



Universidad
LATINA *de Panamá*
SUMMUM DESIDERIUM SAPIENTIA

Facultad de Ingeniería

Proyecto final de graduación presentado como requisito para optar por el título de
Licenciatura en Ingeniería biomédica e instrumentación en la Universidad Latina
de Panamá

**Desarrollo de un modelo basado en aprendizaje profundo con arquitectura
LSTM extendida para el diagnóstico computacional de crisis epilépticas
mediante señales EEG**

Estudiante:

Eliecer Alberto Ramos Villarreal

C.I.P. 7-713-2425

Director:

Ing. Manuel Ceron

Tutor metodológico:

Ing. Alfredo Lescher

Panamá, República de Panamá 2025

Dedicatoria

Le dedico este trabajo, a Dios, a la Virgen, por darme la vida, la salud y la fortaleza para culminar este proyecto, incluso en los momentos de mayor dificultad.

A mis padres, Eliecer Ramos Barría y María Villarreal Iturralde, por su amor incondicional, apoyo constante y por enseñarme, con su ejemplo, el valor del esfuerzo y la perseverancia.

A mis hermanos, Eliecer Antonio Ramos y Aurelio Jahir Reyes, por ser fuente de motivación, alegría y acompañamiento; en cada etapa de este camino.

A mis abuelos y a todos ellos; quienes creyeron en mí y me impulsaron a nunca rendirme. Esta meta, también es de ustedes.

Agradecimiento

En primer lugar, agradecer; a Dios, a la Virgen por estar siempre a mi lado en todo este proceso, por siempre iluminarme y brindarme la sabiduría necesaria para concluir esta etapa de mi vida.

Deseo expresar mi más profundo agradecimiento, a todas las personas, que hicieron posible la realización de esta tesis.

A mi asesor, el Ing. Manuel Cerón, por su orientación técnica, disposición y acompañamiento constante durante cada fase del proyecto, brindándome las herramientas necesarias, para crecer académica y profesionalmente.

Al Ing. Alfredo Lescher, director metodológico, por su guía en la estructuración y enfoque de esta investigación, y por velar por la rigurosidad metodológica que exige el trabajo científico.

A la universidad y sus docentes, por facilitar un entorno de formación que propicia el desarrollo integral.

A mis compañeros y amigos, por su apoyo, ideas y aportes en los momentos clave.

Y, por supuesto, a mi familia, por ser mi sostén emocional y mi principal motor para seguir adelante.



Universidad
LATINA *de Panamá*
SUMMUM DESIDERIUM SAPIENTIA

Declaración Jurada

Yo, Eliecer Alberto Ramos Villarreal con cédula No. 7-713-2425 estudiante (o participante) graduando (a) de la carrera (o programa) de Licenciatura en Ingeniería Biomédica e Instrumentación declaro bajo la gravedad del juramento que el material que aparece en esta tesis de grado es de mi producción intelectual, debido a lo cual exoneró a la Universidad Latina de Panamá de cualquier responsabilidad relacionada en este aspecto.

Para quien conste, firmo la presente declaración el día 23 de julio de 2025.

Firmado EA.Rm

Índice general

Dedicatoria	2
Agradecimiento.....	3
Declaración Jurada	4
Introducción.....	7
Resumen	9
Abstract	10
CAPÍTULO 1. El Problema.....	11
1.1 Antecedentes del problema	12
1.2 Planteamiento del problema	14
1.3 Justificación de la investigación	15
1.4 Objetivos.....	17
1.5 Alcance y límites de la investigación.....	18
1.6 Línea de investigación a la que pertenece el estudio	19
CAPÍTULO 2. Marco Teórico	20
2.1 Epilepsia y crisis epilépticas.....	25
2.2 Ondas cerebrales: ritmos delta, theta, alfa, beta y gamma	27
2.3 Procesamiento de las señales EEG	33
2.4 Inteligencia Artificial y Aprendizaje Automático	37
2.5 Justificación del uso de LSTM e híbridos para el diagnóstico epiléptico.....	42
mediante EEG	42
2.6 Variable de estudio	43
2.7 Tabla de variables	47
2.8 Glosario de términos	48
CAPÍTULO 3. Marco Metodológico	50
3.1 Tipo y diseño de la investigación	51
3.2 Población y muestra	52
3.3 Procedimiento de la investigación.....	53

4. Diseño de la propuesta	55
4.1 Introducción.....	55
4.2 Preprocesamiento de señales EEG	59
4.3 Estructura del modelo CNN + BiLSTM de entrada dual	63
4.4 Entrenamiento del modelo	65
CAPÍTULO 4. ANÁLISIS DE RESULTADOS.....	68
5.1 Introducción.....	69
5.2 Preprocesar señales EEG del dataset CHB-MIT (Children's Hospital Boston - Massachusetts Institute of Technology) disponible en PhysioNet, mediante segmentación, transformadas FFT y DWT para identificar patrones característicos de crisis epilépticas.....	69
5.3 Entrenar un modelo LSTM extendido (CNN + BiLSTM) que pueda aprender patrones preictales en señales EEG.	73
5.4 Evaluar el rendimiento del modelo utilizando métricas como precisión, sensibilidad y la tasa de falsos positivos utilizando los datos del dataset CHB-MIT.....	77
5.5 Validar la capacidad de generalización del modelo sobre datos no utilizados en el entrenamiento.....	81
Discusión y análisis crítico de los resultados.....	84
Conclusiones	86
Recomendaciones	87
Referencia.....	88
Anexo	94

Introducción

La epilepsia es una de las enfermedades neurológicas crónicas, más comunes a nivel mundial, caracterizada por la aparición recurrente de crisis epilépticas. Estas crisis pueden presentarse de manera abrupta e impredecible, afectando la calidad de vida de los pacientes y representando un desafío diagnóstico y terapéutico significativo. En este contexto, la detección temprana y automática de eventos epilépticos mediante señales electroencefalográficas (EEG) se ha convertido en un área de investigación de gran interés, especialmente con el auge de las técnicas de aprendizaje automático y redes neuronales profundas.

El presente trabajo de investigación tiene como objetivo; desarrollar un modelo computacional basado en una arquitectura híbrida de red neuronal, convolución y de memoria a largo y corto plazo (CNN–BiLSTM), para la detección de crisis epilépticas a partir de señales EEG. Para ello, se utilizaron registros de la base de datos pública CHB-MIT, provenientes del Hospital Infantil de Boston, los cuales incluyen anotaciones clínicas verificadas por expertos. El preprocesamiento de las señales incluyó filtrado, paso, banda, remoción de artefactos y normalización. Posteriormente, se extrajeron características relevantes mediante transformada rápida de Fourier (FFT) y transformada discreta de wavelet (DWT), permitiendo capturar tanto componentes frecuenciales como temporales.

El modelo propuesto fue entrenado y evaluado utilizando una estrategia de validación cruzada y métricas como: precisión, sensibilidad, especificidad y AUC. Adicionalmente, se analizó la capacidad de generalización del sistema frente a pacientes no vistos y bases externas, como parte de una validación clínica más robusta.

Esta investigación busca aportar al desarrollo de sistemas automáticos de apoyo al diagnóstico médico, capaces de asistir al personal clínico en la identificación de crisis epilépticas de forma eficiente, precisa y en tiempo real. El enfoque adoptado pretende combinar robustez técnica, aplicabilidad clínica y viabilidad computacional,

con miras a futuras implementaciones, en entornos hospitalarios o dispositivos portátiles de monitoreo continuo.

El contenido de este trabajo se estructura en cuatro capítulos. En el Capítulo 1, se expone el planteamiento del problema, los objetivos de la investigación, la justificación, el alcance, las limitaciones y el marco teórico relacionado con el diagnóstico de crisis epilépticas mediante señales EEG. El Capítulo 2, describe la metodología empleada, incluyendo el tipo de estudio, la población y muestra utilizada, así como las técnicas de recolección, preprocesamiento y análisis de datos. En el Capítulo 3, se detalla el desarrollo del sistema propuesto, abarcando la arquitectura del modelo CNN–BiLSTM, la extracción de características con FFT y DWT, y el proceso de entrenamiento supervisado.

Finalmente, el Capítulo 4, presenta los resultados experimentales, las métricas de validación del modelo, el análisis crítico de desempeño y las conclusiones derivadas del estudio.

Resumen

La presente investigación tiene como finalidad, diseñar e implementar un modelo de red neuronal híbrido CNN–BiLSTM para la detección de crisis epilépticas utilizando señales EEG. Se empleó el dataset CHB-MIT, compuesto por registros clínicos multicanal con anotaciones ictales, y se aplicaron técnicas de preprocesamiento como filtrado paso banda, filtro notch y normalización Z-score. Las características fueron extraídas mediante FFT y DWT, capturando información tanto en el dominio de la frecuencia, como en el tiempo.

El modelo fue entrenado, con una arquitectura de doble entrada para combinar ambas fuentes de información, evaluando su rendimiento mediante validación cruzada y pruebas en pacientes no vistos. Los resultados mostraron un desempeño destacado, con una precisión del 95.45% y un AUC de 0.94, lo que evidencia su potencial clínico. Asimismo, se exploró la capacidad de generalización del modelo en señales EEG de diferentes orígenes, confirmando su robustez frente a variabilidad interpaciente y de adquisición.

Este estudio demuestra la eficacia de combinar técnicas de extracción multiespectral y arquitecturas profundas para abordar el reto de la detección automática de eventos epilépticos, contribuyendo al desarrollo de sistemas de monitoreo continuo y diagnóstico asistido por inteligencia artificial.

Palabras clave: Epilepsia, EEG, CNN, BiLSTM, Detección de crisis, FFT, DWT, Aprendizaje profundo.

Abstract

This research aims to design and implement a hybrid CNN–BiLSTM neural network model for the detection of epileptic seizures using EEG signals. The CHB-MIT dataset was employed, containing multichannel clinical recordings with expertannotated seizure events. Preprocessing steps included band-pass filtering, notch filtering, and Z-score normalization. Features were extracted using FFT and DWT, capturing information in both frequency and time domains.

The model was trained using a dual-input architecture to merge both sources of information, and its performance was evaluated through cross-validation and testing on unseen patients. Results showed outstanding performance, achieving 95.45% accuracy and an AUC of 0.94, highlighting its clinical potential. The model's generalization capabilities were further validated on EEG signals from various sources, confirming its robustness against inter-patient and acquisition variability.

This study demonstrates the effectiveness of combining multispectral feature extraction and deep learning architectures to tackle the challenge of automatic seizure detection, contributing to the development of continuous monitoring systems and AI-assisted diagnostic tools.

Keywords: Epilepsy, EEG, CNN, BiLSTM, Seizure detection, FFT, DWT, Deep Learning.

CAPÍTULO 1. El Problema

1.1 Antecedentes del problema

La epilepsia es una enfermedad neurológica crónica, esta se manifiesta a través de crisis convulsivas recurrentes, causadas por descargas eléctricas anormales en el cerebro. Según la Organización Mundial de la Salud (OMS), se estima que, más de 50 millones de personas en el mundo padecen esta condición, lo que la convierte en uno de los trastornos neurológicos más comunes a nivel global (World Health Organization, 2023). Aproximadamente, el 80% de los casos se presentan en países de ingresos bajos y medios, donde el acceso a servicios especializados de diagnóstico y tratamiento es limitado.

En Panamá, la información estadística sobre la epilepsia aún es fragmentaria, pero el Ministerio de Salud (MINSa) y la Caja de Seguro Social (CSS) han reportado un aumento constante en las consultas neurológicas durante la última década. Según registros de la CSS, entre 2017 y 2022, se atendieron más de 13,000 consultas relacionadas con epilepsia (Caja de Seguro Social, 2023). Además, datos preliminares del Observatorio de Salud Pública del (MINSa), reflejan una prevalencia creciente en zonas urbanas y rurales, aunque aún no existe un registro nacional epidemiológico consolidado (MINSa, 2022). El diagnóstico clínico de la epilepsia, en Panamá, como en la mayoría de los países, se basa en la interpretación médica del electroencefalograma (EEG), prueba fundamental que permite registrar la actividad eléctrica cerebral. Este análisis se realiza de forma manual por parte de un especialista, quien revisa visualmente múltiples canales de señal en sesiones que pueden durar entre 20 y 60 minutos. Este proceso no solo es tiempo-dependiente y susceptible al error humano, sino que también requiere una alta especialización (Fisher et al., 2014).

Actualmente, no existen plataformas automatizadas en los centros de salud panameños, ellos permitan realizar análisis computacional del EEG en tiempo real o como herramienta de apoyo diagnóstico. Esta carencia puede limitar la capacidad de diagnóstico temprano y la eficiencia del sistema de salud, especialmente en contextos rurales donde el acceso a neurofisiólogos es escaso.

A nivel internacional, el uso de técnicas computacionales para interpretar señales EEG ha ganado una creciente atención en la última década. Diversos modelos de aprendizaje profundo han sido implementados con éxito para clasificar patrones cerebrales patológicos. Entre los más utilizados destacan las Redes Neuronales Convolucionales (CNN), las redes Conv1D y las redes LSTM (Long Short-Term Memory). Las CNN han sido ampliamente utilizadas para extraer características locales o espectrales, ya sea desde representaciones visuales o directamente desde transformaciones como FFT y DWT. En combinación con LSTM, permiten mejorar el rendimiento diagnóstico (Acharya et al., 2018). Las redes Conv1D, por su parte, permiten trabajar directamente con secuencias unidimensionales, pero presentan limitaciones al modelar dependencias de largo plazo (Zhou et al., 2023). Por su parte, las redes LSTM han demostrado ser superiores en la detección de patrones temporales complejos, como los presentes en la actividad cerebral, ya que pueden mantener información a largo plazo y evitar la pérdida de contexto en series extensas (Hussein et al., 2019). Aunque las LSTM permiten procesar directamente secuencias crudas, en esta investigación se emplearon transformaciones FFT y DWT con el fin de mejorar la separación entre patrones ictales y no ictales.

Estudios recientes han reportado, que modelos basados en LSTM han alcanzado precisiones superiores al 90% en tareas de clasificación de crisis epilépticas, evidenciando su potencial para ser utilizados en entornos clínicos, es decir, herramientas de apoyo diagnóstico (Liu et al., 2024). Además, en contextos hospitalarios como las Unidades de Cuidados Intensivos (UCI), donde el monitoreo EEG continuo es esencial para la vigilancia neurológica, la integración de sistemas computacionales inteligentes podría optimizar los tiempos de respuesta y la capacidad de atención, reduciendo errores de interpretación y cargas de trabajo (Kiral-Kornek et al., 2018).

Esta elección metodológica dio paso al desarrollo de una arquitectura híbrida que combina convoluciones 1D, procesamiento secuencial y entradas transformadas para maximizar la sensibilidad diagnóstica del sistema. Por tanto, el

diagnóstico computacional de crisis epilépticas mediante redes LSTM se presenta como una solución innovadora, técnicamente viable y con un impacto clínico potencial, especialmente en países como Panamá, que requieren alternativas de apoyo a la interpretación médica especializada. Esta línea de investigación se alinea con las tendencias actuales en inteligencia artificial aplicada a la salud y con los esfuerzos por modernizar tecnológicamente el sistema sanitario nacional.

1.2 Planteamiento del problema

El diagnóstico de epilepsia, en Panamá, como en muchos otros países de ingresos medios, se realiza principalmente a través del análisis visual de señales EEG por parte de un especialista. Este proceso, aunque clínicamente aceptado, carece de apoyo computacional automatizado y depende enteramente de la experiencia del neurofisiólogo, lo que puede conducir a variaciones en la interpretación, retrasos en la confirmación del diagnóstico, y en algunos casos, diagnósticos incompletos. Actualmente, no se han identificado sistemas implementados en los hospitales del país, que integren inteligencia artificial para apoyar el análisis de señales EEG. Esta ausencia de herramientas computacionales automatizadas limita la capacidad de diagnóstico eficiente, especialmente en contextos rurales donde el acceso a neurofisiólogos es escaso.

A nivel regional, el uso de algoritmos de aprendizaje automático para el diagnóstico computacional de epilepsia es aún limitado, y en Panamá no se han identificado estudios científicos que implementen este tipo de modelos en entornos hospitalarios o de investigación aplicada. Esta ausencia evidencia una brecha tecnológica y metodológica importante que, impide el aprovechamiento de herramientas digitales con potencial clínico probado en otros contextos.

De lo antes descrito, el investigador se hace la siguiente pregunta:

¿Puede una red neuronal LSTM extendida ser entrenada con señales EEG de una fuente hospitalaria reconocida, identificar patrones característicos de

crisis epilépticas con suficiente precisión para ser utilizada como herramienta diagnóstica? Este proyecto busca desarrollar, entrenar y evaluar un modelo basado en LSTM extendido mediante transformaciones espectrales y módulos convolucionales para el diagnóstico computacional de epilepsia, empleando registros clínicos de una fuente hospitalaria reconocida. El objetivo final es evaluar la viabilidad y precisión del modelo, con miras a su posible futura implementación en hospitales del país, como herramienta de apoyo clínico.

1.3 Justificación de la investigación

La epilepsia, como trastorno neurológico crónico, afecta la calidad de vida de quienes la padecen debido a las crisis recurrentes, el estigma social, y la falta de seguimiento médico estructurado. La epilepsia genera un impacto considerable en la salud pública debido a la frecuencia de las crisis, la estigmatización social y los riesgos asociados a su diagnóstico tardío o erróneo. En países con sistemas sanitarios en desarrollo, uno de los principales desafíos es la falta de recursos especializados para interpretar adecuadamente los estudios EEG, lo que limita las oportunidades de atención oportuna y seguimiento clínico continuo (WHO, 2023). La incorporación de sistemas de análisis computacional basados en inteligencia artificial permitiría mejorar la precisión del diagnóstico y reducir la carga asistencial sobre los especialistas, al actuar como herramientas complementarias en la interpretación de los registros EEG (Kiral-Kornek et al., 2018).

En especial en entornos, como las Unidades de Cuidados Intensivos (UCI), donde la vigilancia neurológica debe ser constante, la posibilidad de automatizar el análisis de actividad cerebral ofrece ventajas clínicas sustanciales. Estudios recientes han demostrado, que el uso de algoritmos de aprendizaje profundo puede optimizar la detección de patrones patológicos en tiempo real, lo que contribuye a mejorar los tiempos de respuesta médica y disminuir el riesgo de complicaciones (Jiang et al., 2024).

Desde la perspectiva universitaria, este proyecto representa una contribución directa al desarrollo del conocimiento en la línea de investigación de Ciencias de la Salud, específicamente en el área de Ingeniería Clínica y Biomédica. Permite la aplicación práctica de conceptos adquiridos en asignaturas como procesamiento de señales biomédicas, fundamentos de inteligencia artificial y desarrollo de modelos de aprendizaje profundo. Además, promueve la interdisciplinariedad entre la ingeniería, la medicina y la informática aplicada, alineándose con las tendencias globales en salud digital y medicina personalizada. Por tanto, más allá del cumplimiento de los requisitos académicos, este proyecto busca ser un aporte institucional y científico desde la Universidad Latina de Panamá hacia una problemática sanitaria vigente.

Desde la perspectiva metodológica, el uso de redes LSTM (Long Short-Term Memory) se justifica por su eficacia comprobada en el análisis de señales temporales. Aunque, las LSTM pueden trabajar sin transformaciones espectrales, la inclusión de representaciones como FFT y DWT permite facilitar el aprendizaje de patrones preictales complejos. (Hussein et al., 2019). Esta arquitectura ha sido utilizada en investigaciones recientes donde se han alcanzado niveles de precisión superiores al 90% en la clasificación de crisis epilépticas, lo cual demuestra su idoneidad para este tipo de aplicación (Liu et al., 2024).

La implementación de este modelo se realizará en un entorno controlado y experimental, empleando registros clínicos validados por expertos, lo que garantiza la solidez técnica de los resultados y su posibilidad de réplica futura. Este enfoque también promueve el uso de herramientas accesibles y de código abierto, compatibles con los recursos computacionales disponibles para estudiantes y docentes en el contexto local.

En función de lo anterior, y durante la fase de desarrollo experimental, se planteó utilizar una arquitectura LSTM pura, en la fase de experimentación se observó que la combinación de representaciones espectrales (FFT y DWT) junto con capas convolucionales previas a la red LSTM mejoraba significativamente la sensibilidad del modelo, especialmente en crisis breves o con patrones difusos (Roy

et al., 2019). Esta modificación se basó en evidencia reciente sobre el uso de arquitecturas híbridas para EEG y se mantuvo alineada con el objetivo principal del trabajo: mejorar el diagnóstico automatizado de la epilepsia mediante modelos basados en aprendizaje profundo. Esta modificación no contradice el enfoque original, sino que lo fortalece al permitir una mayor sensibilidad ante eventos breves o patrones difusos de difícil detección con arquitecturas simples. Esta decisión metodológica fue guiada por la necesidad de mejorar el recall del modelo y reducir falsos negativos en crisis breves (Zhang et al., 2023).

1.4 Objetivos

Objetivo General

Desarrollar un modelo basado en aprendizaje profundo con arquitectura LSTM extendida para el diagnóstico computacional de crisis epilépticas mediante señales

EEG

Objetivos Específicos

1. Preprocesar señales EEG del dataset CHB-MIT (Children's Hospital Boston - Massachusetts Institute of Technology) disponible en PhysioNet, mediante segmentación, transformadas FFT y DWT para identificar patrones característicos de crisis epilépticas.
2. Entrenar un modelo LSTM extendido (CNN + BiLSTM) que pueda aprender patrones preictales en señales EEG.
3. Evaluar el rendimiento del modelo utilizando métricas como precisión, sensibilidad y la tasa de falsos positivos utilizando los datos del dataset CHBMIT.
4. Validar la capacidad de generalización del modelo sobre datos no utilizados en el entrenamiento.

1.5 Alcance y límites de la investigación

Esta investigación se desarrolla, en el ámbito de la inteligencia artificial aplicada a la ingeniería biomédica, con el objetivo de diseñar, entrenar y evaluar un modelo de red neuronal basado en LSTM extendido mediante transformaciones espectrales y módulos convolucionales para mejorar su rendimiento diagnóstico. El estudio utilizará el dataset clínico CHB-MIT, el cual contiene más de 900 horas de grabaciones EEG de 23 pacientes pediátricos con diagnóstico confirmado de epilepsia, provenientes del Hospital Infantil de Boston y el Massachusetts Institute of Technology (MIT).

De este conjunto de datos, se seleccionarán aproximadamente ocho (8) pacientes y un total estimado de 56 archivos .edf, considerando tanto registros con crisis como sin crisis. La selección se hará en función de la calidad de señal, duración y claridad de las anotaciones clínicas. El modelo será entrenado, validado y evaluado en un entorno experimental controlado utilizando herramientas como Python, TensorFlow y Google Colab.

La población objeto del estudio es indirecta, ya que se trabaja exclusivamente con registros clínicos anonimizados, sin interacción con pacientes reales. El propósito del modelo es sentar las bases para su futura implementación como sistema de apoyo diagnóstico en hospitales o centros neurológicos panameños, especialmente donde no hay especialistas disponibles o donde se busca reducir la carga diagnóstica.

El desarrollo de esta investigación se llevará a cabo en un período estimado de abril a diciembre de 2025, comprendiendo una duración total de aproximadamente ocho meses. Durante este tiempo, se realizarán las fases de revisión bibliográfica, preprocesamiento de datos, diseño del modelo híbrido CNN + BiLSTM, entrenamiento, validación, análisis de resultados y redacción del informe final. Este cronograma permitirá desarrollar el proyecto de manera estructurada y acorde con los tiempos establecidos por la Universidad Latina de Panamá para trabajos de grado.

El presente estudio no contempla la implementación clínica directa del modelo ni su integración en tiempo real con dispositivos médicos. Tampoco se considera el uso de bases de datos nacionales, por lo que los resultados se limitarán a la evaluación sobre datos internacionales (CHB-MIT). Asimismo, no se abordarán aspectos terapéuticos o farmacológicos de la epilepsia, ni se analizarán síndromes epilépticos específicos fuera del alcance del dataset. La investigación se centrará únicamente en el diseño y validación de un modelo de clasificación binaria (crisis/no crisis) con fines diagnósticos.

Aunque, se consideraron las limitaciones computacionales del entorno, se logró implementar una arquitectura optimizada que combina módulos convolucionales ligeros y redes BiLSTM, sin comprometer la escalabilidad ni el rendimiento. Por último, se reconoce que los resultados obtenidos en esta fase experimental no sustituyen el juicio clínico profesional, sino que apuntan a ofrecer una herramienta de apoyo automatizado para mejorar la eficiencia diagnóstica basada en señales EEG (Zhang et al., 2023).

La propuesta inicial se centró exclusivamente, en redes LSTM, la fase de desarrollo permitió extender la arquitectura con módulos convolucionales y entradas transformadas, manteniéndose dentro del alcance computacional previsto y en línea con estudios recientes sobre diagnóstico EEG.

1.6 Línea de investigación a la que pertenece el estudio

Esta tesis se enmarca en la Universidad Latina de Panamá en la línea de investigación está en Procesamiento de Señales e Imágenes Médicas en el área de Informática Médica, Bioinformática y Telemedicina.

CAPÍTULO 2. Marco Teórico

Antecedentes de investigaciones realizadas en el tema

En las últimas dos décadas, se ha investigado intensamente; el uso de técnicas de aprendizaje profundo para el diagnóstico de la epilepsia mediante señales EEG. Estudios pioneros demostraron la eficacia de redes neuronales profundas para identificar patrones de crisis epilépticas en registros EEG, eliminando en gran medida la necesidad de características manuales. Por ejemplo, Acharya et al. (2018), aplicaron una red neuronal convolución profunda de 13 capas para clasificar señales EEG intracraneales en estados normales, preictal (previo a la crisis) e ictal (en crisis), logrando una exactitud del 88.67%, especificidad del 90.00% y sensibilidad del 95.00%. Ullah et al. (2018), alcanzaron incluso ~99% de exactitud en el dataset de Bonn al clasificar entre actividad normal, interictal y crisis, usando un ensamble de modelos CNN 1D. Estos primeros trabajos sentaron las bases al demostrar que, las redes profundas pueden superar a los métodos tradicionales en la detección automática de epilepsia (Mallick & Baths, 2024).

Una tendencia importante ha sido la incorporación de redes LSTM (Long Short-Term Memory) y arquitecturas híbridas para explotar tanto las características espaciales como las temporales de las señales EEG. Hussein et al. (2019) propusieron una arquitectura robusta basada en LSTM para detección de crisis epilépticas, mostrando que las RNN avanzadas pueden manejar la dinámica compleja de las series temporales EEG. Asimismo, Thara et al. (2019) desarrollaron un modelo con LSTM apiladas y bidireccionales capaz de detectar y predecir crisis epilépticas, alcanzando hasta un 99% de exactitud en el conjunto de Bonn. Estos trabajos contribuyeron incorporar la memoria de largo plazo de las LSTM para mejorar la detección de eventos epilépticos, incluso con cierta anticipación a la ocurrencia de la crisis (Mallick & Baths, 2024).

Más recientemente, se han explorado arquitecturas híbridas que combinan redes convolucionales con LSTM para aprovechar lo mejor de ambas. Zhao et al. (2024) introdujeron la arquitectura ResBiLSTM, que consiste en una red Residual

1D seguida de una capa LSTM bidireccional, obteniendo resultados sobresalientes: en el dataset de Bonn lograron entre 98.88% y 100% de exactitud en clasificaciones binarias y terciarias, y en el corpus de la Universidad de Temple (TUSZ) –con siete tipos de crisis– lograron ~95% de exactitud y F1 (Zhao et al., 2024). Igualmente, Lee et al. (2024), propusieron un modelo híbrido ResNet-LSTM con preentrenamiento contrastivo, enfocado en la predicción temprana de crisis. Al transformar los EEG en espectrogramas de tiempo-frecuencia e integrar un ResNet preentrenado con una LSTM, validaron su método en dos conjuntos de datos (CHB-MIT y un hospital de Seúl), obteniendo en el primer 91.90% de precisión y 89.64% de sensibilidad, y en el segundo 83.37% y 79.89% respectivamente (Lee et al., 2024). Estos resultados demuestran mejoras significativas en la generalización del modelo a distintos pacientes y entornos clínicos, reduciendo las alarmas falsas (tasas de falsos positivos de ~0.05 en CHB-MIT). En conjunto, los estudios internacionales más recientes han logrado elevar la eficacia de la detección computacional de epilepsia, abordando también casos de clasificación multiclase de tipos de crisis y la predicción con anticipación (Zhao et al., 2024).

Gómez Caballero, Catalina (2019) – *“Automatic seizure detection based on imaged-EEG signals through statistical learning.”* Tesis de Maestría, Univ. de los Andes (Colombia). En este trabajo se implementó una estrategia de *Deep Learning* para la detección automatizada de convulsiones, transformando las señales EEG en imágenes para su análisis (p. ej., mapas tiempo-frecuencia) e introduciendo redes neuronales convolucionales totalmente conectadas. La metodología prescindió de la extracción manual de rasgos, aplicando directamente los algoritmos de aprendizaje profundo a cientos de horas de registros EEG de pacientes, tanto de *scalp EEG* (CHB-MIT, 23 pacientes) como intracraneales (EPILEPSIAE). Los resultados fueron altamente satisfactorios, con desempeños muy elevados: por ejemplo, un modelo general entrenado cruzadamente obtuvo en promedio ~99.3% de exactitud y 99.6% de especificidad en la detección de crisis en la base CHB-MIT. Estas métricas superan notablemente las de estudios previos en las mismas bases

de datos (que rondaban 62–85% de accuracy), logrando además valores sólidos de precisión, *recall* y puntaje-F1 incluso bajo escenarios desequilibrados.

La inclusión de datos intracraneales mejoró la sensibilidad, en algunos casos difíciles, alcanzando cerca del 98% en exactitud y especificidad al combinar registros de distintos tipos. En suma, esta tesis confirmó que los enfoques con redes neuronales profundas pueden igualar o exceder el estado del arte en detección de crisis epilépticas, reduciendo drásticamente falsos positivos (0 falsos positivos en 18 de 24 pacientes en ciertas configuraciones).

Francisco D. Quinga Quinga (2017) – Predicción de crisis epilépticas utilizando técnicas de procesamiento de señales electroencefalográficas y aprendizaje de máquina (Tesis de grado, Universidad de las Fuerzas Armadas ESPE, Ecuador). El objetivo principal fue diseñar, implementar y evaluar un algoritmo capaz de identificar el estado preictal (antes de la convulsión) y distinguirlo del estado interictal (normal) a partir de cambios dinámicos en las señales EEG. La metodología incluyó el procesamiento avanzado de señales EEG y la extracción de características relevantes, empleando algoritmos de clasificación de aprendizaje de máquina para predecir la ocurrencia de convulsiones inminentes. Los resultados mostraron un alto nivel de precisión, logrando cerca de 99% de exactitud en la distinción de estados preictales vs. normales en escenarios de validación, lo que evidencia la viabilidad de anticipar crisis epilépticas con suficiente anticipación.

David A. Vela Aguilera (2022) – 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). En esta investigación se desarrolló un proceso automatizado para reconocer y anotar episodios epilépticos en registros EEG utilizando técnicas de aprendizaje automático. Se implementaron dos clasificadores supervisados (una red neuronal y una máquina de soporte vectorial), incorporando filtrado de señales, extracción de características y entrenamiento/evaluación con datos de EEG públicos (Universidad de Bonn y concurso de la American Epilepsy Society). El sistema logró una precisión superior al 77% al clasificar cuatro tipos de segmentos (ictales, sanos, preictales e

interictales), mejorando a más de 97% de exactitud al simplificar el problema a tres o dos clases.

Yan Huang (2019) – A Deep Learning Approach to Seizure Prediction with a Desirable Lead Time (Tesis de maestría, Case Western Reserve University). Esta tesis propuso un enfoque de aprendizaje profundo con redes LSTM para predecir convulsiones epilépticas con un tiempo de anticipación reducido. En particular, introdujo un modelo de dos fases, que combina una red LSTM para distinguir períodos preictales vs. interictales en las señales EEG y una cola de memoria de predicción para generar alertas tempranas. El objetivo fue conseguir alarmas con solo ~5 minutos de anticipación (frente a los 60 minutos típicos de estudios previos) sin perder precisión. Evaluado sobre un amplio conjunto de datos clínicos (incluyendo la base del Center for SUDEP Research), el modelo alcanzó una sensibilidad promedio de 95.24%, superando significativamente a un predictor aleatorio y demostrando el potencial de las LSTM en la predicción de crisis epilépticas.

Catarina da Silva Lourenço (2023) – Deep Learning for EEG Analysis (Tesis doctoral, Universidad de Twente). En este trabajo doctoral se abordó la detección automatizada de descargas epileptiformes interictales (IEDs) en EEG utilizando técnicas de deep learning, motivado por la lentitud y subjetividad del análisis visual tradicional. La autora llevó a cabo una revisión exhaustiva de los métodos existentes durante las últimas décadas, desde enfoques tradicionales hasta redes neuronales profundas, evaluando sus desempeños y limitaciones en la identificación de IEDs. Como resultado, se demostró que los modelos de deep learning ofrecen los mejores resultados hasta la fecha en la detección de estas señales, si bien se destaca la importancia de estandarizar los datos y métricas de evaluación para comparar objetivamente los modelos y facilitar su adopción clínica.

Álvarez Mijares, Dimas (2020) – *“Máquinas de aprendizaje para clasificar señales electroencefalográficas de pacientes con epilepsia.”* Tesis de Maestría, Univ. Nacional de Colombia. En este trabajo se analizó el desempeño de distintos algoritmos de *machine learning* para clasificar señales EEG de pacientes

epilépticos, principalmente, con el fin de distinguir automáticamente entre sujetos sanos y sujetos con epilepsia a partir de sus registros EEG. Se exploraron técnicas de minería de datos como los parámetros de sincronización para transformar las señales en índices estadísticos, que capturan patrones ocultos, los cuales luego alimentaron a clasificadores como las Máquinas de Soporte Vectorial (SVM) implementadas en R. Para entrenamiento y validación se utilizó una combinación de datos EEG de 10 pacientes epilépticos y 10 sujetos sanos, incluyendo en el conjunto epiléptico algunas grabaciones durante una convulsión obtenida incidentalmente. El mejor modelo (una SVM con kernel apropiado) consiguió una eficacia de clasificación del ~99% al separar correctamente las EEG de pacientes con epilepsia de las de individuos sanos. Este altísimo nivel de acierto corroboró la potencia de las máquinas de aprendizaje en la discriminación de condiciones patológicas en EEG, alineándose con resultados publicados anteriormente y constituyendo un aporte significativo hacia sistemas automáticos de apoyo al diagnóstico de epilepsia.

Estos antecedentes regionales confirman el interés global en aplicar redes neuronales profundas al diagnóstico de la epilepsia, y sientan un precedente para el presente trabajo al evidenciar los logros y desafíos en contextos similares. Las metodologías, objetivos y resultados de estos estudios han guiado por estos avances, el presente trabajo implementa una arquitectura híbrida CNN + BiLSTM, que aprovecha simultáneamente la extracción espacial de características y la modelación secuencial de la actividad EEG, buscando mejorar aún más las métricas de rendimiento alcanzadas en investigaciones previas.

2.1 Epilepsia y crisis epilépticas

La epilepsia es un trastorno neurológico crónico caracterizado por la predisposición del cerebro a generar convulsiones recurrentes no provocadas, que afectan a unos 50–70 millones de personas en el mundo. Estas convulsiones surgen por actividad eléctrica cerebral anormal, manifestándose desde breves alteraciones de conciencia hasta crisis generalizadas. Una crisis epiléptica representa un

estallido de descargas eléctricas excesivas en las redes neuronales, que interrumpe momentáneamente la función normal del cerebro y puede generar espasmos musculares, ausencias o convulsiones tónico-clónicas. La detección oportuna es esencial, pues las crisis no tratadas pueden conllevar daño neurológico (Wang et al., 2023).

El diagnóstico se basa principalmente en la correlación clínica con registros de EEG, técnica no invasiva, que capta la actividad eléctrica cerebral en tiempo real mediante electrodos colocados sobre el cuero cabelludo (Ramos-Argüelles et al., 2009). Estos detectan las oscilaciones de voltaje generadas por la sinapsis de millones de neuronas corticales, ver Figura 1, permitiendo identificar patrones epilépticos como los complejos punta-onda. Aunque, el análisis del EEG lo realiza un neurólogo, esta interpretación visual es extensa y sujeta a fatiga y variabilidad (Zhao et al., 2024). Por ello, se investiga el uso de sistemas computacionales que automaticen esta detección, agilizando el diagnóstico y apoyando al especialista.



Figura 1. Electroencefalografía (3 Hz) de un niño al momento de una crisis epiléptica. Fuente: Ramos-Argüelles, F., Morales, G., Egozcue, S., Pabón, R. M., & Alonso, M. T. (2009).

Señales eléctricas del cerebro y electroencefalografía (EEG)

La actividad eléctrica cerebral surge de la transmisión de potenciales de acción y corrientes transmembranales entre neuronas. Cuando grupos amplios de neuronas corticales se activan de forma sincrónica, generan oscilaciones detectables extracelularmente como diferencias de voltaje. El EEG registra estas variaciones mediante electrodos en el cuero cabelludo, y fue desarrollado inicialmente por Hans Berger, en 1929, tras observaciones previas de Richard Caton (Tayeb & Khoshbin, s. f.).

Como técnica no invasiva, el EEG permite captar la actividad eléctrica cerebral en microvoltios. Aunque, estas señales no son sinusoidales puras, su descomposición en componentes frecuenciales revela patrones útiles para el análisis clínico y computacional. Las oscilaciones EEG se agrupan en bandas de frecuencia específicas, que reflejan distintos estados cerebrales (Fisiología de la actividad eléctrica del cerebro, s. f.). Para extraer características relevantes, se utilizan herramientas como la Transformada Rápida de Fourier (FFT) y la Transformada Discreta de Wavelet (DWT), que permiten representar la señal en dominios frecuenciales y tiempo-frecuencia, respectivamente. En este trabajo, ambas transformadas fueron empleadas como etapa clave para alimentar un modelo híbrido CNN + BiLSTM con información rica y complementaria de las señales EEG.

2.2 Ondas cerebrales: ritmos delta, theta, alfa, beta y gamma

Las oscilaciones eléctricas del cerebro se clasifican en cinco bandas de frecuencia: delta, theta, alfa, beta y gamma, asociadas a distintos estados

funcionales y diferenciadas por su rango de frecuencia y amplitud (Niedermeyer & da Silva, 2005). En la Figura 2 se ilustran sus morfologías típicas en un EEG.

- Las **ondas delta (δ)** (< 4 Hz), presentan la mayor amplitud (100–200 μ V) y predominan durante el sueño profundo y en la infancia. Su presencia en adultos despiertos puede indicar patología cerebral (Kandel et al., 2013).
- Las **ondas theta (θ)** (4–7 Hz) tienen amplitud intermedia (>30 μ V) y aparecen en sueño ligero y REM. En vigilia adulta, pueden asociarse a somnolencia o estados alterados (Guyton & Hall, 2016).
- Las **ondas alfa (α)** (8–13 Hz) son típicas de la vigilia relajada con ojos cerrados. Se generan en regiones occipitales y disminuyen con la actividad mental o al abrir los ojos. Reflejan relajación cortical y maduración cerebral (Niedermeyer & da Silva, 2005).
- Las **ondas beta (β)** (13–30 Hz), de baja amplitud (<20 μ V), se asocian a estados de alerta y concentración, con mayor presencia en regiones frontales. Su reducción puede señalar disfunción cortical (Guyton & Hall, 2016).
- Las **ondas gamma (γ)** (>30 Hz), presentan muy baja amplitud y se vinculan con procesos cognitivos superiores como percepción y atención. Son difíciles de registrar en EEG rutinarios debido a su baja potencia y sensibilidad al ruido muscular (Buzsáki & Draguhn, 2004).




Figura 2. Ejemplo de ondas cerebrales registradas en EEG. Fuente: Guyton & Hall, 2016.

Además de la frecuencia, otras propiedades relevantes del EEG incluyen la amplitud (en microvoltios), la morfología de las ondas, su reactividad (cambios ante estímulos como abrir los ojos), la distribución topográfica (regiones donde se presentan) y la aparición de patrones anormales (como las descargas punta-onda epilépticas). Estas características permiten interpretar el EEG no solo en función de su contenido espectral, sino también de su valor clínico.

Dado que, las distintas bandas de frecuencia contienen información diferenciada sobre los estados cerebrales, su análisis mediante técnicas como FFT y DWT permite identificar patrones característicos de las crisis epilépticas. Estas bandas fueron incorporadas indirectamente a través de las características extraídas y procesadas en el presente estudio.

Medición de señales EEG: electrodos, sistemas de colocación y canales

Para registrar el EEG se colocan electrodos, en la superficie de la cabeza, que detectan las diferencias de potencial eléctrico entre distintos puntos del cuero

cabelludo. Cada electrodo de registro recoge la señal resultante de la actividad eléctrica subyacente en la corteza cercana a su ubicación. Dado que, los voltajes del EEG son muy pequeños (decenas de μV), es indispensable amplificarlos mediante un amplificador diferencial, que resalta la diferencia de voltaje entre un par de electrodos (un electrodo activo y un electrodo de referencia). Así, un canal de EEG representa la señal de diferencia de potencial en el tiempo entre dos electrodos específicos. Es importante destacar que el EEG no mide el voltaje absoluto en un solo punto (lo cual físicamente no tiene sentido), sino siempre el voltaje relativo entre dos electrodos; por ello la elección del punto de referencia es crucial.

Tipos de electrodos: En EEG de superficie se emplean típicamente electrodos de disco metálico (por ejemplo, de oro o aleación de plata-cloruro de plata) que se adhieren al cuero cabelludo con pasta conductora. Estos electrodos pueden ser pasivos o activos (los activos incluyen un pequeño preamplificador en el propio sensor para reducir ruido). Habitualmente se utilizan alrededor de 19 a 21 electrodos en el montaje estándar de un EEG clínico rutinario (*Tayeb & Khoshbin, 2021*), aunque, pueden añadirse más según la necesidad (p. ej., electrodos adicionales para registro en monitoreos prolongados o montajes de alta densidad en investigación). También, existen electrodos especiales: electrodos de aguja (pequeñas agujas subdérmicas, menos comunes en EEG rutinario), electrodos esféricos o de copa, y electrodos adhesivos pregelificados. Para asegurar buena calidad de la señal, es fundamental que la impedancia de contacto de cada electrodo con la piel sea baja (idealmente $< 5\text{--}10\text{ k}\Omega$); esto se logra limpiando la piel y usando geles conductores.

Sistema 10–20 de colocación: la distribución estándar internacional de electrodos en el cuero cabelludo se denomina sistema 10–20. Esta convención estandariza la colocación de electrodos en función de distancias relativas al nasión, inión y puntos preauriculares, distribuidos en múltiplos del 10% o 20%. Cada posición está nombrada con una letra y un número: las letras indican la región cerebral subyacente (Fp = frontopolar, F = frontal, C = central, P = parietal, O = occipital, T = temporal, A = auricular o mastoidea) y el número indica el lado

(números impares = hemisferio izquierdo, números pares = hemisferio derecho, y el sufijo “z” significa posición central o media). Por ejemplo, C3 está sobre la corteza central (área sensorimotora) del lado izquierdo, y Pz es un punto parietal en la línea media. En total, el sistema estándar incluye puntos como Fp1, Fp2, F7, F8, F3, F4, C3, C4, P3, P4, O1, O2, más puntos centrales (Fz, Cz, Pz) y electrodos en mastoides o pabellones auriculares (A1, A2) que a menudo se usan como referencias. La Figura 3 muestra esquemáticamente esta disposición.




Figura 3. Esquema del sistema internacional 10–20 de colocación de electrodos EEG. Fuente: (Tayeb & Khoshbin, 2021).

En EEG clínicos típicos se utilizan de 16 a 24 canales, cada uno representando una derivación entre dos electrodos. Con los sistemas digitales modernos, estas derivaciones pueden reconfigurarse posteriormente. En este estudio se emplearon 17 canales seleccionados del sistema 10–20 incluidos en el dataset CHB-MIT, asegurando una cobertura representativa de regiones relevantes para la detección de crisis epilépticas.

Montajes de registro EEG: monopolar (referencial) vs bipolar

Al configurar un EEG, se debe escoger cómo se conectarán los electrodos entre sí para formar las derivaciones o canales. Existen dos tipos principales de montajes de registro EEG (*Tayeb & Khoshbin, 2021*):

Montaje referencial (unipolar o monopolar): cada electrodo activo en el cuero cabelludo se registra respecto a un electrodo de referencia común. Es decir, todos los canales comparten el mismo punto de referencia inactivo. Este electrodo de referencia idealmente debería captar mínimas señales cerebrales, de modo que refleje un voltaje “cero” de fondo (en la práctica no existe un punto totalmente neutro, pero se eligen ubicaciones, que introducen el menor ruido posible). Comúnmente se usan como referencia las mastoides (A1, A2), el promedio de todos los electrodos (referencia promedio), el electrodo Cz (vértice) o colocaciones extracraneales (por ejemplo, en la frente o el lóbulo de la oreja). En un montaje referencial típico, por ejemplo, podríamos tener canales F3–A1, C3–A1, O1–A1, etc., si A1 (mastoides izquierda) es la referencia. La ventaja de este montaje es que facilita identificar la amplitud absoluta de la actividad en cada región respecto al punto de referencia. Sin embargo, si la referencia recoge actividad eléctrica significativa (por ejemplo, si A1 capta señales cerebrales o ruido), esa influencia aparecerá en todos los canales. Por ello, a veces se comparan distintas elecciones de referencia, para asegurar como los hallazgos son consistentes.

Montaje bipolar: los canales se forman conectando pares de electrodos cercanos en serie, de modo que cada electrodo (excepto en los extremos) sirve a la vez como referencia de uno de sus vecinos y como activo respecto a su otro vecino. En este esquema no hay un único electrodo de referencia común, sino que se registran diferencias locales entre regiones adyacentes. Por ejemplo, en un montaje bipolar longitudinal anteroposterior (conocido como montaje “doble banana”), los canales podrían ser Fp1–F3, F3–C3, C3–P3, P3–O1 en el lado izquierdo (y análogamente en el derecho), formando cada canal con electrodos a lo largo de la línea sagital lateral de la cabeza. De esta manera, la actividad que es común a ambos electrodos de un par (por ejemplo, ruido general o actividad difusa) tiende a cancelarse, mientras que las diferencias focales se resaltan.

El montaje bipolar ofrece una mejor localización espacial de un fenómeno (pues una anomalía aparecerá invertida de fase en los dos canales adyacentes que comparten el electrodo involucrado, ayudando a “localizar” su origen entre ambos). Como inconveniente, la interpretación a veces es más compleja, y puede requerir referenciar los datos para comprobar los hallazgos.

En la práctica, durante la lectura de un EEG clínico es común revisar múltiples montajes del mismo registro (tanto referenciales como bipolares) para obtener diferentes perspectivas de la actividad eléctrica cerebral. Gracias a la digitalización, el tecnólogo o neurólogo puede reformatear el EEG y cambiar de montaje (por ejemplo, de referencial a bipolar, o a un montaje promedio) tras la adquisición, sin repetir el estudio. Esto permite detectar con mayor confianza eventos sutiles, eliminando artefactos que puedan aparecer solo en cierto montaje. En definitiva, los montajes referencial y bipolar son herramientas complementarias para el análisis exhaustivo de las señales EEG.

En este estudio se utilizaron registros del dataset CHB-MIT, el cual emplea el sistema internacional 10–20 con un número variable de canales según el paciente. Las señales multicanal se procesaron para extraer características espectrales (FFT) y tiempo-frecuencia (DWT) por canal.

2.3 Procesamiento de las señales EEG

Las señales EEG, crudas, contienen información valiosa sobre el estado cerebral, pero también incluyen artefactos (actividad no cerebral, como movimientos oculares, parpadeos, actividad muscular, interferencia eléctrica de 50/60 Hz, otro.). Además, debido a su naturaleza compleja y no estacionaria, suele ser necesario aplicar técnicas de procesamiento digital de señal para resaltar las características de interés. El procesamiento de señales EEG típicamente involucra varias etapas: (1) preprocesamiento o filtrado de las señales, (2) extracción de características relevantes en distintos dominios (tiempo, frecuencia, tiempo-frecuencia, otro.), y a

veces (3) selección de características antes de alimentar modelos de clasificación (Singh & Krishnan, 2023). A continuación, describimos brevemente algunas técnicas comunes.

Preprocesamiento: el objetivo del preprocesamiento es mejorar la calidad de la señal EEG antes del análisis principal. Esto incluye, por ejemplo:

- **Filtrado:** para eliminar componentes no deseados. Un EEG rutinario suele filtrarse con un pasa-bandas aproximadamente de 0.5–1 Hz (filtro de alta frecuencia para remover la componente DC y fluctuaciones lentísimas) hasta 50–70 Hz (filtro de baja frecuencia para suprimir el ruido de alta frecuencia, incluyendo artefactos musculares). Adicionalmente, se suele aplicar un filtro notch estrecho en 50 Hz (o 60 Hz, según el país) para atenuar la interferencia de la red eléctrica. Estos filtros preservan las bandas fisiológicas principales (delta a gamma baja) y mejoran la relación señal/ruido.
- **Rechazo de artefactos:** las señales provenientes de parpadeos, movimientos o pulsos musculares pueden confundirse con actividad cerebral lenta o rápida. Existen métodos manuales (p.ej., descartar segmentos contaminados) y automáticos para mitigar artefactos. Una técnica avanzada es la Separación de Componentes Independientes (ICA), que descompone la señal en componentes estadísticamente independientes para identificar y eliminar aquellos asociados a artefactos (como los componentes característicos de parpadeos o latidos) antes de reconstruir el EEG “limpio”. Otra estrategia es incluir canales auxiliares (como electrooculograma EOG para ojos, o electromiograma EMG para músculo) y luego restar su influencia de la señal EEG.
- **Segmentación o selección de ventanas de interés:** en muchos análisis se dividen los registros continuos en épocas breves (por ejemplo, segmentos de 1-2 segundos) para tratarlos de manera estacionaria. En detección de eventos (p. ej. detección de crisis epilépticas) puede ser útil resaltar las

secciones preictales, ictales, otro., y descartar períodos interictales prolongados sin eventos. En este estudio, se utilizaron segmentos de 1 segundo con un 50% de solapamiento, lo que permitió aumentar la sensibilidad del modelo en eventos breves.

Tras el preprocesamiento, se asume que la señal EEG está más limpia y preparada para extraer medidas cuantitativas o cualitativas que describan su contenido informativo.

Extracción de características: consiste en calcular parámetros o transformaciones de la señal EEG, que capturen patrones relevantes de manera compacta, facilitando la clasificación o interpretación. Las características pueden extraerse en diversos dominios:

- **Dominio del tiempo:** se analizan directamente las ondas EEG crudas. Características típicas incluyen medidas estadísticas (media, desviación estándar, curtosis de la señal en un periodo), potencia o energía en el dominio temporal, detección de picos o patrones transitorios específicos, duración de eventos, otro. Por ejemplo, en epilepsia puede contarse la tasa de apariciones de ciertas espigas por minuto como rasgo.
- **Dominio de la frecuencia (análisis espectral):** dado que, el EEG es una mezcla de ritmos, es muy informativo cuantificar cuánta potencia tiene la señal en cada banda de frecuencia. Para ello, se emplea la Transformada de Fourier o versiones discretas rápidas (FFT), que descomponen la señal en sus componentes sinusoidales. El resultado es un espectro de frecuencias, donde picos en ciertas bandas indican predominio de esas oscilaciones. Por ejemplo, se puede calcular la potencia espectral en bandas delta, theta, alfa, beta y gamma para distintos canales, y usar esos valores como características. En este estudio, se aplicó la FFT a cada ventana multicanal (17 canales, 100 muestras por canal) para obtener representaciones espectrales, que sirvieron como una de las entradas al modelo híbrido.

- **Dominio tiempo-frecuencia:** las crisis epilépticas y muchos eventos EEG son transitorios, es decir, sus características espectrales varían en el tiempo. Para analizar señales no estacionarias, la Transformada de Fourier por sí sola es insuficiente, porque perdería la localización temporal de las frecuencias. En su lugar, se recurre a técnicas de transformada tiempo frecuencia, entre las cuales destaca la Transformada Wavelet (ondeleta). La wavelet aplica funciones base dilatables y trasladables (en lugar de senos fijos) para descomponer la señal simultáneamente en tiempo y frecuencia. Esto permite identificar qué frecuencias ocurren en qué momentos, con resoluciones adaptativas (alta resolución temporal para componentes de alta frecuencia, y mayor resolución frecuencial para componentes de baja frecuencia, gracias a la naturaleza multi-resolución de las wavelets). En términos simples, una wavelet es una “ventana” oscilatoria corta, que se desliza sobre la señal, captando estructura local. Existen wavelets continuas (CWT) y discretas (DWT); estas últimas realizan una descomposición en subbandas anidadas.

En este trabajo, se empleó la DWT para extraer coeficientes multiescala de cada canal, resultando en una matriz de características (17 canales, 4 coeficientes) que fue usada como segunda entrada del modelo. La combinación de FFT y DWT permitió representar tanto la energía espectral como la evolución multiresolución de la actividad epiléptica (*Najafi et al., 2022*).

- **Dominio espacial:** en registros con múltiples canales, también es posible explotar la información sobre cómo las señales en diferentes electrodos se relacionan. Técnicas como mapas topográficos (brain maps) muestran la distribución espacial de la potencia en distintas bandas sobre la cabeza. Otra estrategia es calcular características de conectividad o correlación entre canales (por ejemplo, coherencia entre dos regiones en cierta banda, que indica cuánto están sincronizadas esas áreas). Estos análisis ya entran en el terreno de la neurociencia de redes y son útiles, por ejemplo, en análisis de

redes epileptogénicas o para estudiar sincronización cortical. Aunque, en este estudio no se implementaron explícitamente medidas de conectividad funcional, las redes neuronales convoluciones aplicadas por canal podrían capturar patrones espaciales relevantes mediante su entrenamiento.

2.4 Inteligencia Artificial y Aprendizaje Automático

El término Inteligencia Artificial (IA), se refiere al campo de la informática que estudia el diseño de agentes capaces de percibir su entorno y actuar racionalmente para alcanzar metas, imitando funciones cognitivas humanas; como el razonamiento, la planificación, el aprendizaje o la percepción como se observa en la Figura 4. Este campo comprende diversas áreas como los sistemas expertos, la robótica, el procesamiento de lenguaje natural y, en las últimas décadas, el aprendizaje automático (machine learning), que constituye una de sus ramas más aplicadas (Russell & Norvig, 2021).




Figura 4. Representación jerárquica de la Inteligencia Artificial y sus ramas principales. Fuente: Russell & Norvig, 2021.

El aprendizaje automático se define como la capacidad de un sistema computacional para mejorar su rendimiento en una tarea específica a través de la experiencia, sin haber sido programado explícitamente para ello. En lugar de escribir instrucciones detalladas, el enfoque consiste en entrenar modelos con datos de ejemplo para que estos infieran patrones y relaciones subyacentes. Los algoritmos de aprendizaje automático generan modelos matemáticos (como árboles de decisión, máquinas de vectores de soporte o redes neuronales), que ajustan sus parámetros para realizar tareas como clasificación, regresión o agrupamiento. Se distinguen tres tipos principales: aprendizaje supervisado (con datos etiquetados), no supervisado (con datos sin etiquetar) y semisupervisado (mixto). Estas técnicas se aplican en ámbitos tan diversos como el diagnóstico médico, la predicción financiera o el reconocimiento facial (Mitchell, 1997).

El aprendizaje profundo (deep learning), es una subcategoría del aprendizaje automático basada en redes neuronales profundas, compuestas por múltiples capas jerárquicas de unidades de procesamiento. Estas redes son capaces de aprender representaciones de alto nivel de los datos de entrada, mediante la extracción automática y progresiva de características. Por ejemplo, en tareas de visión por computadora, las capas iniciales pueden detectar bordes y contornos, mientras que las intermedias capturan formas y texturas, y las finales identifican objetos completos. Esta capacidad para abstraer información compleja ha llevado al aprendizaje profundo a alcanzar resultados sobresalientes en áreas como el procesamiento del lenguaje natural, el reconocimiento de voz y, recientemente, en el análisis automático de señales biomédicas como el electroencefalograma (Goodfellow, Bengio & Courville, 2016).

En esta investigación, se implementó un enfoque de aprendizaje profundo utilizando una arquitectura híbrida compuesta por redes neuronales convolucionales (CNN) y redes de memoria a largo corto plazo bidireccionales (BiLSTM). Esta combinación permitió aprovechar las ventajas de ambas estructuras: mientras las CNN capturan patrones locales y espaciales en la señal EEG (como bordes o transiciones abruptas), las BiLSTM procesan dependencias temporales a largo

plazo, lo que es crucial en la detección de eventos transitorios, como las crisis epilépticas. Las características extraídas mediante FFT y DWT fueron utilizadas como entradas separadas, en ramas paralelas del modelo, permitiendo un análisis simultáneo, en múltiples dominios de representación de la señal.

Arquitecturas de redes neuronales aplicadas al EEG

La naturaleza compleja, dinámica y ruidosa de las señales EEG plantea un desafío para su análisis automatizado. Afortunadamente, los avances en redes neuronales artificiales han proporcionado herramientas potentes para procesar estos datos. Las dos grandes familias de arquitecturas de redes más utilizadas en problemas con EEG son: las redes neuronales convolucionales (CNN) y las redes neuronales recurrentes (RNN), destacando dentro de estas últimas las variantes de memoria a largo corto plazo (LSTM). Además, también se han investigado enfoques híbridos que combinan CNN y RNN, buscando aprovechar las fortalezas de cada una (Roy et al., 2019).

Redes Neuronales Convolucionales (CNN): son un tipo de red profunda originalmente desarrollada para procesar datos con estructura de rejilla, como imágenes 2D, aunque también se adaptan a series temporales unidimensionales. Las CNN se caracterizan por sus capas convolucionales, donde filtros aprendibles se deslizan sobre la entrada, detectando características locales (por ejemplo, detectores de bordes en una imagen o patrones de onda en EEG), y capas de pooling, que reducen la dimensionalidad. En contextos de EEG, las CNN se han utilizado para: (a) procesar series temporales crudas de cada canal con convoluciones 1D, (b) analizar representaciones espectrales (como espectrogramas) usando convoluciones 2D, y (c) capturar relaciones espaciales entre múltiples canales.

La fortaleza de las CNN radica en su capacidad de extraer automáticamente características relevantes sin requerir ingeniería manual, además de su alta

paralelización sobre GPU, lo que las hace eficientes (Schirrmeister et al., 2017). Sin embargo, no manejan bien dependencias de largo plazo en señales temporales extensas, ya que sólo ven ventanas locales de datos.

Redes Neuronales Recurrentes (RNN) y LSTM: las RNN están diseñadas para procesar secuencias largas, integrando una forma de memoria mediante retroalimentación. Cada salida de una capa se alimenta como entrada junto al siguiente dato. Sin embargo, sufren del problema del desvanecimiento del gradiente, que limita su capacidad para aprender dependencias a largo plazo (Pascanu et al., 2013).

Esto se resolvió con las LSTM (Long Short-Term Memory), introducidas por Hochreiter y Schmidhuber (1997). Estas incorporan puertas de entrada, salida y olvido, que permiten retener o descartar información selectivamente. Las LSTM son eficaces para detectar transiciones o secuencias prolongadas, como las fases preictales del EEG, que anteceden a una convulsión (Roy et al., 2019). Estudios recientes muestran que, los modelos basados en LSTM superan en precisión a CNN puras para clasificar señales EEG con alta dependencia temporal (Najafi et al., 2022). Pese a su poder, las LSTM requieren más recursos computacionales, son menos paralelizables y más propensas al sobreajuste si el volumen de datos no es suficiente.

Modelos híbridos (CNN + LSTM y variantes): Para combinar lo mejor de ambas arquitecturas, se han propuesto modelos híbridos donde una CNN actúa como extractor inicial de características y una LSTM integra esa información en el tiempo. Este enfoque ha demostrado altos niveles de precisión en tareas como la detección binaria de epilepsia. Xu et al. (2020), propusieron un modelo CNN-1D seguido de una LSTM que alcanzó más del 99% de exactitud en el dataset de Bonn. Otros modelos utilizan estructuras paralelas (CNN y LSTM en ramas separadas), o incluso integran mecanismos de atención para enfocar el procesamiento en segmentos o canales relevantes.

Otros han incorporado además mecanismos de atención; para que la red “aprenda” a enfocarse en los canales o tiempos más relevantes. También, existen modelos híbridos paralelos (donde una rama CNN y otra LSTM procesan la señal en paralelo y luego sus representaciones se fusionan), e incluso el uso de CNN 2D en paralelo a LSTM para aprovechar mapas tiempo-frecuencia. En general, los enfoques híbridos han mostrado mejorar el rendimiento en tareas difíciles, sobre todo en clasificación multi-clase de eventos EEG, donde hay que distinguir entre múltiples tipos de patrones epilépticos o estados cognitivos. Como era previsible, combinar redes hace al modelo más pesado y complejo, por lo que exige buenos volúmenes de datos y poder de cómputo. Sin embargo, conforme aumentan los disponibles (por ejemplo, bases de EEG masivas como la del Temple University Hospital con miles de eventos) y con optimizaciones, estos modelos están demostrando ser actualmente, el estado del arte en análisis de EEG para diagnóstico asistido por IA.

En este estudio, se aplicó una arquitectura híbrida compuesta por dos ramas paralelas: una red convolucional (CNN-1D) y una red de tipo BiLSTM, como se muestra en la Figura 5, donde cada rama procesa diferentes representaciones de la señal EEG: una basada en Transformada Rápida de Fourier (FFT) y otra en Transformada Discreta de Wavelet (DWT). Esta estrategia dual permitió analizar la señal en dominios complementarios (frecuencia y tiempo-frecuencia), capturando tanto patrones espectrales como transitorios, y fusionando luego sus representaciones para mejorar la discriminación entre estados epilépticos y no epilépticos.




Figura 5. Ejemplo de arquitectura CNN-LSTM aplicada a EEG. Fuente: Roy et al., 2019.

2.5 Justificación del uso de LSTM e híbridos para el diagnóstico epiléptico mediante EEG

El diagnóstico de epilepsia mediante señales EEG representa un desafío técnico debido a la naturaleza altamente dinámica, no estacionaria y multicanal de la actividad cerebral. Estas características dificultan el análisis manual e impulsan la búsqueda de soluciones automatizadas basadas en inteligencia artificial. Las redes neuronales con memoria a largo corto plazo (LSTM), una variante de las redes recurrentes (RNN), han demostrado ser especialmente adecuadas para esta tarea, ya que pueden capturar relaciones temporales complejas presentes en secuencias prolongadas de señales.

Las LSTM se caracterizan por su capacidad para retener información a lo largo del tiempo mediante una arquitectura basada en puertas de control (entrada, salida y olvido). Esta estructura les permite detectar patrones relevantes en secuencias EEG que anteceden o acompañan eventos epilépticos. Por ejemplo, fases preictales o transiciones súbitas pueden ser aprendidas y reconocidas por una LSTM entrenada adecuadamente, incluso en medio de ruido y variabilidad interpaciente (Hochreiter & Schmidhuber, 1997).

Estudios recientes respaldan el uso de LSTM en contextos de clasificación de crisis epilépticas, mostrando su capacidad para superar modelos clásicos o incluso CNN puras en tareas donde la dimensión temporal es crítica (Roy et al., 2019; Najafi et al., 2022). Estas redes son capaces de modelar tanto señales EEG crudas como representaciones procesadas (como coeficientes de wavelets o espectros de Fourier), lo que las hace versátiles.

Sin embargo, a pesar de su efectividad, las LSTM presentan limitaciones como la alta demanda computacional, menor paralelización y sensibilidad al sobreajuste. Para mitigar estas debilidades, en esta investigación se propuso una

arquitectura híbrida que combina CNN y LSTM bidireccionales en un esquema paralelo, alimentado por dos tipos de representaciones de la señal EEG: FFT (dominio frecuencial) y DWT (dominio tiempo-frecuencia). La inclusión de CNN permite extraer automáticamente características locales relevantes en cada dominio, mientras que la BiLSTM capta dependencias temporales de largo alcance, mejorando así el rendimiento general del sistema. Esta estructura híbrida responde a la necesidad de abordar simultáneamente la complejidad espacial, temporal y espectral del EEG en contextos clínicos reales.

Además, el uso de estrategias como segmentación por ventanas con solapamiento, reducción de umbral para aumentar sensibilidad, y funciones de pérdida como Focal Loss contribuyen a optimizar la detección de eventos epilépticos, incluso en situaciones con crisis breves o baja relación señal/ruido. En conjunto, estos elementos justifican la elección y adaptación de modelos LSTM dentro de una arquitectura híbrida CNN-BiLSTM como una solución efectiva, escalable y clínicamente útil para el diagnóstico automatizado de epilepsia mediante EEG.

2.6 Variable de estudio

En esta investigación se identifican dos tipos de variables fundamentales: la variable independiente, correspondiente al modelo de red neuronal LSTM que se implementa, y la variable dependiente, que representa el rendimiento diagnóstico de dicho modelo en la detección de crisis epilépticas mediante señales EEG. Ambas variables están asociadas directamente, con los objetivos específicos del estudio, permitiendo medir su cumplimiento a través de indicadores cuantitativos.

Definición conceptual de las variables

Variable independiente: Modelo Híbrido CNN–BiLSTM (Red Neuronal de Memoria a Corto y Largo Plazo con Extracción Espacial): las redes neuronales LSTM (Long Short-Term Memory) constituyen una variante de las redes recurrentes

diseñadas para procesar datos secuenciales, capaces de retener información a largo plazo mediante mecanismos internos de memoria y puertas de control. Estas arquitecturas son especialmente eficaces, en dominios; como el análisis de series temporales, incluyendo aplicaciones biomédicas como el diagnóstico de eventos cerebrales anómalos a partir de señales EEG (Haykin, 2001; Goodfellow, Bengio & Courville, 2016).

En el presente estudio, la variable “Modelo Híbrido CNN–BiLSTM” hace referencia a una arquitectura de red neuronal profunda que integra dos componentes principales:

- (1) Capas convolucionales (CNN) aplicadas por separado a dos representaciones de las señales EEG (FFT y DWT), encargadas de extraer características espaciales relevantes.
- (2) Capas bidireccionales LSTM (BiLSTM) que procesan dichas características en el dominio temporal, permitiendo capturar dependencias tanto hacia adelante como hacia atrás en el tiempo. Esta estructura paralela y fusionada permite una representación robusta de eventos preictales y epilépticos.

Variable dependiente: Rendimiento del algoritmo: El rendimiento de un algoritmo de clasificación supervisada describe su capacidad para discriminar correctamente entre distintas clases, en este caso entre ventanas de EEG correspondientes a eventos epilépticos (crisis) y no epilépticos. Este desempeño se mide mediante métricas estándar como exactitud (accuracy), sensibilidad (recall), precisión, especificidad, y AUC-ROC, las cuales permiten evaluar tanto la eficacia global como la capacidad del modelo para detectar eventos de bajo predominio como las crisis epilépticas (Bishop, 2006; Rodríguez & Rojas, 2009). En esta investigación, se consideran dos dimensiones claves:

- Capacidad de clasificación, entendida como la habilidad del modelo para asignar correctamente etiquetas a las ventanas analizadas, especialmente frente al desbalance de clases.

- Capacidad de generalización, referida a la robustez del modelo al ser expuesto a señales nuevas o no utilizadas en el entrenamiento. Esta dimensión permite verificar la aplicabilidad del modelo en contextos clínicos reales y variados, más allá del conjunto de datos original.

Definición operacional de las variables

Modelo Híbrido CNN–BiLSTM (Red Neuronal de Memoria a Corto y Largo Plazo con Extracción Espacial): operacionalmente, la variable " Modelo híbrido CNN–BiLSTM " se implementa en Python utilizando TensorFlow y Keras. Para la dimensión extracción de características, se realiza un preprocesamiento multietapa que incluye:

- Segmentación de las señales EEG en ventanas de 10 segundos con
- Normalización de los datos por canal.
- Aplicación de transformadas FFT (frecuencia) y DWT (tiempo-frecuencia) para obtener representaciones espectrales por ventana.

Estas transformaciones generan dos conjuntos de entrada que se integran como rutas paralelas al modelo. Cada muestra de entrada tiene forma [ventanas, canales, coeficientes], adaptada a los requisitos de las capas convolucionales y recurrentes.

Para la dimensión estructura del modelo, se define una arquitectura con dos ramas:

- Una entrada CNN+BiLSTM para las características espectrales obtenidas por FFT.
- Una entrada CNN+BiLSTM separada para las características tiempo frecuencia obtenidas por DWT

Ambas ramas se combinan (concatenación) antes de pasar a capas densas con activación ReLU, Dropout del 30%, y una capa final sigmoidea.

La función de pérdida utilizada fue SigmoidFocalCrossEntropy (para enfrentar el desbalance de clases), y se empleó el optimizador Adam con tasa de aprendizaje ajustable. Los valores operacionales de los indicadores incluyen:

- Número de capas: 2 CNN + 2 BiLSTM + 2 Dense
- Unidades por capa: 32 (Conv1D), 64 (BiLSTM), 64 (Dense)
- Funciones: ReLU, Sigmoid
- Dropout: 30%

Esta estructura modular permite que el modelo aproveche la riqueza complementaria de ambas representaciones (FFT y DWT), logrando así una mayor sensibilidad en la detección de eventos ictales, incluso en ventanas muy breves.

Variable Dependiente (Rendimiento del algoritmo): para evaluar el rendimiento, se utilizan las funciones de evaluación integradas en Scikit-learn sobre los datos de prueba y validación. En la dimensión capacidad de clasificación, los indicadores se calculan, con las siguientes fórmulas:

$$\text{Accuracy: } \frac{TP+TN}{TP+TN+FP+FN} ,$$

$$\text{Recall (sensibilidad): } \frac{TP}{TP+FN} .$$

$$\text{Precisión: } \frac{TP}{TP+FP}$$

$$\text{F1-score: } 2 * \frac{\text{Precision} * \text{recall}}{\text{Precision} + \text{Recall}}$$

$$\text{Falso Positivo: } \frac{FP}{\text{Total}}$$

En la dimensión capacidad de generalización, se evalúan:

- La diferencia absoluta entre el F1-score obtenido en validación y test.
- La estabilidad del recall ante ventanas no vistas.
- La comparación entre ventanas predichas como crisis y eventos ictales reales en archivos .edf de pacientes del CHB-MIT no usados en entrenamiento.

Este análisis permite valorar si el modelo puede ser utilizado en entornos clínicos reales con nuevos pacientes Zhang et al. (2020), Sahami et al. (2020).

2.7 Tabla de variables

OBJETIVO GENERAL		Desarrollar un modelo basado en aprendizaje profundo con arquitectura LSTM extendida para el diagnóstico computacional de crisis epilépticas mediante señales EEG.	
OBJETIVOS ESPECÍFICOS	VARIABLES	DIMENSIONES	INDICADORES
Procesar señales EEG del dataset CHBMIT (Children's Hospital Boston - Massachusetts Institute of Technology) disponible en PhysioNet, mediante segmentación,	Variable independiente (Preprocesamiento del dataset CHBMIT).	Configuración temporal de las ventanas. Transformación de características.	Tamaño de ventana en segundos Grado de solapamiento entre ventanas. Aplicación de FFT
transformadas FFT y DWT para identificar patrones característicos de crisis epilépticas.	Variable dependiente (Resultado del procesamiento Dataset CHB-MIT)	Calidad del filtrado.	Aplicación de DWT Número de coeficientes extraídos Tipo de filtros (Notch, Bandpass) Frecuencias utilizadas.
Entrenar un modelo LSTM extendido (CNN + BiLSTM) que pueda aprender patrones preictales en señales EEG.	Variable independiente (Entrenamiento modelo IA)	Estructura de red neuronal. Regularización y optimización.	Tipo de capas (Conv1D, BiLSTM) Cantidad de capas Unidades por capa Tasa de Dropout Función de pérdida utilizada (e.g., focal loss) Algoritmo de optimización

Evaluar el rendimiento del modelo utilizando métricas como precisión, sensibilidad y la tasa de falsos positivos utilizando los datos del dataset CHB-MIT.	Variable dependiente (Rendimiento del algoritmo con data conocida)	Métricas de clasificación. Capacidad de detección por ventana.	Precisión Sensibilidad (Recall) F1-score AUC Porcentaje de ventanas etiquetadas correctamente Número de coincidencias con eventos ictales
Validar la capacidad de generalización del modelo sobre datos no utilizados en el entrenamiento.	Variable dependiente (Rendimiento del algoritmo con data no conocida).	Estabilidad del desempeño. Evaluación individual por archivo .	Diferencia de F1-score entre validación y test Diferencia en AUC y Recall. Presencia/ausencia de crisis detectadas Tasa de falsos negativos por archivo.

2.8 Glosario de términos

Epilepsia: Enfermedad neurológica caracterizada por una predisposición continua a generar crisis epilépticas recurrentes, acompañada de consecuencias neurobiológicas, cognitivas, psicológicas y sociales. (Sociedad Española de Neurología, 2023, Guía de Epilepsia, SEN).

Crisis epiléptica: episodio transitorio con signos y/o síntomas provocados por actividad neuronal anómala excesiva o sincronizada en el cerebro. (Sociedad Española de Neurología, 2023, Guía de Epilepsia, SEN).

Electroencefalograma (EEG): técnica de exploración funcional del sistema nervioso central que registra la actividad eléctrica cerebral en tiempo real. (RamosArgüelles et al., 2009).

Señales biomédicas: variables fisiológicas relevantes (por ejemplo, EEG o ECG), cuyo comportamiento en el tiempo puede registrarse y analizarse para evaluar el estado de salud. (Vivaldi y Maldonado, 2001).

Aprendizaje profundo (Machine Learning, ML): campo de la inteligencia artificial que permite que los sistemas aprendan patrones y realicen predicciones a partir de datos, sin ser programados explícitamente. (Mitchell, 1997).

Aprendizaje profundo (Deep Learning, DL): subcampo del aprendizaje automático basado en redes neuronales con múltiples capas ocultas, capaces de aprender representaciones jerárquicas y complejas de los datos. (Goodfellow, Bengio & Courville, 2016).

Inteligencia artificial (IA): disciplina de la informática que desarrolla sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el razonamiento, el aprendizaje o la percepción. (Russell & Norvig, 2016).

Red neuronal convolucional (Convolutional Neural Network, CNN): Arquitectura de red neuronal utilizada para el procesamiento de datos con estructura espacial o temporal, capaz de extraer automáticamente características mediante filtros convolucionales. (LeCun, Bengio & Hinton, 2015).

Red neuronal recurrente (Recurrent Neural Network, RNN): tipo de red que incorpora conexiones cíclicas para modelar secuencias y dependencias temporales en los datos. (Goodfellow et al., 2016).

Transformada Rápida de Fourier (Fast Fourier Transform, FFT): algoritmo que descompone una señal en sus componentes de frecuencia, permitiendo analizar su contenido espectral. (Cooley & Tukey, 1965).

Transformada Wavelet Discreta (Discrete Wavelet Transform, DWT): herramienta matemática que descompone una señal en distintos niveles de resolución temporal y frecuencial, útil para analizar señales no estacionarias como el EEG. (Daubechies, 1990).

CAPÍTULO 3. Marco Metodológico

3.1 Tipo y diseño de la investigación

Según Hernández-Sampieri y Mendoza (2018), la investigación aplicada es aquella orientada a resolver problemáticas prácticas mediante la aplicación del conocimiento científico en un contexto real, enlazando la teoría con un producto o solución de carácter útil.

En este mismo orden de ideas, el enfoque cuantitativo en una investigación implica la recolección y análisis de datos numéricos mediante procedimientos estadísticos y computacionales, buscando medir objetivamente los fenómenos y probar hipótesis (Hernández-Sampieri & Mendoza, 2018).

Por otra parte, un diseño no experimental se caracteriza, porque el investigador no manipula deliberadamente las variables independientes, sino que observa los fenómenos tal como ocurren en su ambiente natural para luego analizarlos. Este tipo de estudio puede llevarse a cabo, bajo un alcance transversal, es decir, recolectando los datos en un solo momento del tiempo con el propósito de describir variables y analizar sus interrelaciones en ese punto (Hernández, Fernández & Baptista, 2014).

En consideración a lo anterior, el estudio realizado se clasifica como investigación aplicada con enfoque cuantitativo, de diseño no experimental y alcance transversal. Esto se debe a varias razones. En primer lugar, es aplicada porque su finalidad es desarrollar una solución tecnológica práctica –un modelo de inteligencia artificial– para mejorar la detección de crisis epilépticas, abordando un problema concreto de la salud pública. Además, el enfoque es cuantitativo, porque se trabajó con señales EEG numéricas y se aplicaron métodos computacionales y estadísticos para extraer información y evaluar el desempeño del modelo, cuantificando resultados en forma de métricas de clasificación.

En segundo lugar, tiene un diseño no experimental dado que no se manipularon variables independientes ni se asignaron aleatoriamente sujetos a grupos; el trabajo se basó en la observación y análisis de datos EEG existentes, sin

intervención sobre los pacientes o las condiciones de registro. Asimismo, el diseño es de corte transversal, ya que los datos se recolectaron de una base disponible en un único intervalo de tiempo (registros históricos), sin dar seguimiento longitudinal a los pacientes.

3.2 Población y muestra

La población objetivo de la investigación corresponde a los registros de EEG de pacientes epilépticos disponibles, en la base de datos pública CHB-MIT (Children's Hospital Boston – MIT). Dicha base, accesible a través de PhysioNet, contiene aproximadamente 23 casos de pacientes pediátricos con epilepsia, con largas grabaciones de EEG multicanal muestreadas típicamente a 256 Hz. Para el presente estudio se extrajo una muestra de ocho (8) pacientes seleccionados mediante muestreo no probabilístico por conveniencia. Según Otzen y Manterola (2017), este tipo de muestreo se caracteriza por seleccionar los casos más accesibles o disponibles para el investigador, siendo una estrategia común cuando se trabaja con datos secundarios o registros ya existentes, como en este caso.

La elección de los casos en la base de datos antes mencionada, se basó en la disponibilidad y calidad de sus registros: de cada uno se tomaron siete (7) pacientes de EEG (grabaciones) que cumplieran con los criterios necesarios, de los cuales 4 contienen al menos una crisis epiléptica anotada y tres (3) corresponden a segmentos sin crisis. Este criterio de selección intencional permitió disponer de un conjunto de datos manejable y relativamente equilibrado en cuanto a la presencia/ausencia de eventos epilépticos por paciente, garantizando a la vez que los canales de EEG fueran comparables entre sí (se trabajó únicamente con los 17 canales comunes a todos los casos seleccionados).

Si bien, la muestra no es aleatoria ni representativa de toda la población de pacientes, este muestreo por conveniencia se consideró adecuado dadas las características del proyecto. Según Hernández-Sampieri & Mendoza (2018), es

común recurrir a datos disponibles de buena calidad para desarrollar y probar la solución propuesta, más que buscar una generalización estadística. La muestra aprovechó los datos existentes más relevantes para los fines del modelo, cumpliendo con los requisitos de tamaño y confiabilidad necesarios para el entrenamiento y la evaluación del sistema de detección.

3.3 Procedimiento de la investigación

El procedimiento seguido en esta investigación responde a un enfoque cuantitativo de carácter aplicado, con diseño no experimental y transversal, orientado al desarrollo y validación de un modelo computacional; para la detección automatizada de crisis epilépticas a partir de señales EEG. A continuación, se describen las etapas fundamentales, que guiaron la ejecución del estudio:

Planteamiento del problema: se identificó la necesidad de optimizar el diagnóstico clínico de la epilepsia mediante herramientas automatizadas, que permitan detectar eventos ictales con alta precisión a partir de señales electroencefalográficas (EEG). El problema central consistió en diseñar un modelo computacional capaz de analizar registros EEG reales y detectar la presencia de crisis, minimizando los falsos negativos, que comprometen la utilidad clínica del sistema. Se definieron objetivos específicos orientados al preprocesamiento, segmentación, extracción de características, diseño e implementación del modelo de red neuronal, y evaluación del rendimiento sobre pacientes no vistos.

Revisión de la literatura: durante el desarrollo de esta investigación se llevó a cabo una revisión sistemática y exhaustiva de fuentes académicas relacionadas con el diagnóstico de epilepsia mediante señales EEG y técnicas de inteligencia artificial. Se consultaron un total de 56 referencias, de las cuales 27 corresponden a artículos científicos indexados en revistas internacionales, 8 son tesis académicas (de maestría, licenciatura y doctorado), 6 corresponden a libros especializados en fisiología, inteligencia artificial o aprendizaje automático, y 15 son documentos

técnicos, informes institucionales o sitios académicos verificados. Esta revisión permitió establecer un marco teórico sólido en torno al uso de arquitecturas como LSTM, CNN y modelos híbridos (CNN+BiLSTM), así como al procesamiento espectral y tiempo-frecuencia de señales EEG mediante técnicas como la Transformada Rápida de Fourier (FFT) y la Transformada Wavelet Discreta (DWT). También, se analizaron investigaciones recientes que abordan el desbalance de clases, el preprocesamiento avanzado de señales biomédicas, y estrategias de validación cruzada para garantizar generalización. Los resultados de esta revisión fundamentan tanto la selección del dataset CHB-MIT como el diseño de la arquitectura dual empleada en este estudio, y sitúan el presente trabajo dentro de la línea de investigaciones actuales sobre sistemas de diagnóstico asistido por inteligencia artificial.

Tipo y diseño de investigación: la presente investigación se clasifica como aplicada, ya que su objetivo es la creación de un sistema práctico de apoyo al diagnóstico. Se adopta un diseño no experimental de tipo transversal, pues no se manipularon deliberadamente las variables, sino que se observó y modeló el comportamiento de las señales EEG en un único punto temporal por cada segmento. Este diseño es apropiado para estudios computacionales con datos ya existentes y etiquetados. El enfoque metodológico fue cuantitativo, basado en el análisis de datos numéricos, entrenamientos supervisados y evaluación mediante métricas estadísticas.

Selección de la muestra: la muestra estuvo compuesta por registros de EEG extraídos de la base de datos CHB-MIT, seleccionados mediante un muestreo no probabilístico por conveniencia, dada la disponibilidad de archivos y la calidad de las anotaciones ictales. Se utilizaron ocho(8) pacientes, con siete (7) archivos por paciente (4 con crisis y 3 sin crisis), lo que permitió construir una base equilibrada en términos de presencia y ausencia de eventos. Cada archivo contenía múltiples canales EEG con una frecuencia de muestreo de 256 Hz y anotaciones clínicas verificadas por expertos. Esta base fue recopilada en el Hospital Infantil de Boston bajo consentimiento informado y publicada de forma anonimizada en PhysioNet,

eliminando toda información personal identificable. Por tratarse de un dataset público con fines investigativos, no se requiere aprobación adicional por parte de un comité de bioética, para su uso en estudios como el presente.

Diseño de la propuesta: el sistema desarrollado fue estructurado como un pipeline secuencial compuesto por las siguientes etapas: adquisición de datos, preprocesamiento, segmentación, extracción de características, modelado, entrenamiento y evaluación. Se diseñaron diagramas de bloques, esquemas de arquitectura neuronal, tablas de hiperparámetros y flujos de datos que estructuran el funcionamiento completo del modelo. El proyecto fue desarrollado íntegramente en Python sobre Google Colab, utilizando recursos de GPU para acelerar el entrenamiento. La propuesta fue validada con métricas objetivas sobre datos clínicos reales, cumpliendo con los estándares metodológicos del campo.

Informe de resultados: finalmente, se elabora un informe integral que recoge cada una de las etapas del estudio, desde la formulación del problema y los objetivos hasta el diseño metodológico, el desarrollo del modelo, los hallazgos obtenidos y las conclusiones. La estructura del documento responde a los lineamientos definidos por la institución académica correspondiente, asegurando coherencia formal y rigurosidad científica.

4. Diseño de la propuesta

4.1 Introducción

El desarrollo del presente trabajo se fundamenta en la implementación de un sistema automatizado para la detección de crisis epilépticas a partir de señales EEG multicanal, utilizando técnicas de inteligencia artificial. El enfoque planteado busca resolver el problema de diagnóstico asistido en pacientes con epilepsia, reduciendo la carga manual del análisis de registros electroencefalográficos, y mejorando la sensibilidad del proceso de detección.

Con este objetivo, se diseñó e implementó un modelo de red neuronal profunda híbrido, basado en una arquitectura CNN + BiLSTM con entradas duales, capaz de integrar características espectrales y tiempo-frecuencia obtenidas mediante transformadas FFT y DWT respectivamente. Este diseño permite que el sistema aproveche tanto la información global de las bandas de frecuencia (captada por la FFT), como las transiciones locales no estacionarias (resaltadas por la DWT), lo cual resulta especialmente relevante en la detección de eventos ictales que presentan cambios bruscos en el tiempo.

El sistema propuesto fue entrenado utilizando señales EEG reales provenientes de la base de datos CHB-MIT, compuesta por registros de pacientes pediátricos con epilepsia. A partir de estos registros, se seleccionaron múltiples archivos por paciente, incluyendo episodios con y sin crisis, lo cual permitió construir un conjunto de datos representativo para el entrenamiento supervisado. Las señales fueron segmentadas en ventanas de 10 segundos con solapamiento de 5 segundos, permitiendo así abordar el problema como una clasificación binaria ventana a ventana, donde cada segmento era etiquetado como “crisis” o “no crisis” según las anotaciones oficiales.

Durante el procedimiento metodológico, se consideraron todas las fases necesarias para garantizar la robustez del modelo: preprocesamiento de las señales, extracción de características, creación del dataset balanceado, diseño e implementación del modelo, entrenamiento supervisado, evaluación mediante métricas especializadas, y validación con datos de pacientes no utilizados durante el entrenamiento. Este flujo de trabajo se resume a través del diagrama presentado en la Figura 6, donde se observan todas las etapas, que componen el procedimiento, desde la adquisición de datos hasta la evaluación del modelo.




Figura 6. Diagrama en bloque del flujo metodológico propuesto.

Parámetros iniciales y herramientas

Para el desarrollo e implementación del sistema de detección de crisis epilépticas a partir de señales EEG, se empleó un entorno de programación en Python basado en Google Colab, el cual permite ejecutar código en la nube con acceso gratuito a unidades de procesamiento gráfico (GPU). Esta plataforma fue elegida por su compatibilidad con librerías científicas, su capacidad de almacenamiento integrado con Google Drive y su soporte para experimentación reproducible en proyectos de investigación biomédica.

Durante el diseño y ejecución del modelo se integraron diversas herramientas computacionales especializadas en procesamiento de señales biomédicas, transformación espectral y modelado con redes neuronales profundas. La siguiente

tabla resume las principales librerías utilizadas, junto con su propósito dentro del flujo metodológico:

Tabla 1. Librerías empleadas y su función principal

Librería	Versión	Función
NumPy	1.24.3	Manipulación de arrays multidimensionales y cálculos numéricos generales.
MNE	1.5.0	Lectura, preprocesamiento y filtrado de señales EEG en formato .edf.
PyWavelets	1.4.1	Cálculo de la Transformada Discreta de Wavelet (DWT) para análisis tiempo-frecuencia.
TensorFlow	2.15.0	Creación y entrenamiento del modelo de red neuronal híbrido CNN-BiLSTM.
Keras	Incluido en TF	Implementación modular de capas y arquitecturas de red.
Matplotlib / Seaborn	3.7.1 / 0.12.2	Visualización de curvas de entrenamiento, matrices de confusión y resultados.
Scikit-learn	1.3.0	Evaluación de métricas de clasificación: accuracy, recall, precisión, AUC.

Todas estas librerías fueron utilizadas sobre el entorno de ejecución de Google Colab con backend Python 3.11, habilitando GPU para acelerar el entrenamiento de redes neuronales recurrentes profundas. El acceso a las señales EEG del dataset CHB-MIT se gestionó mediante integración con Google Drive, lo que facilitó el manejo eficiente de archivos .edf y de los arrays .npy generados tras cada etapa del flujo.

4.2 Preprocesamiento de señales EEG

El preprocesamiento de las señales EEG es una etapa crítica, que garantiza la calidad del análisis posterior, eliminando artefactos y estandarizando los datos para su procesamiento automático. En este estudio, se aplicó una secuencia de pasos sistemáticos utilizando las herramientas MNE, NumPy y funciones propias del flujo de trabajo.

Filtrado: se aplicaron dos tipos de filtros:

- Filtro Notch a 60 Hz: elimina la interferencia proveniente de la red eléctrica, típica en entornos hospitalarios, sin afectar las bandas cerebrales.
- Filtro paso banda 0.5–40 Hz: conserva las bandas fisiológicas cerebrales (delta, theta, alfa, beta y gamma baja), eliminando frecuencias no informativas por debajo de 0.5 Hz y ruidos de alta frecuencia por encima de 40 Hz.

Normalización: cada canal EEG fue normalizado mediante Z-score (restando la media y dividiendo por la desviación estándar) para asegurar que las diferencias de amplitud entre pacientes no afectarán la detección. Esto, también reduce el sesgo durante el entrenamiento del modelo.

Canales utilizados: se seleccionaron los 17 canales comunes a todos los registros procesados:

['FP1-F7', 'F7-T7', 'T7-P7', 'P7-O1', 'FP1-F3', 'F3-C3', 'C3-P3', 'P3-O1', 'FP2-F4', 'F4-C4', 'C4-P4', 'P4-O2', 'FP2-F8', 'F8-T8', 'T8-P8', 'FZ-CZ', 'CZ-PZ']

Aquellos canales, que no estaban presentes en algún archivo fueron excluidos de forma consistente para mantener una estructura uniforme en todo el conjunto de datos.

Segmentación en ventanas: las señales preprocesadas se dividieron en segmentos fijos de 10 segundos de duración (2560 muestras), con un solapamiento de 5 segundos entre ventanas consecutivas como se muestra en la Figura 7. Esta técnica, conocida como ventanas deslizantes, permite incrementar el número de

muestras disponibles para el modelo, mejorar la sensibilidad a eventos de corta duración y generar un conjunto más robusto para clasificación binaria.

A cada ventana se le asignó una etiqueta binaria (1 = crisis, 0 = no crisis), según su coincidencia temporal con los eventos ictales anotados en el dataset original.



Figura 7. Esquema de segmentación en ventanas.

En la siguiente imagen se muestra cómo las ventanas de EEG se extraen con traslape sobre la señal continua: cada ventana tiene 10 segundos, desplazándose 5 segundos a la derecha en cada paso.

Extracción de características

Tras segmentar las señales EEG en ventanas de 10 segundos (2560 muestras por canal), se aplicaron dos técnicas complementarias de extracción de características para capturar información tanto frecuencial pura como tiempo frecuencia localizada, alimentando posteriormente una arquitectura dual en paralelo:

Transformada Rápida de Fourier (FFT): la Transformada Rápida de Fourier se utilizó para descomponer cada segmento en sus componentes sinusoidales, obteniendo un espectro de frecuencias por canal. La FFT permite representar la distribución de energía en distintas bandas frecuenciales (delta, theta, alfa, beta, gamma baja), lo cual es útil para detectar picos o patrones rítmicos característicos de actividad epiléptica.

- Se aplicó la FFT sobre cada uno de los 17 canales.
- Se retuvieron los primeros 100 coeficientes del espectro, que concentran la mayor parte de la energía útil.
- Esto genera un tensor de entrada con forma: $X_{fft}.shape = (n_{ventanas}, 17, 100)$

Transformada Discreta Wavelet (DWT): La DWT (wavelet de Daubechies 'db4', nivel 3) permite una descomposición jerárquica de la señal EEG, capturando patrones transitorios como descargas epilépticas, que cambian con el tiempo. Esta técnica supera la limitación de la FFT de asumir estacionariedad.

- Se extrajo la media absoluta de los coeficientes de cada subbanda por canal.
- Esto genera una matriz resumen de cuatro (4) coeficientes por canal, manteniendo la estructura temporal y espacial.
- Resultado: $X_{dwt}.shape = (n_{ventanas}, 17, 4)$

Justificación del uso conjunto

1. La FFT permite capturar picos espectrales claros, como las ondas espiga en crisis generalizadas.
2. La DWT detecta eventos abruptos en el tiempo, como el inicio de una descarga.
3. Al combinar ambas técnicas, se obtiene un conjunto de características robusto y complementario, que refleja mejor la naturaleza compleja y no estacionaria de las señales EEG epilépticas.

Tabla 2 Dimensiones de salida.

Técnica	Forma de salida	Detalle
FFT	(5567, 17, 100)	100 coeficientes de frecuencia por canal
DWT	(5567, 17, 4)	Media absoluta de coeficientes por canal y nivel (nivel 3)

Creación del dataset balanceado

Uno de los principales desafíos en la detección automática de crisis epilépticas es el fuerte desbalance de clases presente en los datos originales. Las crisis representan eventos muy breves dentro de largas grabaciones de EEG, esto provoca que el número de ventanas etiquetadas como no crisis sea considerablemente superior al de ventanas con crisis. Este fenómeno genera un problema conocido como sesgo de clase mayoritaria, que puede llevar al modelo a aprender a predecir mayormente la clase negativa (no crisis) para optimizar métricas como la exactitud, sacrificando la sensibilidad.

Para mitigar este sesgo, se construyó un conjunto balanceado binario 1:10, consistente en:

567 ventanas etiquetadas como crisis (clase 1)

5000 ventanas seleccionadas aleatoriamente de la clase no crisis (clase 0)

Esta proporción fue elegida para mantener una presencia significativa de la clase minoritaria sin sacrificar completamente la representatividad de la clase mayoritaria, y se alinea con prácticas comunes en investigaciones recientes sobre clasificación de EEG con crisis poco frecuentes. El subconjunto de ventanas no crisis fue extraído de manera aleatoria mediante muestreo estratificado, asegurando una diversidad de pacientes y segmentos temporales.

Este balance fue aplicado antes del entrenamiento del modelo, y su estructura final quedó conformada como:

Clase	Cantidad de muestras	Porcentaje aproximado
No crisis (0)	5000	89.8%
Crisis (1)	567	10.2%
Total	5567	100%

Tabla 3. Cantidad de muestra y su respectivo porcentaje.

La proporción 1:10 entre ventanas etiquetadas como crisis y no crisis fue seleccionada como un compromiso entre realismo clínico y viabilidad técnica. Las crisis epilépticas son eventos poco frecuentes en registros EEG prolongados, representando en muchos casos menos del 1% del tiempo total. Por tanto, un modelo entrenado con la distribución original estaría sesgado hacia la clase mayoritaria (no crisis), reduciendo su sensibilidad. A la vez, un balance 1:1 artificial podría inducir sobreajuste y una alta tasa de falsos positivos, no deseable en contextos clínicos.

La proporción elegida permite incrementar la representación de la clase minoritaria sin distorsionar completamente la naturaleza del problema. Esta estrategia ha sido utilizada en estudios recientes sobre detección de crisis y otras anomalías médicas poco frecuentes, ya que mejoras métricas como el F1-score y AUC sin comprometer la especificidad. En este trabajo, el balance 1:10 facilitó el entrenamiento de un modelo sensible y clínicamente viable, capaz de detectar patrones preictales con un bajo nivel de falsas alarmas.

4.3 Estructura del modelo CNN + BiLSTM de entrada dual

El modelo diseñado corresponde a una arquitectura híbrida con doble entrada, compuesta por dos ramas paralelas: una procesando características extraídas mediante FFT y otra con DWT. Esta decisión de diseño se basa en la

complementariedad entre ambas técnicas: la FFT capta información global de frecuencia, mientras que la DWT representa patrones transitorios localizados en el tiempo y la frecuencia, típicos en eventos epilépticos, ver esquema en la Figura 8 donde se observa la arquitectura del modelo empelado.

Cada rama tiene la siguiente estructura:

- Una capa convolucional 1D (Conv1D), que actúa como extractor local de características.
- Una capa Bidireccional LSTM, que modela dependencias temporales hacia el pasado y futuro.

Luego, ambas salidas se concatenan y pasan por capas densas, con activación ReLU y un Dropout para evitar sobreajuste. Finalmente, se genera una salida binaria mediante una función sigmoide.

Justificación de diseño:

Separar ramas permite extraer lo mejor de cada tipo de representación.

BiLSTM ofrece contexto temporal bidireccional, esencial en señales EEG.

Entrada dual mejora la discriminación entre clases con patrones espectrales complejos y eventos cortos.




Figura 8. Arquitectura del modelo CNN + BiLSTM con entradas duales.

4.4 Entrenamiento del modelo

Una vez generado el conjunto balanceado con características FFT y DWT por segmento EEG, se dividieron los datos en tres subconjuntos:

- **70% para entrenamiento**
- **15% para validación**
- **15% para prueba final**

Esta partición se realizó de forma estratificada, garantizando que tanto las ventanas con crisis como las sin crisis estuvieran representadas en cada subconjunto. El objetivo fue entrenar el modelo CNN + BiLSTM en un entorno supervisado, evaluando su rendimiento en datos no vistos durante cada época y evitando así sobre ajuste.

Estrategias de entrenamiento: se implementaron dos técnicas clave de control de sobre entrenamiento:

- **EarlyStopping:** detiene el entrenamiento automáticamente si la pérdida en el conjunto de validación no mejora tras 10 épocas consecutivas.
- **ReduceLROnPlateau:** reduce dinámicamente la tasa de aprendizaje si la métrica de validación se estanca, lo que facilita una convergencia más precisa en las últimas etapas.

Configuración técnica:

- **Función de pérdida:** se utilizó la pérdida binaria por entropía cruzada (binary_crossentropy), adecuada para tareas de clasificación binaria.
- **Optimizador:** Adam con tasa de aprendizaje inicial de $1e-4$, por su estabilidad y velocidad en problemas con datos ruidosos.
- **Métrica principal:** accuracy y métricas derivadas (evaluadas posteriormente).

Validación con datos no vistos

Para validar la capacidad de generalización del modelo CNN + BiLSTM propuesto, se diseñó una evaluación específica sobre archivos de EEG de pacientes no utilizados en el entrenamiento. Esta estrategia busca simular condiciones reales donde el modelo se enfrenta a datos clínicos completamente nuevos y evaluar si conserva su rendimiento diagnóstico.

Evaluación archivo por archivo: cada archivo .edf de los pacientes seleccionados fue procesado individualmente. El procedimiento consistió en:

- Aplicar el preprocesamiento completo (filtrado, normalización, segmentación).
- Extraer las características FFT y DWT por ventana.

- Realizar la predicción binaria por ventana con el modelo previamente entrenado.
- Comparar los segmentos predichos, como crisis, con las anotaciones reales disponibles en la base CHB-MIT.

Tabla resumen por paciente: se generó una tabla de resultados con los siguientes campos por archivo:

- Número total de ventanas
- Número de ventanas detectadas como crisis
- Porcentaje de detección
- Número de coincidencias reales con eventos ictales

Este análisis permitió evaluar no solo si el modelo detecta eventos convulsivos, sino también cuán bien coinciden esas detecciones con los eventos reales registrados.

CAPÍTULO 4. ANÁLISIS DE RESULTADOS

5.1 Introducción

En este capítulo se presentan de forma organizada, los hallazgos obtenidos en la investigación, referentes al diagnóstico computacional de crisis epilépticas mediante señales EEG del dataset CHB-MIT. Se describe primero qué se encontró en los datos, seguido de un análisis crítico de su significado en contexto. El propósito es dar respuesta al objetivo específico de la tesis, mostrando cómo el modelo profundo híbrido CNN-BiLSTM logró detectar eventos epilépticos en las señales EEG. Conforme a lineamientos metodológicos, se separa claramente la presentación objetiva de resultados de su interpretación. Es decir, inicialmente se reportan las medidas de desempeño del modelo y las evidencias cuantitativas sin emitir juicios, y posteriormente, en la discusión, se interpretan y contextualizan estos hallazgos en relación con los objetivos y trabajos previos.

5.2 Preprocesar señales EEG del dataset CHB-MIT (Children's Hospital Boston - Massachusetts Institute of Technology) disponible en PhysioNet, mediante segmentación, transformadas FFT y DWT para identificar patrones característicos de crisis epilépticas.

El primer objetivo específico consistió en transformar las señales EEG multicanal del dataset CHB-MIT en representaciones numéricas significativas, aptas para el entrenamiento de modelos de aprendizaje profundo. Este proceso incluyó filtrado, segmentación, normalización y extracción de características mediante transformadas FFT y DWT, como se ilustra en el diagrama de flujo de la Figura 9.




Figura 9. Diagrama del flujo de preprocesamiento aplicado sobre las señales EEG del dataset CHB-MIT.

Para evaluar el efecto del proceso de filtrado digital sobre las señales EEG originales, se seleccionó un segmento representativo del canal FP2–F8. En la Figura 10 se compara la señal cruda (sin procesamiento) con la señal procesada mediante dos etapas consecutivas de filtrado: un filtro notch centrado en 60 Hz, utilizado para eliminar la interferencia de red eléctrica, y un filtro paso banda de 0.5 a 40 Hz, diseñado para preservar las frecuencias de interés neurofisiológico, suprimiendo componentes de baja y alta frecuencia irrelevantes o ruidosos.

El resultado evidencia una atenuación notable del ruido de alta frecuencia y una mayor suavidad en la traza filtrada, manteniendo la morfología general de la señal cerebral. Esta depuración mejora significativamente la calidad de los datos de entrada al modelo de aprendizaje profundo, permitiendo que las redes neuronales operen sobre señales más limpias y representativas de la actividad cerebral real.




Figura 10. Comparación entre señal EEG cruda y señal filtrada en el canal FP2–F8.

Posteriormente, se llevó a cabo la transformación espectral mediante la transformada rápida de Fourier (FFT). Esta técnica permitió convertir cada ventana temporal en su representación de frecuencia, evidenciando que, en registros sin crisis, la energía se concentra principalmente en bandas bajas (< 10 Hz), típicas de la actividad fisiológica normal. Esta información resultó útil para contrastar con los patrones extraídos por la DWT en escenarios con crisis, aportando una visión complementaria desde el dominio frecuencial.

Complementariamente, se aplicó la transformada wavelet discreta (DWT) para capturar componentes transitorios y localizados en el tiempo, característicos de eventos epilépticos. En la Figura 11 se muestran los coeficientes promedio absolutos por canal (eje vertical) y por nivel de descomposición (eje horizontal), obtenidos a partir de un segmento con crisis.

En el mapa de calor se observan cuatro columnas correspondientes a A3 (aproximación de tercer nivel) y a los detalles D3, D2 y D1.

- A3 concentra la energía de las bajas frecuencias (oscilaciones lentas y de gran amplitud), mientras que los detalles representan componentes progresivamente más rápidas.
- Los valores numéricos indican el promedio absoluto del coeficiente; colores más cálidos reflejan mayor intensidad.

Se aprecia que A3 presenta las intensidades más altas, especialmente en canales como CZ-PZ (7.86×10^{-5}), P4-O2 (7.20×10^{-5}) y FZ-CZ (6.68×10^{-5}), lo que indica que durante la crisis estos electrodos captaron actividad de alta amplitud y baja frecuencia, patrón característico de episodios ictales. Este comportamiento es consistente con la propagación de la crisis en la región centro-parietal y occipital derecha.




Figura 11. Mapa de calor de coeficientes promedio DWT por canal.

Finalmente, para validar visualmente la ocurrencia del evento ictal, se graficó un segmento multicanal de 125 segundos del archivo chb01_04.edf, en el cual se anotaron el inicio y el fin clínico de la crisis. La Figura 12 muestra cuatro canales seleccionados, donde se aprecian claramente alteraciones morfológicas y oscilaciones de mayor amplitud en el periodo ictal, mostrando inicio (verde) y fin (rojo) del evento en seis canales. Estas diferencias son más visibles tras el filtrado, confirmando la eficacia del preprocesamiento.

Figura 4.2b (extendida) - Señales cruda y filtrada con inicio y fin de crisis (125 s)




Figura 12. Señales EEG crudas y filtradas durante una crisis.

Justificación del cumplimiento del objetivo: el proceso de preprocesamiento implementado permitió la conversión sistemática de señales EEG crudas en un conjunto de datos estructurado, balanceado y enriquecido con características relevantes tanto en el dominio de la frecuencia (FFT), como en el dominio tiempo-frecuencia (DWT). Se preservaron los componentes fisiológicos esenciales mediante filtrado selectivo, y se evidenció la diferenciación entre señales normales y con crisis. Por tanto, se considera que este objetivo fue plenamente alcanzado, generando insumos adecuados para la etapa de entrenamiento del modelo.

5.3 Entrenar un modelo LSTM extendido (CNN + BiLSTM) que pueda aprender patrones preictales en señales EEG.

Para cumplir con el segundo objetivo específico, se diseñó y entrenó un modelo de aprendizaje profundo con arquitectura híbrida, que combina redes

convolucionales (CNN) y redes bidireccionales de memoria a largo y corto plazo (BiLSTM), utilizando como entrada dos representaciones complementarias: transformada rápida de Fourier (FFT) y descomposición por wavelets (DWT). Esta arquitectura permite capturar tanto características frecuenciales locales como patrones temporales de largo alcance presentes en las señales EEG.

Capa (tipo)	Forma de salida	Nº de parámetros	Conectada a
fft_input (Capa de entrada)	(None, 17, 100)	0	-
dwt_input (Capa de entrada)	(None, 17, 4)	0	-
conv1d (Conv1D)	(None, 17, 32)	9,632	fft_input[0][0]
conv1d_1 (Conv1D)	(None, 17, 32)	416	dwt_input[0][0]
bidirectional (Bidireccional)	(None, 17, 128)	49,664	conv1d[0][0]
bidirectional_1 (Bidireccional)	(None, 17, 128)	49,664	conv1d_1[0][0]
global_max_pooling1d	(None, 128)	0	bidirectional[0]
global_max_pooling1d_1	(None, 128)	0	bidirectional_1[0]
concatenate (Concatenar)	(None, 256)	0	global_max_pooling1d + global_max_pooling1d_1
dense (Densa)	(None, 64)	16,448	concatenate[0][0]
dropout (Abandono)	(None, 64)	0	dense[0][0]
dense_1 (Densa)	(None, 1)	65	dropout[0][0]

Tabla 4. Arquitectura del modelo.

La tabla 4 ilustra la estructura general del modelo CNN + BiLSTM implementado. Como se observa, la arquitectura cuenta con dos ramas paralelas de entrada: una para los coeficientes FFT con forma (17,100)(17, 100)(17,100), y otra para los coeficientes DWT con forma (17,4)(17, 4)(17,4), correspondientes a 17 canales EEG. Cada rama se procesa de forma independiente a través de una capa

convolucional 1D, seguida por una capa bidireccional BiLSTM. Posteriormente, las salidas son condensadas mediante *global max pooling* y concatenadas. Finalmente, se aplican capas densas con activación ReLU, regularización por *dropout* y una capa de salida con activación sigmoideal.

Este diseño resultó en un total de **125,889 parámetros entrenables**, con una arquitectura optimizada para aprendizaje supervisado binario.




Figura 13. Curva de pérdida en entrenamiento y validación.

La Figura 13 presenta la evolución de la función de pérdida (*loss*) durante las 50 épocas de entrenamiento. Se observa un descenso sostenido tanto en el conjunto de entrenamiento como en validación, lo que indica un aprendizaje progresivo y efectivo. La ausencia de incrementos pronunciados en la pérdida de validación sugiere que el modelo no incurrió en sobreajuste.

Época	Tiempo (s)	Accuracy Entrenamiento	Accuracy Validación
1	9.27	0.8328	0.8982
2	1.14	0.9014	0.8982
3	1.14	0.9031	0.9018
4	1.14	0.9074	0.9305
5	1.14	0.9298	0.9401
6	1.14	0.9407	0.9401
7	1.14	0.9358	0.9377
8	1.14	0.9465	0.9401
9	1.14	0.9393	0.9353
10	1.14	0.9421	0.9377
11	1.14	0.9391	0.9377
12	1.14	0.9446	0.9353
13	1.14	0.9425	0.9413
14	1.14	0.9484	0.9425
15	1.14	0.9535	0.9425
16	1.14	0.9464	0.9413
17	1.14	0.9476	0.9413
18	1.14	0.9586	0.9425
19	1.14	0.957	0.9413
20	1.14	0.9537	0.9389
21	1.14	0.9539	0.9401
22	1.14	0.9574	0.9425
23	1.14	0.9627	0.9425
24	1.14	0.9591	0.9437
25	1.14	0.9662	0.9413
26	1.14	0.9577	0.9449
27	1.14	0.9697	0.9461
28	1.14	0.9653	0.9449
29	1.14	0.971	0.9377
30	1.14	0.9714	0.9437
31	1.14	0.9781	0.9449
32	1.14	0.974	0.9461
33	1.14	0.9765	0.9449

34	1.14	0.9757	0.9425
35	1.14	0.9791	0.9437
36	1.14	0.9808	0.9449
37	1.14	0.981	0.9413
38	1.14	0.9772	0.9437
39	1.14	0.9799	0.9425
40	1.14	0.9796	0.9413
41	1.14	0.9806	0.9461
42	1.14	0.9831	0.9413
43	1.14	0.9837	0.9413
44	1.14	0.9857	0.9413
45	1.14	0.9853	0.9377
46	1.14	0.9864	0.9377
47	1.14	0.9885	0.9425

Tabla 5. Precisión por época y tiempo.

La Tabla 5 resume los valores de *accuracy* obtenidos en cada una de las 50 épocas de entrenamiento y validación. Se incluyó además el tiempo por época, lo que permite observar la eficiencia del entrenamiento. Cabe destacar que, no se superó el límite de 50 épocas debido a la incorporación del callback *EarlyStopping*, el cual se activa en caso de que la pérdida de validación deje de mejorar. Entrenado en un tiempo de 61.71 segundos,

5.4 Evaluar el rendimiento del modelo utilizando métricas como precisión, sensibilidad y la tasa de falsos positivos utilizando los datos del dataset CHB-MIT.

El tercer objetivo específico se orientó a evaluar cuantitativamente el rendimiento del modelo CNN + BiLSTM utilizando métricas, estándar de clasificación binaria aplicadas a un conjunto de prueba extraído del dataset CHB-MIT. Esta evaluación busca determinar la capacidad real del modelo para discriminar entre ventanas EEG con actividad preictal y aquellas correspondientes a actividad normal, con especial atención en minimizar los falsos positivos y maximizar la sensibilidad.

Para ello, se utilizó un subconjunto del dataset reservado exclusivamente para pruebas. Estas señales no fueron vistas por el modelo durante el aprendizaje ni la validación, por lo que permiten una estimación objetiva de su comportamiento ante nuevos datos.

Resultados obtenidos: los resultados fueron altamente satisfactorios, mostrando un modelo robusto y equilibrado en la tabla 6:

Métrica	Valor obtenido
Precisión (Accuracy)	95.45%
Sensibilidad (Recall)	69.41%
Especificidad	98.4%
Tasa de falsos positivos (FPR)	1.6%
Precisión positiva (precisión)	83.10%
F1-score (Crisis)	0.756
Área bajo curva ROC (AUC)	0.94

Tabla 6. Métricas de Clasificación

La matriz resume las predicciones del modelo vs. las verdaderas clases para segmentos sin crisis (No Crisis) y preictales (Crisis). En la diagonal principal aparecen los 739 segmentos no crisis correctamente clasificados como "No Crisis" (verdaderos negativos) y los 59 segmentos preictales correctamente detectados como "Crisis" (verdaderos positivos). Fuera de la diagonal, se observan 12 falsos positivos (segmentos normales etiquetados incorrectamente como crisis) y 26 falsos negativos (segmentos preictales que el modelo no detectó). Visualmente, se aprecia que la gran mayoría de los casos caen en la diagonal, reflejando la alta precisión global del 95%. La sensibilidad del ~69% se corresponde con que de 85 segmentos preictales reales, 59 fueron detectados (celdas coloradas en la fila "Crisis"), mientras que la especificidad ~98% se refleja en muy pocos errores en la fila "No Crisis". Este

balance sugiere que el modelo es bastante confiable: detecta la mayoría de las crisis con muy pocas falsas alarmas, ver figura 14.




Figura 14. Matriz de confusión obtenida en el conjunto de prueba del CHB-MIT.

La Figura 15, muestra la gráfica ROC (*Receiver Operating Characteristic*) muestra la tasa de verdaderos positivos (TPR o sensibilidad) frente a la tasa de falsos positivos (FPR) para diferentes umbrales de decisión del modelo. El área bajo la curva (AUC) es de **0,94**, lo que indica un rendimiento sobresaliente. Se observa que la curva ROC se acerca al extremo superior izquierdo del gráfico, lo que implica que el modelo logra alta sensibilidad con muy pocos falsos positivos en la mayoría de los umbrales. En concreto, para el umbral estándar (punto seleccionado en la curva), obtenemos el par $TPR \approx 0,694$ y $FPR \approx 0,016$, consistente con la sensibilidad $\sim 69\%$ y $FPR \sim 1,6\%$ reportados. Una AUC de 0,94 confirma que, aleatoriamente escogiendo un segmento preictal y uno normal, el modelo tendrá un $\sim 94\%$ de probabilidad de asignar mayor puntaje de “crisis” al segmento preictal, lo cual reafirma la buena capacidad discriminativa del clasificador.




Figura 15. Curva ROC del modelo en datos de prueba (CHB-MIT).

Cumplimiento del objetivo: los resultados permiten afirmar que el modelo cumple satisfactoriamente con el objetivo de evaluar su rendimiento sobre datos no vistos. Se logró una alta precisión global (95%) y una especificidad cercana al 98%, lo cual es fundamental para aplicaciones prácticas donde las falsas alarmas deben ser mínimas. Al mismo tiempo, el modelo mantiene una sensibilidad cercana al 70%, permitiendo detectar la mayoría de las crisis.

Aunque, mejorar la sensibilidad sigue siendo un objetivo a futuro, los niveles alcanzados están dentro del rango reportado en la literatura especializada en detección de crisis epilépticas mediante redes neuronales profundas. Modelos similares han reportado sensibilidades entre 65% y 75% con falsos positivos por debajo del 2%, lo cual posiciona al presente modelo como competitivo y clínicamente viable para aplicaciones de asistencia diagnóstica.

5.5 Validar la capacidad de generalización del modelo sobre datos no utilizados en el entrenamiento.

El cuarto objetivo específico de esta investigación se centró en validar la capacidad de generalización del modelo CNN + BiLSTM frente a datos de pacientes no utilizados durante la etapa de entrenamiento. Esta validación es fundamental para determinar si el modelo es capaz de detectar eventos epilépticos en sujetos desconocidos, simulando un escenario clínico real, donde el sistema debe operar sin necesidad de reentrenamiento previo.

Para esta evaluación, se seleccionaron 25 archivos .edf pertenecientes a los pacientes chb02, chb06, chb10 y chb11 del dataset CHB-MIT, los cuales no fueron utilizados ni en el conjunto de entrenamiento ni en el de validación. Cada archivo fue procesado siguiendo el mismo pipeline previamente definido, incluyendo filtrado notch (60 Hz), paso banda (0.5–40 Hz), normalización Z-score, segmentación con ventanas de 10 segundos y solapamiento de 5 segundos, extracción de características (FFT y DWT), y clasificación ventana por ventana utilizando el modelo ya entrenado.

Una vez generadas las predicciones por ventana, se clasificó cada archivo como:

- **"No crisis"**: si el porcentaje de ventanas etiquetadas como "crisis" fue menor o igual al 1%.
- **"Posible crisis"**: si dicho porcentaje fue mayor al 1%.

Posteriormente, esta clasificación automática fue contrastada contra la información clínica real de los archivos, verificando si efectivamente presentaban o no eventos ictales según las anotaciones oficiales del CHB-MIT.

Resultados: La Tabla 7 resume los resultados obtenidos para cada archivo, se puede observar que esta divide de la siguiente manera:

- archivos (pacientes y .edf).

- Predicción modelo creado (0 NO CRISIS, 1 POSIBLE CRISIS).
- Realidad Clínica según data (0 NO CRISIS, 1 POSIBLE CRISIS).
- Resultado (X si el modelo fallo, gancho si el modelo acertó).

Archivo	Predicción modelo creado	Realidad clínica según Data	Resultado
chb02_01	0	0	☑
chb02_02	0	0	☑
chb02_03	0	0	☑
chb02_16+	1	1	☑
chb02_19	1	1	☑
chb06_02	0	0	☑
chb06_03	0	0	☑
chb06_04	1	1	☑
chb06_06	0	0	☑
chb06_13	0	1	✗
chb06_18	1	1	☑
chb06_24	1	1	☑
chb10_01	0	0	☑
chb10_02	0	0	☑
chb10_03	0	0	☑
chb10_27	1	1	☑
chb10_30	1	1	☑
chb10_38	1	1	☑
chb10_89	0	0	☑
chb11_61	0	0	☑
chb11_62	1	0	✗
chb11_63	1	1	☑
chb11_82	1	1	☑
chb11_92	1	1	☑
chb11_99	1	1	☑

Tabla 7. Predicción vs realidad.

De los 25 archivos analizados:

- **13 archivos clínicamente tenían crisis** → el modelo detectó 12 correctamente como "POSIBLE CRISIS".
- **12 archivos no presentaban crisis** → el modelo clasificó 11 correctamente como "NO CRISIS".

Con base en estos datos, se construyó la matriz de confusión mostrada en la Figura 16, aplicado a pacientes no vistos durante el entrenamiento:




Figura 16. Matriz de confusión del modelo CNN + BiLSTM.

La matriz compara las predicciones realizadas por archivo frente a la verdad clínica (etiquetado real de presencia o ausencia de crisis en cada archivo .edf).

Análisis de desempeño: las métricas obtenidas sobre esta validación de generalización se pueden observar en la tabla 8:

Métrica	Clase "No crisis"	Clase "Crisis"	Promedio Total /
Precisión (precisión)	91.7 %	92.3 %	—

Sensibilidad (Recall)	91.7 %	92.3 %	–
F1-score	91.7 %	92.3 %	92.0 %
Exactitud total (Accuracy)	–	–	92.0 %

Tabla 8. Métricas del dataset en la validación de generalización.

Este resultado demuestra que, el modelo es capaz de generalizar adecuadamente y emitir diagnósticos preliminares fiables sobre señales EEG de pacientes completamente nuevos. La precisión balanceada y la baja tasa de errores sugieren que el aprendizaje del modelo no se limitó a las características individuales de los sujetos del entrenamiento, sino que logró capturar patrones comunes de crisis epilépticas.

Cumplimiento del objetivo: con base en, esta evaluación, se puede afirmar que el cuarto objetivo fue cumplido exitosamente. El modelo demostró una capacidad real de generalización dentro del mismo dataset (intra-paciente), sin requerir ajuste alguno al ser expuesto a señales desconocidas. Este resultado consolida la viabilidad clínica del sistema propuesto, al poder emitir alertas confiables incluso en pacientes no vistos previamente, aspecto esencial para su implementación práctica en entornos reales de monitoreo EEG.

Discusión y análisis crítico de los resultados

Impacto y relevancia clínica de los resultados: los hallazgos de esta investigación confirman el potencial del modelo CNN + BiLSTM propuesto como herramienta de apoyo al diagnóstico y monitoreo de crisis epilépticas. La precisión global del 95.45%, junto con una especificidad del 98.4%, sugiere que el sistema comete muy pocos errores en la clasificación de ventanas EEG. Esto es fundamental para su posible integración en entornos clínicos reales, ya que un bajo

número de falsos positivos contribuye a reducir alarmas innecesarias y estrés para los pacientes. Por otro lado, la sensibilidad de ~69% en detección preictal indica que el modelo es capaz de anticipar aproximadamente 2 de cada 3 crisis, lo cual representa una tasa aceptable para sistemas de alerta temprana que buscan maximizar la seguridad del paciente antes de un episodio convulsivo.

Contribución al área de ingeniería biomédica: desde una perspectiva de ingeniería biomédica, este trabajo demuestra la efectividad de combinar técnicas de procesamiento de señales (FFT y DWT) con redes neuronales profundas en tareas de clasificación de señales fisiológicas. La arquitectura híbrida CNN + BiLSTM permitió capturar patrones espaciotemporales en las señales EEG que serían difíciles de detectar con modelos tradicionales. Además, el análisis de sesgovarianza realizado reveló, que una arquitectura más sencilla presenta menor sobre ajuste y mejor capacidad de generalización frente a modelos más complejos. Esta evidencia es valiosa para el diseño futuro de modelos aplicados al EEG, donde el equilibrio entre complejidad y robustez resulta crítico. Asimismo, la validación sobre datos no vistos y la prueba en un dataset externo ofrecen una contribución experimental sólida en términos de generalización.

Comparación con estudios previos: los resultados obtenidos se alinean con lo reportado en la literatura reciente. Si bien, algunos estudios han alcanzado sensibilidades superiores (~85–90%) o precisión cercana al 98%, estos generalmente aplican configuraciones específicas de evaluación o técnicas intensivas de ajuste de datos. En contraste, este trabajo priorizó un pipeline simple y validaciones más exigentes, como pruebas entre sujetos y análisis sobre bases externas. Por ello, lograr un 95% de precisión con baja tasa de falsos positivos y sensibilidad cercana al 70% constituye un resultado competitivo, respaldado además por prácticas de validación más cercanas a un entorno clínico real. La comparación indirecta con enfoques tradicionales (SVM, árboles de decisión) también sugiere que el modelo propuesto representa una mejora significativa en términos de desempeño y aplicabilidad.

Limitaciones y oportunidades futuras: entre las principales limitaciones se encuentra el desequilibrio en la proporción de segmentos preictales frente a los normales, situación que obligó a aplicar técnicas de balanceo que pueden introducir cierto sesgo. Además, la validación externa —aunque útil— no cubre todos los escenarios clínicos posibles, y el modelo aún requiere mejoras en su sensibilidad para eventos de muy corta duración. Otra limitación relevante es que el sistema aún no ha sido evaluado en tiempo real, ni optimizado para dispositivos embebidos.

Esto representa una línea de trabajo futura importante si se busca trasladar esta arquitectura a sistemas portátiles de monitoreo. Finalmente, una comparación directa con otros modelos clásicos o híbridos no fue realizada, lo cual podría complementar el análisis de desempeño en estudios posteriores.

Conclusiones

Este capítulo presentó, los resultados obtenidos tras implementar y validar un modelo híbrido de aprendizaje profundo para la detección de crisis epilépticas a partir de señales EEG. Se evaluó su desempeño técnico y su capacidad de generalización, apoyándose en evidencias visuales y métricas cuantitativas. A continuación, se resumen los principales hallazgos derivados de cada etapa del estudio:

- En primer lugar, se implementó un proceso de preprocesamiento exhaustivo de las señales EEG del conjunto de datos CHB-MIT, aplicando técnicas de filtrado digital, segmentación temporal y transformadas FFT y DWT para la extracción de características relevantes. Este procedimiento permitió conformar un conjunto de datos estructurado y balanceado, preservando la información significativa asociada a la actividad cerebral durante los episodios ictales y no ictales.

- Posteriormente, se diseñó y entrenó un modelo híbrido CNN–BiLSTM, capaz de capturar tanto las relaciones espaciales como las dependencias temporales presentes en las señales EEG. El modelo alcanzó un rendimiento destacado, con una precisión global del 95.45%, una sensibilidad del 69.1% y una especificidad del 98.4%, valores, que reflejan un desempeño robusto y equilibrado en la identificación de eventos epilépticos. Asimismo, al ser evaluado sobre pacientes no incluidos en el entrenamiento, el modelo mantuvo su capacidad de detección, demostrando una adecuada generalización ante variaciones interpaciente.
- Los resultados obtenidos confirman que, la combinación de transformadas frecuenciales y temporales, junto con arquitecturas de redes profundas, constituye una estrategia eficaz para la detección automática de crisis epilépticas. De este modo, se aporta una metodología sólida y reproducible que puede ser utilizada como base para el desarrollo de herramientas de apoyo al diagnóstico, contribuyendo al fortalecimiento de los sistemas de monitoreo continuo, en pacientes con epilepsia.
- Finalmente, el presente trabajo representa un aporte significativo en la aplicación de técnicas de procesamiento avanzado de señales EEG al ámbito biomédico. Se recomienda, para futuras investigaciones, ampliar la validación del modelo con bases de datos de diferentes orígenes clínicos, incorporar información multimodal y explorar su implementación en sistemas portátiles o en tiempo real, con el propósito de avanzar hacia soluciones tecnológicas accesibles y de impacto clínico directo.

Recomendaciones

A partir de los resultados obtenidos, se plantean recomendaciones orientadas tanto a la aplicación práctica del modelo como a líneas futuras de investigación que pueden derivarse de este trabajo. En primer lugar, se sugiere la integración del modelo en sistemas de monitoreo EEG clínico o en dispositivos

portátiles tipo wearable, dada su alta especificidad y baja tasa de falsos positivos. Sin embargo, este tipo de aplicación debe considerarse, como una herramienta de apoyo y no como sustituto del juicio clínico profesional. Asimismo, sería recomendable incluir una fase de calibración individual por paciente al implementar el sistema en entornos reales, lo que permitiría ajustar el modelo a características particulares de cada caso, mejorando la sensibilidad sin afectar la especificidad. Las alarmas generadas por el sistema deben interpretarse como señales tempranas de riesgo y no como diagnósticos concluyentes, por lo que su uso debe ir acompañado de protocolos de respaldo y supervisión médica directa.

Desde una perspectiva investigativa, esta tesis puede servir como base para futuros trabajos orientados a validar el modelo, con bases de datos EEG más diversas, incluyendo adultos, distintos tipos de epilepsia y registros obtenidos con diferentes configuraciones clínicas. También, se recomienda explorar técnicas de adaptación de dominio o aprendizaje por transferencia, que permitirían ajustar el modelo a nuevos entornos hospitalarios con mínima intervención manual. Otra línea prometedora sería la optimización del modelo mediante arquitecturas más recientes, como redes con mecanismos de atención o modelos tipo Transformer, así como la automatización del ajuste de hiperparámetros. Por último, se propone investigar la predicción de crisis con mayor anticipación, utilizando ventanas preictales más amplias (por ejemplo, 15 a 30 minutos antes del evento), y evaluar la implementación del modelo en tiempo real mediante estudios piloto con hardware clínico o portable, analizando su impacto práctico, aceptación por usuarios y desempeño en entornos reales.

Referencia

Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*, 100, 270–278. <https://doi.org/10.1016/j.compbiomed.2017.09.017>

Caja de Seguro Social. (2023). *Informe estadístico de morbilidad neurológica ambulatoria y hospitalaria, 2017–2022*. Departamento de Registros Médicos, CSS – Panamá.

Fisher, R. S., Acevedo, C., Arzimanoglou, A., et al. (2014). ILAE official report: A practical clinical definition of epilepsy. *Epilepsia*, 55(4), 475–482. <https://doi.org/10.1111/epi.12550>

Hussein, R., Palangi, H., Ward, R. K., & Wang, Z. J. (2019). Epileptic seizure detection: A deep learning approach based on bidirectional long short-term memory networks. *Journal of Neuroscience Methods*, 316, 79–85. <https://doi.org/10.1016/j.jneumeth.2019.108441>

Jiang, M., Wei, X., & Liu, H. (2024). Real-time detection of epileptic seizures in ICU settings using LSTM-based models. *Frontiers in Computational Neuroscience*, 18, 1415967. <https://doi.org/10.3389/fncom.2024.1415967>

Kiral-Kornek, I., Roy, S., Nurse, E., Mashford, B., Karoly, P., Carroll, T., ... & Grayden, D. B. (2018). Epileptic seizure prediction using big data and deep learning: Toward a mobile system. *EBioMedicine*, 27, 103–111. <https://doi.org/10.1016/j.ebiom.2017.12.020>

Liu, Y., Zhang, D., & Yao, L. (2024). Epileptic seizure detection in EEG signals using LSTM and BiLSTM. *PubMed Central*. <https://pubmed.ncbi.nlm.nih.gov/40255197/>

MINSA – Ministerio de Salud. (2022). *Indicadores del Observatorio Nacional de Salud Pública: Enfermedades neurológicas y trastornos crónicos*. Dirección General de Planificación y Evaluación.

World Health Organization. (2023). *Epilepsy: Key facts*. <https://www.who.int/newsroom/fact-sheets/detail/epilepsy>

Zhou, Z., Chen, X., & Wang, S. (2023). Automated recognition of epilepsy from EEG signals using a combining space–time algorithm of CNN–LSTM. *Scientific Reports*, 13(1), 1–14. <https://www.nature.com/articles/s41598-023-41537-z>

Zhang et al., 2023. Enhanced Hybrid Deep Learning Architectures for Epilepsy Detection.

Mallick, S., & Baths, V. (2024). Novel deep learning framework for detection of epileptic seizures using EEG signals. *Frontiers in Computational Neuroscience*, 18, 1340251. <https://doi.org/10.3389/fncom.2024.1340251>

Zhao, W., Wang, W.-F., Patnaik, L. M., Zhang, B.-C., Weng, S.-J., Xiao, S.-X., Wei, D.-Z., & Zhou, H.-F. (2024). Residual and bidirectional LSTM for epileptic seizure detection. *Frontiers in Computational Neuroscience*, 18, 1415967. <https://doi.org/10.3389/fncom.2024.1415967>

Lee, D., Kim, B., Kim, T., Joe, I., Chong, J., Min, K., & Jung, K. (2024). A ResNetLSTM hybrid model for predicting epileptic seizures using a pretrained model with supervised contrastive learning. *Scientific Reports*, 14, 1319. <https://doi.org/10.1038/s41598-023-43328-y>

Gómez Caballero, C. G. (2019). *Automatic seizure detection based on imaged-EEG signals through statistical learning* (master's thesis, Universidad de los Andes, Colombia).

Quinga Quinga, F. D. (2017). *Predicción de crisis epilépticas utilizando técnicas de procesamiento de señales electroencefalográficas y aprendizaje de máquina [Tesis de licenciatura, Universidad de las Fuerzas Armadas ESPE]*.

Vela Aguilera, D. A. (2022). *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]*.

Huang, Y. (2019). *A deep learning approach to seizure prediction with a desirable lead time [Tesis de maestría, Case Western Reserve University]*.

da Silva Lourenço, C. (2023). *Deep learning for EEG analysis [Tesis doctoral, Universidad de Twente]*.

Álvarez Mijares, D. (2020). *Máquinas de aprendizaje para clasificar señales electroencefalográficas de pacientes con epilepsia* [Tesis de maestría, Universidad Nacional de Colombia]. Repositorio Institucional.

Ramos-Argüelles, F., Morales, G., Egozcue, S., Pabón, R. M., & Alonso, M. T. (2009). Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas. *Anales del Sistema Sanitario de Navarra*, 32(Supl. 3), 69–82. <https://doi.org/10.4321/S1137-66272009000600006>

García-Peñas, A. L. (2019). Patrón punta-onda continua en el sueño. *Anales de Pediatría*, 91(1), 56.e1–56.e7. <https://doi.org/10.1016/j.anpedi.2019.01.015>

Tayeb, H. O., & Khoshbin, S. (s. f.). Neurofisiología clínica y electroencefalografía. SNC Pharma. Recuperado de <https://sncpharma.com/wp-content/uploads/2021/02/76.-Neurofisiologia-clinica-y-electroencefalografia.pdf>

Fisiología de la actividad eléctrica del cerebro: electroencefalografía. (s. f.). Facultad de Medicina, UNAM. <https://fisiologia.facmed.unam.mx/index.php/fisiologia-de-laactividad-electrica-del-cerebro-electroencefalografia/>

Niedermeyer, E., & da Silva, F. L. (2005). *Electroencephalography: Basic principles, clinical applications, and related fields* (5.ª ed.). Lippincott Williams & Wilkins.

Guyton, A. C., & Hall, J. E. (2016). *Tratado de fisiología médica* (13.ª ed.). Elsevier España.

Kandel, E. R., Schwartz, J. H., Jessell, T. M., Siegelbaum, S. A., & Hudspeth, A. J. (2013). *Principios de neurociencia* (5.ª ed.). McGraw-Hill.

Buzsáki, G., & Draguhn, A. (2004). Neuronal oscillations in cortical networks. *Science*, 304(5679), 1926–1929. <https://doi.org/10.1126/science.1099745>

Singh, A. K., & Krishnan, S. (2023). Trends in EEG signal feature extraction applications. *Frontiers in Artificial Intelligence*, 5, Article 1072801. <https://doi.org/10.3389/frai.2022.1072801>

- Najafi, T., Jaafar, R., Remli, R., & Wan Zaidi, W. A. (2022). A classification model of EEG signals based on RNN-LSTM for diagnosing focal and generalized epilepsy. *Sensors*, 22(19), 7269. <https://doi.org/10.3390/s22197269>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Russell, S. J., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013). On the difficulty of training recurrent neural networks. In *International Conference on Machine Learning* (pp. 1310–1318).
- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: A systematic review. *Journal of Neural Engineering*, 16(5), 051001. <https://doi.org/10.1088/1741-2552/ab260c>
- Schirrneister, R. T., Springenberg, J. T., Fiederer, L. D., Glasstetter, M., Eggensperger, K., Tangermann, M., ... & Ball, T. (2017). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 38(11), 5391–5420. <https://doi.org/10.1002/hbm.23730>
- Haykin, S. (2001). *Redes neuronales: Un enfoque práctico* (2.^a ed.). Prentice Hall.
- Zhang, Y., Guo, Y., Liu, Y., & Yu, H. (2020). A deep learning framework based on LSTM for feature extraction and classification of EEG signals. *IEEE Access*, 8, 124379–124389. <https://doi.org/10.1109/ACCESS.2020.3006944>
- Rodríguez, G., & Rojas, R. (2009). *Inteligencia Artificial: Un enfoque moderno*. Pearson Educación.
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

- Sheikh, C. (2025, 15 de mayo). *Exactitud, precisión, sensibilidad, especificidad, puntuación F1*. StudyEasy. Recuperado el 17 de junio de 2025, de <https://studyeasy.org/es/course-articles/machine-learning-articles-es/specificities/#:~:text=mantenidas,es%20posible%20lograr%20una%20mayor>
- Hanley, J. A., & McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29–36. <https://doi.org/10.1148/radiology.143.1.7063747>
- Sahami, M., Karami, H., & Ghassemi, N. (2020). Performance evaluation metrics for classification models in biomedical signal processing. *Journal of Medical Systems*, 44(9), 1–11. <https://doi.org/10.1007/s10916-020-01637-1>
- Sociedad Española de Neurología. (2023). *Guía oficial de la Sociedad Española de Neurología sobre epilepsia*. Sociedad Española de Neurología (SEN).
- Vivaldi, E. A., & Maldonado, P. (2001). Computadores en investigación biomédica: I. Análisis de señales bioeléctricas. *Revista Médica de Chile*, 129(7), 815–821.
- Jiménez Vega, A. R., & Meraz Muñoz, A. Y. (2022). Sensibilidad y especificidad. *Medscape España*. (Recurso académico revisado).
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning: With applications in R*. Springer.
- Hernández-Sampieri, R., & Mendoza, C. P. (2018). Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta (8.ª ed.). Ciudad de México: McGraw-Hill.
- Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación* (6.ª ed.). McGraw-Hill.
- Otzen, T., & Manterola, C. (2017). Técnicas de muestreo sobre una población a estudio. *Revista chilena de neuro-psiquiatría*, 55(2), 227–232. <https://doi.org/10.4067/S0717-92272017000200012>

Anexo

LIBRERÍAS Y MONTAJE DE DRIVE

```
! pip install pyedflib mne --quiet.
```

```
Import os import numpy as np
import mne import pywt import
import import import import
import warnings from tqdm
import tqdm from
google.colab import drive
warnings. filter warnings ("ignore", category=RuntimeWarning) drive.
mount('/content/drive')
```

PARÁMETROS

```
base_path = '/content/drive/MyDrive/CHBMIT'
ventana_s = 10 solapamiento_s = 5 fs = 256
muestras_ventana = ventana_s * fs paso
= solapamiento_s * fs
```

PACIENTES Y ARCHIVOS SELECCIONADOS

```
pacientes = {
    'chb01': ['chb01_01.edf', chb01_02.edf',          'chb01_04.edf',  'chb01_05.edf',
    'chb01_15.edf', 'chb01_16.edf', 'chb01_21.edf'],
    'chb03': ['chb03_01.edf', chb03_02.edf',          'chb03_03.edf',  'chb03_05.edf',
    'chb03_06.edf', 'chb03_07.edf', 'chb03_36.edf'],
    'chb05': ['chb05_01.edf', chb05_02.edf',          'chb05_03.edf',  'chb05_06.edf',
    'chb05_13.edf', 'chb05_16.edf', 'chb05_22.edf'],
    'chb08': ['chb08_02.edf', chb08_03.edf',          'chb08_04.edf',  'chb08_05.edf',
    'chb08_10.edf', 'chb08_13.edf', 'chb08_21.edf'],
    'chb14': ['chb14_01.edf', chb14_02.edf',          'chb14_03.edf',  'chb14_06.edf',
    'chb14_07.edf', 'chb14_11.edf', 'chb14_27.edf'],
```

```

'chb15': ['chb15_01.edf', chb15_06.edf',      'chb15_07.edf',  'chb15_15.edf',
'chb15_22.edf', 'chb15_33.edf', 'chb15_49.edf'],
'chb16': ['chb16_01.edf', chb16_02.edf',      'chb16_03.edf',  'chb16_10.edf',
'chb16_11.edf', 'chb16_14.edf', 'chb16_16.edf'],
'chb20': ['chb20_02.edf', chb20_03.edf',      'chb20_04.edf',  'chb20_12.edf',
'chb20_14.edf', 'chb20_15.edf', 'chb20_16.edf']
}

```

EVENTOS ICTALES — formato (inicio_seg, fin_seg) crisis

```

= {
    'chb01_04.edf': [(1467, 1494)], 'chb01_15.edf': [(1732, 1772)], 'chb01_16.edf':
[(1015, 1066)], 'chb01_21.edf': [(327, 420)],
    'chb03_01.edf': [(362, 414)], 'chb03_02.edf': [(731, 796)], 'chb03_03.edf': [(432,
501)], 'chb03_36.edf': [(1725, 1778)],
    'chb05_06.edf': [(417, 532)], 'chb05_13.edf': [(1086, 1196)], 'chb05_16.edf':
[(2317, 2413)], 'chb05_22.edf': [(2348, 2465)],
    'chb08_02.edf': [(2670, 2841)], 'chb08_05.edf': [(2856, 3046)], 'chb08_13.edf':
[(2417, 2577)], 'chb08_21.edf': [(2083, 2347)],
    'chb14_03.edf': [(1986, 2000)], 'chb14_06.edf': [(1911, 1925)], 'chb14_11.edf':
[(1838, 1879)], 'chb14_27.edf': [(2833, 2849)],
    'chb15_06.edf': [(272, 397)], 'chb15_15.edf': [(1591, 1748)], 'chb15_22.edf': [(760,
965)], 'chb15_49.edf': [(1108, 1248)],
    'chb16_10.edf': [(2290, 2299)], 'chb16_11.edf': [(1120, 1129)], 'chb16_14.edf':
[(1854, 1868)], 'chb16_16.edf': [(1214, 1220)],
    'chb20_12.edf': [(94, 123)], 'chb20_14.edf': [(1971, 2009)], 'chb20_15.edf': [(390,
425)], 'chb20_16.edf': [(2226, 2261)]
}

```

```

def ventana_en_crisis(inicio, fin, eventos):
    for ini_c, fin_c in eventos:      if not
(fin <= ini_c or inicio >= fin_c):

```

```

        return True
return False.

# Obtener canales comunes def
obtener_canales_comunes(pacientes, base_path):
    inter = None
    for paciente, archivos in
pacientes.items():
        for archivo in archivos:
            ruta = os.path.join (base_path, paciente,
archivo)
            if not os.path.exists(ruta): continue
            try:
                raw = mne.io.read_raw_edf (ruta, preload=False, verbose=False)
canales = set(raw.ch_names)
                inter = canales if inter is None else inter &
canales
            except: continue
        return(list(inter))

canales_comunes = obtener_canales_comunes(pacientes, base_path)
print(f" {len(canales_comunes)} canales comunes encontrados")

# Segmentación y etiquetado
X, y = [], []

for paciente, archivos in pacientes.items():
    for archivo in archivos:
        ruta = os.path.join (base_path, paciente,
archivo)
        if not os.path.exists(ruta): continue
        try:
            raw = mne.io.read_raw_edf (ruta, preload=True,
verbose=False)
            raw.pick_channels(canales_comunes)
            raw.notch_filter(60)
            raw.filter(0.5, 40)
            datos =
raw.get_data()

```

```

    datos = (datos - datos.mean (axis=1, keepdims=True)) / datos.std (axis=1,
keepdims=True)
    eventos = crisis.get(archivo, [])

    for i in range(0, datos.shape[1] - muestras_ventana, paso):
        seg = datos[i:i + muestras_ventana]          if
seg.shape[1] != muestras_ventana: continue
        etiqueta = 1 if ventana_en_crisis(i // fs, (i + muestras_ventana) // fs,
eventos) else 0
        X.append(seg)
        y.      appends(etiqueta)
except Exception as e:
    print(f" Error en {archivo}: {e}")

```

```

X = np.array(X) y
= np.array(y)
print(f"\n Dataset
generado:
{X.shape},
{y.shape}")

print("Distribución de clases:", np.unique(y, return_counts=True))

```

```

# Balanceo 1:10 idx_no =
np.where(y == 0)[0] idx_si =
np.where(y == 1)[0]
np.random.seed(42)
idx_no_sel = np. random. choice (idx_no, size=5000, replace=False)

```

```

X_bal      =      np.concatenate([X[idx_no_sel],      X[idx_si]])      y_bal      =
np.concatenate([np.zeros(5000),      np.ones(len(idx_si))])      print(f"\n      Dataset
balanceado: {X_bal.shape}, distribución:", np.unique(y_bal, return_counts=True))

```

```

# FFT
X_fft = np.abs (np.fft. rfft (X_bal, axis=-1) [: :100]

# DWT
def extraer_dwt_coef(X):
    coeficientes = [] for i in
tqdm(range(len(X)), desc="DWT"):
    canales = [] for
ch in X[i]:
        coefs = pywt. wavedec (ch, 'db4', level=3)
        canal = np. concatenate ([np. mean(np.abs(c)). reshape (1) for c in
coefs]) canales.append(canal)
coeficientes.append(np.stack(canales)) return np.array(coeficientes)

X_dwt = extraer_dwt_coef(X_bal)

# Guardado final
np.save("X_BINARIO_FINAL.npy", X_fft) np.save("X_BINARIO_DWT.npy",
X_dwt) np.save("y_BINARIO_FINAL.npy", y_bal)
print("\n Guardado: X_BINARIO_FINAL.npy, X_BINARIO_DWT.npy,
y_BINARIO_FINAL.npy")

# ENTRENAMIENTO DE MODELO FINAL — FFT + DWT import
numpy as np
from sklearn. model_selection import train_test_split.
from sklearn. metrics import classification_report, confusion_matrix import
tensorflow as tf.
from tensorflow. keras import layers, Model, Input

```

```
from tensorflow.keras.callbacks import EarlyStopping,  
ReduceLROnPlateau import matplotlib.pyplot as plt imports seaborn as  
sns.
```

```
# Carga de datos
```

```
X_fft = np.load("X_BINARIO_FINAL.npy")    # (5567, 17, 100)  
X_dwt = np.load("X_BINARIO_DWT.npy")      # (5567, 17, 4) y  
= np.load("y_BINARIO_FINAL.npy")         # (5567,)
```

```
print("Datos cargados")
```

```
print("FFT:", X_fft.shape, "| DWT:", X_dwt.shape, "| y:", y.shape)
```

```
# División en Train, Val, Test
```

```
X_fft_train, X_fft_temp, X_dwt_train, X_dwt_temp, y_train, y_temp = train_test_split(  
X_fft, X_dwt, y, test_size=0.3, stratify=y, random_state=42)
```

```
X_fft_val, X_fft_test, X_dwt_val, X_dwt_test, y_val, y_test = train_test_split(  
X_fft_temp, X_dwt_temp, y_temp, test_size=0.5, stratify=y_temp,  
random_state=42)
```

```
# Entradas
```

```
input_fft = Input (shape= (17, 100), name='fft_input')  
input_dwt = Input (shape= (17, 4), name='dwt_input')
```

```
# Rama FFT
```

```
x1 = layers.Conv1D (32, 3, padding='same', activation='relu') (input_fft)  
x1 = layers.Bidirectional(layers.LSTM(64, return_sequences=True))(x1)  
x1 = layers.GlobalMaxPooling1D()(x1)
```

```
# Rama DWT
```

```
x2 = layers.Conv1D (32, 3, padding='same', activation='relu') (input_dwt)
x2 = layers.Bidirectional(layers.LSTM(64, return_sequences=True))(x2) x2
= layers.GlobalMaxPooling1D()(x2)
```

Concatenación

```
x = layers.Concatenate () ([x1, x2]) x =
layers.Dense(64, activation='relu')(x) x
= layers.Dropout(0.3)(x)
output = layers.Dense (1, activation='sigmoid') (x)
```

Compilación

```
model = Model (inputs= [input_fft, input_dwt], outputs=output) model.
compile(optimizer=tf.keras.optimizers.Adam(1e-4),
        loss='binary_crossentropy', # Puedes cambiar a focal loss luego
        metrics=['accuracy'])
```

```
model.summary ()
```

Callbacks

```
early = EarlyStopping (patience=10, restore_best_weights=True) reduce_lr
= ReduceLROnPlateau (patience=5, factor=0.5, verbose=1)
```

Entrenamiento

```
history = model.fit ([X_fft_train, X_dwt_train], y_train,
validation_data=([X_fft_val, X_dwt_val], y_val),
epochs=50, batch_size=64,
callbacks= [early, reduce_lr])
```

Evaluación final

```
test_loss, test_acc = model.evaluate ([X_fft_test, X_dwt_test], y_test, verbose=0)
print (f"\n Accuracy en test: {test_acc*100:.2f}%")
```

```
# Predicción y métricas
```

```
y_pred = (model. predict ([X_fft_test, X_dwt_test]) > 0.5). astype(int)
```

```
print("\n Reporte de Clasificación:")
```

```
print (classification_report (y_test, y_pred, digits=4))
```

```
# Matriz de Confusión
```

```
cm = confusion_matrix(y_test, y_pred) plt.figure(figsize=(5,4))
```

```
sns. heatmap (cm, annot=True, fmt="d", cmap="Blues",
```

```
               xticklabels= ["No Crisis",
```

```
"Crisis"],      yticklabels=["No Crisis",
```

```
"Crisis"]) plt.xlabel("Predicho")
```

```
plt.ylabel("Real") plt.title("Matriz de
```

```
Confusión") plt.tight_layout() plt.show()
```

```
# 2. CURVA ROC y AUC
```

```
from sklearn. metrics import roc_curve, auc import
```

```
matplotlib. pyplot as plt
```

```
# Calcular probabilidades para clase positiva y_proba =
```

```
model.predict([X_fft_test, X_dwt_test]).ravel()
```

```
# Calcular ROC
```

```
fpr, tpr, thresholds = roc_curve (y_test, y_proba) roc_auc
```

```
= auc (fpr, tpr)
```

```
# Graficar
```

```
plt. figure (figsize= (6, 5))
```

```
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC curve (AUC = {roc_auc:.2f})')
```

```
plt.plot([0, 1], [0, 1], color='navy', lw=1, linestyle='--') plt.xlabel('Tasa de Falsos
```

```
Positivos (FPR)') plt.ylabel('Tasa de Verdaderos Positivos (TPR)') plt.title('Curva
```

```
ROC') plt.legend(loc='lower right') plt.grid(True) plt.tight_layout() plt.show()
```

3. OTRAS MÉTRICAS DETALLADAS

```
from sklearn. metrics import accuracy_score, precision_score, recall_score,  
f1_score, confusion_matrix, classification_report, roc_auc_score.
```

```
# Predicciones binarias
```

```
y_pred_bin = (y_proba >= 0.5).astype(int) print("\n  
MÉTRICAS COMPLETAS")  
print (f"Accuracy    : {accuracy_score(y_test, y_pred_bin):.4f}")  
print(f"Precision    : {precision_score(y_test, y_pred_bin):.4f}")  
print(f"Recall       : {recall_score(y_test, y_pred_bin):.4f}")  
print(f"F1-score     : {f1_score(y_test, y_pred_bin):.4f}") print(f"AUC  
: {roc_auc_score(y_test, y_proba):.4f}") print("\nReporte  
completo:\n")  
print (classification_report (y_test, y_pred_bin, target_names= ["No Crisis", "Crisis"]))
```

Panamá, 28 de octubre de 2025.

Señores

UNIVERSIDAD LATINA DE PANAMÁ

E. S. D.


Estimados Señores:

La (el) suscrita (o) Elizabeth A. de Varela, profesora de español notifica haber revisado por solicitud de la (el) estudiante: Eliecer Alberto Ramos Villarreal con cédula de identidad personal número 7-713-2425, el proyecto de Investigación Final de Graduación titulado:

“Desarrollo de un modelo basado en aprendizaje profundo con arquitectura LSTM extendida para el diagnóstico computacional de crisis epilépticas mediante señales EEG”,

y A su vez doy fe de que el documento cumple satisfactoriamente con todos los requisitos formales de ortografía y de redacción exigidos por el idioma español.

Atentamente



The image shows a handwritten signature in blue ink over a printed stamp. The stamp contains the text: "Magister de Español", "Elizabeth A. de Varela", "Céd. 9-123-1842", and "Registro 6287".

Firma del Profesor (a) de español

Nombre del o el profesor)a: Elizabeth de Varela

Cédula de identidad: 9-123-1842

NOTA: Este es un formato de carta para él o el profesor (a) de español que le revise el proyecto final de graduación

UNIVERSIDAD DE PANAMA

DE OSASO

LA FACULTAD DE

Humanidades

ELIZABETH DEL C. ALVARADO

108

382222

EN VIRTUD DE LA POTESTAD QUE LE CONFIEREN LA LEY Y EL ESTATUTO UNIVERSITARIO,
HACE CONSTAR QUE

Elizabeth del C. Alvarado A.

HA TERMINADO LOS ESTUDIOS Y CUMPLIDO CON LOS REQUISITOS
QUE LE HACEN ACREEDOR AL TITULO DE

Licenciada en Humanidades
con Especialización en Español

Y EN CONSECUENCIA, SE LE CONCEDE TAL GRADO CON TODOS LOS DERECHOS,
HONORES Y PRIVILEGIOS RESPECTIVOS, EN TESTIMONIO DE LO CUAL SE LE EXPIDE
ESTE DIPLOMA EN LA CIUDAD DE PANAMA A LOS **veinticinco**
DIAS DEL MES DE **Febrero** DE MIL NOVECIENTOS **noventa y cuatro**

Amillians.
Secretario General

Diploma 41282

Identificación Personal 9-123-1842

Gusm García de S.
Decano

[Signature]
Rector

UNIVERSIDAD AUTÓNOMA DE CHIRIQUÍ

LA FACULTAD DE

Humanidades

EN VIRTUD DE LA POTESTAD QUE LE CONFIEREN LA LEY Y EL ESTATUTO UNIVERSITARIO
HACE CONSTAR QUE

Elizabeth del Carmen A. de Varela

HA TERMINADO ESTUDIOS DE MAESTRÍA Y CUMPLIDO CON LOS REQUISITOS
QUE LE HACEN ACREEDOR AL TÍTULO DE

*Magister en Lingüística Aplicada con Especialización
en Redacción y Corrección de Textos*

Y EN CONSECUENCIA SE LE CONCEDE TAL GRADO CON TODOS LOS DERECHOS,
HONORES Y PRIVILEGIOS RESPECTIVOS, EN TESTIMONIO DE LO CUAL SE LE EXPIDE
ESTE DIPLOMA EN LA CIUDAD DE DAVID, A LOS *7* DE *DICIEMBRE* DE *1995* DEL AÑO DOS MIL DOS.

Secretario General

Diploma - 07570 -

Identificación Personal 9-123-1842

Decano

Juana Ramos Chue
Vice rector

de Investigación y Postgrado

Rector

AMAHAN 30 ACHIBU33

MINISTERIO DE EDUCACIÓN

BAUDARÉN 20 JUANES 17 1995

30 DE ENERO

ATTESTADO

ALBAV 25

100

ESTAD

UNIVERSITARIO

0121051841010

REPÚBLICA DE PANAMÁ
TRIBUNAL ELECTORAL

Elizabeth Del Carmen
Alvarado Aguilar de Varela



NOMBRE USUAL:

FECHA DE NACIMIENTO: **18-JUN-1963**

LUGAR DE NACIMIENTO: **VERAGUAS, SANTIAGO**

SEXO: **F**

TIPO DE SANGRE: **O+**

EXPEDIDA: **05-AGO-2020**

EXPIRA: **05-AGO-2035**

9-123-1842



Elizabeth A. de Varela



SEDE CENTRAL

FORMULARIO DE ENTREGA DE PROYECTO FINAL DE GRADUACIÓN

Nota: Llenar este formulario a máquina de escribir. Entregar este formulario junto con el Proyecto Final de Graduación y los Paz y Salvo

Por este medio, notifico que el Proyecto Titulado: *Desarrollo de un modelo basado en aprendizaje profundo con arquitectura LSTM extendida para el diagnóstico computacional de crisis epilépticas mediante señales EEG.*

Correspondiente al estudiante Eliecer Alberto Ramos Villarreal

De la carrera Licenciatura en Ingeniería Biomédica e Instrumentación

Doy fe que he revisado y autorizado la entrega del Proyecto Final de Graduación (Documento Final), a Secretaría Académica, por reunir los requisitos y acatamientos exigidos por la Universidad Latina de Panamá y sugiere se le asigne la fecha para su defensa oral (sustentación).

Autorización del director del Proyecto Final de Graduación:

Nombre del Profesor director: Manuel Cerón

Firma de Autorización

Teléfono 6821-9043

Autorización del Profesor responsable del Curso Proyecto Final de Graduación:

Nombre del Profesor Alfredo Lescher

Firma de Autorización

Teléfono 6126-3467

En caso de revisión de un Profesor de Español

Notifico que doy fe que el documento cumple satisfactoriamente con todos los requisitos formales de ortografía y de redacción exigidos por el idioma español.

Nombre del Profesor de español: Elizabeth de Varela

Autorización



Firma del Estudiante EA.Bm Fecha de Entrega: 10/30/2025.

Recibido por _____ Fecha
