

UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE HUAMANGA

FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y CIVIL

ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS



“RED NEURONAL ARTIFICIAL PARA DETECTAR EPILEPSIA USANDO ELECTROENCEFALOGRAMAS EN EL HOSPITAL DE NIÑOS DE BOSTON, ESTADOS UNIDOS, 2010”

Tesis presentada por : Bach. Yauri Vidalón, José Elías

Para optar el título profesional de: Ingeniero Informático

Tipo de investigación : Aplicada, descriptivo, transversal, no experimental

Área de investigación : Ciencia de la Computación

Asesor : Dr. Ing. Efraín Elías Porras Flores

Ayacucho, mayo de 2022.

DEDICATORIA

Al único Dios, Yahveh de los ejércitos.

A mi familia.

AGRADECIMIENTOS

El orden no importa, todos son muy especiales.

Quiero agradecer:

A Jehová Dios, por derramar unas gotas de sabiduría sobre mí y haberme cuidado hasta este momento.

A mis padres, Félix y Ruth, por todo su amor incondicional. Y a mis hermanos, Miguel, Débora, Rousell y Judith, gracias por compañía y amor filial.

A mi esposa, Maribel y mi primogénito Daniel Matheus, por todo su amor y paciencia.

A mi alma mater, la Universidad Nacional de San Cristóbal de Huamanga y a los docentes de la ex Escuela de Profesional de Ingeniería Informática. Los conocimientos transmitidos me condujeron en el camino de la ciencia.

A mi supervisor, Dr. Ing. Efraín Elías Porras Flores, por su amistad, paciencia, orientación y guía durante el desarrollo de este proyecto de investigación.

A mi gran amigo, Manuel A. Lagos Barzola, por su compañerismo, ayuda y dilucidaciones sobre el arte de investigar y publicar.

RESUMEN

Según la Organización de Mundial de la Salud (OMS), la epilepsia es una enfermedad cerebral que afecta a más de 50 millones de personas en el mundo, dificultando su normal modo de vida. La epilepsia es una enfermedad innata, incurable, no transmisible, que triplica el riesgo de muerte, reduce el desarrollo personal y social del paciente, siendo considerado como un problema importante de salud pública.

Por su bajo costo del examen y equipamiento, el electroencefalograma (EEG) es la técnica más común para la detección de epilepsia. No obstante, debido a la gran variabilidad en la naturaleza, intensidad y duración de las convulsiones epilépticas, incluso para el mismo paciente a lo largo de su vida, la técnica tradicional de detección epiléptica basada en el análisis visual de encefalogramas es una tarea demorada, tediosa y desafiante hasta para los neurólogos experimentados.

Esta tesis describe el diseño e implementación de una red neural artificial para la detección automática de epilepsia utilizando electroencefalogramas. La investigación fue de tipo aplicada, enfoque descriptivo, transversal y no experimental. Luego de evaluar el desempeño de la red neuronal en la base de datos pública de epilepsia CHB-MIT, utilizando métricas de exactitud, sensibilidad, especificidad y precisión, los resultados fueron sobresalientes.

Palabras clave: Epilepsia, Electroencefalograma, Redes neuronales artificiales, Detección automática de epilepsia.

ABSTRACT

According to the World Health Organization (WHO), epilepsy is a brain disease that affects more than 50 million people in the world, hindering their normal life. Epilepsy is an innate, incurable, non-communicable disease that triples the risk of death, reduces the personal and social development of the patient, and it is considered an important public health problem.

Because the low cost of examination and equipment, the electroencephalogram (EEG) is the most common technique for the detection of epilepsy. However, due to the high variability in the nature, intensity and duration of epileptic seizures, even for the same patient along its life, the traditional technique of epilepsy detection based on visual analysis of encephalograms is a time-consuming, tedious and challenging task even for experienced neurologists.

This thesis describes the design and implementation of an artificial neural network for automatic detection of epilepsy based on electroencephalograms. The type of research was applied, descriptive, cross-sectional, and non-experimental approach. After evaluating the proposed neural net in the public available CHB-MIT epilepsy dataset, using metrics such as accuracy, sensitivity, specificity, and precision, our proposal achieved outstanding results.

Keywords: Epilepsy, Electroencephalogram, Artificial neural networks, Epilepsy automatic detection.

ÍNDICE

PÁGINA DE APROBACIÓN O CONFORMIDAD.....	i
DEDICATORIA.....	ii
AGRADECIMIENTOS	iii
RESUMEN	iv
ABSTRACT	v
INTRODUCCIÓN	1

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

1.1	DIAGNÓSTICO Y ENUNCIADO DEL PROBLEMA	1
1.2	FORMULACIÓN DEL PROBLEMA	4
1.2.1	PROBLEMA PRINCIPAL	4
1.2.2	PROBLEMAS ESPECÍFICOS	4
1.3	OBJETIVOS DE LA INVESTIGACIÓN.....	4
1.3.1	OBJETIVO GENERAL	4
1.3.2	OBJETIVOS ESPECÍFICOS.....	5
1.4	JUSTIFICACIÓN Y DELIMITACIÓN DE LA INVESTIGACIÓN	5
1.4.1	JUSTIFICACIÓN DE LA INVESTIGACIÓN.....	5
1.4.2	DELIMITACIÓN.....	6

CAPÍTULO II

MARCO TEORICO

2.1	ANTECEDENTES DE LA INVESTIGACIÓN	8
2.2	MARCO TEÓRICO.....	11
2.2.1	EPILEPSIA	11
2.2.2	ELECTROENCEFALOGRAFÍA.....	12
2.2.3	REDES NEURONALES ARTIFICIALES	13
2.2.4	MÉTRICAS DE DESEMPEÑO	21
2.2.5	DESARROLLO DE SOLUCIONES BASADO EN REDES NEURONALES	22

CAPÍTULO III
MATERIALES Y METODOS

3.1	TIPO DE INVESTIGACIÓN.....	26
3.2	NIVEL DE INVESTIGACIÓN.....	26
3.3	DISEÑO DE LA INVESTIGACIÓN.....	26
3.4	POBLACIÓN Y MUESTRA	27
3.4.1	POBLACIÓN.....	27
3.4.2	MUESTRA.....	27
3.5	VARIABLES E INDICADORES	27
3.5.1	DEFINICIÓN CONCEPTUAL DE LAS VARIABLES	27
3.5.2	OPERACIONALIZACIÓN DE LAS VARIABLES	28
3.6	TÉCNICAS E INSTRUMENTOS PARA EL TRATAMIENTO DE DATOS E INFORMACIÓN.....	28
3.6.1	TÉCNICAS PARA RECOLECTAR INFORMACIÓN	28
3.6.2	INSTRUMENTO PARA RECOLECTAR INFORMACIÓN	28

CAPÍTULO IV
RESULTADOS Y DISCUSION

4.1	RESULTADOS.....	29
4.1.1	RESULTADOS DEL PROCESAMIENTO DE LA BASE DE DATOS.....	29
4.1.2	RESULTADOS DE LA PREPARACIÓN DE DATOS.....	32
4.1.3	RESULTADO DEL DISEÑO DE LA ARQUITECTURA DE RED	34
4.1.4	RESULTADO DEL ENTRENAMIENTO Y TEST	35
4.1.4.2	PROCESO DE ENTRENAMIENTO UTILIZADO.....	35
4.1.4.3	PROCESO DE EVALUACION DE DESEMPEÑO.....	36
4.1.4.4	RESULTADO ALCANZADO POR EL MODELO	36
4.2	DISCUSION DE RESULTADOS.....	37

CAPÍTULO V
CONCLUSIONES Y RECOMENDACIONES

5.1	CONCLUSIONES	38
-----	--------------------	----

5.2	RECOMENDACIONES.....	38
	REFERENCIAS BIBLIOGRÁFICAS	40
	ANEXOS	43
	ANEXO 1. MATRIZ DE CONSISTENCIA.....	43

Lista de tablas

Tabla 1: Información por paciente extraída de la base de datos.....	32
Tabla 2: Desempeño del modelo usando validación cruzada (10-folds).....	36

Lista de Figuras

Figura 1 : Electro-encefalograma que mapea un ataque epiléptico en el lóbulo izquierdo del cerebro Fuente: (Mayo Clinic, 2020).	12
Figura 2: Modelo matemático de una red neuronal artificial.....	14
Figura 3: Red MLP con seis entradas, dos capas ocultas y dos salidas.....	16
Figura 4: Operación de convolución. Entrada una matriz 5x5, filtro 3x3. El resultado es la sumatoria del producto, elemento a elemento, de la entradas con el filtro sobrepuesto.	17
Figura 5: Filtro de Sobel. a) detector en el eje horizontal, b) detector en el eje vertical.....	17
Figura 6: Red CNN de dos capas convolucionales para clasificar imágenes.	19
Figura 7: Función de activacion sigmoidea.	20
Figura 8: Función de activacion ReLU.	20
Figura 9: Flujo de trabajo en el desarrollo de soluciones con redes neuronales [Adaptado de (Hurbans, 2020)].	23
Figura 10: Línea de tiempo de los registros EEG del paciente 1. Los registros que contienen convulsiones están sombreados de color rojo.....	29
Figura 11: EEG de 21 electrodos y su posicionamiento de acuerdo al sistema 10-20.....	30
Figura 12: EEG sin-convulsión de 3 minutos de duración.....	30
Figura 13: EEG con-convulsión de 3 minutos de duración. La epilepsia se da entre los segundos 6313 a 6348.....	31
Figura 14: Ilustración de la anotación de ventanas temporales basado en una variación del algoritmo de voto mayoritario.....	34
Figura 15: Arquitectura de red para detección de epilepsia.....	34

INTRODUCCIÓN

Debido a la cantidad de personas que padecen epilepsia y la manera como altera la vida de estas personas, la OMS la ha categorizado como un problema de salud pública recomendando a los Estados a abordar este problema de salud (OMS, 2020). La epilepsia es un trastorno cerebral, sin causa conocida aparente, no contagiosa, que produce convulsiones en el cuerpo que van desde sutiles hasta fuertes contracciones musculares incontrolables. Dichas manifestaciones frecuentes (diarias) cambias drásticamente la salud y desarrollo personal de la persona (Wyllie, 2020). Las convulsiones cambian el estilo de vida de la persona, como piensan, como se comportan, como se sienten, como se desenvuelven en con su entorno social (Bandstra, Camfield, & Camfield, 2008).

Una de las complicaciones físicas que sufre una persona es la convulsión que a menudo aparece de súbito y puede tener intensidad variable. Especialmente cuando las convulsiones son duraderas, puede provocar lesiones en la cabeza, pérdida de consciencia y ahogamientos, que si no se presta la atención medida oportuna puede producir la muerte. De acuerdo a (Mayo Clinic, 2020), la epilepsia triplica el riesgo de muerte; según (Jacoby & Austin, 2007) la gente saludable, por desconocimiento y falta de susceptibilidad, ha estigmatizado a quienes padecen de epilepsia.

Se estima que 50 millones de personas en el mundo padecen epilepsia, de los cuales el 80% viven en países pobres (OMS, 2019). Asimismo, sólo el 25% de las personas que viven en países pobres han recibido atención médica. Se prevé que, con una medicación adecuada, se podría evitar hasta el 70% de las convulsiones.

En el caso peruano, no hay mucha información respecto a los numero de personas que sufren epilepsia. De manera general, el Ministerio de Salud

indica que el 1% (uno) de peruanos padecen epilepsia (Instituto de Ciencias Neurológicas del Perú, 2019).

El diagnóstico de epilepsia se base en la repetición de convulsiones diarias. Pero como el 10% de las personas pueden sufrir convulsiones a lo largo de su vida, frecuentemente existe diagnósticos incorrectos. Lo que suele confundir a los médicos es que no todas las epilepsias manifiestan convulsiones, como también no todas las convulsiones son epilepsia.

Para realizar un diagnóstico preciso de epilepsia, debido a que muestra la actividad eléctrica del cerebro a lo largo de tiempo, el electroencefalograma (EEG) es la técnica más utilizada para explorar el cerebro. Cabe aclarar que EEG se refiere tanto al dispositivo médico para realizar el estudio clínico como a los registros (en la forma de series temporales) resultado de examen. Así, el diagnóstico de epilepsia consiste en explorar y analizar visualmente los registros de diferentes EEG del paciente. Sin embargo, debido a la compleja naturaleza del cerebro y a la alta variabilidad de la señal, inclusive para el mismo paciente, el proceso de análisis es tedioso y susceptible a errores incluso para los médicos más experimentados.

A fin de mitigar las dificultades en el proceso de diagnóstico de epilepsia, en este trabajo diseñamos un sistema de análisis automático de registros EEG como herramienta de soporte al diagnóstico médico. Nuestra propuesta se basa en una red neuronal artificial capaz de detectar patrones convulsivos, sutiles y pronunciados, que padece las personas epilépticas. Habiendo evaluado el desempeño de la red en una base de datos EEG publica, se obtuvieron resultados sobresalientes en términos de sensibilidad y precisión.

CAPÍTULO I

PLANTEAMIENTO DEL PROBLEMA

1.1 DIAGNÓSTICO Y ENUNCIADO DEL PROBLEMA

Los recientes avances en neurología, psicología y psiquiatría con soporte de la inteligencia artificial y modernas técnicas de tratamiento de la información ha conducido a un mejor conocimiento de cerebro humano, tanto a nivel anatómico, fisiológico, molecular, nervioso y cognitivo (Rim, Sung, Min, & Hong, 2020). La importancia de estudiar cerebro se basa en la premisa de que si conociéramos como el cerebro procesa la información, entonces podríamos conocer su propio funcionamiento fisiológico y de los demás órganos del cuerpo. Así, idealmente se podría detectar enfermedades degenerativas en etapas iniciales y prevenir desarrollo, identificar comportamientos y conductas anómalos, detectar estados emocionales anormales y pensamientos negativos, puesto que absolutamente todo ser humano está controlado por el cerebro gracias a su ligación con el sistema nervioso central (Banich & Compton, 2018).

Anatómicamente, el cerebro es una estructura que consiste de millones de neuronas, que son células especializadas que se enlazan y comunican entre sí para procesar la información proveniente de los estímulos internos y externos de la persona. El cerebro controla el sistema nervioso al cual está conectado través de la médula espinal. Como las ramificaciones del sistema nervioso se extienden a todos los rincones del cuerpo, el cerebro puede controlar y acceder a la información provista por los órganos que conforman nuestro ser (Damasio, 2005).

Fisiológicamente, las neuronas del cerebro procesan la información percibida o producida por los sentidos. Esta información, en el cerebro, consiste en señales químico-eléctricas, también llamado neurotransmisores, que fluyen entre las neuronas localizadas entre las diferentes regiones cerebrales (Bear, Connors, & Paradiso, 2015). Este mismo procesamiento realizado por las neuronas

producen los procesos cognitivos, pensamientos, recuerdos, emociones, decisiones o acciones (Ackerman, 1992).

Un cerebro saludable procesará y transmitirá la información adecuadamente. Al contrario, un cerebro con alguna anomalía hará lo opuesto. Por tanto, una mala función cerebral, causada por alguna enfermedad fisiológica o mental, conllevará a la reducción del desempeño psico-físico y alteración de la salud de la persona.

Una enfermedad neurológica conocida desde la antigüedad es la epilepsia. La epilepsia es una patología neurológica provocada por el incremento anormal de la actividad de las neuronas, generalmente en algunas regiones del cerebro a la altura de la corteza cerebral. La epilepsia se manifiesta mediante convulsiones del cuerpo, llamado ataque epiléptico, que se repiten con cierta frecuencia debido a los cambios repentinos, pero bruscos en el funcionamiento del cerebro (Koubeissi & Azar, 2017) (Wyllie, 2020).

Una persona diagnosticada con epilepsia, según el grado de la enfermedad, puede ver afectada su calidad de vida a sufrir trastornos neurológicos, cognitivos, psicológicos y sufrir estigmatización social. Esto puede ser particularmente perjudicial en personas que viven en países en vías de desarrollo por la falta de servicios médicos (OMS, 2019).

Con la invención de la electroencefalografía (electroencephalography - EEG) en los años 20's, se ha conseguido estudiar la epilepsia. Utilizando los registros EEG, los médicos han podido localizar y rastrear las actividades eléctricas anormales del cerebro que se producen cuando las neuronas se comunican entre sí. Un dispositivo médico de EEG consta de electrodos que se colocan sobre la cabeza del paciente para medir el potencial eléctrico (en micro-voltios μV) resultantes de la corriente iónica producida durante la neurotransmisión (Akhandia, Islam, & Rahman, 2013). Estas señales se van visualizando en un monitor, se digitalizan y/o se imprimen para su posterior análisis.

El bajo costo de un examen EEG y su procedimiento simple, hicieron que la EEG

se convierta en el instrumento preferido por los neurólogos para detectar y diagnosticar patologías cerebrales. Un equipo EEG es simple y barato si lo comparamos con otros dispositivos como la Tomografía Computarizada (TC) e imágenes basada en resonancia magnética (IRM).

Para entender la magnitud de este problema social, la Organización Mundial de la Salud (OMS) estima que la epilepsia afecta a más de 50 millones, o 1%, personas en el mundo. De éstos, 80%, viven en países en vías de desarrollo (OMS, 2019). Peor aún, se tiene conocimiento que la epilepsia causa de muerte prematura en muchos pacientes antes de los 50 años. Reiterando que pacientes de países pobres y países en vías de desarrollo son los que menos oportunidades tienen para hacer una vida más llevadera debido a la limitación de los servicios médicos (falta equipos y médicos capacitados para diagnosticar epilepsia) y carencia de medios económicos de los pacientes para costear su tratamiento.

A pesar de los avances en medicina, a la fecha, la epilepsia no tiene cura, pero un adecuado tratamiento puede hacer la diferencia en la vida del paciente. Por tanto, una detección y diagnóstico correcto de la epilepsia puede llevar a un tratamiento acorde al tipo/grado de la enfermedad (Wyllie, 2020).

Por otro lado, debido a la complejidad y variabilidad de la manera como se manifiesta la epilepsia, su correcto diagnóstico es difícil, incluso para médico con años de experiencia.

A fin de mitigar el problema social generado por la epilepsia, recientemente, la comunidad científica de reconocimiento de patrones viene realizando esfuerzos en desarrollar técnicas de detección automática de epilepsia basado en electroencefalogramas (Zhou et al., 2018). Es más, la aparición de equipos EEG de bajo costo ha facilitado el registro y disponibilidad de grandes volúmenes de datos EEG con fines de investigación, muchos de ellos, de acceso libre y soportados por hospitales, clínicas y universidades, como la base de datos de (EPILEPSAE, 2021) y (PhysioNet, 2021).

Sin embargo, a pesar de los resultados alentadores (Roy et al., 2019), la naturaleza ruidosa de la señales EEG, la grande variabilidad de patrones epilépticos entre pacientes, la compleja naturaleza del funcionamiento del cerebro, hacen que la detección automática de epilepsia sea un problema abierto en la comunidad científica y continúe desafiando los a los más modernos algoritmos propuestos.

De las aseveraciones enunciadas se concluye la detección automática de epilepsia todavía es un problema abierto. Por tanto, proponemos caracterizar una nueva red neuronal que procese las simultáneamente las características temporales y espaciales de los EEGs a fin de proveer detector de epilepsia con alto grado de sensibilidad y precisión. En este contexto se formuló la siguiente interrogante: ¿Cuáles son las características de una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas?

1.2 FORMULACIÓN DEL PROBLEMA

1.2.1 PROBLEMA PRINCIPAL

¿Cuáles son las características de una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas, 2021?

1.2.2 PROBLEMAS ESPECÍFICOS

- a) ¿Cuáles son las características de datos de entrada en una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas?
- b) ¿Cómo es la arquitectura de red en una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas?
- c) ¿Cuáles son las características de salida de la red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas?

1.3 OBJETIVOS DE LA INVESTIGACIÓN

1.3.1 OBJETIVO GENERAL

Diseñar una red neuronal artificial para la detección de epilepsia mediante

técnicas de inteligencia artificial utilizando electroencefalogramas, 2021.

1.3.2 OBJETIVOS ESPECÍFICOS

- a) Identificar los datos de entrada de la red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas.
- b) Caracterizar la arquitectura de red de una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas.
- c) Describir los datos de salida una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas.

1.4 JUSTIFICACIÓN Y DELIMITACIÓN DE LA INVESTIGACIÓN

1.4.1 JUSTIFICACIÓN DE LA INVESTIGACIÓN

La epilepsia tiene gran impacto social por el número de personas que padecen esta patología. Según la OMS, son más de 50 millones de personas en el mundo, 80% radicando en países pobres (OMS, 2019). Asimismo, su estudio abre un mundo de solidaridad con las personas que sufren epilepsia, siendo una enfermedad incurable, con patrones de convulsiones impredecibles y de grande variabilidad e intensidad interpersonal (Wyllie, 2020), afecta fuertemente la calidad de vida de los pacientes, teniendo consecuencias cognitivas, sociales, culturales y psicológicas.

En el caso peruano, no se tiene informes oficiales sobre el número real de personas con epilepsia. Se presume que, para evitar la estigmatización social, muchos pacientes no informan sobre su estado de salud. Estimaciones muy generales del Ministerio de Salud indican que el 1% (uno) de peruanos padecen epilepsia (Instituto de Ciencias Neurológicas del Perú, 2019).

Por tanto, disponer de herramientas de análisis automática de electroencefalogramas coadyuvaría a mejorar el trabajo de diagnóstico, tiempo de detección y toma de decisiones de los médicos frente a casos de epilepsia.

Esta investigación busca el análisis, discusión y difusión de las técnicas y herramientas de inteligencia artificial y su posible apoyo a las tareas de diagnóstico médico, facilitando un mejor tratamiento de los pacientes.

En lo práctico, esta investigación propone solución frente al problema planteado, contribuyendo a sentar las bases teórico-prácticas de diseño de redes neuronales.

En lo metodológico, esta investigación buscará la integración de las técnicas e instrumentos de la inteligencia artificial (campo de las redes neuronales profundas) a la resolución de un problema real, relativamente estudiado en el Perú.

Finalmente, en cuanto a su alcance, esta investigación diseminará un nuevo tipo de componente de software, llamado “inteligente”, que encapsula un módulo predictor basado en redes neuronales para el soporte a la toma de decisiones.

1.4.2 DELIMITACIÓN

a) DELIMITACIÓN TEÓRICA

El presente trabajo de investigación está dirigido al uso de métodos y técnicas de inteligencia artificial para diseñar una red neuronal artificial para la detección de epilepsia en electroencefalogramas.

b) DELIMITACIÓN TEMPORAL

El horizonte temporal será comprendido entre el mes de abril del 2021 hasta el mes de marzo del 2022.

c) DELIMITACIÓN ESPACIAL

La presente investigación no tiene delimitación especial en el problema, en la recolección de datos y presentación de las conclusiones. Se trabajará sobre una base de datos pública de electroencefalogramas CHB-MIT Scalp EEG Database

(PhysioNet, 2021). Este contenedor contiene aproximadamente 640 horas de grabación de 23 pacientes, 5 hombres y 18 mujeres, entre 3 a 23 años.

CAPÍTULO II

MARCO TEÓRICO

2.1 ANTECEDENTES DE LA INVESTIGACIÓN

La epilepsia es una patología cerebral provocada por el aumento anormal de la actividad neuronal en algunas regiones del cerebro. Esta enfermedad produce una serie de convulsiones o movimientos incontrolados del cuerpo llegando hasta la pérdida de consciencia, denominándose a esta etapa como un ataque o convulsión epiléptica (Koubeissi & Azar, 2017).

Siendo una enfermedad que afecta la salud y calidad de vida los pacientes, la comunidad científica ha venido desarrollando investigaciones para desarrollar métodos de detección de patrones de convulsiones epilépticas basado en electroencefalogramas (EEG), esto es, dado un mapa electroencefalográfico debemos concluir fehacientemente si éste contiene señales de epilepsia o no (Rim et al., 2020).

Antes de presentar los trabajos relacionados (o antecedentes de la investigación), paso a describir algunos conceptos propios del área neurológica utilizados para describir etapas de una convulsión epiléptica, los mismos que se utilizan algunos investigadores para categorizar secciones de un EEG.

Así, de acuerdo a (Koubeissi & Azar, 2017), la epilepsia tiene cuatro estados o periodos:

- Preictal (periodos antes de la convulsión),
- Ictal (periodo de la convulsión en sí misma),
- Postictal (periodos después de la convulsión), e
- Interictal (periodo de tiempo transcurrido antes de la siguiente convulsión después de la actual, o etapa mientras no hay convulsiones).

Cabe destacar que no existe consenso, ni siquiera en la comunidad médica entre la duración de las diferentes etapas, excepto el ictal, que es

determinado por los expertos en base estudios y exámenes clínicos, con la observación exhaustiva del electroencefalograma.

En general, detectar y diagnosticar si un paciente tiene epilepsia consiste en analizar visualmente un electroencefalograma e identificar la parte donde se produce la convulsión epiléptica, que siguiente la notación expresada arriba corresponde a identificar la fase ictal. Normalmente, este proceso es realizado por un experto neurólogo o psiquiatra mediante análisis del EEG, junto con otros exámenes clínicos.

Desde el punto de vista de la informática, el objetivo es desarrollar sistemas de software especializados que realicen el análisis de EEG de manera automática y con alto grado de confiabilidad.

A continuación, se resumen brevemente los antecedentes de investigación más relevantes para este proyecto de investigación:

El estudio primigenio de (Shoeb & Guttag, 2010) propone utilizar inteligencia artificial para clasificar pequeños segmentos de EEG como convulsión o sin-convulsión. Dado como test 173 secuencias de convulsiones de 20 segundos de duración, el modelo propuesto consigue reconocer 96% de los mismos en la base de datos CHB-MIT (PhysioNet, 2021). Para ello utilizan las máquinas de vectores de soporte (Support Vector Machine, SVM) y características espectrales extraídas en el dominio de frecuencia de las señales. No obstante, utiliza el método de evaluación por registro EEG para cada sujeto, es decir, los datos del mismo sujeto son evaluados contra sí mismo, ofreciendo un resultado muy optimista.

Más tarde, el estudio de (Zhou et al., 2018) propone utilizar redes neuronales convolucionales (CNN) para detectar segmentos de convulsiones y sin-convulsiones de 1 segundo de duración. La arquitectura de red tiene una capa de convolución, seguido de una capa de max-pooling y una capa de neuronas totalmente conectadas (FC). Evalúan el desempeño tanto en el dominio temporal

como en el dominio de frecuencia, informando un incremento de 62% a 97% de exactitud al utilizar el espacio de frecuencia utilizando la base de datos CHB-MIT (PhysioNet, 2021). La evaluación es por sujeto, por tanto, el resultado es muy optimista. Además, el gran saldo no necesariamente corresponde a la fuente de datos, sino probablemente al tener un modelo simple de una capa, este ha memoriza los datos (*overfitting*).

A continuación, el estudio de (Abbasi, Rashad, Basalamah, & Tariq, 2019) utilizan redes neuronales recurrentes LSTM para modelar la variación temporal de los electro-encefalogramas en pacientes neo-natos. Las características se extraen manualmente, descriptores llamadas exponentes de Hurst y promedio de movimiento auto-regresivo para entrenar la red LSTM. La red LSTM consiste de dos capas más una capa de clasificación. Los autores reportan una tasa de reconocimiento de 98% del estado interictal vs ictal en la base de datos de la Universidad de Bonn (Andrzejak et al., 2001). Como detalle, dicha base de datos es ínfimamente pequeña, contiene un solo canal y todas las partes están debidamente etiquetadas y los datos provenientes de los pacientes están combinados, que refleja la alta tasa de reconocimiento.

Recientemente, el estudio de (Chakrabarti, Swetapadma, & Pattnaik, 2021) propone un método de detección de epilepsia basado en una red LSTM de 1 capa simple, más una capa densamente conectada que realiza la combinación de características extraídas por la LSTM. La red LSTM contiene 256 características de salida, cuya salida alimenta a una capa de 128 neuronas totalmente conectadas. En un experimento de clasificación de segmentos como convulsiones y sin-convulsiones, informan de una tasa de exactitud promedio de 99.4% en la base de datos CHB-MIT (PhysioNet, 2021) estableciendo el estado del arte. Los autores realizan una evaluación por validación cruzadas con 10-folds, pero no informa qué registros fueron utilizados para el entrenamiento ni la estrategia para tratar el desbalance de datos entre segmentos con convulsiones y sin convulsiones.

De los trabajos propuestos en párrafos precedentes, se observa que muchos de

los estudios no establecen con claridad las etapas de selección de datos y preparación de datos, por lo cual no puede ser reproducidos satisfactoriamente hasta alcanzar la exactitud que la reportan. En contraposición, nuestra propuesta será totalmente documentada con claridad a fin de garantizar la reproducibilidad de los resultados.

2.2 MARCO TEÓRICO

2.2.1 EPILEPSIA

La epilepsia es una patología de tipo neurológico del sistema nervioso central que se manifiesta mediante el comportamiento anormal de la actividad cerebral causando convulsiones del cuerpo, comportamiento anormal, llegando incluso a la pérdida de consciencia (Koubeissi & Azar, 2017).

La epilepsia afecta a hombres y mujeres, sin restricción de edad, raza o condición económico-social, siendo una enfermedad incurable, pero puede ser tratable clínicamente.

La naturaleza de la convulsión epiléptica puede variar ampliamente en cada convulsión y va desde quedarse paralizado mirando fijamente por algunos segundos, hasta movimientos descontrolados del rostro y boca, brazos y piernas, acompañados hasta caídas repentinas y pérdidas de consciencia (Mayo Clinic, 2020).

El tratamiento de epilepsia consiste en la administración de medicamentos y la operación quirúrgica para mitigar el impacto de las convulsiones. Al ser una afección incurable, el paciente requerirá tratamiento de por vida (OMS, 2020).

Causas de la Epilepsia:

Aunque no existe acuerdo sobre la causa real de la afección, existe consenso en ciertas causas perceptibles en la mitad de los pacientes epilépticos (Mayo Clinic, 2020).

A continuación, se enumeran las posibles causas de epilepsia:

- Predisposición genética.
- Traumatismo en la cabeza, debido a algún golpe o lesión en la cabeza.
- Condiciones cerebrales producido por algún tumor o derrame cerebral.
- Infecciones, como la meningitis, encefalitis.
- Enfermedad prenatal debido a la infección en la madre, desnutrición.

2.2.2 ELECTROENCEFALOGRAFÍA

La electro-encefalografía (EEG) es la prueba más utilizada para detectar y diagnosticar epilepsia. En este examen, se colocan electrodos sobre el cuero cabelludo con un gel conductor. Un electro-encefalograma consiste del registro de la actividad eléctrica cerebral. La Figura 1 muestra un EEG resaltando una epilepsia.

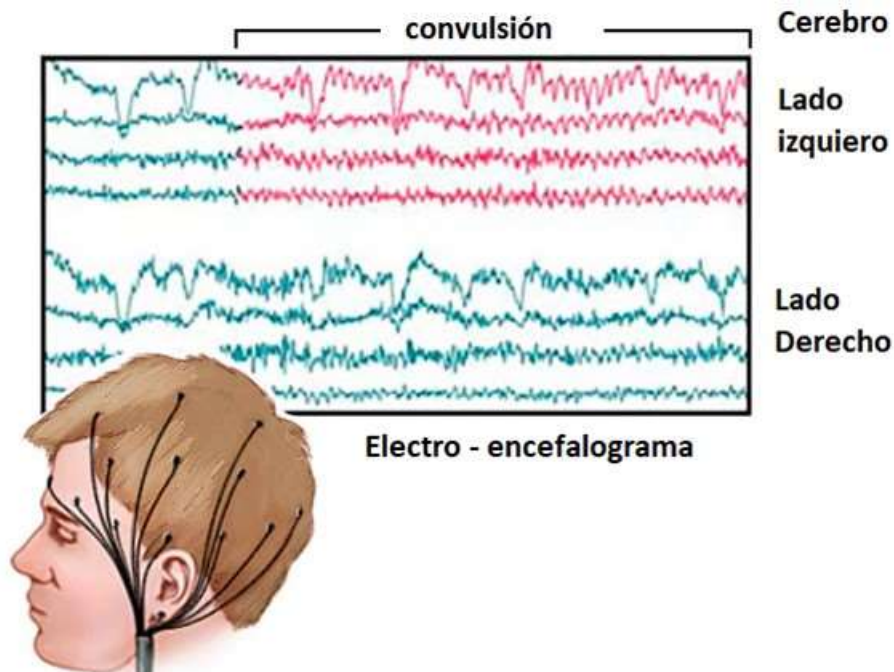


Figura 1 : Electro-encefalograma que mapea un ataque epiléptico en el lóbulo izquierdo del cerebro Fuente: (Mayo Clinic, 2020).

Algunos pacientes presentarán cambios significativos en la amplitud de la señal, incluso mientras no esté durante una convulsión. En otros pacientes, los cambios de amplitud de la señal son apenas perceptibles.

Los exámenes de EEG generalmente se realiza mientras está despierto, o dormido. La duración del registro es variable, desde minutos, horas, hasta días a fin de registrar alguna convulsión.

Aunque durante el análisis del EEG se suele tratar de identificar las etapas preictal (antes de la convulsión), ictal (durante), postictal (después) e interictal (entre convulsiones), no existe consenso en la duración de las etapas preictal y postictal. Las bases de datos EEG públicas sólo tienen anotaciones de pacientes sanos con señales normales, mientras que los pacientes epilépticos tienen sólo las anotaciones ictal.

2.2.3 REDES NEURONALES ARTIFICIALES

La neurona es la unidad fundamental de procesamiento de información en el cerebro: capta las señales nerviosas que emiten las neuronas vecinas, las procesa y luego las transmite hacia las neuronas circundantes. El cerebro humano tiene aproximadamente 100 mil millones de neuronas que están interconectadas entre sí con la finalidad de procesar la información de los sentidos y controlar los órganos internos mediante el sistema nervioso (Lundy-Ekman, 2017).

Inspirada en este mecanismo de transmisión de la información que sucede en el cerebro, se crearon las neuronales artificiales allá por los años 40's del siglo pasado, llamándola *perceptron*. Una neurona artificial es una función matemática que mapea una entrada hacia una salida deseada (Goodfellow, Bengio, & Courville, 2016).

$$y = f(x)$$

Ecuación 1

Propiamente, la ecuación matemática de la neurona artificial realiza la suma del producto resultante de las señales de entradas x_i (llamados también características, descriptores, o *features*) por sus pesos w_i (weights) respectivos,

para a continuación aplicar una función de activación F (una transformación no lineal) para obtener una salida deseada (también llamado predicción). La Ecuación 2 ilustra la ecuación matemática básica de la neurona

$$y = F \left(\sum w_i * x_i \right) \quad \text{Ecuación 2}$$

La Figura 2 ilustra un *perceptron* o neuronal artificial con 5 entradas y una salida. Al tener 5 entradas, la neurona también tiene 5 pesos. A continuación, utiliza – para este caso- la función de activación escalón, cuya finalidad es reducir las posibles salidas a dos casos (por ejemplo, 0 y 1).




Figura 2: Modelo matemático de una red neuronal artificial

Una cuestión fundamental para que la neurona artificial nos retorne la salida deseada es saber qué peso le asignamos a cada entrada. Como es difícil conocer de antemano tales valores, la solución es aprender los pesos a partir de los datos que hayamos recolectado para el problema que queremos resolver.

El proceso de aprendizaje de los pesos w_i se realiza utilizando un método de optimización a fin de minimizar el error entre salida deseada y la salida actual ofrecida por la neurona. El aprendizaje se utiliza el método de optimización llamado descenso de gradiente (*gradient descent*) que se basa en retro propagación (back propagation) del error mediante una combinación de derivadas calculadas mediante la regla de la cadena (Goodfellow et al., 2016).

Al proceso de aprendizaje también se le denomina proceso de entrenamiento, siendo un proceso iterativo en el cual se va mostrando ejemplos, casos o datos a la neurona con la finalidad de enseñar a reconocerlos. A mayor cantidad y diversidad de ejemplos presentados, mejor ajustados resultaran los pesos de la neurona.

Si bien una sola neurona puede realizar tareas simples, como, por ejemplo, la operación lógica OR, AND, etc., las tareas más complejas requerirán del uso de más neuronas. Por citar, la operación lógica XOR requiere de al menos dos neuronas, clasificar una imagen requiere de algunos cientos o miles de neuronas, mientras que reconocer los sonidos del habla necesitarán tal vez de millones de neuronas.

La colección de neuronas para resolver un determinado problema se denomina red neuronal artificial (RNA). Las RNAs se organizan en complejas estructuras arquitectónicas de una o varias capas (*layers*) consecutivas de procesamiento de las entradas de datos antes de predecir la salida deseada.

Actualmente, existen soluciones bien establecidas de RNAs para detección de spam en correos electrónicos, clasificación, detección y segmentación de objetos en imágenes, descripción de imágenes, reconocimiento de actividades en videos, reconocimiento y transcripción del habla. No obstante, existen otras áreas donde la aplicación de RNAs todavía es limitada, por ejemplo, en la medicina, la agricultura, la economía.

2.2.3.1 TIPOS DE REDES NEURONALES

Dependiendo de la manera como procesan los datos y de acuerdo a los objetivos de investigación de la presente tesis, describimos dos tipos de RNAs:

- a) Redes neuronales multicapa (*Multi Layer Perceptron - MLP*).
- b) Redes neuronales convolucionales (*Convolutional Neural Network – CNN*).

Para el lector interesado en otros tipos de redes neuronales, recomendamos la lectura de los estudios de (Haykin, 2008) y (Aggarwal, 2018) en redes neuronales.

Una **red neuronal multicapa** no es otra cosa que la tradicional y antigua RNA. Utiliza en toda su estructura neuronas artificiales totalmente interconectadas, excepto la capa de entrada y la capa de salida. Es decir, dada una neurona, su salida será entrada de las neuronas en la capa siguiente, mientras que sus entradas se conectan a las salidas de las neuronas de la capa precedente.

Para mejor comprensión de su estructura, las redes neuronales se organizan en capas, denominándose capas ocultas a las capas intermedias entre la entrada y la salida. La Figura 3 ilustra una red MLP.




Figura 3: Red MLP con seis entradas, dos capas ocultas y dos salidas.

Una **red neuronal convolucional** (CNN) utiliza grupos de neuronas llamados filtros o *kernels* para capturar la información espacial de los datos (Goodfellow et al., 2016).

Matemáticamente, en CNN, se realiza la convolución (*multiplicación*) entre los datos de entrada y los filtros a fin de capturar patrones de correlación espacial. Para este fin, los filtros no son más que pequeñas matrices en una, dos o tres dimensiones, ó 1D, 2D, 3D, respectivamente. La Figura 4 ilustra un ejemplo de convolución utilizando un filtro 2D.

Desde el punto de vista del tratamiento de los datos, los filtros crean mapas de características (*feature maps*) que resumen la presencia de ciertas características (*features*) detectadas en los datos de entrada.

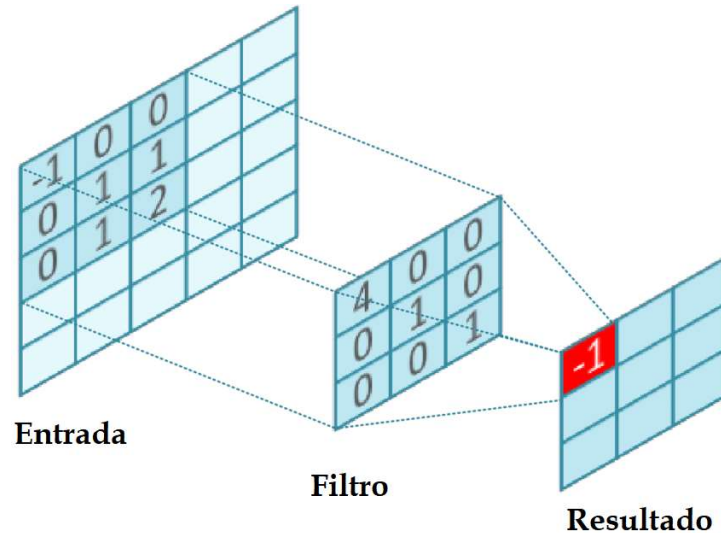


Figura 4: Operación de convolución. Entrada una matriz 5x5, filtro 3x3. El resultado es la sumatoria del producto, elemento a elemento, de la entradas con el filtro sobrepuesto.

Por un lado, los filtros pueden ser diseñados manualmente, como los filtros de Sobel para la detección de contornos (Gonzalez & Woods, 2017). Estos filtros son matrices 2D de tamaño 3x3 que realzan las regiones de cambios bruscos de intensidad en la dimensión horizontal y vertical de una imagen, formando los bordes de los objetos en la imagen. La Figura 5 ilustra el filtro de Sobel.

$$g_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix}$$

(a)

$$g_y = \begin{bmatrix} -1 & -2 & +1 \\ 0 & 0 & 0 \\ -1 & +2 & +1 \end{bmatrix}$$

(b)

Figura 5: Filtro de Sobel. a) detector en el eje horizontal, b) detector en el eje vertical.

Por otro lado, la mayor innovación de las redes CNN es que **los filtros pueden ser aprendidos** durante el entrenamiento de la red, pudiendo utilizarlos para extraer mapas de características representativos de los datos (Ayyadevara, Reddy, & Safari, 2020). Estos mapas de características pueden ser utilizados como entradas para otras tareas.

La elección del tipo y tamaño del filtro, depende del problema que se pretende modelar. Por ejemplo, los datos registrados por un electrocardiograma a lo largo de tiempo pueden ser procesados con filtros 1D (Hsieh, Li, Hwang, & Hsiao, 2020), mientras que los datos provenientes de una reconstrucción tomográfica será preferentemente procesada por filtros 3D (Liu et al., 2021).

Similar a las redes MLP, una red CNN se organiza en capas de convolución, donde que las primeras capas extraen características de bajo nivel, como líneas, curvas, puntos); mientras que las capas más profundas extraen características de alto nivel, como la forma de un ojo, boca, nariz (Qin, Yu, Liu, & Chen, 2018).

Durante el diseño de una red CNN, una práctica común es incrementar el número de filtros a medida que se agregan más capas a la red. A mayor profundidad de la red, los patrones capturados se vuelven más complejos; por tanto, se requieren más filtros a fin de capturar las múltiples combinaciones de dichos patrones (Albelwi & Mahmood, 2017).

La Figura 6 ilustra una red CNN que clasifica imágenes en dos categorías: gatos y perros. Se puede observar que la red CNN consta de dos capas o bloques de convolución. Cada capa realiza una convolución, seguida de una función de activación. A fin de reducir la carga computacional, después de cada bloque se utiliza un sub-muestreo para reducir el tamaño de los datos, lo que a su vez dota a los filtros de características invariantes a la escala y rotación de las imágenes de entrada.




Figura 6: Red CNN de dos capas convolucionales para clasificar imágenes.

2.2.3.2 FUNCIONES DE ACTIVACIÓN

La función de activación es una transformación matemática que se aplica a la salida de las neuronas (Goodfellow et al., 2016).

El uso de la función de activación tiene dos objetivos básicos:

- a) Agregar no-linealidad a la salida: característica permite el aprendizaje/actualización de los pesos durante la fase de entrenamiento.
- b) Limitar la salida a un rango específico de valores: característica que otorga rapidez al aprendizaje de los pesos de las neuronas.

Dos características deben ser cumplidas para que una función sea una función de activación:

- a) Ser función no lineal.
- b) Ser diferenciable, para un valor de entrada debe ser posible calcular su primera derivada.

Dentro de una red neuronal, es común colocar funciones de activación después de cada capa, sean redes totalmente conectadas o redes convolucionales.

Existen diferentes tipos de funciones de activación. A continuación, describimos las funciones de activación utilizadas en este trabajo.

- a) **Función de activación Sigmoidea:** Utiliza la función de regresión logística

$$f(x) = \frac{1}{1 + e^{-x}} \quad \text{Ecuación 3}$$

La función sigmoidea tiene una forma de S, limitando los valores entre cero y uno. La Figura 7 muestra la transformación de los datos de entrada por una función sigmoidea.

Función de Activación Sigmoide

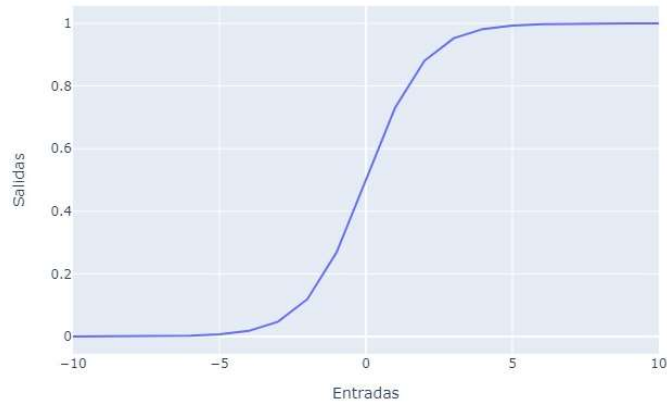


Figura 7: Función de activación sigmoidea.

- b) **Función de activación ReLU:** Utiliza la función de Rectificación Lineal (en inglés, Rectified Linear Unit).

$$f(x) = \max(0, x)$$

Ecuación 4

La Figura 8 muestra la transformación de los datos de entrada por una función de rectificación lineal.

Función de Activación ReLU

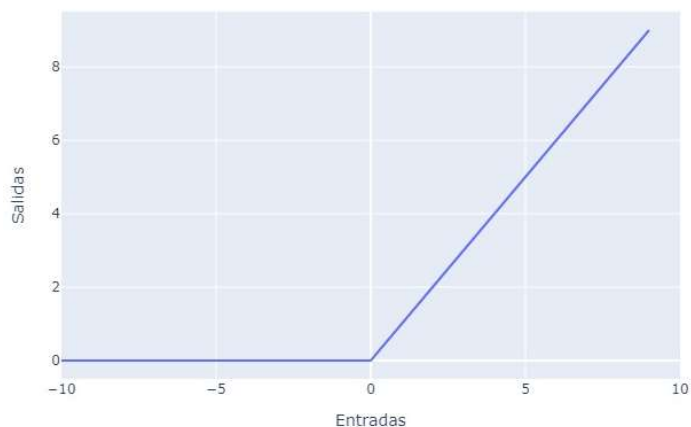


Figura 8: Función de activación ReLU.

La función ReLU tiene una forma de línea doblada, poniendo a cero los valores negativos. Desde su introducción, es la función de activación estándar en las redes neuronales debido a que acelera el tiempo de

entrenamiento a la vez que incrementa el desempeño de la red.

- c) **Función de activación Softmax:** Utiliza la función de regresión logística multinomial (varias categorías) y es utilizado frecuentemente como la función de activación de la capa de salida.

$$f(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad \text{Ecuación 5}$$

Diferente de las funciones de activación precedentes, la entrada y salida son vectores, siendo la salida un vector normalizado, es decir la suma de sus elementos es uno. Esta propiedad hace que la función *softmax* puede ser utilizada como un predictor de probabilidades, frecuentemente utilizado en problemas de clasificación.

Por ejemplo, sea el vector $v = [1.2, 2.0, 0.5]$, aplicando la Ecuación 5, tenemos:

$$\text{softmax}(v) = [0.2687, 0.5979, 0.1334]$$

note que la suma la salida es 1.

El lector interesado en otras funciones de activación puede revisar los trabajos de (Goodfellow et al., 2016), (Aggarwal, 2018) y (Ayyadevara et al., 2020); o dirigirse a la documentación a los principales *frameworks* de redes neuronales.

2.2.4 MÉTRICAS DE DESEMPEÑO

Con la finalidad de evaluar el desempeño del modelo clasificador binario, si éste es capaz de distinguir entre señales epilépticas y señales normales en electroencefalogramas, utilizaremos las siguientes métricas de sensibilidad y especificidad, muy utilizadas en el ambiente médico:

- a) **Sensibilidad:**

Mide la habilidad del modelo para detectar señales epilépticas en electroencefalogramas y se mide como:

$$\text{Sensibilidad} = \frac{VP}{VP + FN} \quad \text{Ecuación 6}$$

Donde, VP es el número de verdaderos positivos (es decir, la cantidad de señales epilépticas detectadas), FN es el número de falsos negativos (es decir, la cantidad de señales epilépticas no detectadas u omitidas).

Por ejemplo, un test con 90% de sensibilidad retornará un resultado positivo en el 90% de personas que tienen epilepsia, pero devolverá negativo (falso negativo) para el 10% de personas que tienen epilepsia y debieron haber dado positivo.

b) **Especificidad:**

Mide la habilidad del modelo para detectar señales normales o señales no epilépticas en electroencefalogramas y se mide como:

$$\text{Especificidad} = \frac{VN}{VN + FP} \quad \text{Ecuación 7}$$

Donde, VN es el número de verdaderos negativos (es decir, la cantidad de señales normales detectadas), FP es el número de falsos positivos (es decir, la cantidad de señales normales confundidas como señales epilépticas).

Por ejemplo, un test con 90% de especificidad retornará correctamente negativo para 90% de personas que no tienen la enfermedad, pero devolverá positivo (falso positivo) para el 10% de personas no tienen la enfermedad y debieron haber dado negativo.

2.2.5 DESARROLLO DE SOLUCIONES BASADO EN REDES NEURONALES

Desarrollar una solución de redes neuronales no implica solamente la implementación algorítmica de la arquitectura, sino que ésta depende de los datos que se dispongan y como se procesen estos.

A continuación, basado en (Hurbans, 2020), se presentan las etapas para el desarrollo de soluciones con redes neuronales, como se ilustra en la Figura 4.

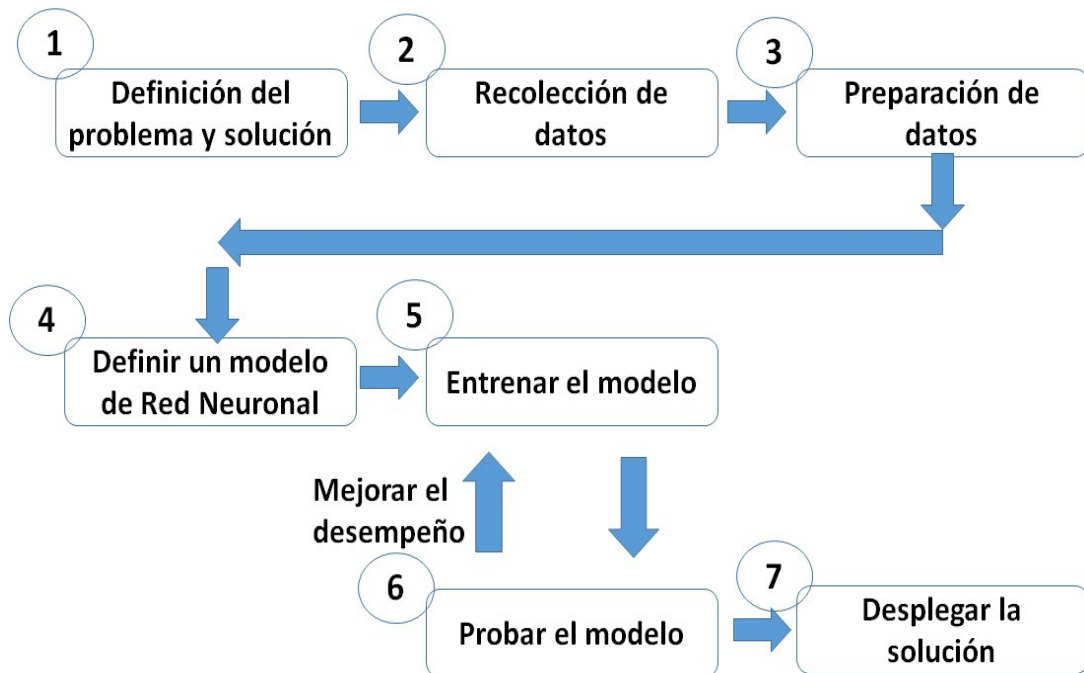


Figura 9: Flujo de trabajo en el desarrollo de soluciones con redes neuronales [Adaptado de (Hurbans, 2020)].

1. Definición del problema y solución:

Identificación del problema, parámetros y variables de estudio y planteamiento del diseño experimental para la recolección de datos.

2. Recolección de datos:

Los datos dependen del proyecto deseado, así, los datos pueden ser recolectados específicamente para el proyecto, o tomados o adaptados desde otras fuentes de datos, base de datos públicas, entre otros. La calidad y cantidad de datos afectará directamente el desempeño del sistema propuesto.

3. Preparación de datos:

La preparación de los datos se realiza para quitar los datos faltantes, datos inconsistentes, datos duplicados y, si es necesario, transformar los datos. Los datos tal cual son, no son útiles para ser utilizados por el modelo.

4. Definir un modelo de red neuronal:

Consiste en buscar la mejor organización y arquitectura de redes neuronales que mejor se ajuste al problema a ser resuelto. Si se dispone de datos categóricos etiquetados, se utilizará un algoritmo de clasificación. Si los datos son numéricos para realizar alguna predicción, se utilizará un algoritmo de regresión. Por otro lado, si los datos no tienen ninguna etiqueta (es decir, se desconoce su organización a priori), algún algoritmo de agrupamiento (o clustering) deberá ser utilizado.

5. **Entrenar la red neuronal:**

El modelo es entrenado a fin de mejorar su habilidad de realizar el mapeamiento entre entradas y salidas. El entrenamiento es un procedimiento iterativo de ajustar los pesos de cada una de las neuronas del modelo utilizando algún algoritmo de optimización.

A fin de ir evaluando el desempeño del modelo mientras vamos entrenando se divide el conjunto de datos en dos grupos, conjunto de entrenamiento y conjunto de test, en la proporción de 80/20 y 70/30.

El modelo se entrena en el conjunto de entrenamiento, se testea en el conjunto de test.

6. **Test de la red neuronal:**

Testar el modelo consiste en evaluar si el modelo cumple las expectativas. Para tal fin, el conjunto de test nunca debe ser utilizado para ajustar el modelo, esto podría llevar a tener conclusiones equivocadas. Para evaluar el modelo, se utilizan métricas como exactitud, sensibilidad, especificidad y precisión.

Si el modelo no trabaja bien, deberá ser remodelado tanto en su arquitectura como variando los parámetros de entrenamiento con la finalidad de mejorar las métricas.

7. **Despliegue de la solución:**

Una vez entrenado el modelo, se entrega empaquetado para ser utilizado como un componente de algún sistema informático de mayor envergadura.

CAPÍTULO III

MATERIALES Y METODOS

3.1 TIPO DE INVESTIGACIÓN

En esta tesis seguimos la taxonomía de (Hernández, Fernández, & Baptista, 2016) para describir el criterio metodológico de la presente investigación.

Siendo la investigación aplicada aquella que pretende dar solución a un problema específico, nuestra investigación es de **aplicada** porque el nuestro objetivo es proveer un método de detección automática que mitigue las limitaciones del procedimiento tradicional basado en la observación visual directa de EEGs.

3.2 NIVEL DE INVESTIGACIÓN

Como nuestro trabajo de investigación consiste en caracterizar la variable de estudio red neuronal artificial para detección de epilepsia en EEGS, el nivel de investigación es **descriptivo**.

3.3 DISEÑO DE LA INVESTIGACIÓN

En nuestro estudio observamos y caracterizamos la variable de estudio red neuronal artificial, no realizamos ninguna manipulación deliberada, por tanto, es una investigación **no experimental**.

Tomando en cuenta el periodo de recolección de datos, los estudios no experimentales a su vez pueden clasificarse como transversales y longitudinales. En el primer caso, se recogen datos en un solo momento y tiempo, mientras que, en el segundo caso, los datos se colectan en diferentes momentos y tiempo. En nuestro caso, cogemos una base de datos pública de registros EEGs que fueron recolectados en el Hospital de Niños de Boston (Goldberger et al., 2010). Para nuestro propósito, nuestra investigación es **transversal**.

3.4 POBLACIÓN Y MUESTRA

3.4.1 POBLACIÓN

La población está compuesta de todos los registros de EEG provistos en la base de datos de (Goldberger et al., 2010), que contienen aproximadamente 982.92 horas de grabación de EEGs y 198 convulsiones epilépticas de 23 pacientes.

3.4.2 MUESTRA

Se consideró un muestreo no probabilístico para seleccionar todos los registros EEG que contengan convulsiones. Así, nuestra muestra contiene 185.51 horas de grabación de EEGs y 181 convulsiones epilépticas de 23 pacientes.

3.5 VARIABLES E INDICADORES

3.5.1 DEFINICIÓN CONCEPTUAL DE LAS VARIABLES

Variable de estudio:

Red neuronal artificial

Representa la organización de las neuronas artificiales (o nodos) para detectar epilepsia en electroencefalogramas.

Indicadores de la variable de estudio

Datos de entrada

Datos provistos por el electroencefalograma, de determinado tamaño temporal (segundos) y espacial (cantidad de electrodos), para ser procesados por la red neuronal artificial.

Arquitectura de red

Es la organización, disposición e interconexión de las neuronas en grupos o capas para detectar epilepsia. Es la parte fundamental de la red neuronal

artificial.

Datos de salida

Es la salida de la red neuronal artificial, datos que permiten realizar predicciones.

3.5.2 OPERACIONALIZACIÓN DE LAS VARIABLES

El criterio utilizado para la operacionalización de las variables fue atendiendo a las etapas de procesamiento de datos que realiza una neurona artificial y se muestra a continuación:

Variable de estudio	Indicadores de la variable de estudio
Red neuronal artificial.	<ul style="list-style-type: none">• Datos de entrada.• Arquitectura de red.• Datos de salida.

3.6 TÉCNICAS E INSTRUMENTOS PARA EL TRATAMIENTO DE DATOS E INFORMACIÓN

3.6.1 TÉCNICAS PARA RECOLECTAR INFORMACIÓN

Entre las técnicas que se utilizaron para recolectar la información se utilizó el análisis documental de diferentes fuentes relativos a electroencefalografía, procesamiento de señales y redes neuronales artificiales.

3.6.2 INSTRUMENTO PARA RECOLECTAR INFORMACIÓN

Los instrumentos que se utilizaron fueron:

- Registros de EEG.

CAPITULO IV

RESULTADOS Y DISCUSION

4.1 RESULTADOS

4.1.1 RESULTADOS DEL PROCESAMIENTO DE LA BASE DE DATOS

Los datos fueron obtenidos de la base de datos publica *Children's Hospital Boston-Massachusetts Institute of Technology* (CHB-MIT), disponible online en (Goldberger et al., 2010) . La base de datos contiene registros de electroencefalogramas (EEG) de 24 niños con epilepsia intratable (Shoeb & Gutttag, 2010). La grabación EEG fue continua, pero para su distribución fue separada en archivos EDFs, la mayoría de una hora de duración.

Los registros que contienen convulsiones están etiquetados como registros con-convulsión; mientras que los demás, registros sin-convulsión. Los registros con-convulsión pueden contener más de una convulsión epiléptica, cada una de diferente duración. La Figura 10 ilustra la línea de tiempo de registros EEG del paciente 1.



Figura 10: Línea de tiempo de los registros EEG del paciente 1. Los registros que contienen convulsiones están sombreados de color rojo.

La mayoría de registros contienen señales de 23 canales que fueron grabados con un EEG de 21 electrodos. Las señales fueron capturadas con frecuencia de muestreo de 256 Hz. La Figura 11 presenta la disposición de electrodos de acuerdo al Sistema Internacional 10-20 y el montaje de los canales utilizados.

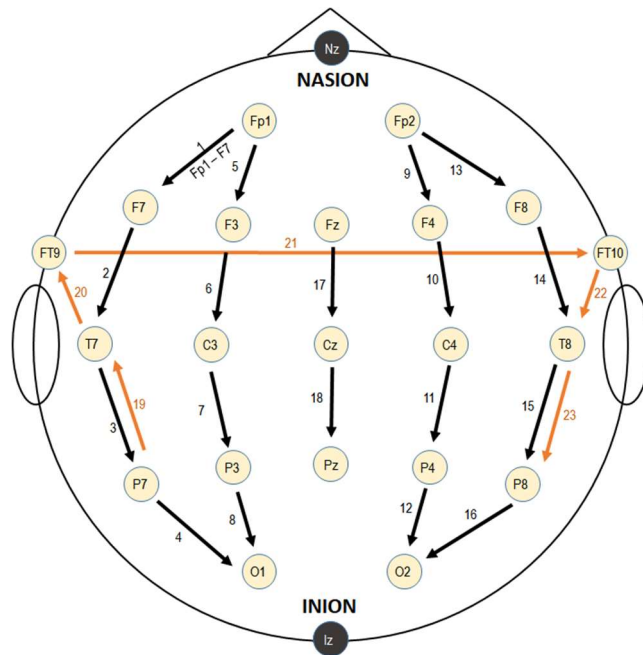


Figura 11: EEG de 21 electrodos y su posicionamiento de acuerdo al sistema 10-20.

La Figura 12 muestra 3 minutos de la señal sin-convulsión. Se puede observar la actividad cerebral en el hemisferio izquierdo (señales de la parte superior) es continua, mientras que en el hemisferio derecho (señales de la parte inferior) hay interrupciones.




Figura 12: EEG sin-convulsión de 3 minutos de duración.

Análogamente, la Figura 13 muestra 3 minutos de la señal con-convulsión. Se puede observar como el patrón epiléptico se reproduce en todos los canales, debido a que el paciente padece de una epilepsia generalizada que afecta todo el cerebro.




Figura 13: EEG con-convulsión de 3 minutos de duración. La epilepsia se da entre los segundos 6313 a 6348.

Aunque los patrones epilépticos son similares para un paciente, éstos varían de paciente a paciente, dependiendo del tipo de epilepsia que padecen, local o generalizada (Shoeb & Gutttag, 2010). La práctica común para detectar epilepsia en EEGs es la observación visual de la señal, siendo un proceso tedioso, demorado y susceptible de errores (falsos positivos).

La Tabla 1 resume la información de cada paciente tomando como referencia los registros que tienen 23 canales. La base de datos contiene 951.93 horas de grabación.

Tabla 1: Información por paciente extraída de la base de datos

Paciente	Sexo – Edad	Número de convulsiones	Duración total de la convulsión (s)	Grabación Total (h)	Grabación Total sólo Convulsiones(h)
chb01	F-11	7	442	40.55	6.65
chb02	M-11	3	172	35.27	2.27
chb03	F-14	7	402	38.00	7.00
chb04	M-22	4	378	156.07	10.66
chb05	F-7	5	558	39.00	5.00
chb06	F-1.5	10	153	66.74	25.89
chb07	F-14.5	3	325	67.05	9.04
chb08	M-3.5	5	919	20.01	5.00
chb09	F-10	4	276	67.87	9.58
chb10	M-3	7	447	50.02	14.02
chb11	F-12	3	806	34.79	2.79
chb12	F-2	27	989	20.69	9.68
chb13	F-3	10	440	11.00	7.00
chb14	F-9	8	169	26.00	7.00
chb15	M-16	20	1992	39.01	14.01
chb16	F-7	8	69	17.00	5.00
chb17	F-12	3	293	20.01	3.01
chb18	F-18	6	317	34.63	5.63
chb19	F-19	3	236	28.93	2.93
chb20	F-6	8	294	27.60	5.57
chb21	F-13	4	199	32.83	3.83
chb22	F-9	3	204	31.00	3.00
chb23	F-6	7	424	26.56	8.96
chb24	Adult	16	511	21.30	12.00
Total		181	11015	951.93	185.51

4.1.2 RESULTADOS DE LA PREPARACIÓN DE DATOS

En este trabajo, proponemos trabajar con los 24 pacientes, pero utilizamos los registros marcados como con-convulsión debido a limitaciones de recursos computacionales. Con todo, tenemos 185.51 horas de datos, de los cuales solamente 11,015 segundos corresponden a ataques epilépticos.

A continuación, se describen cada uno de las etapas de preparación de datos:

1. **Selección de canales:** aunque el dataset tiene 23 canales, observamos que el canal 19 es la inversión del canal 3 y el canal 15 es el mismo canal 23, por tanto, utilizamos 21 canales (vea Figura 11)
2. **Sub-muestreo de la señal:** las señales fueron sub-muestreadas a 128 Hz a fin de acelerar el procesamiento de las mismas, toda vez que no decrece el resultado si lo comparamos con la señal a 256 Hz (Moctezuma & Molinas, 2020).

Proponemos trabajar con la señal original, no se aplica ningún método de eliminación de ruido. Al realizar el montaje se aplicó un filtro butter-worth pasa-banda (Chakrabarti et al., 2021).

3. **Segmentación de la señal en ventanas temporales:** los datos EEG se separan en pequeñas ventanas temporales de 1, 5 y 10 de duración utilizando la técnica de ventanas deslizantes. Se utilizan tamaños de ventana similares a otras propuestas con fines de comparación de nuestra propuesta.
4. **Anotación de ventanas temporales y etiquetado:** los datos EEG consisten de muestras discretas en la dimensión de tiempo. Primeramente, asignamos la marcación uno (1) a todas las muestras que recaen dentro de la convulsión epiléptica designada por los expertos, las demás muestras las marcamos como cero (0). Seguidamente, para etiquetar la ventana, utilizamos una variación del algoritmo de voto mayoritario a fin de dar prioridad a las muestras de convulsión: si el conteo de ocurrencias de unos es mayor a cierto umbral, etiquetamos la ventana como uno (1, convulsión), de lo contrario, etiquetamos la ventana como cero (0, normal).

La Figura 14 ilustra el proceso de etiquetado de ventanas utilizando el umbral de 20%. La cuarta ventana por mayoría de votos sería etiquetada como 0, mientras que, con nuestro método, la ventana es etiquetada como 1.

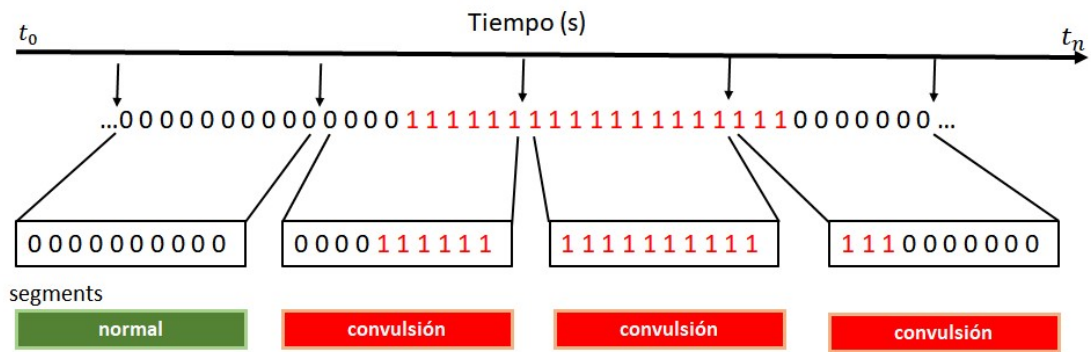


Figura 14: Ilustración de la anotación de ventanas temporales basado en una variación del algoritmo de voto mayoritario.

Luego, de la preparación de datos, los datos de entrada para nuestro modelo es una matriz $E \times T$, donde:

E , el número de canales del EEG, 21 en nuestro caso.

T , la longitud de la ventana temporal (por ejemplo, si la ventana es 5 s, T será una secuencia de $5 * 128 = 640$ elementos)

4.1.3 RESULTADO DEL DISEÑO DE LA ARQUITECTURA DE RED

Para hacer frente a la naturaleza espacial-temporal del EEG, proponemos un modelo de red basado en redes neuronales convolucionales, que saca provecho de la fusión de datos en la primera capa a fin de reducir el número de parámetros entrenados.




Figura 15: Arquitectura de red para detección de epilepsia.

La Figura 15 presenta la arquitectura de red propuesta. Acepta como entrada datos de la forma $E \times T$ para clasificarlos en dos clases: Convulsión o Normal.

A continuación, se describe la arquitectura de la red, la misma que consta de tres módulos:

1. **La unidad de fusión de datos:** para proyectar E canales EEG en uno simple para reducir la sobrecarga computacional mientras se preserva la información espacial. La unidad de fusión consiste de una capa convolucional que mapea linealmente E canales a 1. Utiliza un kernel de tamaño 3. La salida de la fusión es una estructura de datos 1xT.
2. **La unidad convolucional:** realiza la extracción automática de características. Consiste de tres capas de convolución (vea Figura 15), cada una con función de activación no lineal ReLU, normalización y capa de sub-muestreo *maxpooling*. Las convoluciones utilizan kernel de tamaño 3 y paso 1, mientras que los sub-muestreos utilizan kernel de tamaño 4 y paso 4. Yendo en profundidad de capas, las convoluciones utilizan 16, 32 y 64 filtros.
3. **La unidad de clasificación:** realiza la clasificación de las ventanas basado en las características extraídas en la unidad precedente. Utiliza una capa de neuronas simples cuyas salidas son modificadas por la función de activación softmax. Con el objetivo de garantizar que el modelo pueda procesar ventanas de diferente longitud, se utiliza una capa de sub-muestreo adaptativo que uniformiza la dimensión de las neuronas, previo al paso de clasificación.

4.1.4 RESULTADO DEL ENTRENAMIENTO Y TEST

4.1.4.1 MEDIDA DE DESEMPEÑO UTILIZADO

En este trabajo utilizamos medidas de exactitud, sensibilidad y especificidad para estudiar el desempeño del modelo propuesto (vea la Sección 2.2.4 para su formulación matemática).

4.1.4.2 PROCESO DE ENTRENAMIENTO UTILIZADO

Como puede observarse en la Tabla 1, la relación entre el número de muestras convulsión (1s) es inmensamente pequeño frente al número de muestras

normales (0s). A fin de corregir el sesgo durante el entrenamiento de la red al tener desbalance entre las clases, utilizamos la función de *loss* entropía-cruzada-ponderada. Como optimizador de parámetros, utilizamos el algoritmo Adam, con una tasa de aprendizaje (*learning rate*) de $1e-4$. El entrenamiento se realiza en 100 épocas con 128 muestras como tamaño de *batch*.

4.1.4.3 PROCESO DE EVALUACION DE DESEMPEÑO

El desempeño del modelo propuesto se ha evaluado utilizando validación cruzada k-folds. Se divide los datos en k grupos mutuamente excluyentes. Durante la evaluación, se extrae un fold para ser usado como test, mientras que los restantes k-1 folds son usados para el entrenamiento del modelo. El proceso se repite k veces. El promedio de las k medidas individuales nos da el resultado final de la validación cruzada.

Para la búsqueda de hiper-parámetros y observar la convergencia del modelo, se extrajo 10% de los datos de entrenamiento como conjunto de validación. En este trabajo utilizamos k=10 para presentar los resultados.

4.1.4.4 RESULTADO ALCANZADO POR EL MODELO

La Tabla 2 resume los resultados alcanzados en la evaluación de nuestro modelo.

Tabla 2: Desempeño del modelo usando validación cruzada (10-folds)

Modelo	Ventana temporal (s)	Exactitud (%)	Sensibilidad (%)	Especificidad (%)	Precisión (%)
(Chakrabarti et al., 2021) ¹	1	86.3 ± 0.46	83.6 ± 3.83	88.9 ± 3.51	88.5 ± 2.84
	5	73.5 ± 3.44	57.3 ± 7.2	89.8 ± 4.4	85.1 ± 4.93
	10	67.9 ± 2.07	50.6 ± 4.34	84.9 ± 6.55	77.8 ± 6.29
Nuestra propuesta	1	88.4 ± 0.8	85.7 ± 1.55	91.1 ± 2.02	90.6 ± 1.8
	5	89.7 ± 1.73	86.4 ± 4.48	92.9 ± 2.7	92.5 ± 2.25

¹ Método de estado del arte

	10	83.2 ± 2.68	71.5 ± 6.39	94.9 ± 2.47	93.7 ± 3.03
--	-----------	--------------------	--------------------	--------------------	--------------------

4.2 DISCUSION DE RESULTADOS

Se observa en la Tabla 2, que nuestro modelo obtiene alto desempeño, especialmente para segmentos de ventana de 5 segundos, donde el promedio de exactitud es 89.7% y sensibilidad 86.4%. Para segmentos de ventana de 1 segundo, el desempeño también es alto y satisfactor. No obstante, para la ventana de 10 segundos, se tiene una drástica caída en la sensibilidad, 71.5%. Argumentamos que el incremento del tamaño de ventana, reduce el número de muestras de convulsiones, por tanto, el modelo aprende más rápidamente las muestras sin convulsiones, lo que explica que la especificidad aún se incremente en este caso.

A fin de evaluar el desempeño de nuestro modelo en relación al trabajo de (Chakrabarti et al., 2021) que estable el estado de arte. Implementamos su modelo y lo evaluamos en nuestros datos bajo los mismos parámetros de entrenamiento y test presentados en la Sección 4.2.3. Puede observarse que el método de (Chakrabarti et al., 2021) se comporta uniformemente bien en ventanas de 1 segundo, sin embargo, en ventanas de 5 y 10 segundos la caída de desempeño es drástica.

Aunque la técnica de (Chakrabarti et al., 2021) va bien en ventanas de 1 segundo, el desempeño de nuestro modelo es superior en todas las métricas para el mismo tamaño de ventana. Por tanto, siendo la sensibilidad uno de los más importantes indicadores a tomar en cuenta para la confiabilidad de un sistema automático de detección de epilepsia, nuestro método provee alta sensibilidad utilizando un modelo de red simple, pero robusto de pocos parámetros ajustables.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

En esta tesis, se ha diseñado, entrenado y evaluado una red neuronal para la detección de epilepsia utilizando electroencefalogramas, obteniendo una tasa de sensibilidad de 86.4% y especificidad de 92.9%, alcanzando resultados competitivos en el estado del arte.

1. Se ha identificado los datos de entrada para la red neuronal para detección de epilepsia, siendo la mejor opción segmentar en pequeñas ventanas de 1 a 5 segundos de duración.
2. Se ha caracterizado la arquitectura de la red neuronal para detección de epilepsia en términos de capas, hiper-parámetros y estrategia de entrenamiento y test.
3. Se ha descrito los datos de salida de la red neuronal para detección de epilepsia, en términos de resultados de clasificación, convulsión y sin-convulsión.

5.2 RECOMENDACIONES

A continuación, se expresan algunas recomendaciones a fin de mejorar el trabajo:

1. El método de fusión utilizado aprende a proyectar los datos de un espacio a otro, por tanto, puede ser utilizado en otras que implique fusión de información.
2. A pesar de los avances, la detección de epilepsia tiene problemas a ser abordados. Todavía no hay un método general de detección de epilepsia debido a los diferentes tipos de epilepsia (focal, generaliza, sutil, fuerte, diferente según la edad del paciente), esto a su vez se debe a la falta de base de datos aún más inmensas, cuyo procesamiento requerirá computadores de mayores prestaciones y recursos.

3. En el Perú, la epilepsia está estigmatizada. Personas que sufren epilepsia o cualquier otra enfermedad mental sobreviven en el anonimato, sin diagnóstico ni tratamiento. La encefalografía abre un campo para explorar la mente, detectar enfermedades mentales y lesiones neuro-generativas. De allí, la importancia de dotar de sistemas de electroencefalografía y sistemas automáticos de detección de epilepsia, exploración y visualización de la actividad cerebral.

REFERENCIAS BIBLIOGRÁFICAS

- Abbasi, M. U., Rashad, A., Basalamah, A., & Tariq, M. (2019). Detection of Epilepsy Seizures in Neo-Natal EEG Using LSTM Architecture. *IEEE Access*, 7, 179074–179085. <https://doi.org/10.1109/ACCESS.2019.2959234>
- Ackerman, S. (1992). *Discovering the Brain*. <https://doi.org/10.17226/1785>
- Aggarwal, C. C. (2018). Neural Networks and Deep Learning. In *Springer* (Vol. 10). Springer.
- Akhanda, M. A. B. S., Islam, S. M. F., & Rahman, M. M. (2013). Detection of Cognitive State for Brain-Computer Interfaces. *2013 International Conference on Electrical Information and Communication Technology, EICT 2013*, 1–6. <https://doi.org/10.1109/EICT.2014.6777878>
- Albelwi, S., & Mahmood, A. (2017). A Framework for Designing the Architectures of Deep Convolutional Neural Networks. *Entropy 2017, Vol. 19, Page 242, 19(6)*, 242. <https://doi.org/10.3390/E19060242>
- Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P., & Elger, C. E. (2001). Indications of Nonlinear Deterministic and Finite-Dimensional Structures in Time Series of Brain Electrical Activity: Dependence on Recording Region and Brain State. *Physical Review. E, Statistical, Nonlinear, and Soft Matter Physics*, 64(6 Pt 1), 8. <https://doi.org/10.1103/PHYSREVE.64.061907>
- Ayyadevara, V., Reddy, Y., & Safari, an O. M. C. (2020). *Modern Computer Vision with PyTorch*. Packt Publishing.
- Bandstra, N. F., Camfield, C. S., & Camfield, P. R. (2008). Stigma of Epilepsy. *Canadian Journal of Neurological Sciences*, 35(4), 436–440. <https://doi.org/10.1017/S0317167100009082>
- Banich, M. T., & Compton, R. J. (2018). *Cognitive Neuroscience*. <https://doi.org/10.1017/9781316664018>
- Bear, M. F., Connors, B. W., & Paradiso, M. A. (2015). *Neuroscience: Exploring The Brain* (4th ed.). Jones & Bartlett Learning.
- Chakrabarti, S., Swetapadma, A., & Pattnaik, P. K. (2021). A Channel Independent Generalized Seizure Detection Method for Pediatric Epileptic Seizures. *Computer Methods and Programs in Biomedicine*, 209, 106335. <https://doi.org/10.1016/J.CMPB.2021.106335>
- Damasio, H. (2005). *Human Brain Anatomy in Computerized Images* (2nd ed.). Oxford University Press.

- EPILEPSAE. (2021). The European Epilepsy Database. Retrieved May 19, 2021, from <http://www.epilepsy-database.eu/>
- Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... Stanley, H. E. (2010). CHB-MIT Scalp EEG Database v1.0.0. Retrieved November 22, 2021, from <https://physionet.org/content/chbmit/1.0.0/>
- Gonzalez, R. C., & Woods, R. E. (2017). *Digital Image Processing* (4th ed.). Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Haykin, S. (2008). *Neural Networks and Learning Machines*. Pearson Education.
- Hernández, R., Fernández, C., & Baptista, P. (2016). *Metodología de la Investigación* (6th ed.). McGraw-Hill.
- Hsieh, C. H., Li, Y. S., Hwang, B. J., & Hsiao, C. H. (2020). Detection of Atrial Fibrillation Using 1D Convolutional Neural Network. *Sensors (Basel, Switzerland)*, 20(7). <https://doi.org/10.3390/S20072136>
- Hurbans, R. (2020). *Grokking Artificial Intelligence Algorithms*. Retrieved from <https://www.manning.com/books/grokking-artificial-intelligence-algorithms>
- Instituto de Ciencias Neurológicas del Perú. (2019). Cirugía Especializada en Pacientes con Epilepsia de Difícil Control. Retrieved May 1, 2020, from <http://www.incn.gob.pe/>
- Jacoby, A., & Austin, J. K. (2007). Social Stigma for Adults and Children with Epilepsy. *Epilepsia*, 48(SUPPL. 9), 6–9. <https://doi.org/10.1111/j.1528-1167.2007.01391.x>
- Koubeissi, M. Z., & Azar, N. J. (2017). *Epilepsy Board Review : A Comprehensive Guide*.
- Liu, Q., Liu, Y., Chen, K., Wang, L., Li, Z., Ai, Q., & Ma, L. (2021). Research on Channel Selection and Multi-feature Fusion of EEG Signals for Mental Fatigue Detection. *Entropy*, 23(4). <https://doi.org/10.3390/E23040457>
- Lundy-Ekman, L. (2017). *Neuroscience : Fundamentals for Rehabilitation* (5th ed.). Saunders.
- Mayo Clinic. (2020). Epilepsy - Symptoms and Causes. Retrieved February 24, 2022, from <https://www.mayoclinic.org/diseases-conditions/epilepsy>
- Moctezuma, L. A., & Molinas, M. (2020). EEG Channel-Selection Method for Epileptic-Seizure Classification Based on Multi-Objective Optimization. *Frontiers in Neuroscience*, 14, 593.

<https://doi.org/10.3389/FNINS.2020.00593/BIBTEX>

- OMS. (2019). Más del 50% de las personas con epilepsia no reciben atención médica en América Latina. Retrieved April 18, 2021, from Noticias de la Organización Mundial de la Salud website: <https://news.un.org/es/story/2019/01/1449982>
- OMS. (2020). Epilepsia. *Organización Mundial de La Salud. Tópicos En Salud*. Retrieved from <https://www.who.int/es/news-room/fact-sheets/detail/epilepsy>
- PhysioNet. (2021). The Research Resource for Complex Physiologic Signals. Retrieved May 19, 2021, from <https://physionet.org/>
- Qin, Z., Yu, F., Liu, C., & Chen, X. (2018). *How Convolutional Neural Networks See The World - A Survey of Convolutional Neural Network Visualization Methods*. 1(2), 149. <https://doi.org/10.3934/MFC.2018008>
- Rim, B., Sung, N.-J., Min, S., & Hong, M. (2020). Deep Learning in Physiological Signal Data: A Survey. *Sensors*, 20(4), 969. <https://doi.org/10.3390/s20040969>
- 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). <https://doi.org/10.1088/1741-2552/ab260c>
- Shoeb, A., & Guttag, J. (2010). Application of Machine Learning to Epileptic Seizure Detection. *ICML'10: Proceedings of the 27th International Conference on International Conference on Machine Learning*, 975--982.
- Wyllie, E. (2020). *Wyllie's Treatment of Epilepsy* (7th ed.). Wolters Kluwer Medical.
- Zhou, M., Tian, C., Cao, R., Wang, B., Niu, Y., Hu, T., ... Xiang, J. (2018). Epileptic Seizure Detection Based on EEG Signals and CNN. *Frontiers in Neuroinformatics*, 12, 95. <https://doi.org/10.3389/fninf.2018.00095>

ANEXOS

ANEXO 1. MATRIZ DE CONSISTENCIA

TITULO: "RED NEURONAL ARTIFICIAL PARA DETECTAR EPILEPSIA USANDO ELECTROENCEFALOGRAMAS EN EL HOSPITAL DE NIÑOS DE BOSTON, ESTADOS UNIDOS, 2010".

PROBLEMAS	OBJETIVOS	VARIABLES E INDICADORES	METODOLOGÍA
<p>PROBLEMA GENERAL ¿Cuáles son las características de una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas en el Hospital de Niños de Boston, Estados Unidos 2010?</p> <p>PROBLEMAS ESPECÍFICOS a) ¿Cuáles son las características de datos de entrada en una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas? b) ¿Cómo es la arquitectura de red en una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas? c) ¿Cuáles son las características de salida de la red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas?</p>	<p>OBJETIVO GENERAL Diseñar una red neuronal artificial para la detección de epilepsia mediante técnicas de inteligencia artificial utilizando electroencefalogramas en el Hospital de Niños de Boston, Estados Unidos, 2010.</p> <p>OBJETIVOS ESPECÍFICOS a) Identificar los datos de entrada de la red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas. b) Caracterizar la arquitectura de red de una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas. c) Describir los datos de salida una red neuronal artificial para la detección de epilepsia utilizando electroencefalogramas.</p>	<p>VARIABLE DE INTERÉS X: RED NEURONAL ARTIFICIAL</p> <p>VARIABLES DESCRIPTIVAS X1: Datos de entrada Datos provistos por el electroencefalograma, de determinado tamaño temporal (segundos) y espacial (cantidad de electrodos), para ser procesados por la red neuronal artificial. X2: Arquitectura de red Es la organización, disposición e interconexión de las neuronas en grupos o capas para detectar epilepsia. Es la parte fundamental de la red neuronal artificial. X3: Datos de salida Es la salida de la red neuronal artificial, datos que permiten realizar predicciones.</p>	<p>TIPO DE INVESTIGACIÓN Observacional, retrospectivo, transversal y descriptivo</p> <p>NIVEL DE INVESTIGACIÓN Descriptivo</p> <p>DISEÑO No experimental, retrospectivo, transversal.</p> <p>POBLACIÓN La población está compuesta por 24 pacientes epilépticos entre 3 y 23 años edad, varones y mujeres, del Hospital de Niños de Boston Estados Unidos del año 2010.</p> <p>MUESTRA No existe muestra, será un censo, porque se estudia a todas las personas.</p> <p>TÉCNICA Análisis documental.</p> <p>INSTRUMENTO Registro</p>



ACTA DE SUSTENTACIÓN DE TESIS

ACTA N° 038-2022-FIMGC

En la ciudad de Ayacucho, en cumplimiento a la **RESOLUCIÓN DECANAL N° 158-2022-FIMGC-D**, siendo los veintidós días del mes de junio del 2022, a horas 3:00 p.m.; se reunieron los jurados del acto de sustentación, en el Auditorium virtual google meet del Campus Universitario de la Universidad Nacional de San Cristóbal de Huamanga.

Siendo el Jurado de la sustentación de tesis compuesto por el presidente el **Dr. Ing. Manuel Avelino LAGOS BARZOLA**, Jurado el **Mg. Ing. Javier PORTILLO QUISPE**, Jurado el **Ing. José Antonio GUERRERO HINOSTROZA**, Jurado - Asesor el **Dr. Ing. Efraín Elías PORRAS FLORES** y secretario del proceso el **Mg. Ing. Christian LEZAMA CUELLAR**, con el objetivo de recepcionar la sustentación de la tesis denominada “**RED NEURONAL ARTIFICIAL PARA DETECTAR EPILEPSIA USANDO ELECTROENCEFALOGRAMAS EN EL HOSPITAL DE NIÑOS DE BOSTON, ESTADOS UNIDOS, 2010**”, sustentado por el Señor **José Elías YAURI VIDALON**, Bachiller en Ingeniería de Informática.

El Jurado luego de haber recepcionado la sustentación de la tesis y realizado las preguntas, el sustentante al haber dado respuesta a las preguntas, y el Jurado haber deliberado; califica con la nota aprobatoria de **17 (Diecisiete)**.

En fe de lo cual, se firma la presente acta, por los miembros integrantes del proceso de sustentación.

Dr. Ing. Manuel Avelino LAGOS BARZOLA
Presidente

Mg. Ing. Javier PORTILLO QUISPE
Jurado

Dr. Ing. Efraín Elías Porras Flores

Firmado digitalmente por Dr. Ing. Efraín Elías Porras Flores
Fecha: 2022.06.28
08:35:34 -09'00'

Dr. Ing. Efraín Elías PORRAS FLORES
Jurado Asesor

Ing. José Antonio GUERRERO HINOSTROZA
Jurado

Firmado digitalmente por LEZAMA CUELLAR CHRISTIAN

Mg. Ing. Christian LEZAMA CUELLAR
Secretario del Proceso



UNSCH

FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL

"Año del Fortalecimiento de la Soberanía Nacional"

CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 034-2022-FIMGC

El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado en segunda instancia para las Escuelas Profesionales de la Facultad de Ingeniería de Minas, Geología y Civil; en cumplimiento a la Resolución de Consejo Universitario N° 039-2021-UNSCH-CU, Reglamento de Originalidad de Trabajos de Investigación de la UNSCH y Resolución Decanal N° 158-2021-FIMGC-UNSCH-D, deja constancia que Sr./Srta.

Apellidos y Nombres : José Elías, Yauri Vidalón
Escuela Profesional : INGENIERÍA DE SISTEMAS
Título de la Tesis : "RED NEURONAL ARTIFICIAL PARA DETECTAR EPILEPSIA USANDO ELECTROENCEFALOGRAMAS EN EL HOSPITAL DE NIÑOS DE BOSTON, ESTADOS UNIDOS, 2010"
Evaluación de la Originalidad : 5 % Índice de Similitud
Identificador de la entrega : 1855047908

Por tanto, según los Artículos 12, 13 y 17 del Reglamento de Originalidad de Trabajos de Investigación, es **PROCEDENTE** otorgar la **Constancia de Originalidad** para los fines que crea conveniente.

Ayacucho, 12 de junio del 2022

Firmado digitalmente
por LEZAMA CUELLAR
CHRISTIAN

Mg. Ing. Christian LEZAMA CUELLAR
Verificador de Originalidad de Trabajos de Tesis de Pregrado
de la FIMGC

(X) Con depósito para Sustentación y Tramite de Titulo

RED NEURONAL ARTIFICIAL PARA DETECTAR EPILEPSIA
USANDO ELECTROENCEFALOGRAMAS EN EL HOSPITAL DE
NIÑOS DE BOSTON, ESTADOS UNIDOS, 2010

“RED NEURONAL ARTIFICIAL
PARA DETECTAR EPILEPSIA
USANDO
ELECTROENCEFALOGRAMAS EN
EL HOSPITAL DE NIÑOS DE
BOSTON, ESTADOS UNIDOS,
2010”

por José Elías Yauri Vidalón

Fecha de entrega: 11-jun-2022 08:53p.m. (UTC-0500)

Identificador de la entrega: 1855047908

Nombre del archivo: Tesis_Yauri_Vidal_n,_Jos_El_as.pdf (2.01M)

Total de palabras: 11428

Total de caracteres: 65400

"RED NEURONAL ARTIFICIAL PARA DETECTAR EPILEPSIA USANDO ELECTROENCEFALOGRAMAS EN EL HOSPITAL DE NIÑOS DE BOSTON, ESTADOS UNIDOS, 2010"

INFORME DE ORIGINALIDAD

5%

INDICE DE SIMILITUD

4%

FUENTES DE INTERNET

2%

PUBLICACIONES

3%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Nacional de San Cristóbal de Huamanga Trabajo del estudiante	2%
2	hdl.handle.net Fuente de Internet	1%
3	repositorio.upt.edu.pe Fuente de Internet	1%
4	A. Martorell, A. Martin-Gorgojo, E. Ríos-Viñuela, J.M. Rueda-Carnero, F. Alfageme, R. Taberner. "Inteligencia artificial en dermatología: ¿amenaza u oportunidad?", Actas Dermo-Sifiliográficas, 2021 Publicación	1%
5	nanopdf.com Fuente de Internet	<1%
6	"IV Latin American Congress on Biomedical Engineering 2007, Bioengineering Solutions	<1%

for Latin America Health", Springer Nature,
2008

Publicación

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo