

UNIVERSIDAD DEL VALLE DE GUATEMALA  
Facultad de Ingeniería



**Análisis y anotación de señales bioeléctricas de pacientes con  
epilepsia utilizando técnicas de aprendizaje automático  
supervisado y no supervisado**

Trabajo de graduación presentado por Camila Lemus Lone para optar  
al grado académico de Licenciada en Ingeniería Mecatrónica

Guatemala,

2022







UNIVERSIDAD DEL VALLE DE GUATEMALA  
Facultad de Ingeniería



**Análisis y anotación de señales bioeléctricas de pacientes con  
epilepsia utilizando técnicas de aprendizaje automático  
supervisado y no supervisado**

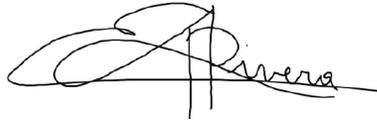
Trabajo de graduación presentado por Camila Lemus Lone para optar  
al grado académico de Licenciada en Ingeniería Mecatrónica

Guatemala,

2022

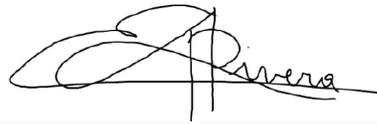


Vo.Bo.:

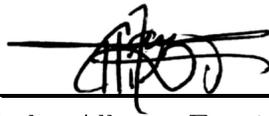


(f) \_\_\_\_\_  
Dr. Luis Alberto Rivera Estrada

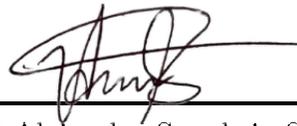
Tribunal Examinador:



(f) \_\_\_\_\_  
Dr. Luis Alberto Rivera Estrada



(f) \_\_\_\_\_  
MSc. Carlos Alberto Esquit Hernández



(f) \_\_\_\_\_  
Dr. Abel Alejandro Sanabria Sanchinel

Fecha de aprobación: Guatemala, 07 de enero de 2023.



La elaboración de este trabajo surge de mi interés particular por la inteligencia artificial, una rama de la tecnología que siempre ha capturado mi atención. Con este proyecto tuve la oportunidad de aprender y aplicar algoritmos de *machine learning* para automatizar procesos en el campo de las ciencias de la salud, lo cual fue una experiencia increíblemente enriquecedora. Esto ha fortalecido mi deseo de continuar investigando sobre estos métodos con infinidad de aplicaciones.

Quiero expresar mi profunda gratitud a mi familia por ser mi mayor inspiración y mi ejemplo a seguir. Especialmente agradezco a mis padres, Mario Lemus y Silvy Lone por creer en mí y apoyarme incondicionalmente a cumplir mis sueños. Sin su amor y sacrificio no sería la persona y profesional que soy hoy en día. Gracias por guiarme por el buen camino, este logro es por ustedes.

Agradezco también a mi hermana, Mayarí, por estar siempre para mí y motivarme a seguir adelante. Gracias a mis abuelos, padrinos y primos por el amor y atención que han tenido siempre conmigo. Su respaldo ha sido fundamental en mi camino académico y personal.

A mis amigos, les agradezco profundamente por su constante ánimo y apoyo, su amistad ha sido muy importante para mí. Gracias por ser testigos y cómplices de sacrificios y aventuras durante estos años de licenciatura.

Mi sincero agradecimiento al Dr. Luis Alberto Rivera, mi asesor, por orientarme y compartir sus conocimientos conmigo. Sin su apoyo y paciencia la realización de este trabajo no hubiera sido posible. También quiero expresar mis agradecimientos a las y los docentes que, a lo largo de mi vida, me transmitieron su pasión por la ciencia, la tecnología y la ingeniería.

Finalmente, agradezco a la Universidad del Valle de Guatemala, mi alma máter, por abrirme sus puertas y formarme como ingeniera.



<b>Prefacio</b>	v
<b>Lista de figuras</b>	x
<b>Resumen</b>	xi
<b>Abstract</b>	xiii
<b>1. Introducción</b>	1
<b>2. Antecedentes</b>	3
<b>3. Justificación</b>	7
<b>4. Objetivos</b>	9
<b>5. Alcance</b>	11
<b>6. Marco teórico</b>	13
6.1. Epilepsia . . . . .	13
6.1.1. Síndromes de epilepsia . . . . .	13
6.1.2. Tipos de crisis epilépticas . . . . .	14
6.1.3. Diagnóstico . . . . .	15
6.1.4. Tratamiento . . . . .	16
6.2. Señales bioeléctricas . . . . .	17
6.2.1. Electroencefalograma (EEG) . . . . .	17
6.2.2. Electrocardiograma (ECG) . . . . .	20
6.2.3. Electromiograma (EMG) . . . . .	20
6.3. Aprendizaje automático . . . . .	20
6.3.1. Aprendizaje supervisado . . . . .	20
6.3.2. Aprendizaje no supervisado . . . . .	23
6.3.3. Aprendizaje por refuerzo . . . . .	23

<b>7. Experimentación con aprendizaje automático supervisado</b>	<b>25</b>
7.1. Bases de datos señales EEG	25
7.1.1. Ubonn EEG <i>Dataset</i>	25
7.1.2. Kaggle American Epilepsy Society Seizure Prediction Challenge	26
7.2. Filtrado de la señales	26
7.3. Selección de características	26
7.3.1. Pruebas de rendimiento en la extracción de características	27
7.4. Entrenamiento de clasificador	27
7.4.1. Redes neuronales (RNA)	27
7.5. Base de datos señales ECG	33
7.5.1. ECG PhysioNet	33
7.6. Selección de características	33
7.7. Entrenamiento del clasificador	34
<b>8. Experimentación con aprendizaje automático no supervisado</b>	<b>35</b>
8.1. K-means Clustering	35
8.2. Clustering Jerárquico	37
8.2.1. Rand Index	37
8.2.2. Resumen de resultados Clustering Jerárquico	38
<b>9. Herramienta de software</b>	<b>39</b>
<b>10. Conclusiones</b>	<b>43</b>
<b>11. Recomendaciones</b>	<b>45</b>
<b>12. Bibliografía</b>	<b>47</b>
<b>13. Anexos</b>	<b>51</b>
13.1. Repositorio de Github	51
13.2. Matrices de confusión de RNA utilizando características en dominio de la frecuencia para dos clases (Ictal/Sano)	51
13.3. Matrices de confusión de RNA usando características en dominio de la frecuencia para dos clases (Interictal/Preictal)	53
13.4. Matrices de confusión de RNA utilizando características individuales en dominio de la frecuencia para dos clases (Ictal/Sano)	55
13.5. Matrices de confusión de RNA utilizando características individuales en dominio de la frecuencia para dos clases (Interictal/Preictal)	58

---

Lista de figuras

---

1. Resumen de resultados con clasificador máquina de vectores de soporte (SVM), María Jesús Angulo 2020 [5]. . . . .	4
2. Resumen de resultados con clasificador red neuronal artificial (RNA), María Jesús Angulo 2020 [5]. . . . .	5
3. Resumen de los resultados de los clasificadores generados: red neuronal (RNA) y máquina de vectores de soporte (SVM), David Vela 2021 [7]. . . . .	5
4. Clasificación operacional de los tipos de crisis, versión extendida ILAE 2017 [11]. . . . .	15
5. Ritmos cerebrales en una señal EEG [24]. . . . .	18
6. Arquitectura típica de una red neuronal [32]. . . . .	22
7. Definición del “margen” entre clases: el criterio que los SVM intentan optimi- zar [34]. . . . .	22
8. Comparación del tiempo de extracción de características por 1 registro. . . . .	27
9. Matriz de confusión Ictal (1) y Sano (2) con RNA, utilizando la razón 1 como característica en dominio de la frecuencia. . . . .	28
10. Matriz de confusión para las clases Ictal (1) y Sano (2) con RNA, utilizando las razones 1, 2 y 3 como características en dominio de la frecuencia. . . . .	29
11. Matriz de confusión para las clases Ictal (1) y Sano (2) utilizando RNA, con el total de características mencionadas anteriormente (6). . . . .	29
12. Matriz de confusión Interictal (1) y Preictal (2) con RNA, utilizando la razón 1 como característica en dominio de la frecuencia. . . . .	30
13. Matriz de confusión para las clases Interictal (1) y Preictal (2) con RNA, utilizando las razones 1, 2 y 3 como características en dominio de la frecuencia. . . . .	30
14. Matriz de confusión para las clases Interictal (1) y Preictal (2) utilizando RNA, con el total de características mencionadas anteriormente (6). . . . .	31
15. Resumen del rendimiento de la RNA para dos clases variando la cantidad de características utilizadas en el dominio de la frecuencia. . . . .	32
16. Resumen del rendimiento de la RNA para dos clasificadores binarios utilizan- do características individuales en dominio de la frecuencia. . . . .	32
17. Resumen de los resultados de la RNA para dos, tres y cuatro clases utilizando características en dominio de la frecuencia. . . . .	33

18. Matriz de confusión entre dos clases utilizando el método de Lorenz . . . . .	34
19. Experimento k-means con 2 grupos . . . . .	36
20. Experimento k-means con 3 grupos . . . . .	36
21. Experimento k-means con 4 grupos . . . . .	36
22. Rand Index . . . . .	37
23. Resumen de resultados clústering jerárquico con Rand Index . . . . .	38
24. Login . . . . .	39
25. Cargar señales . . . . .	40
26. Extracción de características . . . . .	40
27. Entrenamiento del clasificador . . . . .	41
28. Cargar señal y clasificador para observar anotaciones. . . . .	41
29. Observar anotaciones . . . . .	42
30. Matriz de confusión Ictal/Sano con RNA, utilizando las razones 1 y 2 como características en dominio de la frecuencia. . . . .	52
31. Matriz de confusión Ictal/Sano con RNA, utilizando las razones 1, 2, 3 y 4 como características en dominio de la frecuencia. . . . .	52
32. Matriz de confusión Ictal/Sano con RNA, utilizando las razones 1, 2, 3, 4 y 5 como características en dominio de la frecuencia. . . . .	53
33. Matriz de confusión Interictal/Preictal con RNA, utilizando las razones 1 y 2 como características. . . . .	54
34. Matriz de confusión Interictal/Preictal con RNA, utilizando las razones 1, 2, 3 y 4 como características. . . . .	54
35. Matriz de confusión Interictal/Preictal con RNA, utilizando las razones 1, 2, 3, 4 y 5 como características. . . . .	55
36. Matriz de confusión Ictal/Sano con RNA, utilizando la razón 2 como característica en dominio de la frecuencia. . . . .	56
37. Matriz de confusión Ictal/Sano con RNA, utilizando la razón 3 como característica en dominio de la frecuencia. . . . .	56
38. Matriz de confusión Ictal/Sano con RNA, utilizando la razón 4 como característica en dominio de la frecuencia. . . . .	57
39. Matriz de confusión Ictal/Sano con RNA, utilizando la razón 5 como característica en dominio de la frecuencia. . . . .	57
40. Matriz de confusión Ictal/Sano con RNA, utilizando la std como característica en dominio de la frecuencia. . . . .	58
41. Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 2 como característica en dominio de la frecuencia. . . . .	59
42. Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 3 como característica en dominio de la frecuencia. . . . .	59
43. Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 4 como característica en dominio de la frecuencia. . . . .	60
44. Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 5 como característica en dominio de la frecuencia. . . . .	60
45. Matriz de confusión Interictal/Preictal con RNA, utilizando la std como característica en dominio de la frecuencia. . . . .	61

En Guatemala hay alrededor de 325,000 pacientes con epilepsia, no obstante, el acceso a nuevas tecnologías para el estudio de esta enfermedad sigue siendo reducido para algunos neurólogos. Con este trabajo se busca ayudar a los doctores a automatizar el proceso de diagnóstico de epilepsia, mediante una herramienta de *software* en MATLAB, que analice señales bioeléctricas de interés, utilizando técnicas de aprendizaje automático.

Se experimentó con señales electroencefalográficas (EEG) tomadas de la base de datos de la Universidad de Bonn en Alemania y del concurso American Epilepsy Society Seizure Prediction del portal Kaggle. El desarrollo del proyecto consistió en el procesamiento de las señales, la extracción de características en dominio de la frecuencia y posteriormente el entrenamiento y evaluación del clasificador redes neuronales, para dos, tres y cuatro clases, obteniendo una exactitud superior al 99 %. También se experimentó con algoritmos de aprendizaje no supervisado, tales como: kmeans y clustering jerárquico, obteniendo una exactitud promedio del 85.51 %.

Adicional a eso, se agregó a la herramienta de software una sección para procesar señales de electrocardiograma (ECG) y se obtuvo una exactitud del 90.3 % en la clasificación binaria al utilizar características obtenidas por un método no lineal.



In Guatemala, around 325,000 patients have epilepsy, however, access to new technologies for studying this disease is still limited for some neurologists. This work aims to help doctors automate the process of diagnosing epilepsy using a software tool in MATLAB that analyzes bioelectric signals of interest using machine learning techniques.

The study involved electroencephalographic (EEG) signals obtained from the University of Bonn's database in Germany and the American Epilepsy Society Seizure Prediction competition on the Kaggle platform. The project's development included signal processing, feature extraction in the frequency domain, and subsequently training and evaluating a neural network classifier for two, three, and four classes, achieving an accuracy of over 99%. Unsupervised learning algorithms, such as k-means and hierarchical clustering, were also experimented with, resulting in an average accuracy of 85.51%.

Additionally, a section was added to the software tool to process electrocardiogram (ECG) signals and a 90.3% accuracy was obtained in binary classification using features obtained by a non-linear method.



La epilepsia es un trastorno neurológico común caracterizado por convulsiones recurrentes e incapacitantes, conocidas como crisis epilépticas. Cada vez es más común el uso de métodos de aprendizaje automático (*machine learning* - ML) en aplicaciones clínicas y experimentales para el diagnóstico de la epilepsia y otros trastornos neurológicos y psiquiátricos. Los métodos de ML tienen el potencial de proporcionar un rendimiento fiable y óptimo para el diagnóstico clínico, la predicción y la medicina personalizada mediante el uso de algoritmos matemáticos y enfoques computacionales.

Entre las aplicaciones de ML más comunes relacionadas con la epilepsia, se destaca el reconocimiento de patrones de interés en señales EEG. Gracias a los avances tecnológicos, se ha logrado acelerar el diagnóstico de esta enfermedad, que tradicionalmente requiere un análisis manual y anotaciones hechas por parte de médicos especializados. Este método suele ser bastante tardado, especialmente cuando se utilizan registros de varias horas de duración.

El objetivo de este proyecto es mejorar la herramienta de software diseñada en fases anteriores para el estudio médico de la epilepsia. Esto mediante la implementación de nuevas técnicas de aprendizaje automático, analizando diferentes señales bioeléctricas y evaluando el rendimiento de los clasificadores. En trabajos previos se utilizaron características en el dominio del tiempo y con la transformada Wavelet. En esta fase, se lleva a cabo una exploración enfocada en el reconocimiento de patrones relevantes en señales EEG, utilizando características en el dominio de la frecuencia y técnicas de aprendizaje automático supervisado. Además, se realiza un análisis de otras señales bioeléctricas pertinentes para el estudio de la epilepsia, empleando técnicas de aprendizaje automático no supervisado.

En el capítulo [6](#) de este trabajo, se presentan algunas bases teóricas que se utilizaron para el desarrollo de este proyecto. En los capítulos [7](#) y [8](#) se detallan los experimentos realizados, la metodología empleada y los resultados obtenidos. Finalmente, se presentan las conclusiones y recomendaciones para la continuación del estudio.



La epilepsia es una de las afecciones cerebrales graves más comunes y afecta alrededor de 50 millones de personas en todo el mundo [1]. En los últimos años ha aumentado la disponibilidad de aplicaciones clínicas y experimentales de métodos de aprendizaje automático para la epilepsia y otros trastornos neurológicos y psiquiátricos. Mundialmente, se han realizado algunas aplicaciones de aprendizaje automático para la epilepsia, entre las cuales se encuentran, el análisis de neuroimágenes [2], la detección automatizada de convulsiones a partir de electroencefalografía (EEG), videos y datos cinéticos, predicción de la respuesta a la medicación, predicción de los resultados médicos y quirúrgicos, entre otras [3].

En Guatemala, el Centro de Epilepsia y Neurocirugía Funcional, HUMANA, es una organización conformada por destacados profesionales en el campo de las neurociencias. Su enfoque se centra en atender a pacientes que padecen trastornos neurológicos de difícil control, entre los que se incluye la epilepsia [4]. HUMANA se distingue por ser el único centro en Guatemala con un laboratorio de video-electroencefalograma (EEG), lo cual permite la obtención de señales electroencefalográficas de pacientes que presentan posibles episodios epilépticos. En 2020, cuando se inició la primera etapa de este proyecto, se llevó a cabo una entrevista con el Dr. Juan Carlos Lara, director de HUMANA. En dicha entrevista, se destacó que las anotaciones de las señales EEG se realizan de forma manual por parte de profesionales especialistas del hospital. Este proceso implica una considerable cantidad de horas de trabajo dedicadas a identificar los segmentos de interés para, finalmente, emitir un diagnóstico. La duración de esta operación puede variar desde aproximadamente cuatro horas hasta incluso varios días, dependiendo de la longitud del registro.

En la Universidad del Valle de Guatemala (UVG) se realizó en 2020 la primera iteración de una herramienta software de aprendizaje automático, presentada en el trabajo de graduación titulado *Análisis y Reconocimiento de Patrones de Señales Biomédicas de Pacientes con Epilepsia*, por María Jesús Angulo Tijerino [5]. En este trabajo, se encontró que es posible la detección de crisis epilépticas en señales EEG mediante aprendizaje automático, al realizar la correcta caracterización y división de segmentos. En las Figuras 1 y 2 se muestra un resumen de los resultados de este trabajo de graduación. Paralelo a esto, se creó e imple-

mentó una base de datos con señales biomédicas de pacientes de HUMANA, presentada en el trabajo de graduación de María Fernanda Pineda Esmieu, llamado *Diseño e Implementación de una Base de Datos de Señales Biomédicas de Pacientes con Epilepsia* [6]. La base de datos se enlazó con el sistema de aprendizaje automático mencionado anteriormente, y se comprobó que las características del dominio del tiempo utilizadas en el análisis directo son suficientes para generar una exactitud 95% para dos clases.

En 2021, David Alejandro Vela Aguilera presentó la segunda iteración de la herramienta de aprendizaje automático en su trabajo de graduación nombrado *Automatización del Proceso de Anotación de Señales EEG de Pacientes con Epilepsia por Medio de Técnicas de Aprendizaje Automático* [7]. Se realizó ajustes a la interfaz realizada en la fase anterior, la cual fue capaz de emplear algoritmos de aprendizaje automático supervisado para clasificar la señal EEG en una de cuatro clases, obteniendo un promedio de exactitud del 96.7% en el clasificador con mejor desempeño en tiempo continuo. Se utilizó vectores de soporte con características en tiempo continuo y kernel gaussiano. El resumen de los resultados generados se observa en la Figura 3. Adicional a esto, se agregó una nueva sección a la herramienta iniciada en 2020, la cual se encarga de la generación de anotaciones dentro de un apartado con varias opciones de personalización para la visualización.

Cabe resaltar que tanto en la fase de 2020, como en la de 2021, se trabajó, principalmente, con señales EEG en dominio del tiempo, dejando oportunidad para analizar las señales en otro dominio (como el de la frecuencia), y de analizar otro tipo de señales bioeléctricas que también podrían ser de interés para el diagnóstico de la epilepsia. Una de las limitaciones que se tuvo en estos trabajos, es que principalmente se utilizaron técnicas de aprendizaje automático supervisado, lo que abre espacio para profundizar el análisis de los datos con diferentes técnicas de aprendizaje automático.

En 2022, el trabajo de graduación de Jorge Diego Manrique Sáenz, llamado *Herramienta de Software con una Base de Datos Integrada para el Estudio de la Epilepsia - Fase II* [8], buscó principalmente expandir el modelo relacional de la base de datos para poder almacenar características y clasificadores para el análisis automático de señales EEG. También se adaptó la herramienta para almacenar información confidencial de forma segura y se buscó reducir tiempos en los procesos internos.

Mejores Resultados Clasificador SVM									
Análisis	Caso	Base de Datos	Exactitud	VP	FN	FP	VN	Kernel lineal	Kernel RBF
Directo	1	Ubonn	98.0%	50.0%	0.0%	0.0%	50.0%	x	x
			100.0%	50.0%	0.0%	0.0%	50.0%	x	x
			100.0%	50.0%	0.0%	0.0%	50.0%	x	x
			95.0%	10.0%	1.0%	0.0%	9.0%	x	x
	CHB-MIT	96.3%	38.0%	0.0%	3.0%	41.0%	x		
		100.0%	41.0%	0.0%	0.0%	41.0%	x		
Wavelet	2	Ubonn	100.0%	25.0%	0.0%	0.0%	25.0%	x	
			100.0%	25.0%	0.0%	0.0%	25.0%	x	
			100.0%	25.0%	0.0%	0.0%	25.0%	x	
			100.0%	25.0%	0.0%	0.0%	25.0%	x	

Figura 1: Resumen de resultados con clasificador máquina de vectores de soporte (SVM), María Jesús Angulo 2020 [5].

Mejores Resultados Clasificador ANN								
Análisis	Caso	Base de Datos	Exactitud	VP	FN	FP	VN	
Directo	1	Ubornn	99.5%	49.5%	0.0%	0.5%	50.0%	
			99.5%	50.0%	0.5%	0.0%	49.5%	
		CHE-MIT	97.1%	47.6%	0.5%	2.4%	49.5%	
			100.0%	50.0%	0.0%	0.0%	50.0%	
Wavelet	2	Ubornn	99.5%	50.0%	0.5%	0.0%	49.5%	
		Daubechies 4	99.0%	50.0%	1.0%	0.0%	49.0%	
		Daubechies 10	99.5%	50.0%	0.5%	0.0%	49.5%	
			99.0%	49.5%	0.5%	0.5%	49.5%	
		CHE-MIT	Daubechies 4	89.2%	44.9%	5.4%	5.4%	44.4%
			Daubechies 10	81.6%	42.6%	10.8%	7.6%	39.0%

Figura 2: Resumen de resultados con clasificador red neuronal artificial (RNA), María Jesús Angulo 2020 [5].

Características	Tiempo Continuo			Wavelet		
	RNA	SVM		RNA	SVM	
Kernel	-	Gaussiano	Lineal	-	Gaussiano	Lineal
2 Clases	100.00%	99.80%	100.00%	97.70%	98.70%	97.90%
3 Clases	97.90%	98.90%	97.20%	98.20%	98.30%	97.20%
4 Clases	88.00%	91.30%	88.30%	81.20%	83.30%	77.10%
Promedio	95.30%	96.70%	95.20%	92.40%	93.40%	90.70%
Desv. Estándar	5.23%	3.81%	4.99%	7.90%	7.17%	9.64%

Figura 3: Resumen de los resultados de los clasificadores generados: red neuronal (RNA) y máquina de vectores de soporte (SVM), David Vela 2021 [7].



La epilepsia es uno de los trastornos neurológicos más frecuentes. Según la Organización Mundial de la Salud (OMS) cerca del 80% de las personas con epilepsia viven en países de ingresos bajos y medianos. Se estima que el 70% de las personas con epilepsia podría vivir sin convulsiones si se diagnosticaran y trataran adecuadamente [1]. En los últimos años ha aumentado la disponibilidad de aplicaciones clínicas y experimentales de métodos de aprendizaje automático para la epilepsia, no obstante, Guatemala no cuenta con acceso a estas herramientas. Esto implica un gran costo de oportunidad tanto para los doctores como para los pacientes, ya que el análisis de señales consume mucho tiempo y esto atrasa el diagnóstico.

Hasta ahora, en la UVG se han desarrollado dos fases de una herramienta de *software* para el análisis de señales EEG de pacientes con epilepsia, donde se logró clasificar y realizar anotaciones de estas señales. Sin embargo, la herramienta está limitada para el análisis de un solo tipo de señal bioeléctrica y únicamente los dominios tiempo y tiempo-frecuencia utilizando aprendizaje supervisado.

Con este trabajo se amplió el alcance de esta herramienta de *software* para uso médico incorporando diferentes tipos de análisis. La experimentación con una variedad de características y técnicas de aprendizaje automático es esencial para identificar las estrategias más efectivas en el diagnóstico de la epilepsia y mejorar la eficiencia de la herramienta. En esta investigación, se examinó el desempeño de clasificadores de aprendizaje supervisado al emplear características en el dominio de la frecuencia en señales EEG. Adicionalmente, se evaluó e incorporó técnicas de aprendizaje automático no supervisado a la herramienta.



### 4.1 Objetivo general

Mejorar la herramienta de software para el estudio de la epilepsia desarrollada en fases anteriores, incorporando el análisis de distintas señales bioeléctricas, características en el dominio de la frecuencia, y técnicas de aprendizaje automático no supervisado.

### 4.2 Objetivos específicos

- Evaluar señales bioeléctricas, adicionales a las electroencefalográficas, que sean relevantes en el estudio de la epilepsia, y adaptar la herramienta de software para el análisis de dichas señales.
- Explorar características en el dominio de la frecuencia de las señales bioeléctricas, y evaluar el rendimiento de los algoritmos desarrollados anteriormente usando dichas características.
- Evaluar algoritmos de aprendizaje no supervisado e incorporarlos a la herramienta de software.
- Generar anotaciones relevantes automáticamente y validar los resultados con especialistas de HUMANA.



El objetivo de este trabajo de graduación es expandir las capacidades de la herramienta de software desarrollada en 2020 y 2021 en la Universidad del Valle de Guatemala para el análisis de la epilepsia. El alcance de este proyecto engloba la evaluación del rendimiento de diversos clasificadores de aprendizaje automático supervisado en relación con las señales EEG, utilizando características en el dominio de la frecuencia. Además, se lleva a cabo un análisis exhaustivo de las características individuales y de sus combinaciones. Las categorías utilizadas en las pruebas incluyeron: sano, ictal, preictal e interictal.

Además de estas mejoras, se ha incorporado en la herramienta la capacidad de analizar señales de electrocardiograma (ECG), un aspecto que no había sido abordado en las fases previas del proyecto. El análisis de las señales ECG se llevó a cabo mediante la implementación de técnicas de aprendizaje automático no supervisado.

El proyecto enfrentó ciertas limitaciones, entre las que se destaca la incapacidad de llevar a cabo una validación exhaustiva de los resultados mediante la orientación y asesoramiento de profesionales médicos. Además, debido a restricciones de recursos y limitaciones de tiempo, no fue posible realizar pruebas con los datos de pacientes proporcionados por el hospital HUMANA.

Para dar continuidad a este proyecto, se sugiere una estrecha colaboración con HUMANA para llevar a cabo una validación más detallada de los resultados, comparando los casos reales anotados por su equipo de expertos. Asimismo, se recomienda la expansión de la herramienta para abarcar un conjunto más amplio de señales bioeléctricas de interés, como las provenientes del electromiograma (EMG).

Además de esto, se plantea la posibilidad de explorar características estadísticas en el dominio de la frecuencia de las señales EEG, lo que permitiría evaluar su rendimiento mediante un conjunto más variado de clasificadores. También sería beneficioso aplicar diversas técnicas de aprendizaje automático a las señales ECG, enriqueciendo así la funcionalidad de la herramienta y posiblemente descubriendo nuevos patrones y conocimientos relevantes.



## 6.1. Epilepsia

De acuerdo con la Organización Mundial de la Salud, la epilepsia se define como “una enfermedad cerebral crónica no transmisible que se caracteriza por convulsiones recurrentes, que son episodios breves de movimiento involuntario que pueden involucrar una parte del cuerpo (parcial) o todo el cuerpo (generalizado), y que en ocasiones se acompañan de pérdida de consciencia y control de la función intestinal o vesical”. Este tipo de convulsiones (crisis epilépticas) pueden originarse por diversas causas, que pueden ser estructurales, genéticas, infecciosas, metabólicas, inmunológicas, entre otras. No obstante, en aproximadamente el 50 % de los casos, las causas son desconocidas [1].

Es importante resaltar que no todas las personas que tienen convulsiones, padecen de epilepsia. Una persona puede tener convulsiones debido a causas físicas, por ejemplo enfermedades médicas agudas o traumas que comienza antes de la convulsión o bien pueden relacionarse con alguna sustancia o evento al que su cuerpo responde. En estos casos, las convulsiones se denominan “provocadas” y no se diagnostican como epilepsia. La epilepsia se define por dos o más convulsiones no provocadas [9].

### 6.1.1. Síndromes de epilepsia

Las características de las convulsiones varían y dependen de en qué parte del cerebro comienza la alteración y cómo se propaga [1]. Para describir los tipos de crisis epilépticas de una persona, los médicos y otros profesionales de la salud a menudo utilizan un grupo de características que generalmente ocurren juntas, llamadas síndromes [9]. Estas características pueden incluir problemas que el paciente presente (síntomas) y resultados que la persona médica encuentre mediante exámenes y pruebas de laboratorio (signos). Entre el conjunto de características que definen a la mayoría de síndromes de epilepsia se encuentran:

- El tipo y la causa de las convulsiones.
- La edad del paciente cuando las convulsiones comienzan.
- La parte del cerebro involucrada.
- Información genética del paciente.
- Patrones específicos encontrados en el electroencefalograma (EEG) durante y entre convulsiones.
- Hallazgos encontrados en imágenes cerebrales, por ejemplo, imágenes por resonancia magnética (MRI) o tomografías computarizadas (CT).
- Las perspectivas de recuperación o empeoramiento.

Cabe mencionar que la epilepsia es un trastorno del espectro, por lo que hay muchos tipos diferentes de convulsiones y de síndromes de epilepsia. Es importante tener conocimiento de que no necesariamente, todas las características mencionadas, describen a todos los síndromes de epilepsia [9].

### 6.1.2. Tipos de crisis epilépticas

Es de enorme importancia saber distinguir y clasificar los distintos tipos de crisis y encuadrarlos dentro de alguno de los síndromes epilépticos conocidos, ya que, muchas veces de ello dependerá un pronóstico acertado y el éxito del tratamiento [10].

La Liga Internacional contra la Epilepsia (ILAE) presenta una clasificación operacional revisada de los tipos de crisis epilépticas. Esta se observa en la Figura 4. Las principales categorías son: las crisis generalizadas, las crisis focales (también se conocidas como crisis parciales) y las de inicio desconocido. Entre las subcategorías de estos tipos de crisis se encuentran las motoras y no motoras, y específicamente para las crisis focales, está la subcategoría de crisis sin y con alteración del nivel de conciencia [11].

El que se produzcan un tipo u otro de crisis depende del grupo de neuronas que se activen. Durante las crisis generalizadas hay una activación conjunta de todas las neuronas de la superficie cerebral, mientras que durante las crisis focales solo se producen descargas anómalas mediante las neuronas de una zona limitada de la superficie cerebral [12].

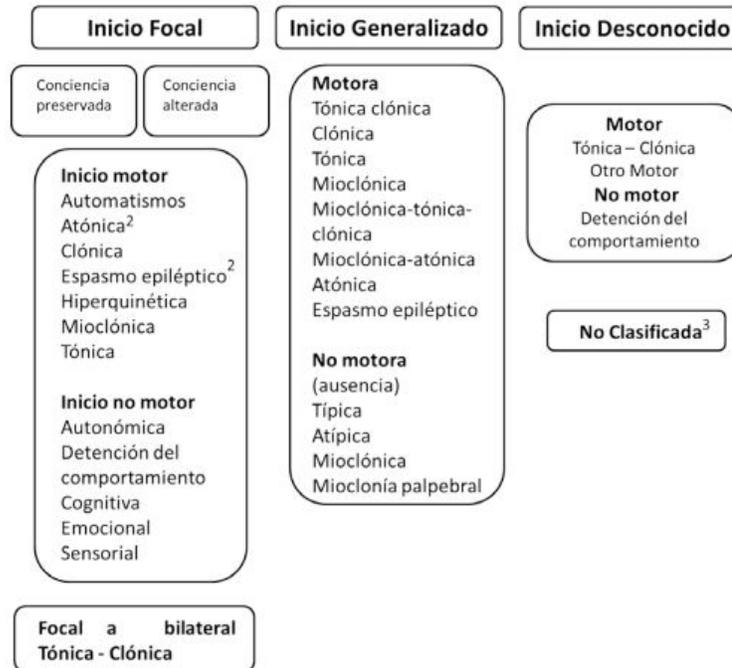


Figura 4: Clasificación operacional de los tipos de crisis, versión extendida ILAE 2017 [11].

### 6.1.3. Diagnóstico

El diagnóstico de epilepsia depende de una historia clínica detallada y precisa hasta en un 90 % [13]. Las pruebas complementarias como la video-electroencefalografía (V-EEG), la tomografía computarizada, las imágenes por resonancia magnética, entre otras, son de ayuda para el estudio y la confirmación ante la sospecha clínica. Esta información no solo permite realizar un diagnóstico adecuado, sino que también permite clasificar de una manera precisa y eficaz las crisis epilépticas, sin dejar de lado la importancia que reviste la semiología al momento de determinar la región cortical que está siendo estimulada y la que finalmente está involucrada en la generación de los síntomas [14]. Para llevar a cabo una valoración completa del paciente con epilepsia, es esencial determinar tanto la causa subyacente como la ubicación de esta actividad eléctricamente anormal. Este proceso requiere el empleo de herramientas diagnósticas, que pueden ser invasivas o no invasivas.

La V-EEG es una técnica en la que se realiza un electroencefalograma continuo con un equipo digital y una grabación simultánea y sincronizada de la conducta y la actividad motora mediante un circuito cerrado de televisión. Se utiliza en pacientes con sospecha de epilepsia, en desórdenes paroxísticos no epilépticos o para condiciones psiquiátricas, como los ataques de pánico, síndromes conversivos y crisis psicógenas [15].

El monitoreo prolongado permite la identificación de la actividad ictal (durante las crisis) e interictal (fuera de las crisis); además permite la correcta clasificación de las convulsiones y la correlación del comportamiento del paciente con los hallazgos electroencefalográficos. Durante los estudios de V-EEG, se utilizan electrodos de superficie no invasivos, pero se pueden incluir también electrodos seminvasivos, tales como los esfenoidales (alambre de

plata recubierto de teflón), colocados mediante anestesia local y que permiten un registro más cercano a los polos de los lóbulos temporales.

Entre otras herramientas que se utilizan para el diagnóstico de epilepsia se encuentran: la magnetoencefalografía (MEG), estudios de neuroimagen, tomografía por emisión de positrones, pruebas neuropsicológicas, en el siguiente artículo se puede encontrar más información al respecto [15].

#### 6.1.4. Tratamiento

Existen diferentes tipos de tratamientos para controlar la epilepsia. El más común es la medicación, en donde los doctores especialistas suelen recetar drogas antiepilépticas (AEDs) que funcionan cambiando el nivel de químicos en el cerebro para controlar y detener los ataques epilépticos [16]. El medicamento es prescrito según el tipo de convulsión, historial médico y edad de la persona. Si el medicamento no funciona, los especialistas pueden recetar combinación de diferentes AEDs. Entre las más comunes se encuentran:

- Valproato de sodio
- Carbamazepina
- Lamotrigina
- Levetiracetam
- Topiramato

La mayoría de las personas que tienen epilepsia responden bien a esta forma de tratamiento, no obstante, algunas personas son resistentes a las AEDs. Lo que significa que su epilepsia no se puede controlar usando las medicaciones prescritas. Entre el 33 % de los adultos y el 20-25 % de los niños con epilepsia no responden a la primera línea de tratamiento, por lo que se deben considerar opciones alternativas [16]. Entre ellas se encuentran:

- Cirugía: Esta opción generalmente funciona mejor para las personas que tienen convulsiones que se originan en una parte específica del cerebro. Se trata de eliminar de forma segura el punto focal, o la parte del cerebro donde comienzan las convulsiones.
- Cambios de dieta: Algunas dietas pueden ayudar a controlar las convulsiones. Las dietas recomendadas incluyen la dieta Atkins modificada, la dieta cetogénica y la dieta de bajo índice glucémico [17]. Estas dietas deben llevarse a cabo con el apoyo de un especialista.
- Estimulación del Nervio Vago (VNS): Esta terapia trata a las personas con convulsiones focales. Funciona enviando pulsos eléctricos a través del nervio vago que conduce al cerebro [18].

## 6.2. Señales bioeléctricas

El análisis de las señales bioeléctricas en el cuerpo humano es de gran importancia para el diagnóstico médico, el monitoreo de signos vitales durante ciertas actividades físicas, en aplicaciones biónicas, entre otras. Estas señales proporcionan información del funcionamiento de los órganos del cuerpo humano, que interpretadas por un especialista se convierten en una poderosa fuente de información del estado de salud de un individuo. Es esencial que estas señales se capturen mediante métodos no invasivos para evitar molestias o daños, simplificando así el proceso de adquisición. Este enfoque no solo conduce a sistemas más simples y económicos, sino que también los hace accesibles a un mayor número de personas [19]. Entre las señales bioeléctricas más populares, se encuentran: las captadas por electroencefalograma, electrocardiograma y electromiograma.

### 6.2.1. Electroencefalograma (EEG)

El electroencefalograma (EEG) consiste en el registro de la actividad eléctrica del cerebro, obtenido mediante electrodos colocados en el cuero cabelludo. Aunque las señales EEG son fundamentales en el estudio de diversas enfermedades, el volumen de datos generado puede dificultar su procesamiento. Este método resulta especialmente útil en el diagnóstico de la epilepsia, permitiendo la detección del momento en que se presenta la anomalía, su localización y la extensión de la alteración (focal, multifocal, regional o bilateral). Además, el EEG ofrece información sobre la reactividad a estímulos sensoriales, como la luz, y la respuesta a fármacos. También es capaz de revelar lentificaciones o aceleraciones de los ritmos cerebrales, permitiendo determinar si son transitorias o permanentes. La morfología de estos ritmos resulta igualmente útil para identificar el tipo específico de epilepsia [20].

### Ritmos cerebrales

Los patrones más frecuentes en las señales EEG para describir la actividad cerebral son los ritmos. Estos ritmos cerebrales cambian con la edad, con el estado de sueño o vigilia y con la presencia de patología [21]. Como se puede ver en la Figura 5, estos ritmos se pueden asociar a diferentes bandas de frecuencia, siendo éstas:

- Ondas  $\delta$  (0.5–4 Hz): Son las más lentas pero también las que tienen mayor amplitud. Son características de cuando el individuo está en el sueño profundo y en algunos procesos anormales. Es el ritmo dominante en los lactantes hasta el año de edad y está presente en las etapas 3 y 4 del sueño. [22]. La producción del ritmo Delta, coincide con la regeneración y restauración del Sistema Nervioso Central [23].
- Ondas  $\theta$  (4–8 Hz): Predominan cuando los sentidos están procesando información interna y el individuo se encuentra desconectado del mundo exterior. Las ondas theta son fuertes durante el enfoque interno como la meditación. El ritmo Theta refleja el estado entre la vigilia y el sueño y se relaciona con la mente subconsciente. Es anormal en adultos despiertos, pero es normal en niños de hasta 13 años. Cuando el ritmo Theta parece funcionar normalmente, media y/o promueve conductas adaptativas complejas como el aprendizaje y la memoria [22].

- Ondas  $\alpha$  (8–12 Hz): Predomina cuando el Sistema Nervioso Central se encuentra en reposo, relajado pero despierto y atento. Es el ritmo dominante en un electroencefalograma normal. Está presente durante la mayor parte de la vida, especialmente después de los trece años, cuando domina el ritmo de reposo. El ritmo Alpha es un estado común para el cerebro y ocurre siempre que una persona está alerta, pero no procesa información de forma activa, es decir, cuando la persona está tranquila pero consciente [22].
- Ondas  $\beta$  (12–30 Hz): Predomina durante el periodo de vigilia. Aparece en los estados en que la atención está dirigida a tareas cognitivas externas, al contrario de las ondas Theta, las cuales aparecían durante los estados cognitivos internos. La frecuencia de este ritmo es rápida, está presente cuando estamos atentos y envueltos en la resolución de tareas o problemas cotidianos, también durante la toma de decisiones o cuando estamos concentrados [23]. Es el estado en el que se encuentra la mayor parte del cerebro cuando tenemos los ojos abiertos y escuchamos, pensamos y procesamos la información sobre el mundo que nos rodea. La banda Beta tiene un rango relativamente grande y se ha dividido en bajo, medio y alto.
- Ondas  $\gamma$  (mayores a 30 Hz): Son las ondas más rápidas y se producen en ráfagas cortas. Se relacionan con el proceso de información simultánea en varias áreas del Sistema Nervioso Central. Es el único grupo de frecuencia que se encuentra en todas las partes del cerebro. Se observan ráfagas de ondas Gamma cuando el cerebro está en estado de alta resolución [23].

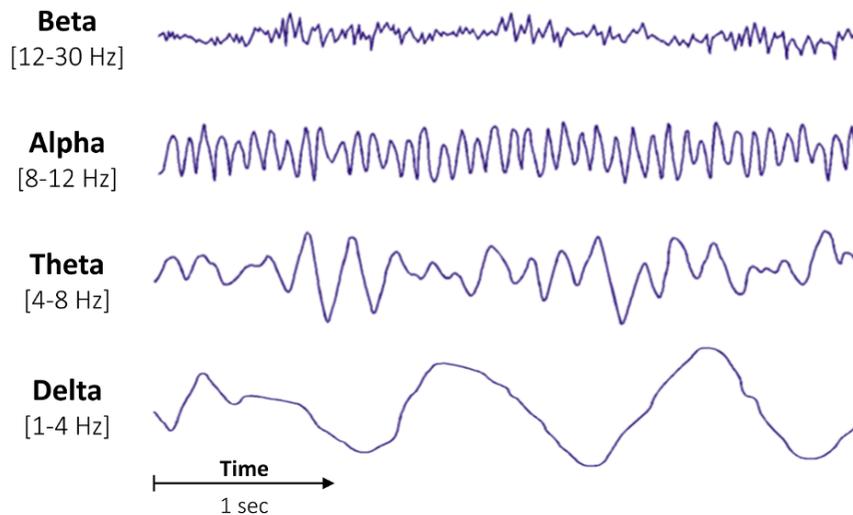


Figura 5: Ritmos cerebrales en una señal EEG [24].

## Características de un registro EEG

Existen múltiples parámetros que nos sirven para identificar o definir un tipo de señal. A estos parámetros se les conoce como características (features) y en el caso de las señales EEG, es común que se clasifiquen en los siguientes grupos:

- Características en dominio del tiempo
- Características en dominio de la frecuencia
- Características no lineales
- Dominio tiempo-escala y tiempo-frecuencia
- Características cepstrales

La selección de estas características es muy importante al momento de querer analizar y clasificar las señales en algún grupo. Para este trabajo, el enfoque será en las características obtenidas en el dominio de la frecuencia, ya que en las fases anteriores del proyecto [5] y [7] ya se exploró el análisis con señales EEG en dominio del tiempo y tiempo-frecuencia.

### Características en el dominio de la frecuencia

La densidad espectral de potencia (PSD) de la señal, que es la base para el cálculo de las características del dominio de la frecuencia, se puede calcular con varios métodos paramétricos y no paramétricos. Los métodos no paramétricos se usan con más frecuencia e incluyen métodos como la transformada de Fourier (generalmente calculada con el algoritmo de transformada rápida de Fourier, FFT), el método de Welch o el método multicono de Thompson [25].

Las características más simples de la señal EEG son características estadísticas, como la media, mediana, varianza, desviación estándar, asimetría, curtosis y similares. No obstante, las potencias relativas de ciertas bandas de frecuencia son las características de dominio de frecuencia más utilizadas en todos los campos de análisis de las señales de EEG [25]. Comúnmente, las bandas de frecuencia más utilizadas son la Delta, Theta, Alpha, Beta, y Gamma, aunque también existe la banda Sigma (12–14 Hz) que a veces se denomina husos de sueño. Las relaciones entre las bandas de frecuencia (ratios) se utilizan ampliamente como características en el análisis de señales de EEG, por ejemplo:

- $\theta/\alpha$
- $\beta/\alpha$
- $(\theta + \alpha)/\beta$
- $\theta/\beta$
- $(\theta + \alpha)/(\alpha + \beta)$
- $\gamma/\delta$
- $(\gamma + \beta)/(\delta + \alpha)$

Las medidas de relación de banda se interpretan normalmente como un reflejo de medidas cuantitativas de actividad periódica u oscilatoria. Esto asumiendo que la medida refleja potencias relativas de componentes periódicos distintos que están bien capturados por rangos de frecuencia predefinidos [26].

### 6.2.2. Electrocardiograma (ECG)

El electrocardiograma o ECG, consiste en la captación de las señales eléctricas originadas por la actividad de biopotenciales en el corazón. La señal captada presenta características diferentes en función del ángulo en que se coloquen los electrodos sobre el cuerpo [27]. Además es útil para detectar problemas cardiacos, como defectos del miocardio, agrandamiento del corazón, defectos congénitos, enfermedades de válvula cardíaca, arritmias, taquicardia o bradicardia, enfermedades de la arteria coronaria, cambios en la cantidad de electrolitos, etc. [28].

El instrumento que se utiliza para adquirir la señal cardiaca se denomina electrocardiógrafo. Los electrocardiógrafos comerciales normalmente adquieren una derivación a la vez. La presentación gráfica del ECG se realiza en una tira de papel con formato cuadrículado estándar, en la mayoría de los casos trazada con una velocidad de 25 milímetros por segundo (mm/s) y con una resolución de amplitud de 10 milímetros por milivoltios (mm/mV) [27].

### 6.2.3. Electromiograma (EMG)

La electromiografía es un procedimiento de diagnóstico utilizado para evaluar la salud de los músculos y las células nerviosas que los controlan, mejor conocidas como neuronas motoras. Los resultados de la electromiografía pueden revelar una disfunción nerviosa, una disfunción muscular o problemas con la transmisión de señales de nervios a músculos.

En la electromiografía se utilizan electrodos para traducir las señales eléctricas que las neuronas motoras transmiten para contraer los músculos, en gráficos, sonidos o valores numéricos que después interpreta un especialista. [28].

## 6.3. Aprendizaje automático

El aprendizaje automático (*machine learning*) es una rama de la inteligencia artificial (IA) que, mediante principios estadísticos e informáticos, permite que las máquinas aprendan por sí mismas a realizar una tarea, sin la necesidad de instrucciones explícitas para resolverla. Con el aprendizaje automático, las máquinas desarrollan algoritmos capaces de hacer ajustes y mejorar su rendimiento a través de la inferencia de datos, identificación e interpretación de patrones [3]. Hay más de una manera en que podemos hacer de esta idea una realidad, pero principalmente se reconocen en tres categorías. Estas categorías son aprendizaje supervisado, aprendizaje no supervisado y aprendizaje por refuerzo.

### 6.3.1. Aprendizaje supervisado

El aprendizaje automático más conocido es el aprendizaje automático supervisado. En este tipo de aprendizaje, se alimenta al algoritmo con iteraciones de datos, lo que permite que los ordenadores interpreten la tarea deseada sin necesidad de programar la tarea de manera explícita. Existen dos tipos principales de aprendizaje supervisado: clasificación y

regresión. La clasificación es el lugar donde se entrena a un algoritmo para clasificar los datos de entrada en variables discretas. Durante el entrenamiento, los algoritmos reciben datos de entrada con una etiqueta de clasificación [29].

La regresión es un método de aprendizaje supervisado en el que se entrena a un algoritmo para predecir una salida a partir de un rango continuo de valores posibles. En la regresión, un algoritmo necesita identificar una relación funcional entre los parámetros de entrada y salida. A diferencia de la clasificación, el valor de salida no es discreto, sino que es una función de los parámetros de entrada. La exactitud de un algoritmo de regresión se calcula en función de la desviación entre la salida precisa y la salida prevista [29].

## Entrenamiento del algoritmo

Para entrenar a los algoritmos de ML, es importante separar la data en los siguientes conjuntos:

- Conjunto de datos de entrenamiento: Es la muestra de datos utilizada para ajustar el modelo; en otras palabras es el conjunto de datos real que usamos para entrenar el modelo.
- Conjunto de datos de validación: Corresponde a la muestra de datos utilizada para proporcionar una evaluación imparcial del ajuste de un modelo en el conjunto de datos de entrenamiento mientras se ajustan los hiperparámetros del modelo. La evaluación se vuelve más sesgada a medida que la habilidad en el conjunto de datos de validación se incorpora a la configuración del modelo [30].
- Conjunto de datos de prueba: La muestra de datos utilizada para proporcionar una evaluación imparcial de un ajuste de modelo final en el conjunto de datos de entrenamiento.

## Redes neuronales (RNA)

Las redes neuronales (*neural network*) reflejan el comportamiento del cerebro humano, lo que permite que los programas informáticos reconozcan patrones y resuelvan problemas comunes en los campos de la IA, el aprendizaje automático y el aprendizaje profundo [31]. Son una forma de modelar matemáticamente un neurón biológico. Su arquitectura, está inspirada en el cerebro humano y en su estructura ampliamente paralela, cuentan con capacidad de adquirir, almacenar y utilizar conocimiento experimental, generalizando su conocimiento a partir de ejemplos anteriores.

Una red neuronal combina diversas capas de procesamiento y utiliza elementos simples que operan en paralelo. Consta de una capa de entrada, una o varias capas ocultas y una capa de salida. Las capas están interconectadas mediante nodos, o neuronas; cada capa utiliza la salida de la capa anterior como entrada. [32] La siguiente figura muestra de forma visual la arquitectura típica de una red neuronal:

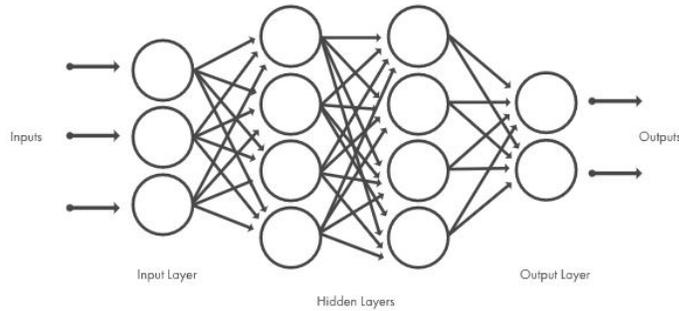


Figura 6: Arquitectura típica de una red neuronal [32].

Con herramientas y funciones para administrar grandes conjuntos de datos, MATLAB ofrece toolboxes especializadas para trabajar con machine learning, tales como la *Deep Learning Toolbox* y la *Parallel Computing Toolbox*.

### Máquina de vectores de soporte (SVM)

La máquina de vectores de soporte (*support vector machine* - SVM), es un algoritmo de aprendizaje supervisado que se utiliza en muchos problemas de clasificación y regresión, incluidas aplicaciones médicas de procesamiento de señales, procesamiento del lenguaje natural y reconocimiento de imágenes y voz [33].

El objetivo de este algoritmo es encontrar un hiperplano que separe de la mejor forma posible dos clases diferentes de puntos de datos [34]. Esto implica el hiperplano con el margen más amplio entre las dos clases, representado por los signos  $+$  y  $-$  en la Figura 7. El margen se define como la anchura máxima de la región paralela al hiperplano que no tiene puntos de datos interiores. El algoritmo solo puede encontrar este hiperplano en problemas que permiten separación lineal; en la mayoría de los problemas prácticos, el algoritmo maximiza el margen flexible permitiendo un pequeño número de clasificaciones erróneas.

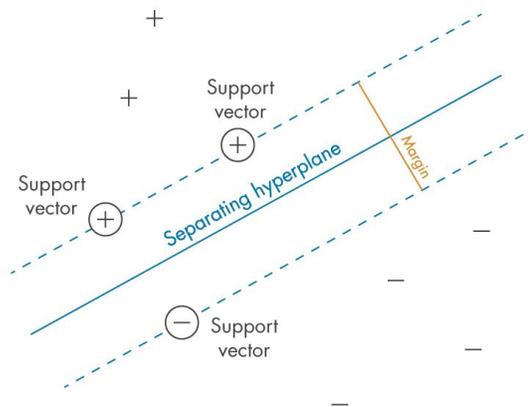


Figura 7: Definición del “margen” entre clases: el criterio que los SVM intentan optimizar [34].

### 6.3.2. Aprendizaje no supervisado

Los algoritmos de aprendizaje no supervisado deducen patrones de conjuntos de datos sin tener como referencia resultados previamente etiquetados o conocidos. A diferencia del aprendizaje supervisado, este método no se puede aplicar directamente a un problema de clasificación o regresión de datos, ya que no se tiene conocimiento de cuáles pueden ser los valores de salida. Esto hace que sea imposible entrenar al algoritmo de la forma usual. El aprendizaje no supervisado se utiliza para descubrir la estructura subyacente de los datos [35].

Como los datos que se introducen en los algoritmos de aprendizaje no supervisados no están etiquetados, el algoritmo intenta dar sentido a los datos por sí mismos, mediante la búsqueda de características y patrones. Este método de aprendizaje automático utiliza el agrupamiento (*clustering*), los componentes principales, las redes neuronales y las máquinas de vectores de soporte [29].

#### K-means Clustering

El objetivo de este algoritmo es agrupar datos, con la cantidad de grupos representados por la variable  $K$ . El algoritmo funciona de forma iterativa para asignar cada punto de datos a uno de los  $K$  grupos en función de las características proporcionadas. Los puntos de datos se agrupan según la similitud de características entre ellos. Los resultados de este algoritmo de agrupamiento son:

- Los centroides de los grupos  $K$ , que se pueden usar para etiquetar nuevos datos.
- Las etiquetas para los datos de entrenamiento (cada punto de datos se asigna a un solo grupo).

Con el K-means clustering, la agrupación permite encontrar y analizar grupos que se han formado orgánicamente, es decir, que los grupos no se asignan antes de ver los datos. Cada centroide de una agrupación, es una colección de valores de características que definen los grupos resultantes. Examinar los pesos de las características del centroide puede ser útil para interpretar cualitativamente la representación de cada grupo.

### 6.3.3. Aprendizaje por refuerzo

El aprendizaje por refuerzo es un modelo de aprendizaje conductual. Se trata de una forma de optimización basada en datos, en donde la máquina aprende de su propia experiencia, interactuando con el entorno. En el aprendizaje por refuerzo, el algoritmo recibe retroalimentación del análisis de datos, conduciendo al usuario hacia el resultado óptimo. El aprendizaje por refuerzo difiere de otros tipos de aprendizaje supervisado, porque el sistema no está entrenado con el conjunto de datos de ejemplo. Más bien, el sistema aprende a través de la prueba y el error [35].



---

## Experimentación con aprendizaje automático supervisado

---

Este capítulo contempla el diseño, implementación y evaluación de algoritmos de aprendizaje automático supervisado para el análisis y reconocimiento de patrones en señales EEG. Se detalla la metodología empleada y los resultados obtenidos utilizando dos clasificadores.

### 7.1. Bases de datos señales EEG

Para explorar y evaluar el rendimiento de los algoritmos desarrollados anteriormente pero con características en el dominio de la frecuencia se requirió de conjuntos de datos etiquetados de señales EEG de pacientes con epilepsia. Se utilizaron los registros de dos bases de datos diferentes, los cuales se encuentran disponibles en el repositorio de Github de este proyecto, disponible en la sección [13.1](#). A continuación se muestra una descripción de cada base de datos utilizada.

#### 7.1.1. Ubonn EEG *Dataset*

Esta base de datos es propiedad de la Universidad de Bonn, en Alemania y consta de cinco conjuntos de datos denotados con letras desde la A hasta la E correspondientes a señales EEG. Las letras A y B corresponden a registros de pacientes sanos, la C y D corresponden a registros de pacientes con epilepsia pero en un intervalo normal, es decir, libres de crisis epilépticas y la letra E se utiliza para registros ictales, es decir, mientras los pacientes experimentan una crisis epiléptica.

Cada conjunto de datos es de un solo canal y tiene una duración de 23.6 segundos con una frecuencia de muestreo ( $F_s$ ) de 173.61 Hz. Los registros de esta base de datos utilizados en este trabajo fueron: “SetA\_Sano\_UBonn.mat” y “SetE\_Ictal\_UBonn.mat”.

### 7.1.2. Kaggle American Epilepsy Society Seizure Prediction Challenge

La base de datos utilizada corresponde al concurso “*American Epilepsy Society Seizure Prediction Challenge*” [36] lanzado por Kaggle, el cual consistió en emplear técnicas de aprendizaje automático para predecir episodios de crisis epilépticas. Cada conjunto de datos presentado en el concurso está en formato .mat y corresponden a registros interictales y preictales de un paciente.

Al igual que en la fase anterior del proyecto [7], se utilizó registros comprendidos entre 30 y 40 minutos previo al episodio, ya que estudios [37] determinaron que el tiempo óptimo de predicción se encuentra al rededor de 33.7 minutos. Las señales están compuestas por 15 canales, con una frecuencia de muestreo de 5000 Hz y una duración de 600 segundos. Los registros utilizados de esta base de datos para el presente trabajo fueron: “Interictal\_EEG\_Data.mat” y “Perictal16\_EEG\_Data.mat”.

## 7.2. Filtrado de la señales

En la fase anterior del proyecto [7] se determinó que el filtro idóneo para procesar este tipo de señal era un filtro pasabandas. El cual estaba compuesto por un filtro Butterworth pasa bajas y otro pasa altas, ambos de segundo orden. Las frecuencias de corte para estos filtros fueron de 0.5 Hz y 85 Hz respectivamente.

## 7.3. Selección de características

En [25] y otros estudios [38] [39], se hizo una revisión de múltiples características utilizadas para analizar señales EEG en los diferentes dominios. Se encontró que para el dominio de la frecuencia, las características más utilizadas en todos los campos de análisis de las señales de EEG, son las potencias relativas relacionadas a ciertas bandas de frecuencia. Es por ello que se decidió explorar con las siguientes razones entre bandas como características:

- razón 1 =  $\theta/\alpha$
- razón 2 =  $\beta/\alpha$
- razón 3 =  $(\theta + \alpha)/\beta$
- razón 4 =  $\theta/\beta$
- razón 5 =  $(\theta + \alpha)/(\alpha + \beta)$
- desviación estándar (std).

Cabe mencionar que características estadísticas como la media, mediana, varianza, desviación estándar, asimetría, curtosis y similares también se utilizan en el dominio de la frecuencia.

### 7.3.1. Pruebas de rendimiento en la extracción de características

Se experimentó con diferentes combinaciones de características, con el objetivo de explorar cuáles de ellas eran las óptimas para las señales EEG en el dominio de la frecuencia. Las características fueron extraídas de los registros de las clases Sano/Ictal obtenidos de la base de datos de Ubonn y posteriormente de los registros Interictal/Preictal del concurso de Kaggle.

A continuación se muestra un cuadro con la comparación del rendimiento de la computadora al crear los vectores de características para una clase:

Cantidad de características	Promedio de tiempo de extracción de características por registro	
	Ubonn - Sano/Ictal	Kaggle - Interictal/Preictal
1	3.07 min	4.33 min
2	6.13 min	9.08 min
3	8.32 min	15.58 min
4	13.86 min	20.20 min
5	14.92 min	26.86 min
6	15.80 min	26.78 min

Figura 8: Comparación del tiempo de extracción de características por 1 registro.

La diferencia de tiempos entre los diferentes pares de clases (Figura 8), puede deberse a la cantidad de muestras que contenía cada registro. Los datos de Ubonn contienen 409,700 muestras por clase y los datos de Kaggle contienen 3 millones de muestras por clase. Otra posibilidad en el cambio de rendimiento podría ser ocasionada por procesos internos de la computadora. En la Figura 8 también se observa que entre más características se extraigan, el tiempo que toma la creación del vector de características aumenta considerablemente.

## 7.4. Entrenamiento de clasificador

Al tener los distintos vectores de características, se procedió a entrenar el clasificador de redes neuronales (RNA). Esto con el fin de evaluar si las características eran las adecuadas para clasificar dos, tres y cuatro clases. Posteriormente se buscaba comparar el porcentaje de exactitud del clasificador al variar el número de características utilizado y sus diferentes combinaciones.

### 7.4.1. Redes neuronales (RNA)

Para los algoritmos de redes neuronales, se utilizó una función de gradiente conjugado con 10 capas ocultas y una distribución del 70% de los datos para el conjunto de entrenamiento, 15% para el conjunto de validación y 15% para el conjunto de prueba empleando la

herramienta Neural Net Pattern Recognition de la Deep Learning Toolbox 14.0 de MATLAB R2021a.

Se realizó el entrenamiento para una clasificación binaria, primero de las clases Ictal/Sano y después de las clases Interictal/Preictal. Inicialmente se hicieron pruebas con los vectores de características generados en el apartado [7.3.1](#), utilizando desde una hasta seis características en dominio de la frecuencia.

Algunas de las matrices de confusión obtenidas, se muestran en las Figuras [9](#), [10](#) y [11](#) para las clases Ictal/Sano y en las Figuras [12](#), [13](#) y [14](#) para las clases Interictal/Preictal.

En la sección [13.2](#) y [13.3](#), se pueden encontrar el resto de matrices de confusión para ambos clasificadores, con las distintas pruebas al variar la cantidad de características utilizadas.

### Matrices de confusión para los clasificadores binarios con RNA

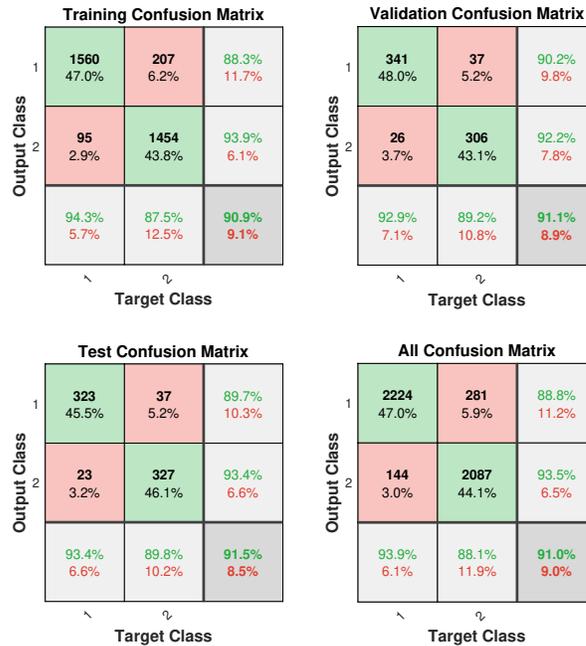


Figura 9: Matriz de confusión Ictal (1) y Sano (2) con RNA, utilizando la razón 1 como característica en dominio de la frecuencia.



Figura 10: Matriz de confusión para las clases Ictal (1) y Sano (2) con RNA, utilizando las razones 1, 2 y 3 como características en dominio de la frecuencia.



Figura 11: Matriz de confusión para las clases Ictal (1) y Sano (2) utilizando RNA, con el total de características mencionadas anteriormente (6).

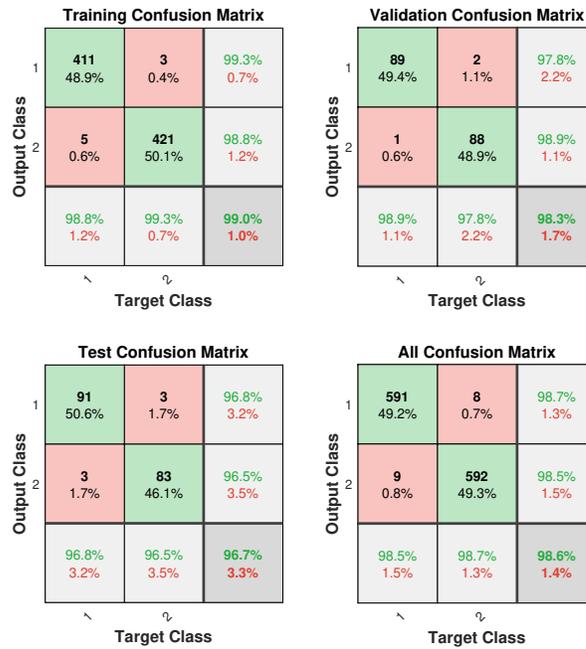


Figura 12: Matriz de confusión Interictal (1) y Preictal (2) con RNA, utilizando la razón 1 como característica en dominio de la frecuencia.

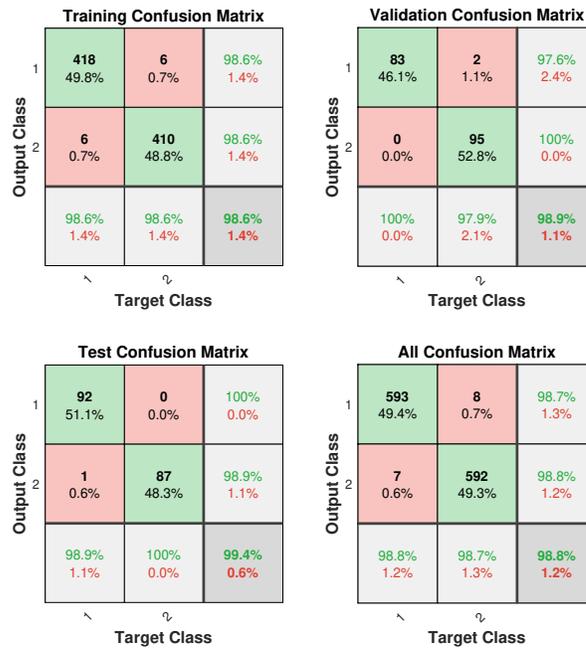


Figura 13: Matriz de confusión para las clases Interictal (1) y Preictal (2) con RNA, utilizando las razones 1, 2 y 3 como características en dominio de la frecuencia.

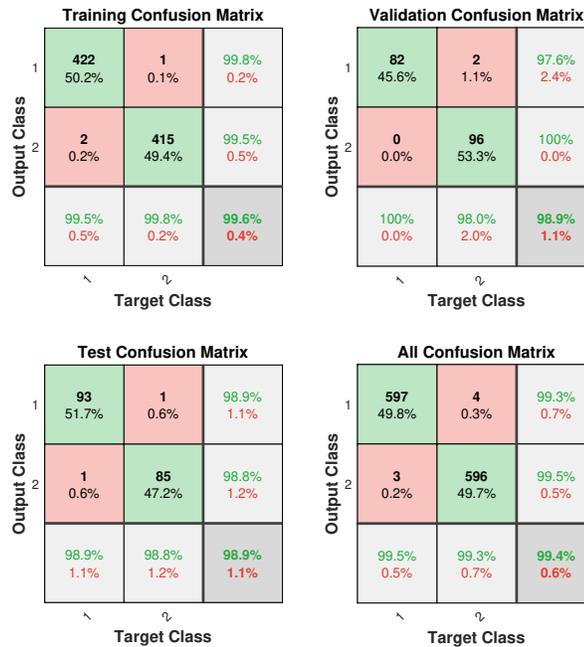


Figura 14: Matriz de confusión para las clases Interictal (1) y Preictal (2) utilizando RNA, con el total de características mencionadas anteriormente (6).

Al tener clasificaciones satisfactorias, como se observa en la Figura 15, utilizando desde una hasta seis características, se decidió hacer otro experimento. Este consistió en probar el rendimiento de la computadora al extraer cada característica individualmente y posterior a eso evaluar la exactitud de la red neuronal. Todo esto se realizó con el objetivo de determinar si las características individuales eran lo suficientemente buenas para generar resultados satisfactorios a un menor costo computacional, e identificar las más precisas según el tipo de clases. En La Figura 16, se observa un resumen del rendimiento y la exactitud del clasificador para cada tipo de característica. En la sección 13.4 y 13.5 de Anexos se encuentra el resto de matrices de confusión del clasificador por cada característica individualmente.

## Resumen de los resultados del clasificador

Cantidad de características	Características utilizadas (razones)	Exactitud RNA	
		Ubonn - Sano/Ictal	Kaggle - Interictal/Preictal
1	1	91.55%	90.50%
2	1, 2	100%	98.90%
3	1, 2, 3	99.99%	98.80%
4	1, 2, 3, 4	99.99%	98.80%
5	1, 2, 3, 4, 5	99.99%	98.80%
6	1, 2, 3, 4, 5, std	100%	99.40%

Figura 15: Resumen del rendimiento de la RNA para dos clases variando la cantidad de características utilizadas en el dominio de la frecuencia.

Como se observa en la Figura 15, los resultados de clasificación para los dos pares de clases fueron muy similares al utilizar dos o más características. El nivel de exactitud para el clasificador Ictal/Sano, se encuentra sobre el 99.99 % en estos casos y el clasificador Interictal/Preictal tuvo una exactitud superior al 98.80 % de igual manera.

De los resultados obtenidos, se observa que al entrenar el clasificador utilizando únicamente dos características en dominio de la frecuencia, se obtienen resultados muy similares que al utilizar tres o más. Entonces, se puede decir que, computacionalmente hablando, es recomendable utilizar un menor número de características en el dominio de la frecuencia para clasificar las dos clases, ya que se invierte menos tiempo y tenemos una exactitud bastante certera en la clasificación.

Extracción de características en dominio de la frecuencia				
Característica	Ubonn - Sano/Ictal		Kaggle - Interictal/Preictal	
	Porcentaje de rendimiento RNA	Tiempo	Porcentaje de rendimiento RNA	Tiempo
razón 1	91.00%	3.10 min	98.60%	4.52 min
razón 2	91.10%	3.08 min	84.20%	4.46 min
razón 3	77.00%	4.60 min	98.50%	6.76 min
razón 4	99.70%	2.88 min	96.10%	4.50 min
razón 5	90.90%	4.60 min	98.30%	6.16 min
std	99.60%	11.00 s	67.40%	9.73 s

Figura 16: Resumen del rendimiento de la RNA para dos clasificadores binarios utilizando características individuales en dominio de la frecuencia.

Al momento de experimentar con las características individuales Figura 16, también se obtuvo resultados satisfactorios. El porcentaje de exactitud en el clasificador Ictal/Sano fue superior al 90 % para cinco de las seis características seleccionadas, (a excepción de la razón 3). Y en el clasificador Interictal/Preictal la exactitud fue superior al 96 % para la mayoría de las características.

Adicional a la clasificación binaria, se hicieron pruebas con tres y cuatro clases (ictal, sano, preictal e interictal) y se obtuvo los resultados mostrados en la Figura 17

Resumen de resultados RNA, EEG		
Características	No. de clases	Exactitud
en Dominio de Frecuencia	2	99.40%
	3	99.90%
	4	98.90%

Figura 17: Resumen de los resultados de la RNA para dos, tres y cuatro clases utilizando características en dominio de la frecuencia.

Como se observa en la Figura 17, la exactitud de clasificación utilizando características en dominio de la frecuencia, es bastante precisa y es mayor que la que se obtuvo en la fase anterior del proyecto como se observa en la Figura 3. No obstante, se debe tomar en cuenta que el entrenamiento del algoritmo utilizando características en dominio de la frecuencia, es considerablemente mas tardado que utilizando características en dominio del tiempo o características de Wavelet.

## 7.5. Base de datos señales ECG

Luego de experimentar con las señales de EEG en dominio de la frecuencia, se procedió a utilizar el clasificador de redes neuronales para identificar crisis en señales ECG. La metodología implementada es similar a lo descrito anteriormente en este capítulo, pero cambiando el tipo de señal y las características utilizadas.

### 7.5.1. ECG PhysioNet

La base de datos utilizada se llama “*Post-Ictal Heart Rate Oscillations in Partial Epilepsy*” disponible en el portal PhysioNet [40]. Contiene registros de ECG anotados los cuales corresponden a oscilaciones de la frecuencia cardíaca postictal en un grupo heterogéneo de pacientes con epilepsia parcial.

La data utilizada, se caracteriza por la aparición de oscilaciones de frecuencia cardíaca de baja frecuencia transitorias de entre 0,01 Hz a 0,1 Hz inmediatamente después de cinco de las once convulsiones registradas en cinco pacientes.

## 7.6. Selección de características

Según el artículo “*Detection of epileptic seizures with a modified heart rate variability algorithm based on Lorenz plot*” [41], se utiliza el método diferencial de frecuencia cardiaca para evaluar si las crisis epilépticas focales pueden detectarse y distinguirse. El método más

simple para evaluar el comportamiento no lineal de señales fisiológicas es conocido como diagrama de Poincaré o Lorenz. Se utilizó este método para obtener las características de las señales ECG, en donde las fluctuaciones del ritmo cardiaco son representadas gráficamente.

Las características que se utilizaron fueron:

- SD1, que corresponde a la variación de latido a latido.
- SD2, que corresponde a las fluctuaciones generales.
- Desviación estándar (std).

## 7.7. Entrenamiento del clasificador

Al entrenar el clasificador de redes neuronales, se obtuvo la siguiente matriz de confusión:

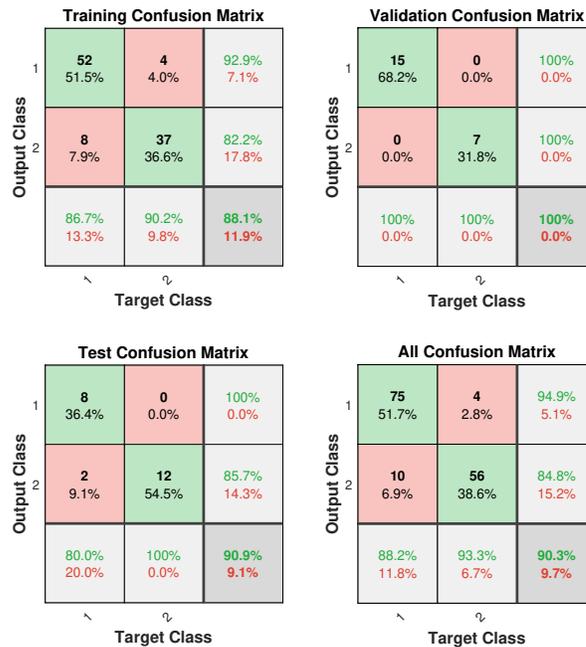


Figura 18: Matriz de confusión entre dos clases utilizando el método de Lorenz

En donde se observa que utilizando el diagrama de Poincaré para diferenciar entre dos clases (persona en reposo o persona haciendo ejercicio) es bastante preciso, teniendo una exactitud de 90.3%.

---

## Experimentación con aprendizaje automático no supervisado

---

Este capítulo contempla el diseño, implementación y evaluación de algoritmos de aprendizaje automático no supervisado para el análisis y reconocimiento de patrones en señales EEG. Se detalla la metodología empleada y los resultados obtenidos utilizando el algoritmo k-means clustering y clustering jerárquico.

### 8.1. K-means Clustering

K-means es un algoritmo de aprendizaje automático utilizado para la agrupación de datos en  $k$  grupos distintos. Funciona iterando a través de los datos y asignando cada punto de datos a uno de los  $k$  grupos basándose en la cercanía del punto a los centros de cada grupo. Una vez que se han asignado todos los puntos de datos a un grupo, se recalculan los centros de cada grupo como la media de los puntos de datos asignados a ese grupo. Este proceso se repite hasta que los centros de los grupos no cambien significativamente o se alcance un límite en el número de iteraciones.

Para utilizar el algoritmo k-means, primero se especifica el número de grupos  $k$  que se desea encontrar en los datos. Luego, se inicializan los centros de cada grupo de forma aleatoria utilizando  $k$  puntos de datos seleccionados al azar del conjunto de datos. A continuación, se iteran a través de los datos y se asignan a cada punto de datos al grupo cuyo centro esté más cerca. Una vez que se han asignado todos los puntos de datos a un grupo, se recalculan los centros de cada grupo como la media de los puntos de datos asignados a ese grupo. Este proceso se repite hasta que los centros de los grupos no cambien significativamente o se alcance un límite en el número de iteraciones.

Para utilizar el algoritmo K-means se especificó el número de grupos  $K$ , que se deseaba encontrar. Se experimentó variando la cantidad de grupos, siendo estos 2, 3 y 4.

## Experimentos

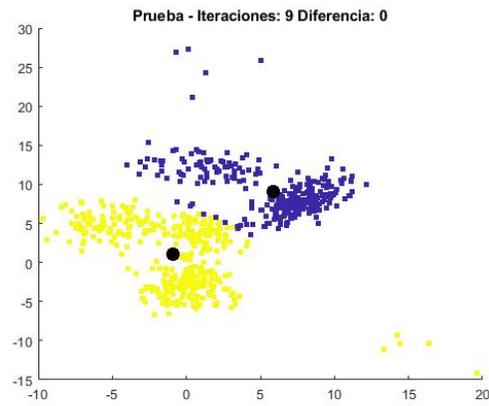


Figura 19: Experimento k-means con 2 grupos

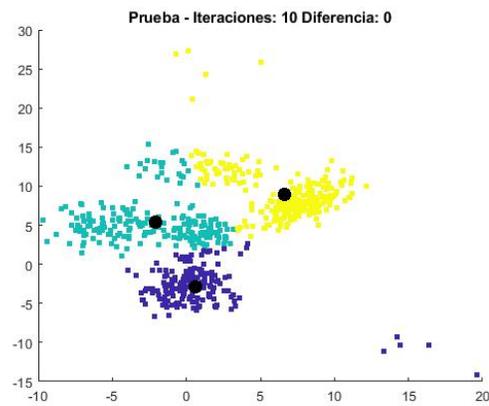


Figura 20: Experimento k-means con 3 grupos

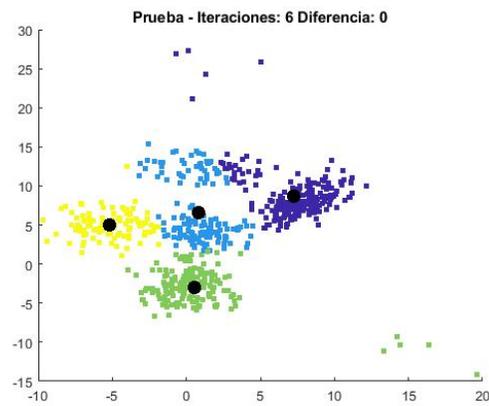


Figura 21: Experimento k-means con 4 grupos

## 8.2. Clustering Jerárquico

El agrupamiento jerárquico es un método de agrupamiento de datos en aprendizaje automático no supervisado que busca construir una jerarquía de clusters. Cada cluster es un conjunto de datos que son similares entre sí según alguna medida de similitud. El proceso comienza asignando cada dato a su propio cluster, y luego combina iterativamente los clusters más similares hasta obtener una jerarquía completa.

En otras palabras este tipo de agrupamiento permite agrupar los datos en diferentes niveles, creando un árbol o dendrograma de clusters. En lugar de un único conjunto de clusters, se crea una jerarquía de múltiples niveles en la que los clusters de un nivel se combinan con otros clusters en el siguiente nivel. Esto permite elegir el nivel o escala de agrupamiento más adecuada según la aplicación.

Para este proyecto se utilizó la Statistics and Machine Learning Toolbox de MATLAB utilizando la función *clusterdata*.

### 8.2.1. Rand Index

Para validar los resultados de clasificación del clustering jerárquico, se utilizó el método Rand Index.

El Rand Index es una medida de similitud utilizada para comparar dos conjuntos de datos etiquetados o clasificados. Se utiliza a menudo en el análisis de clusters, que es una técnica utilizada para agrupar conjuntos de datos en grupos basados en características similares.

Este método mide la proporción de pares de elementos que están clasificados de manera similar tanto en el conjunto de datos original como en el conjunto de datos clasificado. Se calcula como la suma de la proporción de pares de elementos que están clasificados de manera similar tanto en el conjunto de datos original como en el conjunto de datos clasificado y la proporción de pares de elementos que están clasificados de manera diferente tanto en el conjunto de datos original como en el conjunto de datos clasificado, dividida por dos 22

$$RI = \frac{a + b}{\binom{n}{2}} = \frac{\text{correct similar pairs} + \text{correct dissimilar pairs}}{\text{total possible pairs}}$$

Figura 22: Rand Index

El Rand Index se expresa como un número entre 0 y 1, donde un valor de 1 indica una clasificación perfecta y un valor de 0 indica una clasificación completamente aleatoria. El Rand Index es una medida de similitud no ponderada y no tiene en cuenta el orden de los elementos en los conjuntos de datos.

Es importante tener en cuenta que el Rand Index no es una medida de precisión absoluta y puede ser afectado por el tamaño y la distribución de los conjuntos de datos. Por lo tanto,

es necesario evaluar el Rand Index junto con otras medidas de rendimiento para obtener una evaluación más precisa del rendimiento de un modelo de clasificación.

### 8.2.2. Resumen de resultados Clustering Jerárquico

Utilizando el Rand Index como método de verificación, se obtuvieron los siguientes resultados:

<b>Clustering Jerárquico</b>	
<b>No. de clases</b>	<b>Exactitud</b>
2	98.08%
3	82.25%
4	76.20%
Promedio	85.51%
Desv. Estándar	11.30%

Figura 23: Resumen de resultados clústering jerárquico con Rand Index

---

## Herramienta de software

---

En este capítulo se muestran las secciones disponibles en la herramienta de software y un resumen de los pasos que el usuario debe seguir para utilizarla, haciendo énfasis en las secciones de interés para este trabajo.

Primero, en el apartado de anotaciones automáticas, se observa una ventana en donde el usuario puede iniciar sesión.



Figura 24: Login

Al introducir los datos de inicio de sesión, se libera el apartado para crear algoritmo. En esta sección se podrán ingresar las señales que el usuario desee y seleccionar el tipo de clasificación que desea realizar.

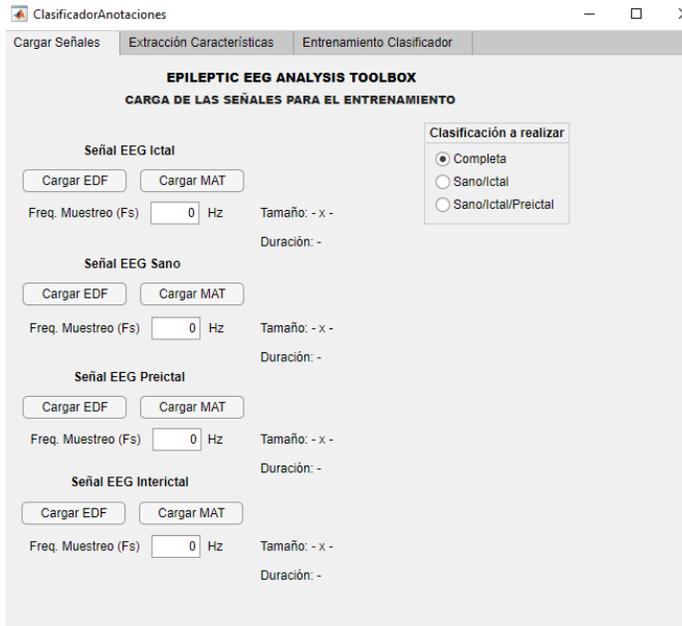


Figura 25: Cargar señales

Posteriormente, en la pestaña de extracción de características se puede seleccionar el dominio utilizado, los canales que se desean analizar y las características específicas según el dominio seleccionado.

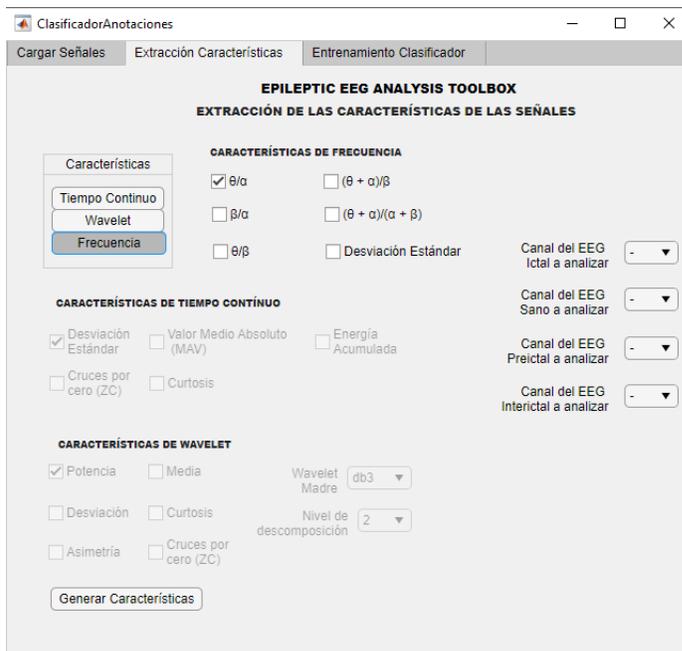


Figura 26: Extracción de características

Luego se procede a la pestaña de entrenar el clasificador en donde se encuentra disponible una opción para guardarlo.

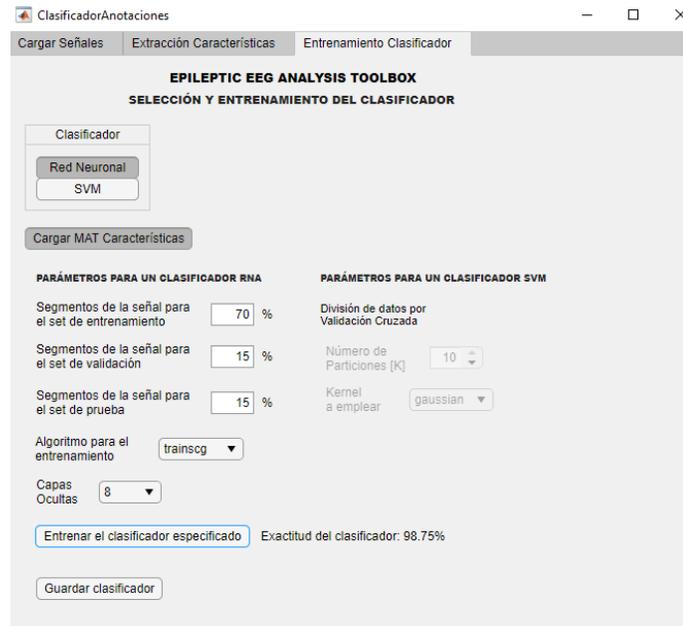


Figura 27: Entrenamiento del clasificador

Posteriormente, regresamos a la pestaña principal y en la sección de anotaciones automáticas, Figura 29, se procede a cargar la señal que se desea analizar. En esta sección también se puede seleccionar los canales que el usuario desea procesar para luego proceder a las anotaciones automáticas.

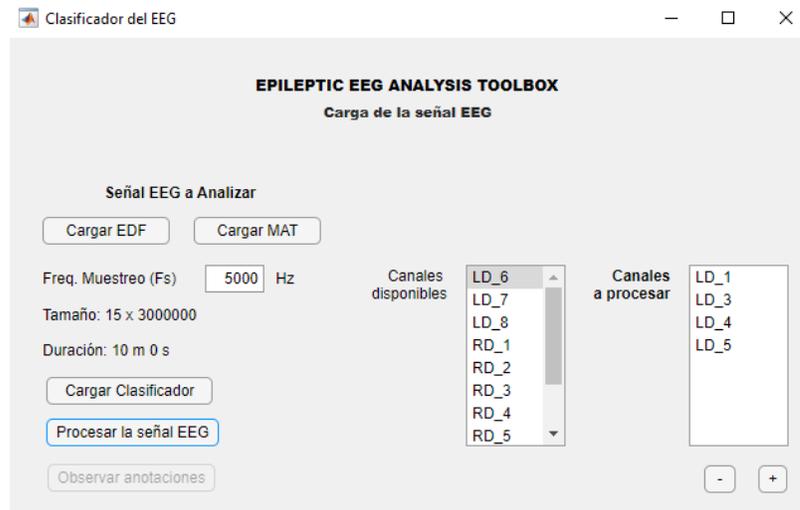


Figura 28: Cargar señal y clasificador para observar anotaciones.

Finalmente en esta sección se pueden visualizar las señales ya anotadas, dependiendo del color que el usuario seleccione y las clases que el algoritmo detecte.

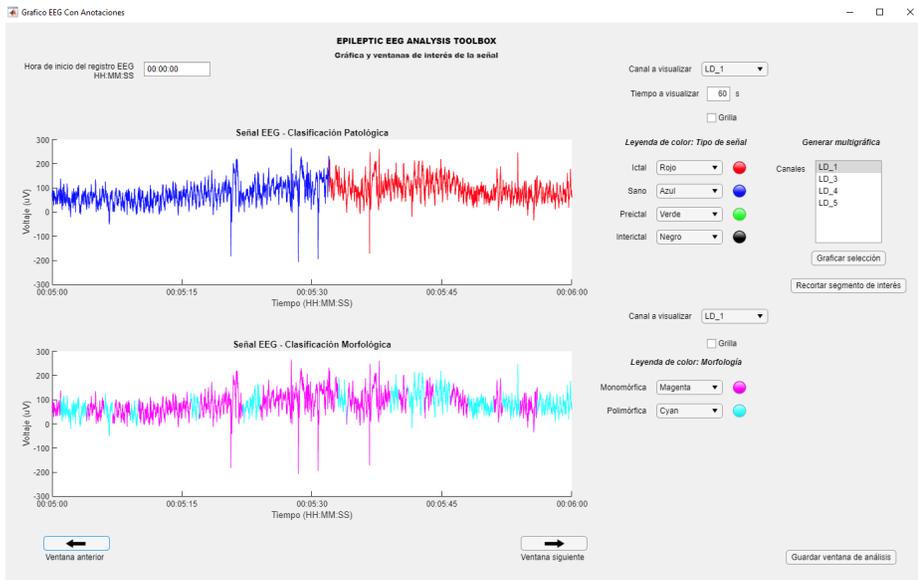


Figura 29: Observar anotaciones

- El clasificador con mayor desempeño para señales EEG, fueron las redes neuronales con un promedio de exactitud del 99.60 % y 0.61 % de desviación estándar.
- La extracción de características en dominio de la frecuencia no es muy eficiente comparándola con la extracción de características de Wavelet o en dominio del tiempo, no obstante, tienen una mejor precisión en el clasificador de RNA.
- Se desarrolló una nueva sección en la herramienta de software, la cual incluye el entrenamiento de un algoritmo de aprendizaje automático para el análisis de señales ECG, obteniendo un 90.3 % de exactitud en la clasificación binaria, mediante el análisis no lineal (Poincaré) para la extracción de características.
- Es conveniente que el vector de características se genere combinando la razón 1 ( $\theta/\alpha$ ) y la razón 2 ( $\beta/\alpha$ ), dado que los clasificadores tienen un rendimiento igual o mayor a 98.90 % en un menor tiempo.
- Los algoritmos de aprendizaje automático no supervisado evaluados, son considerablemente más rápidos que los de aprendizaje supervisado, no obstante, la exactitud de la clasificación se ve comprometida dependiendo del número de clases.



- Se recomienda evaluar más combinaciones de features en los diferentes dominios con el fin de encontrar la combinación óptima, considerando la carga computacional y la exactitud del clasificador.
- Se recomienda obtener registros anotados provenientes de HUMANA, especialmente para evaluar el rendimiento de los clasificadores de aprendizaje automático no supervisado, adicionalmente se recomienda corroborar las anotaciones automáticas con los especialistas.
- Para la continuación de este proyecto, se recomienda profundizar en el análisis de señales ECG, incorporando a la herramienta de software la extracción de features, evaluando más clasificadores y utilizando registros correspondientes a crisis epilépticas.
- Es conveniente obtener una mayor cantidad de datos etiquetados de señales EEG y ECG, dado que la disponibilidad de los mismos en la web es escasa y vale la pena seguir experimentando y evaluando los algoritmos de aprendizaje automático.
- Se recomienda ampliar la sección de anotaciones automáticas de la herramienta, agregando la visualización de más canales simultáneos y tomando en cuenta las necesidades de los especialistas.



- 
- [1] O. Organización Mundial de la Salud, *Epilepsia*, Último acceso 30 Abril 2022, 2022. dirección: <https://www.who.int/es/news-room/fact-sheets/detail/epilepsy>.
  - [2] D. Sone e I. Beheshti, “Clinical Application of Machine Learning Models for Brain Imaging in Epilepsy: A Review,” *Frontiers in Neuroscience*, vol. 15, 2021.
  - [3] B. Abbasi y D. M. Goldenholz, “Machine learning applications in epilepsy,” *Epilepsia*, vol. 60, n.º 10, págs. 2037-2047, 2019.
  - [4] H. Centro de Epilepsia y Neurocirugía Funcional, *HUMANA*, Último acceso 25 Abril 2022, 2022. dirección: <https://humanagt.org/>.
  - [5] M. J. A. Tijerino, “Análisis y Reconocimiento de Patrones de Señales Biomédicas de Pacientes con Epilepsia,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2020.
  - [6] M. F. P. Esmieu, “Diseño e Implementación de una Base de Datos de Señales Biomédicas de Pacientes con Epilepsia,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2020.
  - [7] D. A. V. Aguilera, “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.
  - [8] J. D. M. Sáenz, “Herramienta de Software con una Base de Datos Integrada para el Estudio de la Epilepsia - Fase II,” Tesis de licenciatura, Universidad Del Valle de Guatemala, 2022.
  - [9] E. C. Foundation, *Epilepsy*, Último acceso 08 Mayo 2022, 2022. dirección: <https://www.epilepsy.com/what-is-epilepsy>.
  - [10] C. V. Torres, “Epilepsia,” *Medicine - Programa de Formación Médica Continuada Acreditado*, vol. 11, n.º 73, págs. 4364-4373, 2015.
  - [11] R. S, “Clasificación operacional de los tipos de crisis por la Liga Internacional contra la Epilepsia: Documento - Posición de la Comisión para Clasificación y Terminología de la ILAE,” *Epilepsia*, vol. 58, n.º 4, págs. 522-530, 2017.

- [12] A. A. de Epilepsia, *Diferentes tipos de crisis epilépticas*, Último acceso 09 Mayo 2022, 2022. dirección: <https://www.apicepilepsia.org/que-es-la-epilepsia/diferentes-tipos-de-crisis-epilepticas/>.
- [13] R. Fisher, C. Acevedo, A. Arzimanoglou y col., “ILAE Official Report: A practical clinical definition of epilepsy.,” *Epilepsia*, vol. 55, n.º 4, 2014.
- [14] E. Palacios y C. Clavijo-Prado, “Semiología de la crisis epiléptica: un reto clínico.,” *Repertorio de Medicina y Cirugía*, vol. 25, n.º 4, 2016.
- [15] P. S. Bialik y M. Á. C. Corona, “Avances en el manejo de la epilepsia.,” *Neurología, Neurocirugía y Psiquiatría*, vol. 45, n.º 1, 2017.
- [16] N. H. Service, *Treatment - Epilepsy*, Último acceso 08 Mayo 2022, 2020. dirección: <https://www.nhs.uk/conditions/epilepsy/treatment/>.
- [17] B. M. Center, *Dieta Atkins modificada*, Último acceso 18 septiembre 2022, 2022. dirección: <https://www.bmc.org/es/node/125951>.
- [18] Martorell-Llobregat, C. and González-López, P. and Luna, E. and Asensio-Asensio, M. and Jadraque-Rodríguez, R. and García-March, G. and Moreno-López, P., “Papel de la estimulación del nervio vago en el tratamiento de la epilepsia refractaria. Resultados clínicos e impacto en la calidad de vida,” *Neurología*, ISSN: 02134853. DOI: [10.1016/j.nr1.2019.04.002](https://doi.org/10.1016/j.nr1.2019.04.002).
- [19] J. Varela-Benítez, “Electrodo capacitivo de alta sensibilidad para la detección de biopotenciales eléctricos,” *Revista mexicana de ingeniería biomédica*, vol. 2, n.º 36, págs. 14-23, 2015.
- [20] S. Brailowsky, *Epilepsia*, 1.<sup>a</sup> ed. Fondo de Cultura Económica, 2014.
- [21] C. Bazán, M. Blanco, J. Cárdenas y F. Cruz, “Compresión de señales electroencefalográficas epilépticas y normales,” *Ingeniería Electrónica, Automática y Comunicaciones*, vol. 33, n.º 1, págs. 25-32, 2012.
- [22] N. Barcelona, *¿Qué son las ondas Cerebrales?* Último acceso 18 septiembre 2022, 2022. dirección: <https://www.neurofeedback.cat/que-son-las-ondas-cerebrales/>.
- [23] N. Associates, *Brain Wave Frecuencias*, Último acceso 18 septiembre 2022, 2022. dirección: <https://nhahealth.com/brainwaves-the-language/#:~:text=The%20raw%20EEG%20has%20usually%20for%20%E2%80%9Cactive%E2%80%9D%20intelligence.>
- [24] R. Vallat, *Compute the average bandpower of an EEG signal*, Último acceso 18 septiembre 2022, 2018. dirección: <https://raphaelvallat.com/bandpower.html>.
- [25] I. Stancin, M. Cifrek y A. Jovic., “A Review of EEG Signal Features and their Application in Driver Drowsiness Detection Systems.,” *Sensors (Basel)*, vol. 21, n.º 11, 2021.
- [26] T. Donoghue, J. Dominguez y B. Voytek., “Electrophysiological Frequency Band Ratio Measures Conflate Periodic and Aperiodic Neural Activity.,” *eNeuro*, vol. 7, n.º 6, 2020.
- [27] N. Dugarte, “Técnicas de procesamiento de la señal ECGAR aplicadas en el prototipo DIGICARDIAC,” *Revista del Instituto Nacional de Higiene Rafael Rangel*, vol. 46, n.º 1-2, 2015.
- [28] L. A. Osorio, “Acondicionamiento de Señales Bioeléctricas,” Tesis de licenciatura, Universidad Tecnológica de Pereira, 2007.

- [29] TIBCO, *¿Qué es el aprendizaje supervisado?* Último acceso 08 Mayo 2022, 2022. dirección: <https://www.tibco.com/es/reference-center/what-is-supervised-learning#:~:text=E1%5C%20aprendizaje%5C%20supervisado%5C%20es%5C%20una,de%5C%20manera%5C%20expl%5C%C3%5C%ADcita%5C%20d%5C%C3%5C%B3nde%5C%20buscar>.
- [30] T. Shah, *About Train, Validation and Test Sets in Machine Learning*, Último acceso 18 septiembre 2022, 2017. dirección: <https://towardsdatascience.com/train-validation-and-test-sets-72cb40cba9e7>.
- [31] I. C. Education, *Neural Networks*, Último acceso 18 septiembre 2022, 2022. dirección: <https://www.ibm.com/cloud/learn/neural-networks>.
- [32] MathWorks, *¿Qué es una red neuronal?* Último acceso 20 septiembre 2022, 2022. dirección: <https://la.mathworks.com/discovery/neural-network.html>.
- [33] IBM, *Funcionamiento de SVM*, Último acceso 20 septiembre 2022, 2021. dirección: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=models-how-svm-works>.
- [34] MathWorks, *Support Vector Machine (SVM)*, Último acceso 20 septiembre 2022, 2022. dirección: <https://la.mathworks.com/discovery/support-vector-machine.html>.
- [35] L. Gonzalez, *Aprendizaje no Supervisado*, Último acceso 08 May 2022, 2020. dirección: <https://aprendeia.com/aprendizaje-no-supervisado-machine-learning/>.
- [36] Kaggle, *American Epilepsy Society Seizure Prediction Challenge*, Último acceso 18 septiembre 2022, 2015. dirección: <https://www.kaggle.com/c/seizure-prediction/data>.
- [37] I. B. Slimen, L. Boubchir y H. Seddik, “Epileptic seizure prediction based on EEG spikes detection of ictal-preictal states.,” *J Biomed Res*, vol. 34, n.º 3, 2020.
- [38] H. J. Eoh, M. K. Chung y S.-H. Kim, “Electroencephalographic study of drowsiness in simulated driving with sleep deprivation.,” *International Journal of Industrial Ergonomics*, vol. 35, n.º 4, 2005.
- [39] O. Dressler, G. Schneider, G. Stockmanns y E. F. Kochs, “Awareness and the EEG power spectrum: analysis of frequencies,” *BJA: British Journal of Anaesthesia*, vol. 93, n.º 6, págs. 806-809, 2004.
- [40] PhysioNet, *Post-Ictal Heart Rate Oscillations in Partial Epilepsy*, Último acceso 25 septiembre 2022, 1999. dirección: <https://physionet.org/content/szdb/1.0.0/>.
- [41] J. Jeppesen, S. Beniczky, P. Johansen, P. Sidenius y A. Fuglsang-Frederiksen, “Detection of epileptic seizures with a modified heart rate variability algorithm based on Lorenz plot,” *seizure, European Journal of Epilepsy*, vol. 24, págs. 1-7, 2015.



### 13.1. Repositorio de Github

En el siguiente enlace se encuentra el repositorio de Github que contiene los códigos y los sets de datos utilizados en este trabajo de graduación:

<https://github.com/camilalemus/Estudio-Epilepsia-2022>

### 13.2. Matrices de confusión de RNA utilizando características en dominio de la frecuencia para dos clases (Ictal/Sano)

En este anexo se presenta un conjunto detallado de resultados obtenidos de una serie de experimentos adicionales, los cuales se llevaron a cabo con el propósito de predecir las categorías ictal y sano. Dichas categorías han sido identificadas, para fines de esta investigación, con las etiquetas 1 y 2, respectivamente. En el desarrollo de estos experimentos, se exploró una diversidad de combinaciones de razones (ratios), buscando determinar el conjunto óptimo que contribuye a una clasificación más precisa y robusta.



Figura 30: Matriz de confusión Ictal/Sano con RNA, utilizando las razones 1 y 2 como características en dominio de la frecuencia.



Figura 31: Matriz de confusión Ictal/Sano con RNA, utilizando las razones 1, 2, 3 y 4 como características en dominio de la frecuencia.

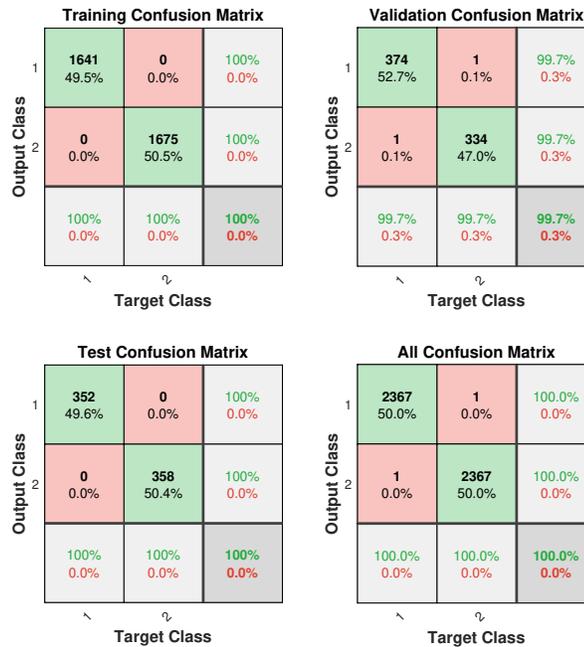


Figura 32: Matriz de confusión Ictal/Sano con RNA, utilizando las razones 1, 2, 3, 4 y 5 como características en dominio de la frecuencia.

### 13.3. Matrices de confusión de RNA usando características en dominio de la frecuencia para dos clases (Interictal/Preictal)

A continuación, se presentan las matrices de confusión generadas por las redes neuronales, las cuales han sido entrenadas utilizando diversas combinaciones de ratios aplicados a características en el dominio de la frecuencia. Estas matrices reflejan el desempeño del modelo en la clasificación de dos estados críticos: interictal y preictal. Para una identificación clara y consistente a lo largo de estos estudios, la fase interictal se denota con la etiqueta 1 y la fase preictal con la etiqueta 2.

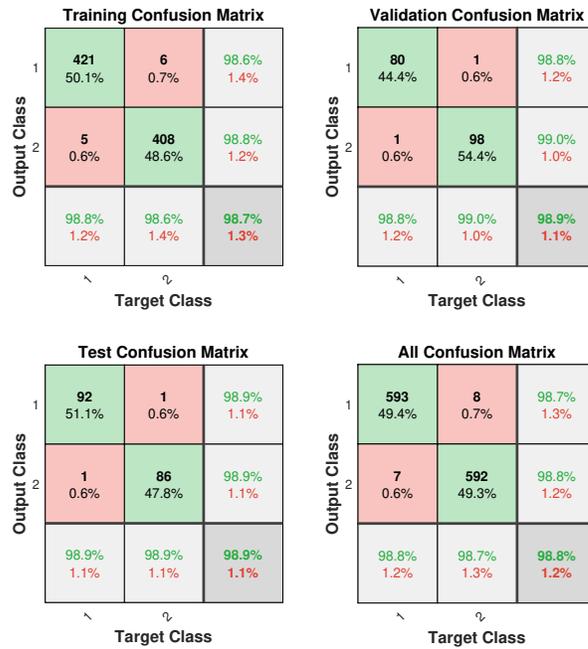


Figura 33: Matriz de confusión Interictal/Preictal con RNA, utilizando las razones 1 y 2 como características.



Figura 34: Matriz de confusión Interictal/Preictal con RNA, utilizando las razones 1, 2, 3 y 4 como características.

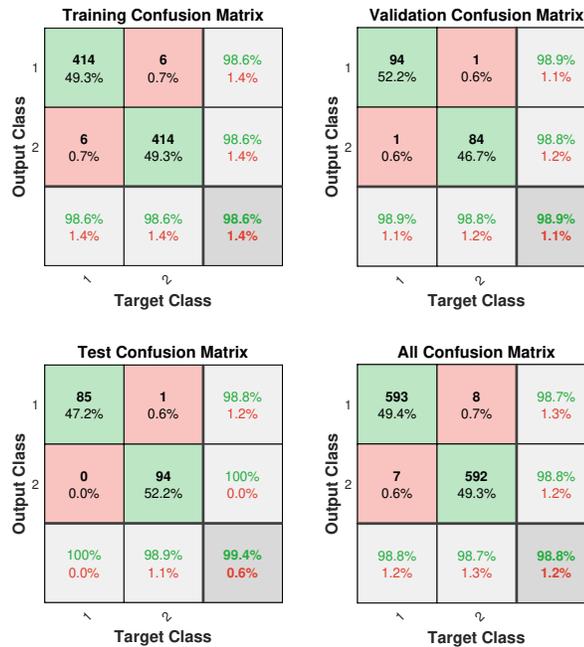


Figura 35: Matriz de confusión Interictal/Preictal con RNA, utilizando las razones 1, 2, 3, 4 y 5 como características.

### 13.4. Matrices de confusión de RNA utilizando características individuales en dominio de la frecuencia para dos clases (Ictal/Sano)

En las siguientes secciones se exponen las matrices de confusión correspondientes a experimentos adicionales realizados con redes neuronales, las cuales han sido implementadas para evaluar características individuales dentro del dominio de frecuencia. Estas matrices tienen el objetivo de ilustrar la efectividad del modelo en la distinción entre dos condiciones específicas: ictal y sano. En este análisis, la clasificación ictal se ha designado con la etiqueta 1, mientras que el estado sano con la etiqueta 2.

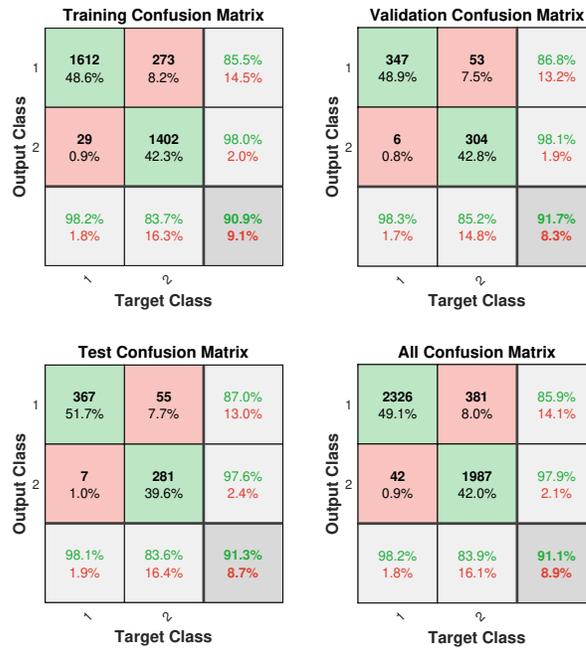


Figura 36: Matriz de confusión Ictal/Sano con RNA, utilizando la razón 2 como característica en dominio de la frecuencia.

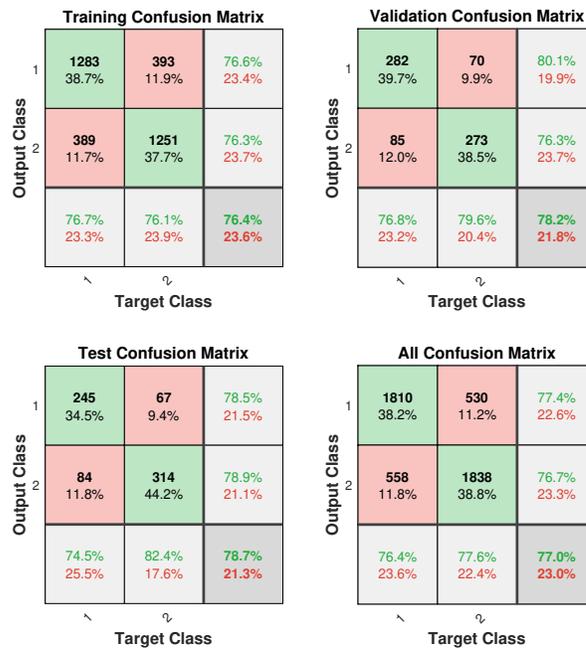


Figura 37: Matriz de confusión Ictal/Sano con RNA, utilizando la razón 3 como característica en dominio de la frecuencia.



Figura 38: Matriz de confusión Ictal/Sano con RNA, utilizando la razón 4 como característica en dominio de la frecuencia.

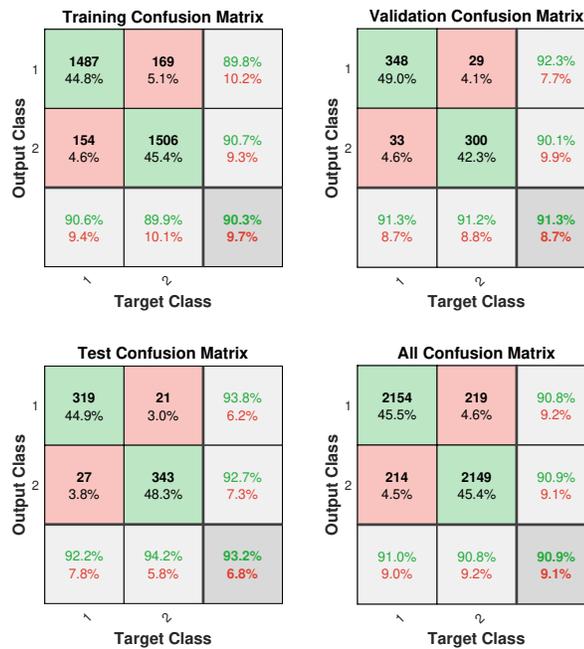


Figura 39: Matriz de confusión Ictal/Sano con RNA, utilizando la razón 5 como característica en dominio de la frecuencia.

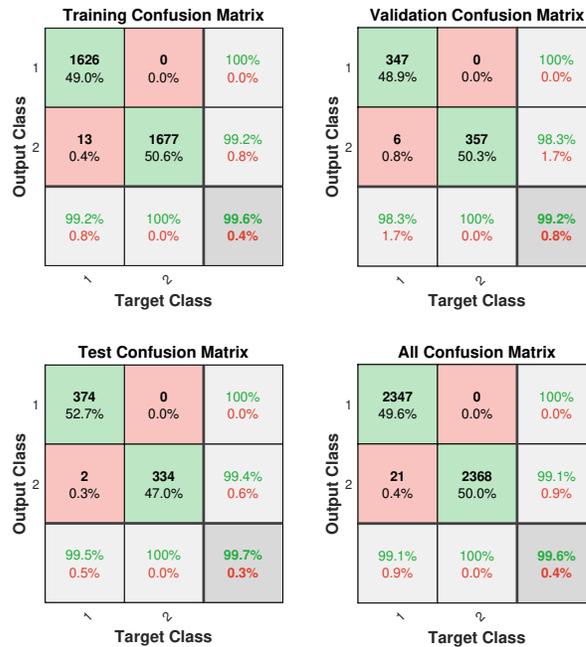


Figura 40: Matriz de confusión Ictal/Sano con RNA, utilizando la std como característica en dominio de la frecuencia.

### 13.5. Matrices de confusión de RNA utilizando características individuales en dominio de la frecuencia para dos clases (Interictal/Preictal)

En la sección que sigue, se despliegan las matrices de confusión generadas por las redes neuronales, que se han configurado para analizar características únicas en el dominio de la frecuencia, enfocadas en distinguir entre dos estados clínicos: interictal y preictal. Para este análisis, hemos asignado la etiqueta 1 a la condición interictal y la etiqueta 2 a la condición preictal.

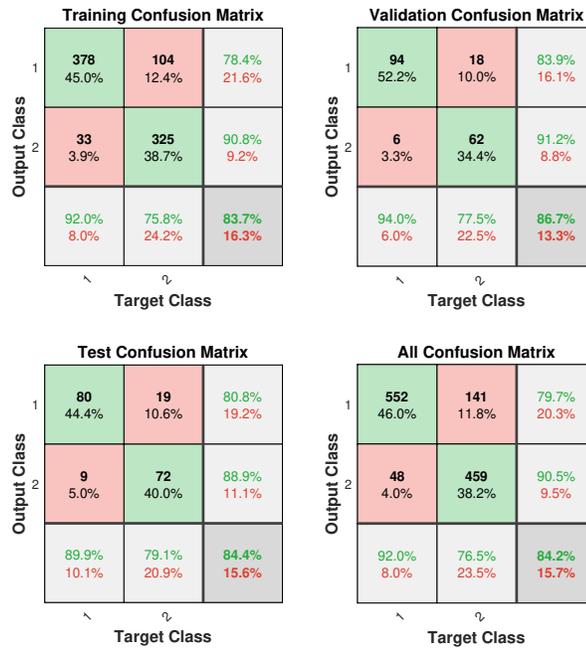


Figura 41: Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 2 como característica en dominio de la frecuencia.



Figura 42: Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 3 como característica en dominio de la frecuencia.

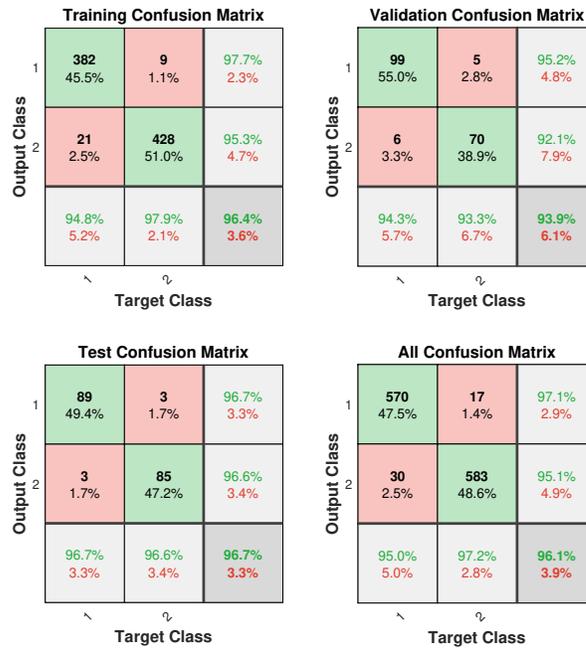


Figura 43: Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 4 como característica en dominio de la frecuencia.

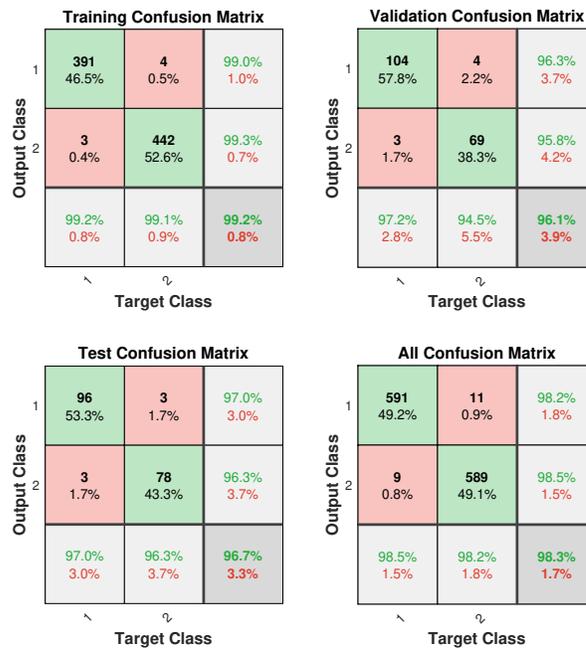


Figura 44: Matriz de confusión Interictal/Preictal con RNA, utilizando la razón 5 como característica en dominio de la frecuencia.

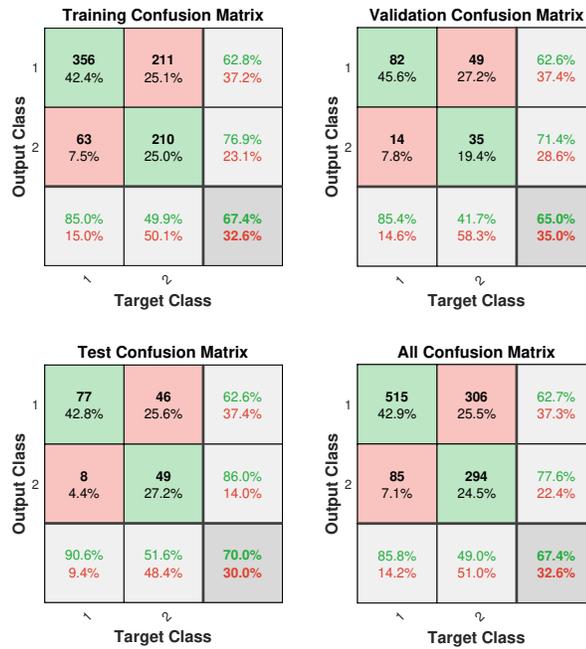


Figura 45: Matriz de confusión Interictal/Preictal con RNA, utilizando la std como característica en dominio de la frecuencia.

