectedLayer**): reduce la salida de la capa convolucional a 5 unidades, representando las 5 clases objetivo.
- Capa softmax (**softmaxLayer**): transforma las salidas de la capa densa en probabilidades, asignando una puntuación a cada clase.

La Figura 23 ilustra la arquitectura de la red utilizada en este experimento.

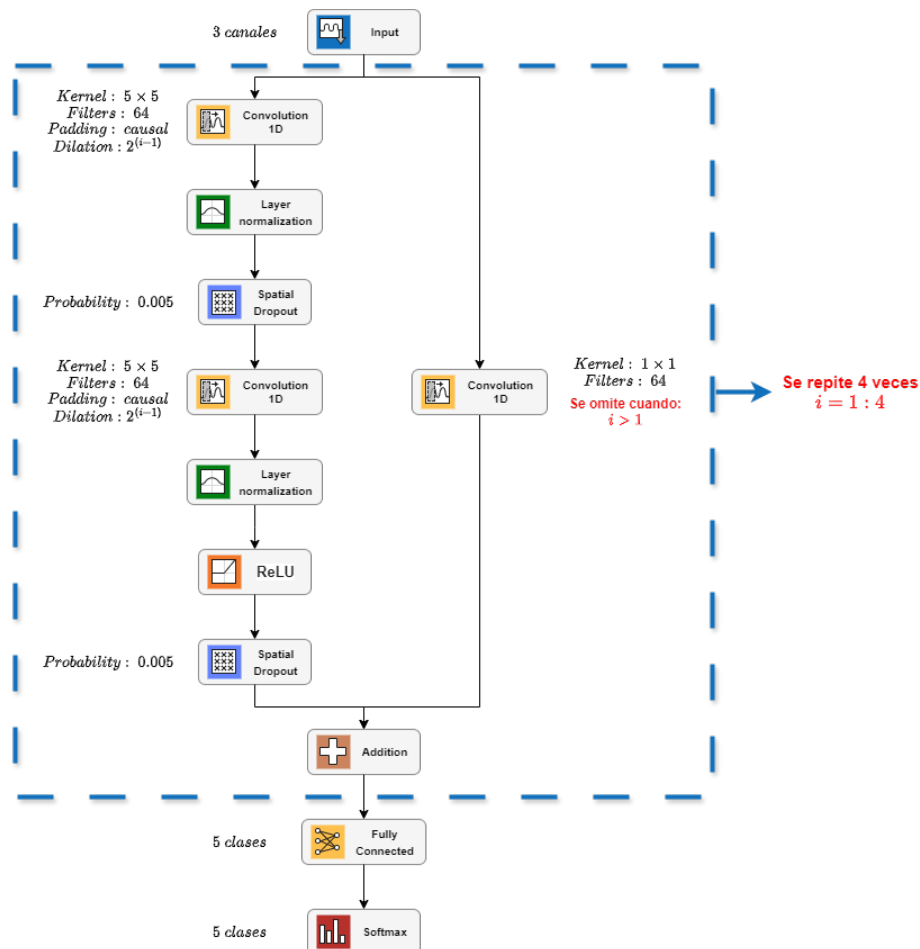


Figura 23. Arquitectura de red TCN utilizada en el experimento

### 9.3.2. Opciones de entrenamiento

Para entrenar la red TCN descrita, se definieron las siguientes opciones de entrenamiento utilizando la función `trainingOptions` de MATLAB. Estas opciones son similares a las empleadas para la red LSTM, con los siguientes parámetros clave:

- Optimizador: `adam`.
- Número máximo de épocas (*epoch*): 60.
- `miniBatchSize`: 1. Cantidad de señales que procesa por iteración.
- Metrics: `accuracy`. La función `trainnet` permite un mayor control de la función de pérdida y otras métricas de evaluación.
- Formato datos de entrada: `CTB`. La función `trainnet` permite un mayor control del formato de los datos de entrada, indica filas corresponden a canal, columnas a muestra de tiempo y tercer dimensión a batch (número de iteración dentro de una época).
- `Verbose` y `Plots`: para graficar y detallar el progreso del entrenamiento.

Las opciones de entrenamiento se establecieron de la siguiente manera en MATLAB:

```
options = trainingOptions('adam',MaxEpochs=60,miniBatchSize=1, ...
    InputDataFormats="CTB",Metrics="accuracy", ...
    Plots="training-progress",Verbose=0);
```


### 9.3.3. Proceso de entrenamiento y resultados

A diferencia del ejemplo con la LSTM, en este se entrenó la red de manera eficiente mediante la función `trainnet`. En este experimento, se integraron las capas definidas, las opciones de entrenamiento configuradas, la función de pérdida y los datos de entrenamiento (`XTrain` y `YTrain`).

El proceso de entrenamiento se realiza con el siguiente comando en MATLAB:

```
net = trainnet(XTrain,TTrain,net,"crossentropy",options);
```

La función `trainnet` se encuentra optimizada para trabajar con redes profundas. Al igual que con `trainNetwork`, mientras se entrena la red, se genera un gráfico que detalla el progreso del modelo (ver Figura 24). Al igual que con la red LSTM, el gráfico muestra cómo la pérdida disminuye y la precisión incrementa conforme avanzan las épocas. En este experimento, la red TCN logró una precisión del 98.99 % en el conjunto de validación, demostrando su efectividad para clasificar secuencias multicanal mediante el aprendizaje de características de las señales.



**Figura 24.** Progreso del entrenamiento de la red TCN

Además, se incluye la matriz de confusión generada (Figura 25), en la cual se identifica siempre una diagonal dominante aunque este modelo fue más propenso a equivocarse. Este comportamiento podría atribuirse a que la TCN puede no haber capturado patrones temporales a largo plazo tan eficazmente como la LSTM debido a las limitaciones de su campo receptivo.

	Dancing	Running	Sitting	Standing	Walking
Dancing	5955	365			
Running	135	7896			17
Sitting			12368		
Standing			9	13981	10
Walking				7	13145
	Dancing	Running	Sitting	Standing	Walking

Clase Predicha

**Figura 25.** Matriz de confusión de la red TCN

A partir de los experimentos realizados en el capítulo anterior y en concordancia con los objetivos específicos 2 al 4 de este trabajo, este capítulo aborda la implementación y evaluación de redes neuronales profundas aplicadas a los estudios EEG provenientes de la base de datos SEIZ TUH. En particular, se presentan los resultados obtenidos al utilizar estructuras de redes LSTM y TCN, adaptadas para el análisis y clasificación de eventos de convulsión y no convulsión. Este enfoque permitió explorar el rendimiento de estas arquitecturas con EEG, sentando las bases para futuras fases de investigación.

## 10.1. Implementación de redes LSTM EEGnet

Teniendo en cuenta el capítulo anterior y [36], las LSTM han demostrado su capacidad para modelar dependencias temporales complejas en datos secuenciales, lo que las convierte en una herramienta viable para el análisis de señales EEG. En esta sección, se detalla la implementación de arquitecturas LSTM con distintas variantes diseñadas específicamente para clasificar eventos de convulsión y no convulsión en los estudios EEG provenientes de SEIZ TUH.

### 10.1.1. Estructuras trabajadas

Como primer estructura, se planteó la que se presenta en la Figura 26, la cual presenta una variante de la red LSTM vista en el capítulo anterior. Esta variante, conocida como BiLSTM, combina dos capas LSTM que operan en direcciones opuestas: una procesa la señal desde el pasado hacia el futuro, y la otra desde el futuro hacia el pasado. Esta estructura surgió buscando que la red capturara patrones temporales tanto en contextos previos como

posteriores, maximizando su capacidad para analizar señales EEG de forma más completa.



Figura 26. Estructura de red BiLSTM EEGnet

La siguiente estructura puesta a prueba, se encuentra en la Figura 27, en esta se busco hacer aún más profunda la red implementando dos capas de LSTM en cascada. Este enfoque, buscaba que ambas capas se apoyaran entre sí para capturar patrones más complejos en las señales.



Figura 27. Estructura de red LSTM EEGnet profunda

Finalmente, se planteó una última estructura en la que se integraron capas basadas en *Wavelets* (*modwt* y *cwt*) junto con la arquitectura de doble LSTM (Figuras 28-29). Este enfoque tenía como objetivo permitir que las capas LSTM aprendieran a partir de representaciones obtenidas mediante la descomposición *Wavelet*, características que demostraron ser útiles en fases anteriores de esta línea de investigación.




Figura 28. Estructura de red LSTM EEGnet con modwt




Figura 29. Estructura de red LSTM EEGnet con cwt

### 10.1.2. Resumen resultados LSTM EEGnet

En el Cuadro 7 se presentan los principales resultados obtenidos al entrenar las diferentes estructuras de LSTM EEGnet. Se destacan los siguientes puntos:

- Se descartaron las configuraciones entrenadas para tres clases, ya que no se alineaban con los objetivos de clasificación definidos anteriormente.
- Las configuraciones con mayor cantidad de unidades ocultas (como 200-150 y 256-128) lograron una precisión consistente del 81.57%.
- Se invirtieron más de 98 horas (4 días y 2 horas) en la puesta a prueba de las LSTM EEGnet.

Estructura	Tiempo de entrenamiento	Precisión	Notas
Figura 26	16:03:00	N/A	Se descarta pues se entrenaron para 3 clases (SEIZ, BCKG, N/A)
Figura 27	35:36:00	81.57%	Unidades ocultas: 300 y 150 respectivamente, Probabilidad Dropout: 20 %
Figura 27	2:40:00	81.57%	Unidades ocultas: 200 y 150 respectivamente, Probabilidad Dropout: 20 %
Figura 27	1:32:00	81.57%	Unidades ocultas: 100 y 75 respectivamente, Probabilidad Dropout: 20 %
Figura 27	3:09:00	18.43%	Unidades ocultas: 120 y 80 respectivamente, Probabilidad Dropout: 20 %
Figura 28	28:49:00	81.57%	Unidades ocultas: 256 y 128 respectivamente, Probabilidad Dropout: 10 %
Figura 29	10:23:00	81.55%	Unidades ocultas: 256 y 128 respectivamente, Probabilidad Dropout: 10 %

**Cuadro 7.** *Resumen resultados con LSTM EEGnet*

## 10.2. Implementación de redes TCN EEGnet

Considerando los resultados obtenidos en el capítulo anterior y [38], las redes TCN han demostrado ser una alternativa eficaz para procesar datos secuenciales, gracias a su capacidad para capturar dependencias temporales a largo plazo mediante convoluciones dilatadas y causales. Estas características las convierten en una opción para el análisis de señales EEG, ya que permiten modelar tanto la estructura temporal como la información frecuencial de estas señales.

En esta sección, se presentan las arquitecturas TCN diseñadas específicamente para clasificar eventos de convulsión y no convulsión en los estudios EEG provenientes de SEIZ TUH, explorando las configuraciones de profundidad, filtros y dilaciones del modelo en esta tarea.

### 10.2.1. Estructuras y resultados

A diferencia de las LSTM EEGnet, las redes TCN no presentaron mayores modificaciones en su estructura base. Como se muestra en la Figura 30, estas redes se componen de una entrada secuencial, varios bloques residuales, y una capa densa seguida de una capa `softmax` para la clasificación. Los cambios realizados en las TCN se limitaron principalmente al incremento en la cantidad de bloques residuales, al tamaño del kernel y a la cantidad de filtros, buscando encontrar la combinación óptima para mejorar la precisión del modelo y su campo receptivo (ver Ecuación (4)).

Además, en algunos experimentos específicos, se optó por modificar la función de activación de `ReLU` a su variante `leaky ReLU`. Este cambio tuvo como objetivo abordar posibles problemas de unidades inactivas (*dying ReLU*), permitiendo a las TCN manejar de mejor manera las regiones de baja variabilidad en las señales EEG.

$$R = (f - 1)(2^k - 1) + 1, \quad (4)$$

donde:

- $R$  es el campo receptivo.
- $f$  es el tamaño de kernel.
- $k$  es el número de capas convolucionales dilatadas.

Al analizar los resultados obtenidos con las TCN (Cuadro 8), se identifica:

- Las configuraciones con kernels pequeños ( $3 \times 3$ ) lograron la mayor precisión (81.46%), probablemente debido a su capacidad para capturar patrones locales específicos en las señales EEG.

- Al incrementar la cantidad de filtros se observó una disminución notable en la precisión. Esto podría deberse a una sobreparametrización, donde la red no logra capturar los patrones relevantes.
- Un *dropout* excesivo podría estar afectando la capacidad de la red para aprender patrones relevantes.
- En comparación con las redes LSTM discutidas previamente, las TCN lograron una precisión similar ( 81 %), pero con tiempos de entrenamiento significativamente menores. Esto destaca su potencial como una alternativa eficiente para el análisis de señales EEG.
- Se invirtieron más de 30 horas en la puesta a prueba de las TCN EEGnet.

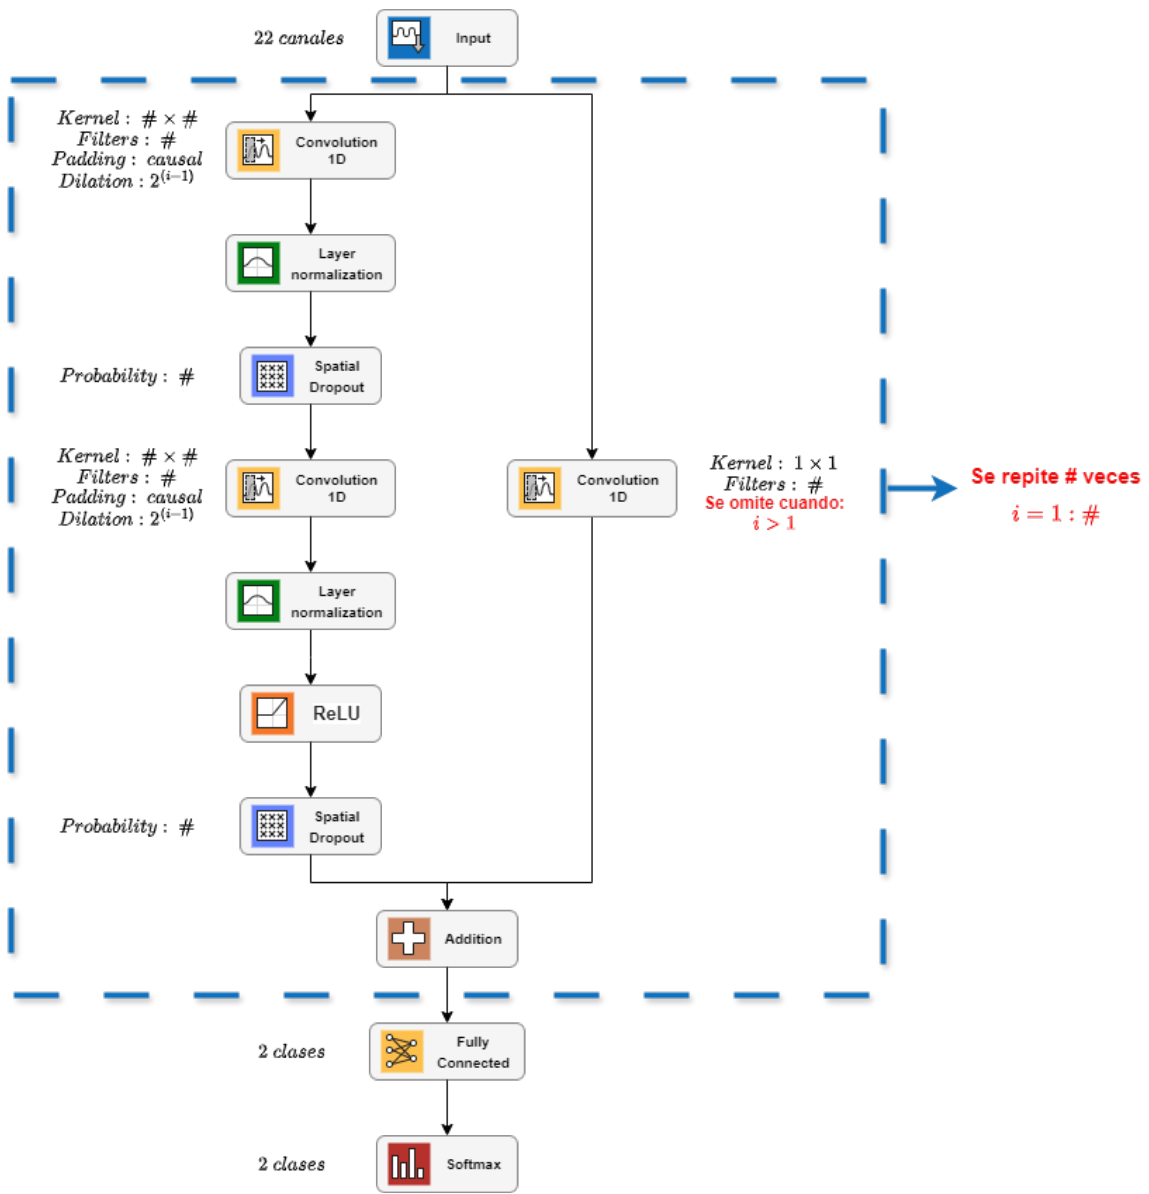


Figura 30. Arquitectura de red TCN utilizada en el experimento

<b>Estructura</b>	<b>Tiempo de entrenamiento</b>	<b>Precisión</b>	<b>Notas</b>
Kernel: $3 \times 3$ , Fil- tros: 64, Bloques re- siduales: 12, Pro- babilidad dropout: 25 %	2:14:00	81.46 %	En 2 horas, procesó más de 600 EEG.
Kernel: $10 \times 10$ , Fil- tros: 64, Bloques re- siduales: 12, Pro- babilidad dropout: 30 %	1:00:00	74.69 %	
Kernel: $14 \times 14$ , Fil- tros: 64, Bloques re- siduales: 12, Pro- babilidad dropout: 30 %	1:15:00	74.31 %	
Kernel: $10 \times 10$ , Fil- tros: 100, Bloques residuales: 16, Pro- babilidad dropout: 30 %	7:13:00	59.09 %	
Kernel: $4 \times 4$ , Fil- tros: 68, Bloques re- siduales: 10, Pro- babilidad dropout: 25 %	11:41:00	77.08 %	
Kernel: $4 \times 4$ , Fil- tros: 68, Bloques re- siduales: 10, Pro- babilidad dropout: 25 %	8:09:00	80.44 %	

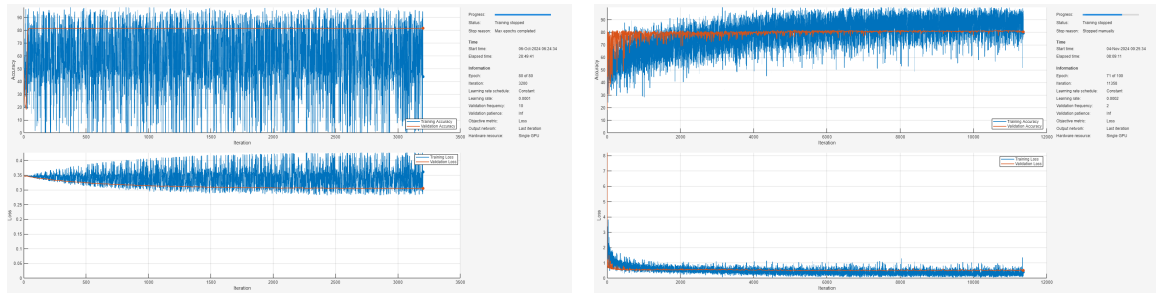
**Cuadro 8.** *Resumen resultados con TCN EEGnet*

### 10.3. Discusión redes EEGnet

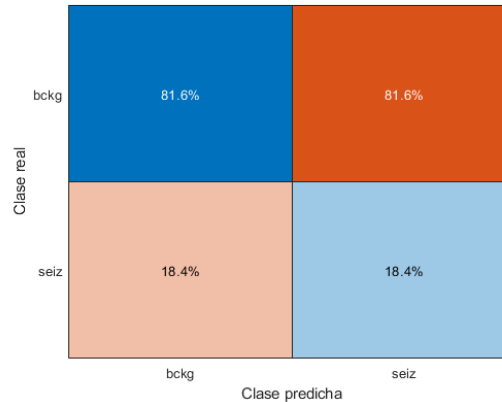
Inicialmente, los esfuerzos de este trabajo se centraron en las arquitecturas LSTM EEGnet, dado que estas cuentan con una amplia documentación en MATLAB y en la literatura. Sin embargo, a pesar de los múltiples experimentos y ajustes realizados, las LSTM no lograron superar una precisión del 81.57 %. El proceso de ajuste de hiperparámetros se tornó complicado, principalmente debido a las limitaciones computacionales, ya que cada iteración en los parámetros requería una inversión significativa de tiempo de entrenamiento y en algunos casos no era posible superar ciertos valores para no sobrepasar la memoria disponible. Además, las redes LSTM presentaron la desventaja de su falta de interpretabilidad, lo que dificultó comprender exactamente qué patrones estaban aprendiendo.

En contraste, las redes TCN EEGnet se posicionaron como una alternativa prometedora. Estas redes no solo mantienen la secuencialidad de los EEG, sino que también aplican convoluciones para extraer características, lo que resulta en una estructura más interpretable en comparación con las LSTM. Adicionalmente, las TCN permitieron experimentar con una mayor variedad de configuraciones y ajustes de hiperparámetros sin incurrir en tiempos de entrenamiento excesivos. A pesar de ello, aún se requiere seguir explorando sus configuraciones para superar la precisión alcanzada hasta ahora, que es similar a la obtenida con las LSTM.

Ambas arquitecturas, LSTM y TCN, mostraron un comportamiento similar durante el entrenamiento: una reducción progresiva de la pérdida (*loss*) y un incremento en la precisión (*accuracy*) hasta estabilizarse. Sin embargo, es evidente que ambas se estancaron en valores de precisión no ideales (ver Figuras 31a-31b). Este estancamiento se reflejó en sus matrices de confusión (Figura 31c), donde se observan confusiones entre las clases, especialmente en la clasificación de eventos de no convulsión (**bckg**) como convulsión (**seiz**). Esto destaca la necesidad de ajustar mejor los modelos para castigar falsos positivos y falsos negativos.



(a) Entrenamiento de red LSTM EEGnet      (b) Entrenamiento de red TCN EEGnet



(c) Matriz de confusión común EEGnet

**Figura 31.** Ejemplos de entrenamiento y matriz de confusión para las redes entrenadas

En conclusión, si bien las redes neuronales profundas demostraron ser una herramienta viable para el análisis y clasificación de señales EEG, es fundamental continuar iterando sobre sus configuraciones y explorar variaciones en sus estructuras e hiperparámetros. Para superar las limitaciones computacionales actuales, se recomienda explorar el uso de *clusters* en línea, computadoras de alto rendimiento (HPC) o la construcción de un *cluster* local.

---

*Herramienta Epileptic EEG Analysis Toolbox*

---

En este capítulo, se describen las mejoras e implementaciones realizadas en la herramienta *Epileptic EEG Analysis Toolbox*, desarrollada a lo largo de las fases anteriores de esta línea de investigación. Estas actualizaciones en conjunto a Dylan Ixcayau [39], incluyen la migración a la última versión de MATLAB 2024, la identificación de las dependencias y paquetes necesarios, así como mejoras en la interfaz de usuario. Este capítulo describe nuevas características y optimizaciones de rendimiento, haciéndola más intuitiva y eficiente para el análisis de EEG en concordancia con el último objetivo de este trabajo.

## 11.1. Migración a MATLAB 2024

En la fase anterior se utilizó MATLAB 2023 [10], [12], pero con la introducción de nuevas funcionalidades en el ámbito del aprendizaje profundo en MATLAB 2024, se procedió a actualizar la herramienta a esta versión más reciente. Esta migración no sólo aprovecha las últimas mejoras en el software, sino que también asegura la funcionalidad continua y la compatibilidad de la herramienta.

### 11.1.1. Evaluación de dependencias para la migración

Como primer paso en el proceso de migración, se realizó una evaluación de dependencias (**Dependency Analyzer**) para identificar los productos adicionales a MATLAB necesarios para la funcionalidad completa de la herramienta. Los productos identificados son los siguientes:

- *Bioinformatics Toolbox*: utilizada en el desarrollo de algoritmos de aprendizaje automático.
- *Database Toolbox*: empleada para el manejo y acceso a la base de datos de la herramienta.
- *Deep Learning Toolbox*: utilizada para implementar y entrenar redes neuronales.
- *Parallel Computing Toolbox*: utilizada para acelerar el procesamiento de la base de datos mediante la ejecución paralela de tareas.
- *Signal Processing Toolbox*: empleada para la extracción y análisis de características de las señales EEG.
- *Statistics and Machine Learning Toolbox*: utilizada para la creación, validación y análisis de algoritmos de aprendizaje automático.
- *Wavelet Toolbox*: empleada en la extracción de características de los EEG.

### 11.1.2. Manejo de herramienta como proyecto y cambios necesarios

Anteriormente, la herramienta *Epileptic EEG Analysis Toolbox* no utilizaba una estructura de proyecto organizada, lo que incrementaba el riesgo de perder archivos importantes y dificultaba la gestión del código. Para abordar esta área de mejora, con la migración se implementó un control de proyecto en MATLAB siguiendo las recomendaciones oficiales [40].

Este control proporciona un entorno organizado para gestionar los archivos y las dependencias de un proyecto. A través de esta implementación, se logró centralizar todos los archivos necesarios, incluyendo *scripts*, funciones, datos y recursos externos. Además, permitió utilizar herramientas integradas, como el *Dependency Analyzer*, para detectar automáticamente las dependencias y paquetes requeridos.

Otro beneficio importante fue la integración con el *Code Analyzer*, que facilitó la detección de posibles errores y mejoras en el código, asegurando que este fuera más robusto y eficiente. Además, la funcionalidad de control de cambios integrada en los proyectos facilitó la gestión de versiones y la colaboración en equipo con [39], garantizando que cualquier modificación realizada fuera rastreable y reversible en caso de errores.

Tras poner a prueba las distintas funcionalidades después de la migración, se determinó que la función `str2double` impedía que la herramienta graficara correctamente. Por lo tanto, se eliminó el uso de esta función y se redujeron los procesos que requerían la conversión. Aquellos que todavía necesitaban realizar esta conversión se cambiaron a `double(string(x))`. Finalmente, se evaluó el estado de los archivos de código (ver Figura 32), revelando archivos con advertencias debido al uso de la función `date2str`, que MATLAB no recomienda.

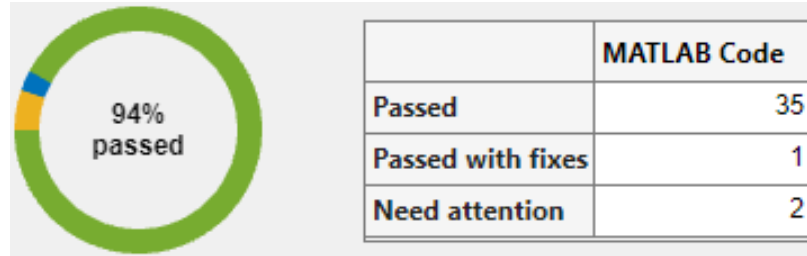


Figura 32. Análisis archivos de proyectos tras cambios en migración


## 11.2. Mejoras y nuevas implementaciones en herramienta

En esta sección, se describen las mejoras y nuevas implementaciones incorporadas en la herramienta *Epileptic EEG Analysis Toolbox*. Estas actualizaciones se centran en optimizar el rendimiento, mejorar la experiencia del usuario y ampliar las capacidades de la herramienta. Cada subsección aborda un aspecto específico de estas mejoras, desde ajustes en la interfaz de usuario hasta la integración de nuevas funcionalidades.

### 11.2.1. Implementación de *Widget Toolbox*

Para utilizar todas las funcionalidades de la herramienta, es necesario que el usuario ingrese sus credenciales en la ventana secundaria que se abre al presionar el botón de conectar. Dado que la herramienta aún se encuentra en pruebas, las contraseñas utilizadas son cortas y sencillas. Sin embargo, cuando la herramienta esté completamente operativa, se espera que las contraseñas sean más largas y complejas para garantizar la seguridad.

Para mejorar la experiencia del usuario al ingresar contraseñas más seguras, se actualizó el campo de entrada de contraseña utilizando el paquete adicional (*add-on*) *Widget Toolbox* de MATLAB, disponible de forma gratuita en el explorador de *add-ons*. Este cambio permite un mejor manejo de la contraseña al no requerir el procesamiento manual de cada carácter para ocultarlo. Además, se implementó un botón para mostrar u ocultar la contraseña y se añadió la funcionalidad de enviar la contraseña al presionar la tecla **Enter**, simplificando el proceso de autenticación (ver Figura 33).



(a) Campo de contraseña oculto

(b) Campo de contraseña visible

Figura 33. Modificaciones campo para ingresar contraseña

### 11.2.2. Protocolo cierre de ventana principal

A lo largo de las fases de esta línea de investigación, la herramienta ha incrementado sus funcionalidades y, por consiguiente, el número de ventanas secundarias. Se detectó que, al cerrar la ventana principal, las ventanas secundarias permanecían abiertas, impidiendo el cierre completo de la aplicación (ver Figura 34).

```
Warning: Error occurred while executing the listener callback for event Custom defined for class
matlabshared.asyncio.internal.Channel:
Error using procesamiento/CaracCloseRequest (line 173)
Invalid or deleted object.
> In matlabshared.asyncio.internal/Channel/onCustomEvent (line 575)
In matlabshared.asyncio.internal.Channel>@(source,data)obj.onCustomEvent(data.Type,data.Data) (line 473)
```

Figura 34. Error al cerrar ventanas secundarias

Para solucionar este problema, se implementó un protocolo que, al cerrar la ventana principal, alerta al usuario que está a punto de cerrar todas las ventanas de la herramienta. Primero, se creó un listado de todas las ventanas secundarias que la herramienta puede abrir, facilitando su identificación y manipulación. Al intentar cerrar la ventana principal, se muestra un mensaje de confirmación al usuario, advirtiéndole que todas las ventanas se cerrarán (ver Figura 35). Si el usuario confirma esta acción, una función recorre y cierra cada ventana secundaria. Además, para garantizar un cierre adecuado de la aplicación, la conexión con la base de datos se cierra y se elimina la instancia de la aplicación principal.

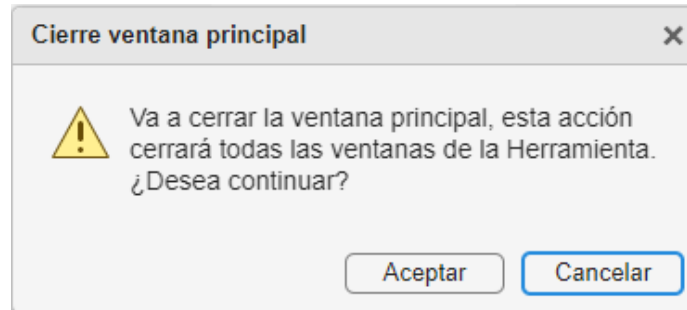


Figura 35. Alerta al cerrar ventana principal

### 11.2.3. Actualización a función `openedf`

Uno de los componentes esenciales de la herramienta es la lectura de los estudios en formato EDF, que contiene los registros de señales EEG. Anteriormente, la herramienta utilizaba la función externa `EDFREAD`, adaptada de [41]. Sin embargo, esta función ha sido marcada como “no soportada” por MATLAB, lo que presenta un riesgo de incompatibilidad futura y podría limitar el uso de funcionalidades más recientes de *software*.

Para abordar esta área de mejora, se desarrolló una nueva función llamada `openedf` que replica la funcionalidad original de `EDFREAD`, pero utilizando la función propia y recomendada actualmente por MATLAB (`edfread`) [42]. Los beneficios de este cambio recaen en:

- **Compatibilidad:** soporta la lectura de archivos EDF y EDF+.
- **Acceso a metadatos:** permite extraer información adicional, como etiquetas, unidades y otros metadatos asociados con los canales de las señales.
- **Versatilidad:** ofrece opciones para leer datos específicos, como rangos de tiempo o canales seleccionados, lo que facilita el análisis de grandes conjuntos de datos (ver Algoritmo 2).
- **Eficiencia:** optimiza la lectura de datos, mejorando el rendimiento al procesar archivos grandes y reduciendo el tiempo de carga [42].
- **Actualizaciones futuras:** es la función recomendada por MATLAB, lo que garantiza soporte, mejoras continuas en futuras versiones del software e integrar fácilmente nuevas funcionalidades relacionadas con la función.

#### 11.2.4. Implementación de montajes de EEG en herramienta

Méndez, en [12], implementó las ventanas de multigráfico, las cuales demostraron ser herramientas útiles para analizar múltiples canales de un EEG de manera simultánea. Sin embargo, como se menciona en la Sección 8.2, en HUMANA se emplean los “montajes” para el análisis de EEG. Estos no solo permiten evidenciar anomalías, sino también reducir artefactos, lo que contribuye significativamente a mejorar la precisión en los diagnósticos.

En este contexto, y con el objetivo de integrar las anotaciones generadas mediante redes neuronales profundas, se propuso la implementación de una ventana secundaria. Esta ventana automatiza el proceso de lectura del estudio, preparándolo en el formato requerido por las redes neuronales para su procesamiento. Este enfoque buscó optimizar la interacción entre el sistema de anotaciones y las arquitecturas de aprendizaje profundo empleadas, facilitando así un análisis más robusto.

Para lograr esta integración, se inició con el cambio del botón denominado “Anotaciones automáticas” a “Anotaciones por canal”, añadiendo además el nuevo botón “Anotaciones por montaje” (ver Figura 36). Este nuevo botón inicializa la ventana presentada en la Figura 37, que permite seleccionar un estudio EEG bajo el estándar 10-20. Automáticamente, el sistema selecciona los canales correspondientes, pero también ofrece al usuario la posibilidad de modificar cualquiera de estos mediante los **dropdown** disponibles (ver Figura 38).

Una vez que el usuario presiona el botón “Selección lista”, el sistema genera automáticamente el montaje bipolar doble banana en un gráfico tipo **stacked**. Como se muestra en la Figura 39, este gráfico incorpora un cursor interactivo que permite a los médicos examinar cada canal de manera intuitiva, facilitando el análisis de las señales EEG.

Esta funcionalidad se complementa con la capacidad de generar un gráfico del montaje aislado en los períodos en que se detectan eventos de convulsión. Como se muestra en la Figura 40, junto al montaje general se despliega una ventana auxiliar que contiene botones correspondientes a cada evento identificado. Al seleccionar uno de estos botones, se genera un gráfico específico del montaje en el instante detectado, como se observa en la Figura 41. Finalmente, si no se identifican eventos de convulsión dentro del estudio, se muestra una notificación informando esta situación, tal como se ilustra en la Figura 42.



Figura 36. Modificaciones ventana de análisis

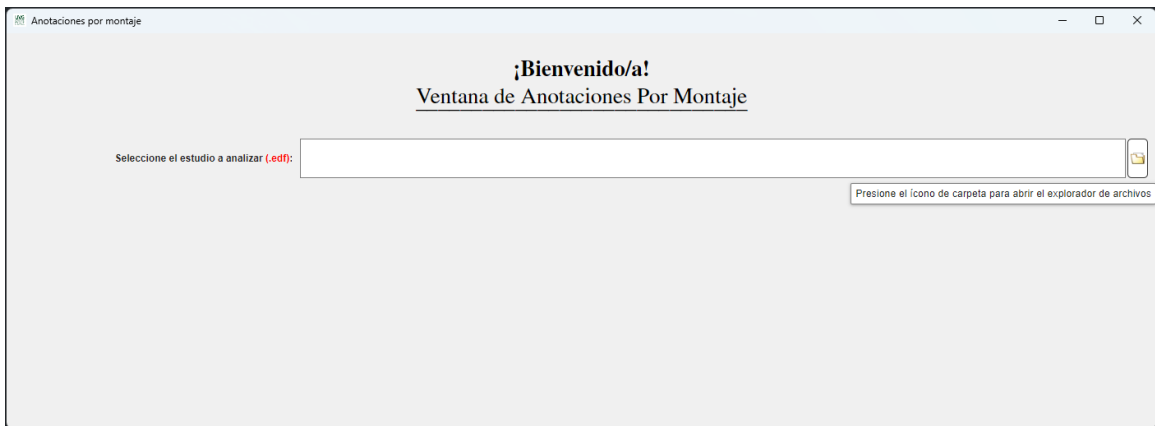


Figura 37. Nueva ventana de anotaciones por montaje



Figura 38. Selección automática de canales estándar




Figura 39. Montaje bipolar doble banana generado automáticamente con su cursor

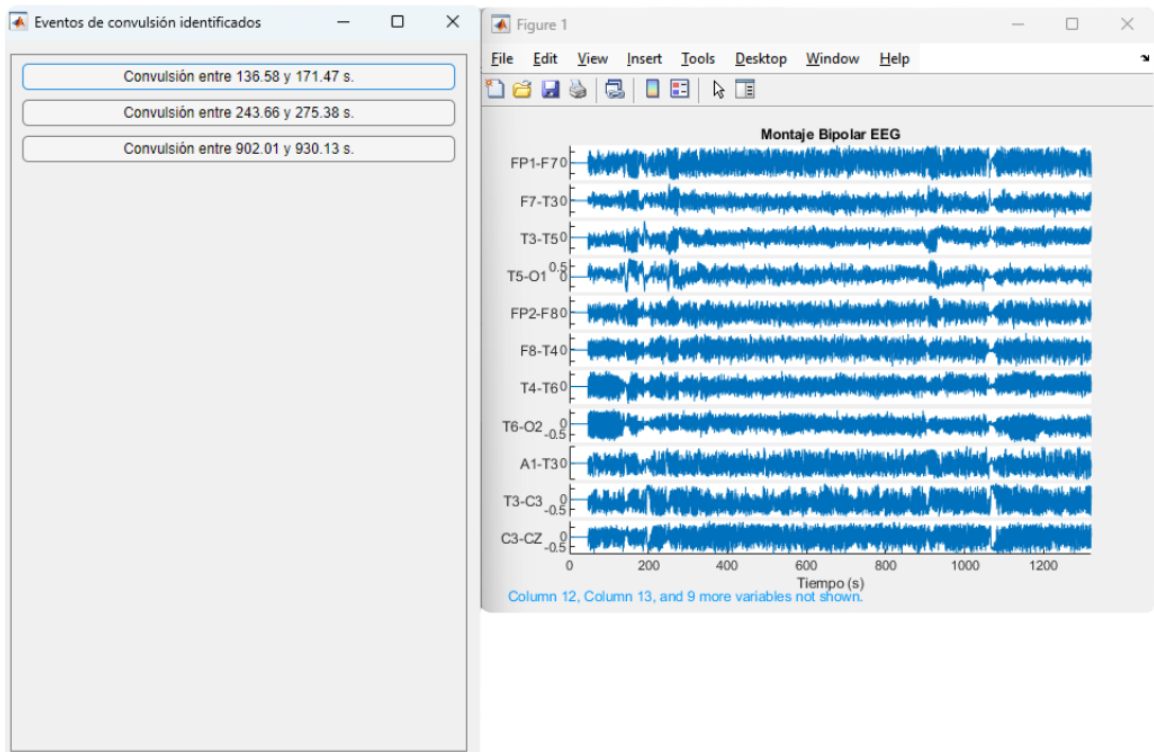


Figura 40. Ventana generada al identificarse eventos de convulsión




Figura 41. Montaje aislado de evento de convulsión generado

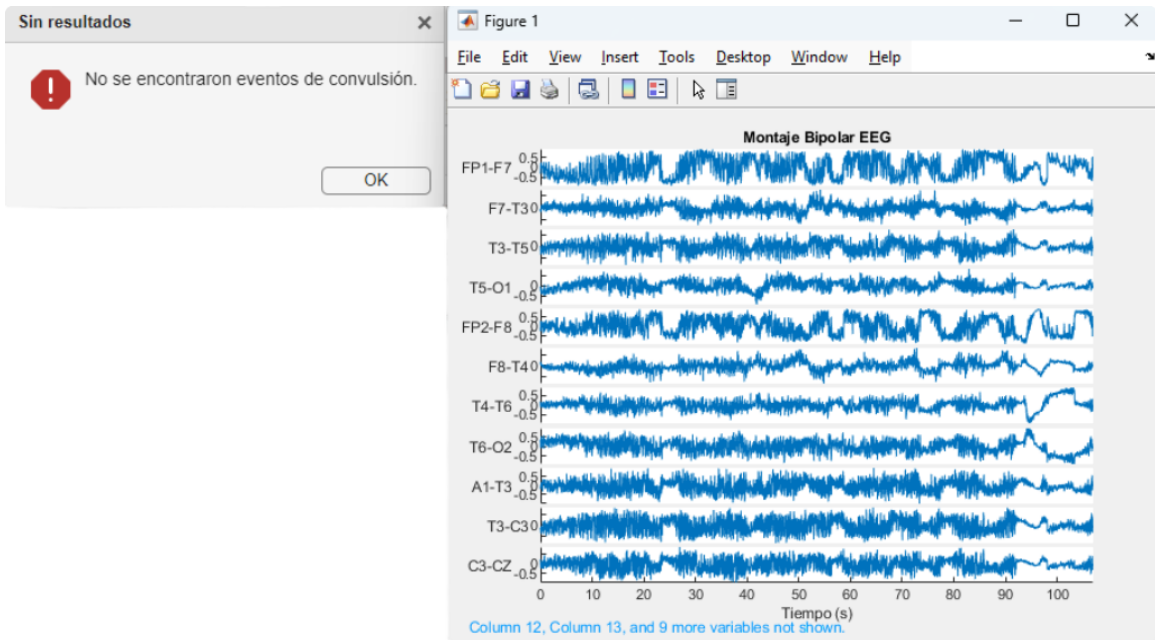


Figura 42. Ventana generada al no identificarse eventos de convulsión

- La recopilación de señales bioeléctricas de múltiples fuentes permitió construir un conjunto de datos más diverso y representativo. Esto contribuyó al desarrollo y validación de algoritmos de aprendizaje automático en un contexto más amplio y realista.
- El acceso a la base de datos de *The Temple University Hospital* (TUH) abrió la posibilidad de explorar un enfoque innovador de aprendizaje profundo para el análisis de EEG. Este enfoque permitió identificar y categorizar patrones asociados con la epilepsia sin depender de procesos manuales de extracción de características.
- Durante este trabajo, se priorizó la preservación de la secuencialidad de las señales EEG para mantener intactas sus características. Esto se logró mediante la implementación y evaluación de estructuras de red LSTM y TCN, alcanzando un rendimiento consistente superior al 81 % en precisión.
- Aunque no se superó la precisión de los algoritmos desarrollados en fases anteriores, este trabajo representa un avance significativo en el uso del aprendizaje profundo dentro de esta línea de investigación. Los algoritmos se diseñaron conforme a los parámetros establecidos por HUMANA, sentando las bases para su futura integración en herramientas de análisis.
- El enfoque basado en aprendizaje profundo se destaca por su capacidad de generar anotaciones relevantes en señales EEG con mínima intervención del usuario, lo que optimiza el proceso de análisis.
- La implementación de análisis estadísticos fue de gran utilidad dentro de los procesos de entrenamiento de las redes LSTM y TCN, así como para su evaluación posterior. Estos análisis permitieron identificar patrones de comportamiento en las métricas de precisión y pérdida, evaluar la eficacia de las configuraciones probadas y determinar oportunidades de mejora en los modelos.

- La herramienta *Epileptic EEG Analysis Toolbox* fue actualizada con nuevas funcionalidades, como la implementación de montajes automatizados y la integración de anotaciones generadas mediante redes neuronales profundas. Asimismo, se realizaron mejoras clave para garantizar la continuidad de la herramienta, optimizar su funcionamiento y mejorar la experiencia del usuario, incluyendo la limpieza y optimización del código.

- Se recomienda explorar los conjuntos de datos adicionales disponibles en la base de TUH y de las otras bases recopiladas, ya que ofrecen amplias oportunidades de estudio. Por ejemplo, mediante estudios EEG en los que identifican artefactos, desarrollar algoritmos capaces de eliminar estos mismos y así tener un estudio limpio a su salida.
- Dado que el campo del aprendizaje automático se encuentra en constante evolución, se recomienda explorar y probar diferentes arquitecturas de redes neuronales profundas para el análisis de EEG. Por ejemplo, transformadores y combinaciones entre arquitecturas CNN-RNN.
- Para superar las limitaciones computacionales identificadas durante los procesos de entrenamiento, se recomienda considerar el uso de recursos más avanzados, como computadoras de alto rendimiento (HPC), *clusters* en línea o incluso la configuración de *clusters* locales utilizando las computadoras disponibles en el laboratorio. Esto permitirá acelerar los tiempos de entrenamiento y explorar configuraciones más complejas de redes neuronales.
- Se recomienda dividir la herramienta *Epileptic EEG Analysis Toolbox* en dos versiones específicas: una enfocada en la práctica clínica, adaptada a las necesidades de los médicos, y otra diseñada para facilitar el desarrollo y prueba de algoritmos de aprendizaje automático. Esta separación permitirá optimizar la funcionalidad de cada versión según su propósito, mejorando tanto la experiencia del usuario médico como la flexibilidad para la investigación y desarrollo.
- Se recomienda explorar la implementación de algoritmos híbridos que combinen enfoques tradicionales de aprendizaje automático con redes neuronales profundas. En este esquema, las redes neuronales profundas se utilizarían para extraer características relevantes de las señales, que posteriormente servirían como entrada para algoritmos tradicionales de aprendizaje automático. Este enfoque puede aprovechar las fortalezas de ambos métodos, maximizando la capacidad de clasificación y análisis de las señales EEG.

- 
- [1] Organización Mundial de la Salud, “Epilepsia: Un imperativo de salud pública,” *Ginebra: Organización Mundial de la Salud*, 2019.
  - [2] J. C. Lara, A. A. Jerez, O. G. Ramírez y J. M. Pérez, *Epilepsia, enfoque multidisciplinario*, 2.<sup>a</sup> ed. Humana Editores, 2014, vol. 1, ISBN: 978-9929-40-461-8.
  - [3] M. K. Siddiqui, R. Morales, X. Huang y N. Hussain, “A review of epileptic seizure detection using machine learning classifiers,” *Brain Informatics*, pág. 5, 2020, doi: 10.1186/s40708-020-00105-1.
  - [4] Centro de Epilepsia y Neurocirugía Funcional (HUMANA), *Epilepsia: Estudio, Tratamiento y Cirugía desde el 2006*. dirección: <https://humanagt.org/epilepsia/#:~:text=VIDEO%2DELECTROENCEFALOGRAMA>.
  - [5] A. Craik, Y. He y J. Contreras-Vidal, “Deep learning for Electroencephalogram (EEG) classification tasks: A review,” *Journal of Neural Engineering*, vol. 16, 2019. DOI: 10.1088/1741-2552/ab0ab5.
  - [6] M. J. Angulo, “Análisis y Reconocimiento de Patrones de Señales Biomédicas de Pacientes con Epilepsia,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2020.
  - [7] M. F. Pineda, “Diseño e Implementación de una Base de Datos de Señales Biomédicas de Pacientes con Epilepsia,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2020.
  - [8] J. D. A. Vela, “Automatización del Proceso de Anotación de Señales EEG de Pacientes con Epilepsia por Medio de Técnicas de Aprendizaje Automático,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2021.
  - [9] C. Lemus Lone, “Análisis y Anotación de Señales Bioeléctricas de pacientes con epilepsia utilizando técnicas de aprendizaje automático supervisado y no supervisado,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2022.
  - [10] C. I. Patzán, “Aplicación sistemática de algoritmos de aprendizaje automático para el estudio de la epilepsia y la detección de segmentos de interés en señales bioeléctricas,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2023.

- [11] M. Shehadeh, "Chameleon Swarm Algorithm: A bio-inspired optimizer for solving engineering design problems," *Expert Systems with Applications*, vol. 174, pág. 114685, 2021, ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2021.114685>. dirección: <https://www.sciencedirect.com/science/article/pii/S0957417421001263>.
- [12] D. A. Méndez, "Extensión, validación y migración de una herramienta de software para el estudio de la epilepsia para su uso en el Centro de Epilepsia y Neurocirugía Funcional (HUMANA)," Tesis de licenciatura, Universidad Del Valle de Guatemala, 2023.
- [13] NEUROVIRTUAL, *Software BWAnalysis EEG/ICU/LTM*. dirección: <https://neurovirtual.com/latam/equipamento/software-bwanalysis-eeg/>.
- [14] TecniScan, *Electroencefalograma*. dirección: <https://www.tecniscan.com/electroencefalograma-4/>.
- [15] Instituto Nacional de la Trastornos Neurológicos y Accidentes Cerebrovasculares (NIH), *Fundamentos del cerebro: Conozca el cerebro*, <https://espanol.ninds.nih.gov/es/trastornos-neurologicos/fundamentos-del-cerebro-conozca-el-cerebro>, 2024.
- [16] F. Ramos, G. Morales, S. Egozcue, R. Pabón y M. Alonso, "Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas," *Anales Sis San Navarra*, vol. 32, n.º Supl. 3, págs. 69-82, 2009. dirección: [https://scielo.isciii.es/scielo.php?script=sci\\_arttext&pid=S1137-66272009000600006](https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272009000600006).
- [17] Departamento de Fisiología, Facultad de Medicina, UNAM, "Fisiología de la actividad eléctrica del cerebro," *Unidad temática I, sesión VII (a)*, 2024.
- [18] R. Shriram, M. Sundhararajan y N. Daimiwal, "EEG Based Cognitive Workload Assessment for Maximum Efficiency," *IOSR Journal of Electronics and Communication Engineering (IOSR-JECE)*, ago. de 2012.
- [19] O. Mecarelli, O. Mecarelli, ed. Springer International Publishing, 2019, ISBN: 978-3-030-04573-9. DOI: 10.1007/978-3-030-04573-9\_9. dirección: [https://doi.org/10.1007/978-3-030-04573-9\\_9](https://doi.org/10.1007/978-3-030-04573-9_9).
- [20] E. Wirrell et al., "Methodology for classification and definition of epilepsy syndromes with list of syndromes: Report of the ILAE Task Force on Nosology and Definitions," *Epilepsia*, vol. 63, n.º 6, págs. 1333-1348, 2022. DOI: <https://doi.org/10.1111/epi.17237>. dirección: <https://onlinelibrary.wiley.com/doi/abs/10.1111/epi.17237>.
- [21] R. Fisher et al., "Clasificación operacional de los tipos de crisis por la Liga Internacional contra la Epilepsia," *Epilepsia*, vol. 58, n.º 4, págs. 522-530, 2017. DOI: 10.1111/epi.13670.
- [22] BioSource Faculty, *EEG Montages: Part 2 - Selecting the Best Comparison*. dirección: <https://www.biosourcesoftware.com/post/eeg-montages-part-2-selecting-the-best-comparison>.
- [23] N. Nilsson, *Introduction to Machine Learning*. Stanford University, 1998, An Early Draft of a Proposed Textbook. dirección: <https://ai.stanford.edu/~nilsson/MLBOOK.pdf>.

- [24] The MathWorks, Inc., *Machine Learning with MATLAB*. The MathWorks, Inc, 2022. dirección: <https://www.mathworks.com/campaigns/offers/next/machine-learning-with-matlab.html>.
- [25] S. Prince, *Understanding Deep Learning*. The MIT Press, 2023. dirección: <http://udlbook.com>.
- [26] D. P. Kingma y J. Ba, *Adam: A Method for Stochastic Optimization*, 2017. arXiv: 1412.6980 [cs.LG]. dirección: <https://arxiv.org/abs/1412.6980>.
- [27] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*. MIT Press, 2016, <http://www.deeplearningbook.org>.
- [28] Google Trends, *Aprendizaje profundo, interés a lo largo del tiempo*. dirección: <https://trends.google.com/trends/explore?date=all&q=%2Fm%2F0h1fn8h&hl=es>.
- [29] BIOPAC Systems, Inc., *EEG ELECTRODE CAP SYSTEMS AND CAPS*. dirección: <https://www.biopac.com/wp-content/uploads/EEG-CAPS.pdf>.
- [30] I. Obeid y J. Picone, “The Temple University Hospital EEG Data Corpus,” *Frontiers in Neuroscience*, vol. 10, 2016, ISSN: 1662-453X. DOI: 10.3389/fnins.2016.00196. dirección: <https://www.frontiersin.org/journals/neuroscience/articles/10.3389/fnins.2016.00196>.
- [31] P. Detti, *Siena Scalp EEG Database*. PhysioNet, 2020. dirección: <https://doi.org/10.13026/5d4a-j060>.
- [32] J. Guttag, *CHB-MIT Scalp EEG Database*. PhysioNet, 2010. dirección: <https://doi.org/10.13026/C2K01R>.
- [33] V. Shah et al., “The Temple University Hospital Seizure Detection Corpus,” *Frontiers in Neuroinformatics*, vol. 12, 2018, ISSN: 1662-5196. DOI: 10.3389/fninf.2018.00083. dirección: <https://www.frontiersin.org/journals/neuroinformatics/articles/10.3389/fninf.2018.00083>.
- [34] S. Ferrell et al., “The Temple University Hospital EEG Corpus: Electrode Location and Channel Labels,” 2022. dirección: [https://isip.piconepress.com/publications/reports/2020/tuh\\_eeg/electrodes/electrodes\\_and\\_channels\\_v30.docx](https://isip.piconepress.com/publications/reports/2020/tuh_eeg/electrodes/electrodes_and_channels_v30.docx).
- [35] S. Lopez, A. Gross, S. Yang, M. Golmohammadi, I. Obeid y J. Picone, “An analysis of two common reference points for EEGs,” en *2016 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*, IEEE, dic. de 2016, págs. 1-5. DOI: 10.1109/spmb.2016.7846854. dirección: <http://dx.doi.org/10.1109/SPMB.2016.7846854>.
- [36] A. Abdelhameed y M. Bayoumi, “Semi-Supervised Deep Learning System for Epileptic Seizures Onset Prediction,” en *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 2018, págs. 1186-1191. DOI: 10.1109/ICMLA.2018.00191.
- [37] C. Janiesch, P. Zscheck y K. Heinrich, “Machine learning and deep learning,” en *Electron Markets 31*, Springer, dic. de 2021, págs. 685-695. DOI: 10.1007/s12525-021-00475-2. dirección: <https://doi.org/10.1007/s12525-021-00475-2>.
- [38] S. Bai, J. Zico y V. Koltun, *An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling*, 2018. arXiv: 1803.01271 [cs.LG]. dirección: <https://arxiv.org/abs/1803.01271>.

- [39] D. A. Ixcayau, “Aplicación de algoritmos de aprendizaje automático, con énfasis en aprendizaje no supervisado, para la identificación y categorización de segmentos de interés en señales bioeléctricas para el estudio de la epilepsia - Fase V,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2024.
- [40] The MathWorks, Inc., *Create Projects*. dirección: [https://www.mathworks.com/help/matlab/matlab\\_prog/create-projects.html](https://www.mathworks.com/help/matlab/matlab_prog/create-projects.html).
- [41] B. Shoelson, *edfRead - File Exchange*, 2024. dirección: <https://www.mathworks.com/matlabcentral/fileexchange/31900-edfread>.
- [42] The MathWorks, Inc., *edfread*. dirección: <https://www.mathworks.com/help/signal/ref/edfread.html>.

## 15.1. Documentación general

Consulte el siguiente enlace con la documentación completa de este trabajo:

[drive.google.com/drive/folders/1RALSA\\_1lnjWWSxAzaAQ\\_-DzhTkVVEjy4?usp=sharing](https://drive.google.com/drive/folders/1RALSA_1lnjWWSxAzaAQ_-DzhTkVVEjy4?usp=sharing)

## 15.2. Repositorio GitHub

Consulte el siguiente enlace con repositorio en GitHub de este trabajo:

[github.com/JAPM8/Herramienta](https://github.com/JAPM8/Herramienta)

### 15.3. Listado de etiquetas disponibles en conjunto de datos TUH SEIZ

Etiqueta	No. Clase	Nombre evento	Localidad
NULL	0	<i>No Event</i>	N/A
SPSW	1	<i>Spike/Sharp and Wave</i>	All
GPED	2	<i>Generalized Periodic Epileptiform Discharges</i>	Generalized
PLED	3	<i>Periodic Lateralized Epileptiform Discharges</i>	Hemispheric/Focal
EYBL	4	<i>Eye blink</i>	Focal
ARTF	5	<i>Artifacts (All)</i>	All
BCKG	6	<i>Background</i>	N/A
SEIZ	7	<i>Seizure</i>	All
FNSZ	8	<i>Focal Non-Specific Seizure</i>	Hemispheric/Focal
GNSZ	9	<i>Generalized Non-Specific Seizure</i>	Generalized
SPSZ	10	<i>Simple Partial Seizure</i>	All
CPSZ	11	<i>Complex Partial Seizure</i>	All
ABSZ	12	<i>Absence Seizure</i>	Generalized
TNSZ	13	<i>Tonic Seizure</i>	All
CNSZ	14	<i>Clonic Seizure</i>	All
TCSZ	15	<i>Tonic Clonic Seizure</i>	All
ATSZ	16	<i>Atonic Seizure</i>	N/A
MYSZ	17	<i>Myoclonic Seizure</i>	N/A
NESZ	18	<i>Non-Epileptic Seizure</i>	N/A
INTR	19	<i>Interesting Patterns</i>	All
SLOW	20	<i>Slowing</i>	All
EYEM	21	<i>Eye Movement Artifact</i>	Focal
CHEW	22	<i>Chewing Artifact</i>	All
SHIV	23	<i>Shivering Artifact</i>	All
MUSC	24	<i>Muscle Artifact</i>	All
ELPP	25	<i>Electrode Pop Artifact</i>	Focal
ELST	26	<i>Electrostatic Artifact</i>	All
CALB	27	<i>Calibration Artifact</i>	All
HPHS	28	<i>Hypnagogic Hypersynchrony</i>	Generalized
TRIP	29	<i>Triphasic Wave</i>	Generalized

**Cuadro 9.** Listado de etiquetas disponibles en base de datos TUH SEIZ  
Nota. Obtenido de [33].

***dying ReLU*** problema que ocurre en redes neuronales cuando las salidas de las neuronas que utilizan la función de activación ReLU quedan permanentemente inactivas, devolviendo siempre un valor de cero. Esto sucede porque los valores de entrada a la función ReLU son constantemente negativos, impidiendo que la neurona aprenda durante el proceso de entrenamiento. 54

**campo receptivo** es la cantidad total de pasos temporales en la entrada que ocasionan una salida de la red convolucional, es decir, cuántas muestras analiza la red para realizar una predicción. 50

**capa de *dropout*** capa que apaga neuronas en una red durante su entrenamiento para forzar a que todas las neuronas aprendan por igual y sin un sobreajuste. La cantidad de neuronas que apaga se define por una probabilidad (porcentaje) asignada a la capa. 48

**conexión residual** mecanismo en arquitecturas de redes neuronales donde la salida de un bloque se combina con su entrada original. Esto se realiza mediante una suma directa o una convolución 1x1 para igualar las dimensiones. Su propósito es facilitar el flujo de información a través de la red, evitando la degradación del gradiente y mejorando el entrenamiento en redes profundas. 48

**convolución causal y dilatada** operación de convolución que utiliza únicamente valores presentes y pasados de la señal (causal), introduciendo además saltos entre muestras (dilatación) para capturar patrones más amplios en los datos con un mismo tamaño de kernel. 48

**EDF** formato europeo de acceso libre para el intercambio y almacenamiento de señales bioeléctricas. 34

**función de activación** función matemática que introduce no linealidades a una red neuronal. Se tiene una variedad de estas: ReLU y sus variantes, tanh, softmax, entre otras. 48

**hiperparámetros** parámetros configurables que controlan el comportamiento de un modelo de aprendizaje profundo durante el proceso de entrenamiento. A diferencia de los parámetros que aprende el modelo (como los pesos y sesgos), los hiperparámetros son definidos antes del entrenamiento y pueden influir significativamente en el rendimiento del modelo. 45

**región de interés** etiquetado de una señal proporcionando punto de inicio y fin para cada aparición de una etiqueta. 33

**secuencia a etiqueta** clasificación en donde se recibe una secuencia completa (e.g., eeg completo) y el algoritmo clasifica toda la secuencia como una sola etiqueta. 34

**secuencia a secuencia** clasificación en donde se recibe una secuencia completa (e.g., eeg completo) y el algoritmo clasifica cada muestra de la secuencia con una sola etiqueta. 34