



## **ESCUELA UNIVERSITARIA DE POSGRADO**

MODELO DE APRENDIZAJE DE SEÑALES ELECTROENCEFALOGRAMA PARA  
MEJORAR LA DETECCIÓN DE CONVULSIONES DE CRISIS DE AUSENCIA EN  
PACIENTES INFANTES NEUROPEDIÁTRICOS

**Línea de investigación:**  
**Sistemas inteligentes, robótica, domótica**

Tesis para optar el grado académico de Doctor en Ingeniería de Sistemas

### **Autor**

Huarote Zegarra, Raul Eduardo

### **Asesor**

Flores Masías, Edward José

ORCID: 0000-0001-8972-5494

### **Jurado**

Cachay Boza, Orestes

Petrlik Azabache, Ivan Carlo

Ogosi Auqui, José Antonio

**Lima - Perú**




**2026**



# 22% Similitud general



El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

## Fuentes principales

- 21%  Fuentes de Internet
- 6%  Publicaciones
- 7%  Trabajos entregados (trabajos del estudiante)

## Marcas de integridad

### N.º de alertas de integridad para revisión

-  **Caracteres reemplazados**  
196 caracteres sospechosos en N.º de páginas  
Las letras son intercambiadas por caracteres similares de otro alfabeto.
-  **Texto oculto**  
196 caracteres sospechosos en N.º de página  
El texto es alterado para mezclarse con el fondo blanco del documento.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.



ESCUELA UNIVERSITARIA DE POSGRADO

MODELO DE APRENDIZAJE DE SEÑALES ELECTROENCEFALOGRAMA PARA  
MEJORAR LA DETECCIÓN DE CONVULSIONES DE CRISIS DE AUSENCIA EN  
PACIENTES INFANTES NEUROPEDIÁTRICOS

**Línea de investigación:**

Sistemas inteligentes, robótica, domótica

Tesis para optar el grado académico de:  
Doctor en ingeniería de sistemas

**Autor**

Huarote Zegarra, Raul Eduardo

**Asesor**

Flores Masías Edward José  
ORCID: 0000-0001-8972-5494

**Jurado**

Cachay Boza, Orestes

Petrlik Azabache, Ivan Carlo

Ogosi Auqui, José Antonio

**Lima – Perú**

**2026**

**Dedicatoria:**

Muy en especial, a mis hijos, por darme la fuerza para continuar con este logro.

**Reconocimiento:**

Mi especial reconocimiento para los distinguidos Miembros del Jurado:

Por su criterio objetivo en la evaluación de este trabajo de investigación. Asimismo, mi reconocimiento para mi asesor: Dr. Flores Masías Edwar José, por las sugerencias recibidas para el mejoramiento de este trabajo.

Por su aporte importante para el logro de la presente investigación, a la neuropediatra

Dra. Judith Raquel Vila Paucarcaja.

Muchas gracias para todos.

## ÍNDICE

RESUMEN .....	8
ABSTRACT .....	9
I. INTRODUCCIÓN.....	10
1.1. Planteamiento del problema.....	10
1.2. Descripción del problema.....	11
1.3. Formulación del problema.....	15
1.4. Antecedentes.....	16
1.5. Justificación de la investigación.....	26
1.6. Limitaciones de la investigación.....	27
1.7. Objetivos.....	28
1.8. Hipótesis.....	29
II. MARCO TEÓRICO.....	30
2.1. Marco conceptual.....	30
III. MÉTODO.....	41
3.1. Tipo de investigación.....	41
3.2. Población y muestra.....	42
3.3. Operacionalización de variables.....	43
3.4. Instrumentos.....	46
3.5. Procedimientos.....	46
3.6. Análisis de datos.....	47
3.6.1. Selección de frecuencias.....	48
3.7. Consideraciones éticas.....	50
IV. RESULTADOS.....	52
4.1. Contrastación de hipótesis.....	52
4.2. Creación del modelo de aprendizaje.....	53
4.2.1. Aprendizaje de modelos basados en inteligencia artificial.....	58
4.2.2. <i>generación de nuevo conocimiento</i> .....	63
4.2.3. <i>Complejidad computacional</i> .....	65

4.2.4. Prueba de hipótesis.....	66
4.3. Análisis e interpretación.....	68
V. DISCUSIÓN DE RESULTADOS .....	69
VI. CONCLUSIONES .....	70
VII. RECOMENDACIONES .....	71
VIII. REFERENCIAS.....	73
IX. ANEXOS .....	79
Anexo 1: Paciente en el momento de evaluación, y se identifica crisis de ausencia en un electroencefalograma .....	79
Anexo 2: Matriz de consistencia .....	80
Anexo 3: Resultado de aplicar la Coherencia en Python, en un entorno Colab.....	82
Anexo 4: Resultado de aplicar la Desviación Estándar en Python, en un entorno Colab .....	84
Anexo 5: Resultado de aplicar R2 en Python, en un entorno Colab.....	86
Anexo 6: Resultado de aplicar el conteo de picos en el momento de crisis en Python, en un entorno Colab .....	89
Anexo 7: Afectación específica del paciente en el momento de crisis de ausencia. ....	90

## ÍNDICE DE FIGURAS

Figura 1. Posiciones de los electrodos según sistema internacional 10-20, para realizar la toma de frecuencias en un electroencefalograma. Fuente: (company, 2025) .....	38
Figura 2. Crisis de ausencia en porciones de frecuencias de cada electroencefalograma, generado por BWAnalysis.....	49
Figura 3. Porción de 500 frecuencia que no es crisis de ausencia.....	50
Figura 4. Procesos para la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos .....	56
Figura 5. Modelo de herramienta de preprocesamiento de datos para el análisis de en datos de tipos EEG. Fuente <a href="https://eeglab.org/">https://eeglab.org/</a> .....	56
Figura 6. Chanel spectral and maps, de 18 canales con 1128000 valores de frecuencias de 09eeg_7uV_1p00s_35Hz.edf, fuente:elaborado en eegLab de Matlab.....	57
Figura 7. Extracción de frecuencias de cada electroencefalograma .....	59
Figura 8. Aprendizaje y comprobación con 1588 sucesos para ‘sin crisis’, ‘con crisis’ y ‘previo’, elaborado en Python. Imagen usando a) Red neuronal backpropagation, b) Red neuronal SOM, c) Vecino más cercano, d) Árbol de decisión .....	62
Figura 9. Matriz de confusión con 1588 sucesos para ‘sin crisis’, ‘con crisis’ y ‘previo’, elaborado en Python. Imagen usando a) Red neuronal backpropagation, b) Red neuronal SOM, c) Vecino más cercano, d) Árbol de decisión, e) Random forest .....	62
Figura 10. En los momentos de crisis se ha identificado a) Coherencia de canales, b) $R^2$ . Elaborado en seaborn de Python.....	64
Figura 11. Desviación estándar máximo por cada momento de crisis de ausencia, elaborado en Python .....	65

## ÍNDICE DE TABLAS

Tabla 1. Posición de los electrodos en función de circunferencia de la cabeza.....	37
Tabla 2. Población que se estudia en la presente investigación.....	42
Tabla 3. Indicador que muestra variable independiente .....	43
Tabla 4. Descripción de indicadores de la variable dependiente .....	44
Tabla 5. operacionalización de variables .....	45
Tabla 6. Resultado de aplicar los modelos basado en inteligencia artificial para la identificación de crisis de ausencia con datos de otro archivo con 1588 registros.....	62

## RESUMEN

El objetivo de la presente investigación es determinar el impacto de un modelo de aprendizaje de señales electroencefalograma en la detección de convulsiones de crisis de ausencia en pacientes infantiles neuropediátricos, tomando como fuente de datos las frecuencias aplicando el filtro Gabor para convertir en patrones de entrada a los diferentes modelos basado en inteligencia artificial, como la red neuronal supervisada, red neuronal SOM, vecino más cercano, árbol de decisión y random forest. La metodología que se utiliza es de tipo aplicada, con un nivel de investigación explicativa, siendo el diseño de la investigación de tipo experimental, con un modelo de aprendizaje que empleará las técnicas de inteligencia artificial con los fines de integración de información que deberá procesar e identificar. La muestra utilizada es de 3484 segundos de electroencefalograma del paciente que está diagnosticados con crisis de ausencia. Con lo cual se obtuvo como mejor resultado al aplicar el modelo de aprendizaje de señales electroencefalograma aplicando el filtro de Gabor a las frecuencias, se obtuvo en el testeo una sensibilidad, especificidad y exactitud para cada modelo respectivamente como red neuronal artificial de tipo como red neuronal artificial de tipo back propagation los valores de 0.99, 1.0, 0.99, 0.93 para la red neuronal SOM 0.99, nan, 0.99, 0.99, para el vecino más cercano 0.99, 0.0, 0.99, 0.97, para árbol de decisión 0.99, 0.0, 0.99, 0.97 y random forest 0.99, nan, 0.99, 0.97 respectivamente. Con el modelo propuesto ha generado nuevos conocimientos en los momentos de crisis de ausencia, se identificó una coherencia en los canales de 0.63 resaltando que en el momento de crisis todos los canales siguen un mismo patrón común, se identificó el coeficiente de correlación  $R^2 = 0.77$  específicamente en los canales 'C3-P3' con 'P4-O2' indicando el nivel de similaridad de las frecuencias en el momento de crisis, se identificó una desviación estándar muy alto (47.49) en el canal 'T6-O2' resaltando los polipunto-cola con más de 5 picos implicando la pérdida de conciencia en el área Temporal y Occipital derecho. Por tanto, concluye que aplicando el modelo propuesto de aprendizaje de señales electroencefalograma detecta las convulsiones de crisis de ausencia en pacientes infantiles neuropediátricos, también dicho modelo genera nuevos conocimientos, tal como la existencia del vínculo de ciertos canales en los segundos de crisis de ausencia y nivel de afectación.

**Palabras claves:** Redes neuronales artificial artificiales, árbol de decisión, red som, random forest electroencefalograma, crisis de ausencia, Filtro Gabor.

## ABSTRACT

The objective of this research is to determine the impact of an electroencephalogram signal learning model on the detection of absence seizures in neuropsychiatric infant patients, using frequencies as a data source and applying the Gabor filter to convert them into input patterns for different artificial intelligence-based models, such as supervised neural networks, SOM neural networks, nearest neighbor, decision trees, and random forests. The methodology used is applied, with a level of explanatory research. The research design is experimental, with a learning model that will use artificial intelligence techniques for the purpose of integrating information that must be processed and identified. The sample used consists of 3,484 seconds of electroencephalogram data from a patient diagnosed with absence seizures. The best result was obtained by applying the electroencephalogram signal learning model using the Gabor filter to the frequencies. The test yielded sensitivity, specificity, and accuracy for each model, respectively, as follows: for the backpropagation artificial neural network, the values were 0.99, 1.0, 0.99, 0.93; for the SOM neural network, 0.99, nan, 0.99, 0.99, for the nearest neighbor 0.99, 0.0, 0.99, 0.97, for decision tree 0.99, 0.0, 0.99, 0.97, and random forest 0.99, nan, 0.99, 0.97, respectively. The proposed model has generated new knowledge in moments of absence crisis. A consistency of 0.63 was identified in the channels, highlighting that in moments of crisis, all channels follow the same common pattern. The correlation coefficient  $R^2 = 0.77$  was identified specifically in channels 'C3-P3' with 'P4-O2', indicating the level of similarity of frequencies at the moment of crisis. A very high standard deviation (47.49) was identified in the 'T6-O2' channel, highlighting poly-point tails with more than 5 peaks, implying loss of consciousness in the right temporal and occipital areas. Therefore, it concludes that applying the proposed model of electroencephalogram signal learning detects absence seizures in neuropsychiatric infant patients. This model also generates new knowledge, such as the existence of a link between certain channels in the seconds of absence seizures and the level of impairment.

**Keywords:** artificial neural network, decision tree, encephalogram, absence seizures, net som, random forest, Gabor Filter.

## I. INTRODUCCIÓN

### 1.1. Planteamiento del problema

Para enmarcarnos en el escenario de estudio sobre la crisis de ausencia en pacientes pediátricos, es necesario conocer la Epilepsia de Ausencia Infantil (EAI) “es una epilepsia infantil familiar generalizada que se caracteriza por crisis de ausencia muy frecuentes (varias al día) y que, por lo general, se presenta en niños entre los 4 y 10 años de edad, con buen pronóstico en la mayoría de los casos”.

El presente trabajo de investigación tiene como finalidad la generación de un modelo de aprendizaje de señales electroencefalograma para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos, para el uso de herramientas tecnológica basada en inteligencia artificial como son la red neuronal supervisada, red neuronal de mapas autoorganizadas (SOM), vecino más cercano, árbol de decisión y random forest, así también encontrar la relación de los canales en el momento de la crisis de ausencia, tomando como fuente datos las frecuencias de los 02 electroencefalogramas (frecuencias de actividades cerebrales en formato original .eeg) en ellas conteniendo 07 crisis de ausencia identificadas por la especialista en un universo de 5434 segundos, considerando que cada segundo tiene 500 frecuencias (ósea 2 717 000 frecuencias totales por cada canal) y están diagnosticados con crisis de ausencia por la especialista neuropediatra. Para que las frecuencias del encefalograma sean ingresadas como patrones de entrada a la red, es necesario aplicar una estrategia para extraer las características resaltantes de las frecuencias contempladas dentro del diagnóstico como crisis de ausencia, así también las frecuencias son menores a  $<2.5$  Hz.

El tipo de investigación es aplicada, con un nivel de investigación explicativa, siendo el diseño de la investigación de tipo experimental. Desde un punto de vista específico se pretende mejorar el nivel de sensibilidad o la tasa de verdaderos positivos, la especificidad o la

tasa de verdaderos negativos, así también el nivel de exactitud en la identificación de crisis de ausencia en los EEG. Esto en base a la especialista neuropediatra donde identifica los momentos de crisis de ausencia visualizando las frecuencias de los canales en un software del fabricante del equipo. Así también tiene que ser contrastado estadísticamente con la funcionalidad del modelo propuesto.

## **1.2.Descripción del problema.**

Es necesario conocer que (Mediclopedia, Clasificación Internacional de las enfermedades icd-10, 2021) en el Clasificador Internacional de Decesos (ICD) basado por World Health Organization (WHO, 2019) clasifica como G40.3 a la epilepsia ausencia juvenil e infancia, también (ORPHANET, 2021) dentro de las enfermedades raras y medicamentos huérfanos califica a la EAI, apareciendo desde la infancia hasta la adolescencia. De manera rutinaria para identificar la crisis de ausencia en pacientes neuropediátricos se aplica la prueba hiperventilación, el cual consiste en soplar un papel en un tiempo determinado y el neuropediatra analiza su comportamiento en el transcurso. Otra de las maneras es utilizar herramientas tecnológicas para la lectura y análisis detallado del comportamiento de las frecuencias del cerebro por medio del electroencefalograma (EEG). (ORPHANET, 2021) identifica que la EAI representa entre un 10% - 17% de todos los casos de epilepsia diagnosticada en niños en edad escolar y que, por lo general, las mujeres están más afectadas que los hombres. Así también el Instituto Nacional de Salud del Niño (INSN, 2020) resalta que en América Latina se sitúa en una media de 17,8/1000 habitantes que padecen de EAI, resaltando que no hay diferencia significativa en el sexo o grupos de edad del habitante. Para (Romero Barzola & Pujol Salud, 2023) considera que la epilepsia es uno de los trastornos neurológicos más comunes, el riesgo de tener crisis de ausencia hasta adulto es de 10%, aunque sólo el 3% será diagnosticado de epilepsia de crisis de ausencia, por lo que se deben tener en

cuenta una amplia gama de otros diagnósticos diferenciales que no corresponden propiamente a epilepsia.

En Perú donde el INSN (2020) indica que hasta la edad de 15 años el 1 a 1.7% de los niños tendrá al menos una crisis no provocada, el 0.7 a 0.8% repetirán la crisis, los factores de riesgo como país en vías de desarrollo es factor medio ambiental, reflejado en la ausencia sanitaria y factores hereditarios. Se utilizarán herramientas tecnológicas para la lectura de frecuencias del cerebro por medio del electroencefalograma de 16 o 32 canales para el mapeo cerebral.

Según Thierer (2021) cuando se realiza una prueba diagnóstica se busca determinar la presencia o ausencia de una patología, como este caso la identificación de las convulsiones de crisis de ausencia en un conjunto de frecuencias, por tanto, lo ideal sería que en base a las frecuencias de crisis de ausencia diagnostique correctamente a todos las pacientes neuropediátricos que no lo padecen y los que sí.

Los médicos Bennett, Arsalan, & Sanjay (2018) en su investigación considera que el diagnóstico correcto de cualquier enfermedad es crucial para el tratamiento eficaz. A pesar de tener tecnologías a la mano, los errores en el diagnóstico son muy frecuentes en la práctica médica y estos errores terminan provocando resultados adversos en los pacientes. En su estudio encontró que los errores más comunes se dan por las deficiencias u omisiones en el examen clínico y en el conocimiento de cada enfermedad. Resaltando que “Las investigaciones sugieren que el mejor conocimiento de las enfermedades y de la anamnesis y el examen clínico puede disminuir los errores diagnósticos”, en este sentido los médicos (Brett, Alyssa, & Robert, 2017) manifiestan que los errores en medicina es uno de los desafíos más trascendentes, así como en otras disciplinas que participan en el cuidado de la salud, por tanto, los diagnósticos han merecido recientemente más atención y se está comenzando a conocer mejor sus

mecanismos para el análisis de eventos adversos, que alcanzaban un 15% a 20% y son los más difíciles de evitar. También Andrew, Sanch, Lisa, & Dipti (2019) espera crear conciencia sobre los problemas comunes y mejorar la práctica en la salud, basándose en su investigación los errores comunes, tal como aplicado la vacuna individual para la fiebre amarilla fue la más discutida, ya que el 28,4% de los incidentes clínicos notificados fueron por las vacunas.

Desde el punto de vista global, según el Dr. Gabrielle Rudolf, especialista de ORPHANET identifica que la EAI representa entre un 10% - 17% de todos los casos de epilepsia diagnosticada en niños en edad escolar. La incidencia se ha estimado en 1/50.000-1/12.500 habitantes en los Estados Unidos y que, por lo general, las mujeres están más afectadas que los hombres. (Epilepsy, 2024) considera que los niños que tienen estas características que comienzan antes de los 4 años, el 10 % tiene deficiencia de GLUT1 (una mutación en el SLC2A1). Otros genes vinculados a este síndrome incluyen el GABRG2 y el CACNA1A, hasta el 20 % de los pacientes pueden tener un familiar en primer grado con crisis. Para Epilepsy (2024) los miembros afectados de la familia suelen tener epilepsia de ausencia infantil considerada hasta en un 20% de los pacientes. Así también INSN (2020) resalta que en América Latina se sitúa en una media de 17,8/1000 habitantes, resaltando para esta investigación no hubo diferencias significativas de acuerdo con el sexo o grupos de edad del habitante. Para Romero Barzola & Pujol Salud (2023) considera que la epilepsia es uno de los trastornos neurológicos más comunes, el riesgo de por vida de tener una crisis para un adulto es de hasta el 10%, aunque solo el 3% será diagnosticado de epilepsia, y ocurre por múltiples razones (trastornos metabólicos, abstinencia alcohólica u otros trastornos neurológicos) por lo que se deben tener en cuenta una amplia gama de otros diagnósticos diferenciales que no corresponden propiamente a epilepsia, pues desde el 2017 la Liga Internacional contra la Epilepsia (ILAE) utiliza una clasificación basada en tres niveles: el tipo de crisis, el tipo de

epilepsia y el síndrome epiléptico. En cada nivel la etiología y las comorbilidades deben identificarse por las implicaciones terapéuticas.

Desde el punto de vista local, a consideración del INSN (2020) indica que hasta la edad de 15 años 1-1.7% de los niños tendrá al menos una crisis no provocada, el 0.7-0.8% repetirán la crisis, los factores de riesgo como país en vías de desarrollo es factor medio ambiental, reflejado en la ausencia sanitaria y factores hereditarios.

En este contexto la descripción del problema se basa en los errores frecuentes de diagnósticos, específicamente en la detección de crisis de ausencia en las frecuencias del EEG, y que pueden ser muy perjudiciales para los pacientes. Por tanto, para la elaboración de un modelo hay que tomar en cuenta una de las medidas dada por Altman DG. (1994) donde menciona que la valuación de la sensibilidad, especificidad y nivel de exactitud se puede aplicar a los pacientes con las convulsiones de crisis de ausencia (E+), el test puede resultar positivo, expresando que la enfermedad existe (T+), o negativo, quedando la enfermedad sin diagnóstico (T). El T+ en E+ es un verdadero positivo (VP), porque se diagnostica enfermedad en alguien verdaderamente enfermo. El T- en E+ es lo que llamamos un falso negativo (FN), porque no se diagnostica enfermedad en alguien que está enfermo. La capacidad del test para diagnosticar enfermedad puede cuantificarse como la cantidad de T+ en E+ (los VP), sobre el total de los tests realizados en E+ (los VP más los FN).

El cociente  $VP / (VP + FN)$  es la tasa de verdaderos positivos, o SENSIBILIDAD del test. Cuanto mayor es la sensibilidad del test, más enfermos serán diagnosticados adecuadamente, con lo que la tasa de FN será menor.

El cociente  $VN / (VN + FP)$  es lo que se llama tasa de verdaderos negativos, o ESPECIFICIDAD del test. Cuanto mayor es la especificidad del test, más sanos serán diagnosticados adecuadamente, con lo que la tasa de FP será menor.

El NIVEL DE EXACTITUD está dado por  $(VP + VN) / (VP + FP + FN + VN)$  es la probabilidad de que el resultado del test prediga correctamente la presencia o ausencia de la enfermedad.

A partir del análisis de los resultados de los informes se puede evaluar una consecuencia del diagnóstico. Por tanto, también es necesario evaluar el nivel de asertividad del tratamiento pues esto conlleva a la mejora del paciente o a la prolongación de crisis.

Considerando la enfermedad que la padece cada uno de las personas diagnosticadas con epilepsia de tipo crisis de ausencia, siendo una de sus limitaciones estar ausente mentalmente por breves segundos, por tanto, para identificarlas, será por medio de un equipo de tipo electroencefalograma (EEG), sin necesidad de ser invasivos, corroborado por el psiquiatra alemán (Berger, 1929) donde refleja que esta técnica suele ser no invasiva, es obtenerlo por medio de las señales eléctricas del cerebro.

### **1.3. Formulación del problema.**

#### ***Problema general***

¿Cómo el modelo de aprendizaje de señales electroencefalograma aplicando el filtro Gabor a las frecuencias mejora la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos?

#### ***Problemas específicos***

- PE1: ¿Cómo identificar el nivel de sensibilidad en la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos basado en un nuevo modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias?

- PE2: ¿Cómo identificar el nivel de especificidad en la detección de convulsiones de crisis de ausencia en pacientes infantes de una institución neuropsiquiátrica basado en un nuevo modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias?
- PE3: ¿Cómo identificar el nivel de exactitud en la detección de convulsiones de crisis de ausencia en pacientes infantes de una institución neuropsiquiátrica basado en un nuevo modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias?

## **1.4. Antecedentes**

### **Antecedentes Internacionales**

Según Anuragi, Sisodia, & Pachori (2021) en su investigación realizada en la India, la epilepsia es un trastorno neurológico que ha afectado gravemente la vida de muchas personas en todo el mundo. Las señales de electroencefalograma (EEG) se utilizan para caracterizar el estado del cerebro y detectar diversos trastornos. Las señales de EEG son de naturaleza no estacionaria y no lineal. Por lo tanto, es un desafío procesar con precisión y aprender de las señales de EEG registradas para detectar trastornos como la epilepsia. Esta investigación propuso un marco de aprendizaje automatizado utilizando el método de transformada de ondas empíricas basado en la expansión de la serie Fourier-Bessel (FBSE-EWT) para detectar ataques epilépticos de las señales de EEG. El método de detección de límites de espacio de escala se adoptó para segmentar el espectro de expansión de la serie de Fourier-Bessel (FBSE) de múltiples señales de EEG segmentadas en el tiempo de tamaño de fotograma. El análisis de la señal de EEG segmentada en el tiempo de varios tamaños de cuadro se realizó utilizando cuatro tamaños de cuadro diferentes: longitud completa, mitad, cuarto y medio cuarto de las señales EEG registradas. Se investigaron dos enfoques diferentes de segmentación en el tiempo en las

señales de EEG: 1) señales de segmentación basadas en tamaños de tramas múltiples y 2) señales de segmentación basadas en tamaños de tramas múltiples con relleno de ceros en la señal restante. Se aplicó el método FBSE-EWT para descomponer las señales de EEG en señales de sub-banda estrecha. Se calcularon características como longitud de línea (LL), log-energy-entropy (LEnt) y norm-entropy (NEnt) a partir de varias señales de subbanda de rango de frecuencia. Se empleó el método de clasificación de características en relieve-F para seleccionar las características más significativas; esto reduce la carga computacional de los modelos. Las características acumuladas mejor clasificadas se utilizaron para clasificación utilizando aprendizaje automático de soporte de mínimos cuadrados (LS-SVM), máquina de vectores de soporte (SVM), k-vecino más cercano (k-NN) y clasificadores de árbol en bolsa de conjunto. El marco propuesto para la detección de ataques epilépticos se evaluó en dos conjuntos de datos de EEG de referencia disponibles públicamente: el conjunto de datos de EEG de Bonn y el Children's Hospital Boston (CHB) y el Instituto de Tecnología de Massachusetts (MIT), conocido como el cuero cabelludo CHB-MIT Conjunto de datos de EEG. El entrenamiento y la prueba de los modelos se realizaron utilizando la técnica de validación cruzada de 10 veces. El marco de aprendizaje basado en FBSE-EWT se comparó con otros métodos de vanguardia utilizando ambos conjuntos de datos. Los resultados experimentales mostraron que el marco propuesto logró una precisión de clasificación del 100% en el conjunto de datos de EEG de Bonn, mientras que la precisión de clasificación del 99,84% en el conjunto de datos de EEG de cuero cabelludo CHB-MIT.

Contribución: Utilizó un prototipo funcional para la detección de epilepsia usando segmentación de las señales EEG.

Componentes de la contribución: Usa transformada de Fourier a las frecuencias del Electroencefalograma, aplicando funciones previas al análisis.

Ideas reusables en mi proyecto: Aplicaciones previas como transformada de Fourier.

Según Galaviz (2021) en su investigación tiene como propósito hallar una relación entre la escucha de música y el estrés académico generado por una actividad cognitiva, al observar cambios significativos en las ondas cerebrales de estudiantes del Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE). Las señales se obtuvieron con una diadema electroencefalográfica (EpoC+ de Emotiv). Los estudiantes estuvieron bajo distintos estímulos sonoros realizando multiplicaciones básicas durante 5 minutos. Con los resultados obtenidos, se puede observar que la sesión en silencio y la sesión relajante tuvieron mayor efectividad al reducir la aparición de ondas beta alta (20-32 Hz), las cuales están relacionadas con el estrés. Por otro lado, el comportamiento de las ondas cerebrales depende mucho de los gustos musicales de los participantes y su interacción diaria con la música. Extrayendo las características del electroencefalograma mediante la potencia absoluta o bandas de potencia.

Contribución: Utilizó un método de extracción de patrón el método de bandas de potencia (en Matlab bandpower).

Componentes de la contribución: Usa la extracción de características bandpower.

Ideas reusables en mi proyecto: bandpower, y se usará como equivalente a la ganancia de frecuencias.

Así también basadas en notables investigaciones con excelentes resultados como (Shih, y otros, 2016), (L, D, & J, 2021) , (Sunao, Irwin, Jonathan, Yoshikata, & Tom, 1999) que usa la transformada rápida de Fourier (FFT) para el manejo de frecuencias del EEG.

Para Weifeng et al. (2021) en su investigación proponemos un marco CNN ligero y poco profundo de extremo a extremo, que permite el conjunto de datos EEG-Motor Raw como entradas, para aumentar la precisión de decodificación mediante Channel-Mixing-ConvNet. El primer bloque de red está diseñado en forma de apilar implícitamente capas de convolución

espacio-temporal para aprender las características de EEG temporales y espaciales después de mezclar los canales de EEG, en comparación con la construcción independiente anterior de una sola capa convolucional temporal y espacial, este método combina las capacidades de extracción de características de las dos capas.

Para Arti, Dilip, & Ram (2021) propone un marco de aprendizaje automatizado utilizando el método de transformada de ondas empíricas basado en la expansión de la serie Fourier-Bessel (FBSE-EWT) para detectar ataques epilépticos de las señales de EEG. El método de detección de límites de espacio de escala se adoptó para segmentar el espectro de expansión de la serie Fourier-Bessel (FBSE) de múltiples señales de EEG segmentadas en el tiempo de tamaño de fotograma.

Para Villazana León (2017) en la detección de cambios abruptos en señales epilépticas del EEG considera a la epilepsia como un trastorno crónico del cerebro que afecta a aproximadamente 60 millones de personas en todo el mundo. En su investigación concluye que en un promedio 30% de las personas que están diagnosticadas con epilepsia, no responden o superan este diagnóstico con tratamiento con uno o más medicamentos ni a la intervención quirúrgica o de cirugía resectiva. Es bien sabido que la ocurrencia de las convulsiones epilépticas produce una serie de cambios dinámicos súbitos y repentinos en las señales cerebrales que se manifiestan como crisis parciales o generalizadas en el paciente epiléptico.

Para Sebamai, Ranjeeta & Mrutyunjaya (2021) considera que al principal vector aleatorio de mínima varianza es la técnica sugerida para proporcionar una excelente precisión de clasificación, una capacidad de detección superior, una velocidad más rápida y una tasa insignificante de falsos positivos por hora, una estructura más simple y solidez para clasificar las señales de convulsiones y no convulsiones.

Para Fitri, Jeffri, Winnugroho, & Astri (2021) en su investigación, de los 39 pacientes con msTBI, 19 fueron diagnosticados con NCSE; sólo dos cumplían los criterios definitivos, y los restantes eran posibles NCSE. El delirio y el deterioro perceptivo solo se encontraron en NCSE, mientras que la agitación psicomotora fue mayor (12,8% vs. 5,1% en NCSE vs. no NCSE). La característica más común del EEG fue la actividad rítmica ( $>0,5$  Hz) sin fluctuación, que mejoró con la administración de fármacos antiepilépticos, por tanto, sugiere la aplicación en el lóbulo.

Para Hikmat, Maha, & Enas (2019) donde a partir de datos de EEG en estado de reposo registrados para 36 niños, que se dividieron por igual en dos grupos emparejados de TEA leve y grave. El análisis de EMD se aplicó a sus datos de EEG para identificar las características de las funciones de modo intrínseco (IMF), los patrones de SODP, el área elíptica y los valores de la medida de tendencia central (CTM). Luego se utilizó una red neuronal artificial para determinar la precisión de las medidas de resultado de este modelo para distinguir entre los dos grupos de TEA.

Para Cristóvão Ferreira, Moniz Dionísio, Ferreira, & Coelho (2024) a pesar de tener un diagnóstico visual claro de crisis de epilepsia que representa un evento compatible con un ataque epiléptico durante la video-polisomnografía. Al aplicar el electroencefalograma se obtuvo los resultados normales. Por tanto, la secuencia de frecuencias obtenidas se ha logrado identificar la relación que existe la crisis de ausencia asociada al sueño (EHS) donde el resultado fue negativo. Por lo que es un caso atípico y que requiere más evaluación o intervención de tecnología de mejor precisión o tratamiento con carbamazepina.

Para Chris Liu & Friedman (2024) consideran que el aprendizaje automático (ML) y la inteligencia artificial (IA) son un campo en rápido desarrollo, con un interés creciente en integrar y aplicar estas herramientas para ayudar a los médicos a enfrentar incertidumbres de

diagnósticas de epilepsia, apoyándose con algoritmos de aprendizaje automático, en particular las redes neuronales artificiales profundas, se emplean cada vez más en la interpretación de electroencefalogramas (EEG), identificación de anomalías, neuroimágenes, datos de dispositivos portátiles y videos de convulsiones.

Tomando con contribución la aplicación de la IA en escenario de crisis de ausencia así como en epilepsia.

Para Torres-Gaona, Aledo-Serrano, & García-Morales (2023) en su investigación tuvo como objetivo principal determinar si el algoritmo basado e IA llamado mjn-SERAS puede detectar convulsiones de forma temprana utilizando datos específicos del paciente para crear un modelo matemático personalizado basado en el entrenamiento EEG, definido como el reconocimiento programado de convulsiones, dando una predicción de cuándo o en qué condiciones se puede presentar nuevamente estas crisis, que por lo general es un período de unos pocos minutos, en pacientes diagnosticados de epilepsia. Donde en la investigación aplica la sensibilidad y especificidad del algoritmo de inteligencia artificial. Se buscó en la base de datos de las Unidades de Epilepsia de tres centros médicos españoles y se seleccionaron 50 pacientes evaluados entre enero de 2017 y febrero de 2021, diagnosticados de epilepsia focal refractaria a los que se les realizó seguimiento video-EEG entre 3 y 5 días, un mínimo de 3 crisis por paciente, con una duración superior a 5 segundos y el intervalo entre cada crisis fue superior a 1 hora. Excluyeron a los menores de 18 años. El algoritmo identificó patrones preictales e interictales a partir de datos de EEG utilizando nuestro algoritmo de aprendizaje y se comparó con la evaluación de un epileptólogo experimentado. Se entrenaron modelos matemáticos individuales de cada paciente utilizando este conjunto de datos de características. Se revisaron un total de 1.963 horas de 49 vídeos-EEG, con una media de 39,26 h por paciente. El vídeo-EEG registró 309 ataques, que fueron analizados posteriormente por los epileptólogos. El algoritmo mjn-SERAS se entrenó en 119 convulsiones y se realizaron pruebas

divididas en 188 convulsiones. El análisis estadístico incluye los datos de cada modelo y reporta 10 falsos negativos (no se detectan episodios registrados por video-EEG) y 22 falsos positivos (alerta detectada sin correlación clínica o señal EEG anormal en 30 min). Específicamente, el algoritmo automatizado de IA mjn-SERAS logró una sensibilidad del 94,7 % (95 %; IC 94,67–94,73) y una puntuación F que representa una especificidad del 92,2 % (95 %; IC 92,17–92,23) en comparación con el rendimiento de referencia representado. por una media (media armónica o promedio) y un valor predictivo positivo del 91%, con una tasa de falsos positivos de 0,55 por 24 h en el modelo independiente del paciente.

En este escenario, del análisis de electroencefalogramas, Ors Quixal & Castells Ramón (2023) ha aplicado una red neuronal artificial convolucional ayudar a pacientes que han padecido de coma a causa de un paro cardiaco, y como fuente de insumo para poder identificar la sobrevivencia o no de dicho paciente ha sido a partir del rendimiento cerebral obtenido por medio del electroencefalograma, para ello ha considerado en su red neuronal el modelo de tipo average y de tipo desviación estándar, aplicado a una red neuronal convolucional tridimensional con el fin de reducir los dimensión en el espacio temporal, así en una siguiente capa a una capa densa para poder identificar la salida con el resultado obtenido. Como aporte a la presente investigación es que es un modelo el cual se debe considerar como parámetros de entrada en grupo o por plano (como un plano de imagen), bajo este modelo de adquirir los datos de las frecuencias en paralelo, a la vez analizarlas como modelos para aprendizaje aplicando en average pooling y desviación típica, ha logrado obtener una precisión en su investigación es de 95.01% para pacientes con valores favorables y 98.01% para pacientes con diagnósticos desfavorables, para pacientes que pueden recuperarse o no respectivamente. Adicionalmente como la toma de datos es muy grande ya que por lo general las tomas de información a un paciente por medio del electroencefalograma es de varios minutos (de 30 minutos en adelante), y las tomas son por cada segundo en función, por tanto, se extiende a

60x30x5 a más, implicando a esto para el proceso de entrenamiento tener un hardware de regular característica (en memoria y procesador).

Para Gleichgerrcht, Munsell, & Alhusaini (2021) concluye que con el uso de modelos de máquina soporte vectorial (SV) y de aprendizaje profundo (DL) tomando como fuente de datos a 336 resonancias magnéticas cerebral estructural y 863 de difusión de regiones de interés (basados en ROI) de pacientes mostrando que los modelos para identificar TLE tuvieron un rendimiento mejor o similar (68–75 %) en comparación con los modelos para lateralizar el lado de TLE (56–73 %, excepto los basados en estructuras) según los datos de difusión, con el patrón opuesto observado para los datos estructurales. (67-75% para diagnosticar versus 83% para lateralizar). El modelo propuesto por el autor clasifica para pacientes con esclerosis del hipocampo fueron más precisos (68–76%) que los modelos que estratificaron a pacientes sin lesiones (53–62%). Por tanto, los modelos SV y DL tuvieron un desempeño similar en varios casos en los que SV superó levemente a DL.

Para Sollee, Tang, & Bienfait Igraneza (2022) ha hecho un análisis de trabajos recientes en la investigación de la epilepsia han tenido como objetivo utilizar métodos basados en IA para mejorar el diagnóstico, el pronóstico y el tratamiento, con el objetivo de desarrollar herramientas altamente precisas y confiables para ayudar en una mejor toma de decisiones clínicas. Aquí, revisamos cómo los investigadores utilizan actualmente métodos de IA en el análisis de datos de neuroimagen en epilepsia, además proporciona análisis críticos de las técnicas existentes basados en IA.

Para Duckrow, Ceolini, & Zaveri (2021) a partir de grabaciones continuas brindan la oportunidad de estudiar los correlatos conductuales de las descargas epileptiformes a medida que los pacientes realizan su vida diaria. Se captura las interacciones y se muestra en la pantalla táctil del teléfono inteligente en ocho pacientes los registros electrográficos (acumulando

35,714 h) y mediante el uso de un modelo de red neuronal artificial que abordó si el comportamiento reflejaba las descargas epileptiformes. Obteniendo como resultado de manera personalizada las entradas el comportamiento de las frecuencias observados (R: 0,2–0,6, mediana 0,4) en los teléfonos inteligentes. Demostrando el comportamiento digital cotidiano y convertirlo en marcadores personalizados de la actividad de la enfermedad en la epilepsia.

### **Antecedentes nacionales**

Según Padilla Gallegos (2018) en su investigación realizada en la Arequipa, cuyo título es “Características clínicas y epidemiológicas en pacientes diagnosticados de epilepsia, en el servicio de pediatría del hospital regional Honorio Delgado Espinoza, Arequipa”, Describe las características clínicas y epidemiológicas en pacientes diagnosticados de epilepsia, en el Servicio de Pediatría del Hospital Regional Honorio Delgado Espinoza, Arequipa 2016-2018. Realizando un estudio de tipo observacional, retrospectivo de corte transversal, mediante la revisión de historias clínicas de pacientes con diagnóstico de epilepsia, en el Servicio de Pediatría que cumplieron criterios de selección. Se aplicó una ficha de recolección de datos. Se muestran los resultados mediante estadística descriptiva, con 312 pacientes ha logrado el 33.3% de los pacientes corresponden al grupo etario escolar; el 55.4% son de sexo masculino; 40.7% iniciaron las crisis epilépticas cuando eran lactantes; el 90.1% de los pacientes no tienen antecedentes familiares de epilepsia; el tipo de epilepsia generalizada se presentó en un 54.5%; el 17,9% presento síndrome epiléptico, siendo de estos el más frecuente la epilepsia benigna de la lactancia con 69.6%; la etiología de causa desconocida fue la más frecuente con 65.7%; el 83.0% son tratados ácido valproico, seguido de la fenitoína con 42.6%; la comorbilidad más usual fue la discapacidad cognitiva con 53.9%.

Contribución: Utilizó un diagnóstico de crisis de ausencia en el área de pediatría.

Componentes de la contribución: Generó reporte de crisis de ausencia.

Ideas reusables en mi proyecto: Crisis de ausencia o pequeño mal.

Según Palomino (2021) en su investigación, a partir del Video EEG prolongado y la Resonancia Magnética Nuclear protocolo epilepsia, para su investigación considera relevante, así como necesario la utilización de las dos herramientas para el diagnóstico de pacientes con epilepsia, específicamente en los casos de epilepsia focal refractaria, con la intención de establecer correlaciones electroclínicas e imagenológicas, bajo el criterio del especialista donde encuentre y/o identifique alteraciones estructurales y eléctricas en el encéfalo representado en una secuencia de frecuencias propio del electroencefalograma, lo cual permitirá una mayor aproximación de la localización dentro del estándar internacional 10-20 del probable foco epiléptico, para ello se ha tomado como población y muestra (al total de la población) a pacientes con diagnóstico de Epilepsia Focal refractaria y que sean atendidos en la unidad de epilepsia del Hospital Nacional Edgardo Rebagliati Martins. Como resultado tienen que de acuerdo con la ubicación de la zona sintomatogénica, las epilepsias focales más frecuentes corresponden al lóbulo temporal, seguido las del lóbulo frontal, parietal y occipital, hallazgos de similar respuesta con los diagnósticos de los nuevos pacientes como fuente testeo en el servicio de neurología del Hospital Rebagliati en el 2017.

Contribución: Logró focalizar la epilepsia en las áreas del cerebro, en base a un conjunto de pacientes diagnosticados.

Componentes de la contribución: focalización del área del cerebro donde se encuentra el origen, así como otros detalles necesarios para ser tomado como insumo y una mejor decisión por parte del especialista en neurología.

Ideas reusables en mi proyecto: focalizar la zona de afectación del paciente en el área del cerebro, tomando en cuenta las señales electroencefalograma.

### 1.5. Justificación de la investigación

En la **justificación teórica** que se va a realizar en la presente investigación, va en función de la creación de un nuevo modelo y la detección de convulsiones de crisis de ausencia mediante el aprendizaje artificial de señales electroencefalograma, específicamente red neuronal supervisada, red neuronal SOM, vecino más cercano, árbol de decisión y random forest, así también encontrar la relación de los canales en el momento de la crisis a partir de las frecuencias como patrones de entrada para poder ingresar a la red, así lograr situar a la presente investigación en una realidad desde la óptica médica sanitaria, por tanto, es necesario el aprendizaje de la investigación para la detección de convulsiones de crisis de ausencia en un paciente neuropediátrica. Respecto a la dificultad de detección de convulsiones de crisis de ausencia mediante el aprendizaje artificial de señales electroencefalograma es desarrollar el modelo para el sistema inteligente de manera integral desde la planeación de la investigación, el análisis de los datos obtenidos, el diseño para el desarrollo de la investigación, la construcción o implementación basado en un lenguaje de programación que permita plasmar la investigación, y las pruebas realizadas, aplicando modelos de inteligencia artificial, como es red neuronal supervisada, red neuronal SOM, vecino más cercano, árbol de decisión y random forest, así también encontrar la relación de los canales en el momento de la crisis, además contará con un fuente teórica actualizada respecto al tema de la presente investigación. Según Méndez (2012) la **justificación practica** se tiene cuando “su desarrollo va a permitir dar solución al problema o al menos va a permitir proponer estrategias que al aplicarlo permitan resolverlo”, por tanto en la presente investigación pretende unificar todos los pasos para identificar la crisis de ausencia, reflejados en un modelo que permitirá apoyar a las áreas médicas de los centros asistenciales, permitiendo mostrar las ventajas que se pueda obtener con un modelo donde exprese un conjunto de pasos y a la vez se logre el aprendizaje artificial de señales EEG como son: apoyar en la dificultad de detección de convulsiones de crisis de

ausencia en una institución neuro pediátrica, mediante la sensibilidad, especificidad y nivel de exactitud. Cuando se tiene la información de las señales EEG que refleje la crisis de ausencia en el sistema permitirá mostrarlo en cuadro estadístico o tablero la relación que hay entre los canales lo cual permitirá una mejor toma de decisiones. Respecto a la **justificación metodológico**, para el desarrollo de ésta investigación se usó una perspectiva de la teoría general del sistema, ayudando a tener una visión general de apoyo en la dificultad de detección de convulsiones de crisis de ausencia en infantes, los problemas, las causas y posibles soluciones; para el desarrollo e implementación del aprendizaje artificial, complementada con otras metodologías y herramientas necesarias para el campo de la inteligencia artificial, estratégicamente se van a usar en las fases claves donde se necesita el apoyo para cumplir cada una de estos criterios de calidad, para así evidenciar mediante un producto o prototipo que sea de calidad y que cumpla el fin para el cual fue creado.

#### **1.6. Limitaciones de la investigación**

La obtención de la información sensible, puesto que esta información va relacionada con pacientes infantes, por ende, hay que tener adicionalmente el permiso de los datos, específicamente de las señales electroencefalograma que se les ha realizado, el tratamiento médico, el instrumental usado y el diagnóstico.

Agendar citas con la especialista neuropediatra para fidelizar la información de crisis de ausencia en el electroencefalograma, ya que la información en internet es ambigua.

En la presente investigación, en referencia al producto software intenta proporcionar al especialista la identificación de crisis de ausencia que más se acerque al diagnóstico visual en el electroencefalograma.

El modelo propuesto no intenta modificar algoritmos contemplados en esta investigación, lo que trata es de utilizar una secuencia de algoritmos adecuados basados en

inteligencia artificial, para el aprendizaje de frecuencias que representen una crisis de ausencia y previo a ello, a partir del electroencefalograma, así también encontrar la relación de los canales en el momento de la crisis.

Los datos que van a ser procesados para el diagnóstico van a ser a partir de los electroencefalogramas, que sea encontrados y definido como la existencia de crisis de ausencia corroborados por la neuropediatra.

Para la presente investigación se ha considerado como alcance a toda la población, por la limitación de encontrar informes neuro pediátricos con crisis de ausencia.

Cabe resaltar que los datos del paciente en todo momento se consideran como anónimo, basándose en el código de ética del (Colegio Médico, 2021) y las fuentes que lo contemplan.

## **1.7. Objetivos**

### ***Objetivo general***

Desarrollar un nuevo modelo de aprendizaje de señales electroencefalograma para mejorar la detección de convulsiones de crisis de ausencia aplicando el filtro Gabor en pacientes infantes neuropediátricos.

### ***Objetivos específicos***

- OE1: Identificar el nivel de sensibilidad mediante un nuevo modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.
- OE2: Identificar el nivel de especificidad mediante un nuevo modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.

- OE3: Identificar el nivel de exactitud mediante un nuevo modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.

## 1.8.Hipótesis

### *Hipótesis general*

El modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias mejora la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.

Cabe resaltar que el modelo de aprendizaje será considerado a la red neuronal supervisada, red neuronal SOM, vecino más cercano, árbol de decisión y random forest para realizar su posterior comparativa de resultados.

### *Hipótesis específica*

HE1: Mediante modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias identifica el nivel de sensibilidad en la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.

HE2: Mediante modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias identifica el nivel de especificidad en la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.

HE3: Mediante modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias identifica el nivel de exactitud en la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.

## II. MARCO TEÓRICO

### 2.1. Marco conceptual

Según Gómez (2013) afirma que la **inteligencia artificial** puede definirse como “el medio por el cual las computadoras, los robots y otros dispositivos realizan tareas que normalmente requieren de inteligencia humana”. En esta sentido según Weifeng Ma (2021) la **red neuronal backpropagation** ha logrado un gran éxito en la decodificación de señales de EEG y las diferentes aplicaciones realizadas, los decodificadores basados en estas arquitecturas realizan la extracción y clasificación de características por separado en una etapa integrada, sin embargo, una gran cantidad de parámetros entrenables por la red neuronal artificial introducidos por el modelo dificultan la mejora del rendimiento de decodificación de EEG y desafiar la interpretabilidad del proceso de decodificación utilizado CNN. Para (Dan C. Cireşan, 2011) este proceso inicia con los patrones de entrada  $X_p = (x_0, x_1, x_2, \dots, x_n)$ , esta cantidad de patrones de entrada define la estructura de la red, así en cada neurona de la capa oculta viene reflejado por  $net_{pj}^h = \sum_{i=0}^n w_{ji}^h x_{pi} + \theta_j^h$ , donde  $net$  representa la salida de una neurona de la capa oculta, el valor  $w$  es el peso sináptico,  $x$  es el patrón de entrada asociado a  $w$  y se suma al umbral. Con respecto a la capa de salida los valores de entrada  $I_{pj} = f_j^i(net_{pj}^h)$ , donde  $I$  representa la salida de la capa oculta, donde a su vez es entrada para la capa de salida con su respectivo peso  $w_{kj}^o$ , y la función  $f$  es la función  $f(x) = (1 + e^{-x})^{-1}$ , una vez terminada el forward se prepara para el backware con la función  $f'(x) = f(x)(1 - f(x))$ , esto para encontrar el error en cada neurona  $\delta_{pk}^o (T_{pk} - O_{pk}) f_k^{o'}(net_{pk}^o)$ , para así actualizar los pesos sinápticos con  $w_{kj}^o(t+1) = w_{kj}^o(t) + n \delta_{pk}^o I_{pj}$ , donde implica que se actualiza el peso sináptico de la capa de salida a la capa oculta,  $n$  es el factor de aprendizaje, también la actualización de peso de la capa de entrada  $w_{ji}^h(t+1) = w_{ji}^h(t) + n \delta_{pj}^h x_i$ , este

proceso se repite en manera de épocas cumplidas o hasta que  $EMC_p = \frac{1}{2} \sum_{k=0}^s \delta_{pk}^2 = \frac{1}{2} \sum_{k=0}^s (T_{pk} - O_{pk})^2$  sea un valor pequeño, donde  $s$  es la cantidad de neuronas de la capa de salida.

Considerando este modelo backpropagation para la presente investigación los patrones de entrada  $X_p = (x_0, x_1, x_2, \dots, x_n)$ , serian las frecuencias en porción de 210 y la salida deseada será de tamaño 1  $\{1,0\}$ , donde 1 si lo padece de crisis de ausencia y 0 que no lo padece, de esta manera para cada una de las porciones y los diagnósticos.

Para Teuvo (1989) ha mostrado el modelo de **red neuronal autoorganizativo** (SOM), en una red en el cual no se considera un tutor en el proceso de aprendizaje, para lograr ello se basó en la manera como la información es captada a través de los órganos sensoriales de los animales (específicamente en el córtex superior), donde las zonas detectoras se ordenan y representan internamente formas de mapas bidimensionales (la capa competitiva), donde compiten y se agrupan según las características resaltantes de cada imagen ingresadas. Este tipo de red neuronal permite clasificar de acuerdo con los patrones característicos, este tipo de red neuronal tiene un aprendizaje basado en competencia, por tanto, no se considera un tutor para que menaje el error en el proceso de aprendizaje, ya que no se considera un valor deseado en el cual tienda los resultados. Formalizado en la ecuación  $\min \|X_p - W_j\| = \min \sum_{i=1}^N (X_{pi} - W_{ji})^2$  para encontrar la neurona vencedora. Donde:  $X_p$ :  $X_{p1}, X_{p2}, \dots, X_{pN}$ , y el vector de pesos  $W_j$ :  $W_{j1}, W_{j2}, \dots, W_{jN}$ , ya se realiza por un método competitivo, donde lo ideal en el proceso de aprendizaje es que se asemejen lo más posible  $X_{pi}$  con  $W_{ji}$  o dicho de otra manera  $(X_{pi} - W_{ji}) \text{ sea } = 0$ , la ecuación  $\Delta W_{ji}(n+1) = \alpha(n) h_{ci}(n) (X_{pi} - W_{ji}(n))$  refleja la actualización de pesos donde  $n$  es el número de ciclos,  $\alpha$  es la tasa de aprendizaje, el  $h(\cdot)$  refleja el grado de afectación que va a tener el valor como resultado ese peso sináptico y esto depende proporcionalmente de la cercanía de la neurona elegida (ósea la neurona elegida tiene valor 1

y el que está más lejos del elegido pero en rango de la topología tendrá valor cerca a cero y el que está fuera de la topología tendrá valor cero), la topología es un plano escogido al momento del inicio del procesamiento, donde puede ser ‘hexagonal’ o ‘cuadrada’ o ‘lineal’, cabe resaltar que (Teuvo, 1989) recomienda la hexagonal y no recomienda la lineal, y también el factor de aprendizaje  $\alpha(t) = \alpha_0 e^{-\frac{t}{\lambda}}$  dónde:  $\alpha_0$  es el radio inicial para cubrir todos los nodos de acuerdo al tipo de vecindad establecida.

Considerando este modelo red SOM para la presente investigación los patrones de entrada  $X_p = (x_0, x_1, x_2, \dots, x_n)$ , serían las frecuencias en porción de 500 y el proceso se adaptaría para saber si es que tiene o no, donde se va a agrupar  $\{2,1,0\}$  donde se identifica como ‘previo’, ‘con crisis’ y ‘sin crisis’ respectivamente.

Para Xie, Zhong, Tian, & Pan (2025) considera para **el vecino más cercano** que la agrupación en clústeres ha desempeñado durante mucho tiempo un papel crucial en los algoritmos de aprendizaje no supervisado. En las últimas décadas, se han propuesto y desarrollado varios algoritmos de agrupación en clústeres clásicos en diferentes direcciones. uno de los algoritmos de agrupación en clústeres más representativos, particiona los datos minimizando el error cuadrático. Realizando las diferentes pruebas y encontrar el valor más idóneo para poder tener un mejor resultado respecto a la sensibilidad, especificidad y precisión, en pacientes diagnosticados con crisis de ausencia y para lograr ello se ha utilizado la librería sklearn en python. Dentro de la estructura del vecino más cercano se usó la creación de pesos iniciales de manera ‘uniform’, una métrica de ‘minkowski’, se define el tamaño de datos de entrada de 31 356 000 frecuencias, para los 3484 sucesos (en 18 canales), con salida de tipo ‘sin crisis’, ‘con crisis’ y ‘previo’, y una vecindad de 2 a 7, encontrando el mejor resultado con una vecindad de 2. Se ha obtenido una sensibilidad, especificidad y exactitud respecto a la identificación de ‘sin crisis’, ‘con crisis’ y ‘previo’ con 0.0, 1.0, 2.0 para el testeo del mismo archivo y 0.99, 0.0, 0.99 para el testeo del segundo archivo.

También se va a considerar dentro de la máquina de aprendizaje el **árbol de decisión**, para Sean, Rongxing, Yunguo, & Songnian, BloomDT (2024) en *An improved privacy-preserving decision tree inference scheme*, consideran los árboles de decisión son versátiles y se pueden aplicar a muchos dominios, e incluso se han utilizado para predecir qué información demográfica es importante para la eficacia del aprendizaje en línea, a menudo se eligen para tareas de aprendizaje automático, ya que pueden proporcionar información rápida y precisa clasificaciones, se entienden fácilmente, y los árboles de decisión sirven como base para muchos otros modelos de aprendizaje automático, se pueden entrenar mucho más rápido que los modelos más grandes y potentes, como como redes neuronales artificiales, así considera que es un importante aporte realizado por Quinlan (1993). Dentro de los tipos de árbol de decisión tenemos al ID3, C4.5, C5.0 y CART, de los cuales debe tenerse en cuenta al momento de la implementación. Desde el punto de vista de Sean, Rongxing, Yunguo, & Songnian (2024) BloomDT - An improved privacy-preserving decision tree inference scheme, consideran a los modelos de aprendizaje automático basados en árboles de decisión (DT) son versátiles y pueden aplicarse a muchos dominios. Pueden predecir ataques de ciberseguridad proporcionar diagnósticos de atención médica e incluso se han utilizado para predecir qué información demográfica es importante para la eficacia del aprendizaje en línea. Los árboles de decisión a menudo se eligen para tareas de aprendizaje automático, ya que pueden proporcionar clasificaciones rápidas y precisas, se entienden fácilmente y sirven como base para muchos otros modelos de aprendizaje automático, incluidos AdaBoost y modelos de bosque aleatorios. Además, los modelos DT se pueden entrenar mucho más rápido que modelos más grandes y potentes, como las redes neuronales artificiales. Debido al rápido tiempo de entrenamiento de los modelos DT, los proveedores de modelos pueden dedicar menos tiempo a producir modelos más precisos, ya que el hiperajuste tomaría menos tiempo que el hiperajuste de un modelo más complejo. Breiman (L. Breiman, 1984) considera que a partir de los vectores de entrenamiento

$x_i \in R^n, i = 1, 2, \dots, l$  y el vector etiquetado o salida  $y \in R^l$  dividiéndolo de manera recursiva de acuerdo con el espacio de etiquetas de tal manera que se agrupen los patrones de entrada que tengan las mismas etiquetas, donde los datos del nodo  $m$  es representado por  $Q_m$  con  $n_m$  registros, considerando que para cada caso se divide  $\theta = (j, t_m)$  consistiendo en una entidad  $j$  y un umbral de  $t_m$ , partiéndolo los datos en dos subconjuntos  $Q_m^{left}(\theta)$  y  $Q_m^{right}(\theta)$ , aplicados de manera que  $Q_m^{left}(\theta) = \{(x, y) \mid x_j \leq t_m\}$ , para el otro lado  $Q_m^{right}(\theta) = Q_m(\theta) \setminus Q_m^{left}(\theta)$ , donde la candidata a ser elegido como parte del nodo raíz del árbol o sub árbol se aplica en función de la ganancia de cada candidata usando  $G(Q_m, \theta) = \frac{n_m^{left}}{n_m} H(Q_m^{left}(\theta)) + \frac{n_m^{right}}{n_m} H(Q_m^{right}(\theta))$ , hasta que llegue a la profundidad del árbol que será la decisión.

Considerando este modelo árbol de decisión para la presente investigación los patrones de entrada  $X_p = (x_0, x_1, x_2, \dots, x_n)$ , serían las frecuencias en porción de 500 y la salida deseada será de tamaño 1  $\{2, 1, 0\}$ , donde 2 es previo a la crisis, 1 si lo padece de crisis de ausencia y 0 que no lo padece, de esta manera para cada una de las porciones y los diagnósticos.

Otro modelo para aplicar en la presente investigación es el algoritmo **Randon Forest**, así Breiman (2001) considera como una técnica de aprendizaje, donde en el proceso de aprendizaje debe tender a un objetivo, implicando que es aprendizaje supervisado, donde genera múltiples árboles de decisión a partir de un conjunto de datos para el entrenamiento, los resultados obtenidos se combinan entre ellos para obtener un modelo único a partir de un conjunto de árboles. Realizado durante este proceso a partir de los siguientes pasos, primero se considera la cantidad de árboles a partir de un conjunto de  $m$  datos aleatorios ( $m$  menor que el total de datos), comúnmente llamados predictores, así también como segundo paso es extender en cada árbol en los más profundo posible (hacer lo más frondoso posible), donde la prioridad de ser elegido es aplicando el método estadístico llamado Bootstrap, combinando con la salida

final  $Y$  ( $Y$  definida como la salida deseada). Definiéndolo como una colección de árboles estructurados de tipo  $\{h(x, \theta_k)\}$  donde  $\{\theta_k\}$  es un vector aleatorio distribuido de manera independiente e idéntico, y cada subárbol es convertido a un voto, donde la clase más popular tiene que ser  $x$ , para ello se aplica la función de decisión  $H(x) = \arg \max \sum_{i=1}^k I(h_i(x) = Y)$ , donde  $H(x)$  es la combinación del modelo de clasificación,  $h_i$  es el signo del modelo del árbol de decisión,  $Y$  es la salida de la variable,  $I(\cdot)$  es el indicador de la función. Este método muestra ventaja en casos de clasificación y predicción. Basado en un método competitivo de votaciones de los árboles generados por cada porción de datos del total. Así también la simplicidad de entrenamiento hace que requiera menor recursos por la complejidad generada, manteniendo los resultados cercanos al esperado, así también reduce la cantidad de dimensiones generadas por parte de los datos, manteniendo su precisión mientras va creciendo la cantidad de datos. Para (Jesús, 2020) este método es utilizado en diferentes áreas como teledetección, bancos, medicina, finanzas, comercio electrónico, clasificación, etc.

Considerando este modelo árbol de decisión para la presente investigación los patrones de entrada  $X_p = (x_0, x_1, x_2, \dots, x_n)$ , serían las frecuencias en porción de 500 y la salida deseada será de tamaño 1  $\{2,1,0\}$ , donde 2 es previo a la crisis de ausencia, 1 si lo padece de crisis de ausencia y 0 que no lo padece, de esta manera para cada una de las porciones y los diagnósticos.

Para Homan (1987) el **electroencefalograma** (EEG) muestra la actividad eléctrica y se puede captar mediante los electrodos mediante un equipo. Estos electrodos pasan a ser canales, los cuales se distribuyen a lo largo del cráneo de diferentes maneras. El INC (2021) de España menciona que es el registro de la actividad eléctrica del cerebro. Se realiza mediante la colocación de electrodos en el cuero cabelludo (la piel que cubre la parte superior de la cabeza) y los impulsos se envían a una máquina especial. El EEG se puede usar para diagnosticar trastornos del cerebro y el sueño.

Según Millard (2003) resalta al **filtro de Gabor** como filtros en un dominio de frecuencias para extraer orientaciones de una textura específica, teniendo como orientaciones a considerar 0°, 45°, 90°, 135°, 180°, 225°, 270° y 315°, es una oscilación de frecuencias en una onda plana con una envolvente gaussiana, realizando una convolución a cada una de las frecuencias espaciales similar a la longitud de onda.  $g(x,y)=1/(2\pi\sigma_g^2) \cdot \exp[-((x')^2 + (y')^2)/(2\sigma_g^2)] \cdot \exp(j^2\pi F(x \cos[\theta] + y \sin[\theta]))$ ; donde:  $\sigma_g$  determina la extensión espacial del filtro.  $(x',y')$  son las coordenadas rotadas de  $(x,y)$  respectivamente.  $x'=x \cos[\alpha] + y \sin[\alpha]$   
 $y'=-x \sin[\alpha] + y \cos[\alpha]$

Los parámetros  $F$  y  $\theta$  controlan el desplazamiento en frecuencia en el dominio espectral y  $\alpha$  controla la rotación de las coordenadas.

Según Structure (2022) muestra los datos de **tipo encefalograma** a los formatos como .edf el cual es un estándar europeo, .eeg el cual es un formato estándar americano que lo usan la mayoría de dispositivos, estos dispositivos tiene una posición en específico para colocarlos en la cabeza del paciente, siendo los valores en la Tabla 1 basado en el sistema internacional 10-20 y la representación en la Figura 1 de acuerdo a la posición frontal (F), temporal (T), central (C), parietal (P), occipital (O) y auricular (A), así también la combinación de ellos como Fp en la posición Frontal parietal (Fp), hemisferio izquierdo (IMPAR), hemisferio derecho (PAR), línea media (Z), por tanto las frecuencias a analizar para el proceso de aprendizaje, considerando a Shoeb (2009) donde en el análisis de las frecuencias se considera para niños menores de 11 años los criterios de 'Fp1-F3', 'F3-C3', 'C3-P3', 'P3-O1', 'Fp2-F4', 'F4-C4', 'C4-P4', 'C4-O2', 'Fz-Cz', 'Cz-Pz', 'Fp1-F7', 'F7-T3', 'T3-T5', 'T5-O1', 'Fp2-F8', 'F8-T4', 'T4-T6', 'T6-O2':


Tabla 1.

*Posición de los electrodos en función de circunferencia de la cabeza*

<b>Frecuencia para analizar (Shoeb, 2009)</b>	<b>Obtención de frecuencias según posición del electrodo</b>
paciente01['Fp1-F3']	paciente01['EEG Fp1'] - paciente01['EEG F3']
paciente01['F3-C3']	paciente01['EEG F3'] - paciente01['EEG C3']
paciente01['C3-P3']	paciente01['EEG C3'] - paciente01['EEG P3']
paciente01['P3-O1']	paciente01['EEG P3'] - paciente01['EEG O1']
paciente01['Fp2-F4']	paciente01['EEG Fp2'] - paciente01['EEG F4']
paciente01['F4-C4']	paciente01['EEG F4'] - paciente01['EEG C4']
paciente01['C4-P4']	paciente01['EEG C4'] - paciente01['EEG P4']
paciente01['C4-O2']	paciente01['EEG C4'] - paciente01['EEG O2']
paciente01['Fz-Cz']	paciente01['EEG Fz'] - paciente01['EEG Cz']
paciente01['Cz-Pz']	paciente01['EEG Cz'] - paciente01['EEG Pz']
paciente01['Fp1-F7']	paciente01['EEG Fp1'] - paciente01['EEG F7']
paciente01['F7-T3']	paciente01['EEG F7'] - paciente01['EEG T3']
paciente01['T3-T5']	paciente01['EEG T3'] - paciente01['EEG T5']
paciente01['T5-O1']	paciente01['EEG T5'] - paciente01['EEG O1']
paciente01['Fp2-F8']	paciente01['EEG Fp2'] - paciente01['EEG F8']
paciente01['F8-T4']	paciente01['EEG F8'] - paciente01['EEG T4']
paciente01['T4-T6']	paciente01['EEG T4'] - paciente01['EEG T6']
paciente01['T6-O2']	paciente01['EEG T6'] - paciente01['EEG O2']

**Figura 1.**

Posiciones de los electrodos según sistema internacional 10-20, para realizar la toma de frecuencias en un electroencefalograma. Fuente: (company, 2025)



Para AprendeIA (2020) considera que un **patrón** es un conjunto de datos sin referencia a resultados conocidos o etiquetados, estos datos son elementos de diferentes tipos, como auditivos, gráficos, entre otros, en el cual se construye con el objetivo de generar una regla, para ver la repetición o en su caso de recurrencia.

Para INSN (2020) considera a la **epilepsia** una condición neurológica caracterizada por la crisis de epilepsia recurrentes y no provocadas por desencadenantes inmediatos identificables.

Así también Ratnaprabha RavindraBorhade (2020) a la epilepsia (**convulsiones de crisis de ausencia**, entre otros) se considera la enfermedad neurológica más común en el mundo. También recomienda la predicción temprana de las convulsiones en sus diferentes expresiones o de un ataque epiléptico en la influencia de la vida del paciente diagnosticado epiléptico. Esto se da por la condición de pacientes epilépticos que en su vida cotidiana sufren condiciones de ausencia cerebral en breves segundos (de 3 a 7 segundos), especialmente que las ocurrencias sean impredecibles.

Así también según Kidshealth (2021) las **crisis de ausencia** consisten en períodos de conocimiento breves y repentinos. Son más frecuentes en niños que en adultos, los niños con crisis de ausencia por epilepsia tienen crisis donde "se quedan en blanco" durante unos pocos segundos. La mayoría de los niños con crisis de ausencia típicas en la infancia las superan con la edad al hacerse adolescentes. En más detalle el INSN (2020) define como ausencias típicas de corta duración (a lo más 20 segundos cada crisis), siendo frecuente 7 segundos, con la particularidad que la puede tener varias veces al día, mientras dura esa crisis de ausencia se detiene la actividad motora con alteración y recuperación abruptas de la conciencia. Una de las maneras de cómo identificarlas es provocando adrede una hiperventilación. Para Epilepsy (2024) considera desde un panorama general a la epilepsia infantil como una epilepsia generalizada genética/ideopática que debe considerarse en un niño con condiciones normales con múltiples crisis de ausencia diarias, asociadas con puntas-ondas generalizadas de 2.5 - 3.5 Hz, así también considera que puede ser frecuentes (varias veces al día) y tienen una duración promedio de 10 segundos. Desde el punto de vista de las frecuencias generadas por el electroencefalograma, Marlon Igor & Guillermo (2006) considera para la crisis de ausencia como brotes generalizados y complejos de tipos punta-onda lenta de 2.5 a 3.1Hz de los cuales tienen un término y fin de manera abrupta el cual tienen asociación de la misma forma, también llamado polipunta-onda lenta.

El INSN (2020) define a la **crisis no provocada** a las que ocurren en ausencia de un consiente sistémico agudo del cerebro; pueden ser un evento aislado o pueden ser potencialmente la primera manifestación de una epilepsia de etiología a determinar. Más de la mitad de las crisis epilépticas corresponden a este grupo.

Para Villazana León (2017) en la detección de cambios abruptos en señales epilépticas del EEG considera a la **epilepsia** como un trastorno crónico del cerebro que afecta a aproximadamente 60 millones de personas en todo el mundo. En su investigación concluye que

en un promedio 30% de las personas que están diagnosticadas con epilepsia, no responden o superan este diagnóstico con tratamiento con uno o más medicamentos ni a la intervención quirúrgica o de cirugía resectiva. Es bien sabido que la ocurrencia de las convulsiones epilépticas produce una serie de cambios dinámicos súbitos y repentinos en las señales cerebrales que se manifiestan como crisis parciales o generalizadas en el paciente epiléptico.

Para INSN (2020) considera como criterio de **diagnóstico de la epilepsia** como clínico, y cuando el paciente cumple por lo menos una de las condiciones, tales como tener 2 crisis epilépticas no provocadas (o reflejadas) que no ocurren en una separación de 24 horas, como segundo caso también con riesgo de recurrencia para desarrollar un segundo evento en los siguientes 10 años, mayor al 60%, y la tercera un diagnóstico de este.

### III. MÉTODO

#### 3.1. Tipo de investigación

**Aplicada:** Basado en Valderrama (2002) indica que esta investigación es de tipo aplicada por que construye, modifica y aplica a una realidad concreta. Además, dicha investigación aplicada busca una resolución rápida y practica del problema consignando toda teoría ya aplicada anteriormente que guarda relación con respecto a la investigación básica. Por tanto, para la presente investigación es de tipo Aplicada ya que se creará un nuevo modelo de aprendizaje de señales electroencefalograma aplicando conceptos y fundamentos sobre las técnicas basadas en inteligencia artificial con la aplicación del filtro de Gabor a las frecuencias para el reconocimiento de frecuencias características, específicamente a convulsiones de crisis de ausencia en pacientes infantiles neuropediátrico. Donde se tiene que disgregar las frecuencias, aplicar los filtros para tener los patrones característicos y estos sean aprendidos por medio de técnicas basadas en inteligencia artificial y ser detectados. Por tanto, se puede validar el funcionamiento de la aplicación, usando la matriz de confusión.

**Explicativa:** Según Hernández (2014) en función de los objetivos para combinar elementos de estudio como conceptos, técnicas generan un sentido de entendimiento y es sumamente estructurado, ya que se sigue una secuencia para obtener los resultados en la presente investigación, desde los conceptos como el filtro de Gabor aplicado a las frecuencias hasta el aprendizaje de convulsiones por la red neuronal artificial supervisada, red neuronal SOM, vecino más cercano, árbol de decisión y random forest, siendo explicados hasta los resultados, resaltando el nuevo modelo de aprendizaje de señales electroencefalograma para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantiles.

**Experimental:** Los resultados serán expuestos en base a un conjunto de experimentos orientados a medir los efectos del nuevo modelo de aprendizaje electroencefalograma basado

en la aplicación del filtro de Gabor aplicado a las frecuencias para el aprendizaje de señales electroencefalograma de los modelos basados en inteligencia artificial, por tanto el nuevo modelo como variable independiente. El diseño es cuasi experimental, ya que los informes diagnósticos que son parte de la muestra experimental no serán de manera aleatoria, por tanto, no va a ver diferencia de grupos (Roser, 2015).

### 3.2. Población y muestra

#### Población

Según López (2020) la población se entiende por población al conjunto llamado finito o infinito de elementos a considerar con características comunes o comúnmente llamado objeto de estudio, que después de procesar los datos que proporciona dicho objeto de estudio serán extendidas a las conclusiones de la presente investigación, quedando representado la solución al problema planteado en la Tabla 1. Por tanto, la población tomada en la presente investigación va a ser de 3844 segundos en frecuencias (01 paciente con 2 archivos de electroencefalograma de 18 canales y que representa 34 596 000 frecuencias totales) del paciente que padece crisis de ausencia obtenida desde el año 2021 hasta la actualidad y revisada en el consultorio particular de la Neuropediatra (ubicada en el Distrito de pueblo Libre – Lima- Perú). Este tamaño de población y muestra también fue tomada en cuenta por la investigación de Hikmat, Maha, & Enas (2019) donde a partir de datos de EEG en estado de reposo de los segundos tomados por el dispositivo, generando frecuencias de 500 Hz, mostrado en la Tabla 2.

**Tabla 2.**

*Población que se estudia en la presente investigación*

<b>Población</b>	<b>Cantidad (Seg)</b>	<b>Indicadores</b>
Electroencefalograma con crisis de ausencia.	3844	Sensibilidad = Tasa de verdaderos positivos.
Electroencefalograma con crisis de ausencia.	3844	Especificidad = Tasa de verdaderos negativos.

Electroencefalograma con crisis de ausencia.	3844	Exactitud = probabilidad de presencia o ausencia de la enfermedad.
--	------	--

### Muestra

Según Hernández (2014) indica “la muestra se define como aquellos elementos que se han extraído de la población, para que el sector de la población es considerado como elemento de objeto de estudio”, y por conveniencia ya que permite seleccionar entre todos los datos cada estado corroborado con la neuropediatra, específicamente los informes en el cual ha sido diagnosticado como crisis de ausencia, y que sean casos a ser incluidos. Por tanto, la muestra que se debe considerar de la siguiente manera:

$$n = 3844 \text{ segundos en frecuencias}$$

### 3.3.Operacionalización de variables

Según Rodríguez Rodríguez, Breña Oré, & Esenarro Vargas (2021) la asertividad y la pertinencia al elegir temas de investigación se centran en la identificación de las variables, pues las imprecisiones en su elección, conceptualización, instrumentalización y su medición conducen a planteamientos espurios, que podrían explicar los bajos índices de concreción de los estudios de investigación. Por tanto:

**Variable Independiente:** Modelo de aprendizaje. Se identifica el indicador en la Tabla 3.

**Tabla 3.**

*Indicador que muestra variable independiente*

<b>Indicador</b>	<b>Descripción</b>
Presencia-Ausencia	Cuando es No, es porque no existe Método alternativo basado en modelo de aprendizaje de señales electroencefalograma, y aún nos encontramos en la situación actual del problema.  Cuando es Sí, es cuando se aplicó la solución (Método alternativo modelo de aprendizaje de señales electroencefalograma) y se espera obtener resultados.

**Variable dependiente:** Detección de convulsiones de crisis de ausencia. Se identifica los indicadores en la Tabla 4.

**Tabla 4.**

*Descripción de indicadores de la variable dependiente*

<b>Indicador</b>	<b>Descripción</b>	<b>Fórmula</b>	<b>Índice</b>
Índice de sensibilidad	Comprende la tasa de verdaderos positivos, el cálculo de un coeficiente orientado a diagnosticar pacientes con crisis de ausencia.	$\textit{Sensibilidad} = \frac{VP}{VP + FN}$	[0 – 100%]
Índice de especificidad	Comprende la tasa de verdaderos negativos, el cálculo de un coeficiente orientado a diagnosticar pacientes con crisis de ausencia.	$\textit{Especificidad} = \frac{VN}{VN + FP}$	[0 – 100%]
Nivel de exactitud	Comprende la probabilidad de que el resultado del test prediga correctamente la presencia o ausencia de la enfermedad, el cálculo de un coeficiente orientado a diagnosticar pacientes con crisis de ausencia.	$\textit{Exactitud} = \frac{VP + VN}{VP + FP + FN + VN}$	[0 – 100%]

**Tabla 5.**  
*Operacionalización de variables*

Variables	Definición conceptual	Definición operacional	Dimensiones	Indicadores	Instrumento
<p><b>Variable Independiente:</b> Modelo de aprendizaje.</p>	<p>Según (María de Lourdes Gutiérrez Cordero, 2017) define un modelo de aprendizaje “no existe un único modelo válido que se pueda ajustar a la muestra de datos analizados. Es decir, la mayoría de las veces existe más de un modelo posible y es por ello, que el tema más complicado es saber y comprobar cuál ajusta mejor y por lo tanto, es el más adecuado de todos ellos” (p. 69).</p>	<p>El modelo de aprendizaje mejora la detección de convulsiones de crisis de ausencia en pacientes infantiles ya que a través de este se sensibiliza, especificidad y exactitud en la prueba diagnóstica.</p>		<p>Presencia – Ausencia.</p>	
<p><b>Variable Dependiente:</b> Detección de convulsiones de crisis de ausencia</p>		<p><b>Pruebas diagnósticas</b> Según (Altman DG, 1994) Estas proporciones son parámetros inherentes a la prueba diagnóstica, en términos generales, menos dependientes de la prevalencia de la enfermedad.</p>	<p><b>Nivel de sensibilidad</b></p> $Sensibilidad = \frac{VP}{VP + FN}$ <p><b>Nivel de especificidad</b></p> $Especificidad = \frac{VN}{VN + FP}$ <p><b>Nivel de exactitud</b></p> $Exactitud = \frac{VP + VN}{VP + FP + FN + VN}$ <p>Donde: VP: Verdaderos Positivos FP: Falsos positivos FN: Falsos negativos VN: Verdaderos negativos</p>	<p>Ficha de observación</p>	

### 3.4. Instrumentos

#### a. Instrumento para investigación de campo.

- Electroencefalograma.
- Informes de diagnóstico.
- Cuestionarios.
- Entrevistas.

#### b. Instrumentos para investigación experimental.

- Electroencefalograma. '09eeg\_7uV\_1p00s\_35Hz.edf' y  
'27eeg\_7uV\_1p00s\_35Hz.edf'.
- Informes de diagnóstico, proporcionado por la neuropediatra de manera oral.
- Equipo de 32 canales marca Neuro Virtual modelo BWIII.
- Software BWAnalisys versión 1.103.0.62 x64 PVD06.
- Software Matlab - eegLab en su versión 2025.0.0
- Software Python mne en su versión 1.9.0

#### c. Descriptiva

- Fotografías de casos de crisis de ausencia de tipo polipunta-onda
- Libreta de apuntes de criterios considerados por la neuropediatra.
- Entrevista a la neuropediatra

#### d. Computadora

- Hardware
- Software

### 3.5. Procedimientos

Para realizar la recolección de datos como insumo para la investigación, se tendrá en cuenta los siguientes procedimientos:

- Diseño y elaboración del nuevo modelo de aprendizaje
  - Importar datos sin procesar ('Import raw data')
  - Reducir la resolución de datos ('Downsample the data')
  - Filtros de paso alto ('High-Pass filter the data')
  - Detectar y rechazar canales malos ('Detect and Reject bad channels')
  - Crear patrones para aprender ('Create patterns for learning')
  - Entrenamiento de dipolos ('Fit equivalent current dipolos')
  - Matriz de confusion para comparar todos los métodos ('Confusion Matrix compare between all methods')
- Análisis e interpretación de la información.
- Elaboración de discusión, conclusiones y recomendaciones.
- Redacción del informe final.
- Presentación, revisión, reajuste y aprobación del informe de la presente investigación.
- Sustentación de la tesis.

### **3.6.Análisis de datos**

Se aplicará el análisis de información en base a la descripción en un consultorio neuropediátrico, los resultados de informes diagnósticos, con información de tipo electroencefalograma y la ubicación de las convulsiones de crisis de ausencia de infantes que acuden a dicho consultorio. A fin de mejorar la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos, para su posterior seguimiento y tratamiento por parte del galeno o de otros campos de investigación como la biología, farmacología, etc. Estos datos serán procesados con una herramienta de evaluación estadística de confiabilidad del instrumento tal como la matriz de confusión del Python.

Los datos que se recaben para la presente investigación serán analizados de modo experimental, con el nuevo modelo de aprendizaje de señales electroencefalograma plasmado en un software (Python). Con la realización de diferentes experimentos y pruebas para medir las implicancias como nuevos conocimientos de este nuevo modelo, para la detección de convulsiones de crisis de ausencia en infantes.

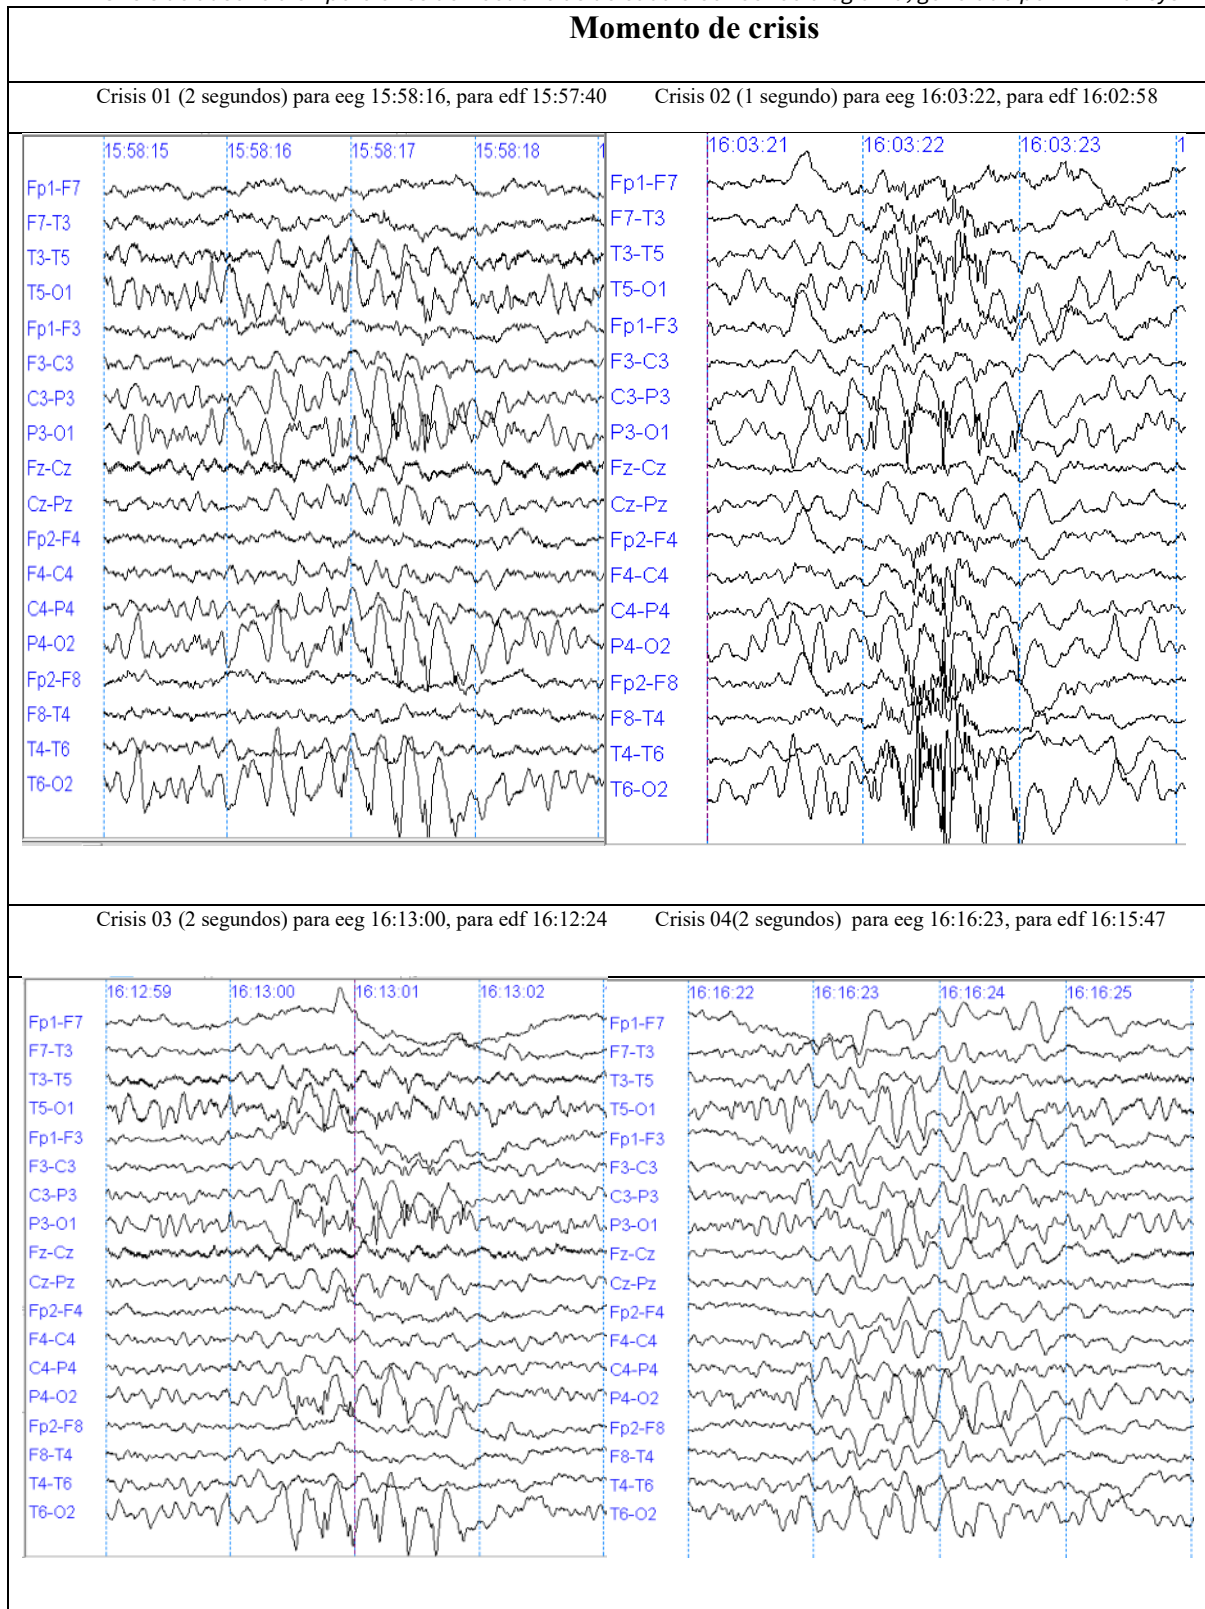
### **3.6.1. Selección de frecuencias**

#### **Positivas**

Cabe resaltar que las porciones de frecuencias dentro del electroencefalograma fueron diagnosticadas como crisis de ausencia e identificadas bajo criterio de una neuropediatra, seleccionadas de manera manual, basado su experiencia en la identificación visual de las frecuencias representadas por crisis de ausencia (punta-onda y polipunta-onda tal como lo menciona Epilepsy (2024), ya que se identificó que en los momentos de crisis de ausencia tienen por lo menos 5 picos, tal como se visualiza en la Figura 2 en cada uno de los momentos de crisis, siendo considerados como valor 1 donde si identifica con crisis de ausencia, teniendo en cuenta que en formato .eeg los tiempos son diferentes para el formato .edf, esto por el proceso de conversión, esto ha permitido realizar el análisis en el momento, la duración y la forma en como se representa de manera visual de cada crisis de las 04 crisis identificada en el archivo '09eeg\_7uV\_1p00s\_35Hz.edf', donde la primera crisis ocurrió a las 15:38:16, la segunda ocurrió a las 16:03:22, la tercera ocurrió a las 16:13:00 y la cuarta ocurrió a las 16:16:23 con duración de 2, 1, 2 y 2 segundos respectivamente. Así también estos momentos y duración mostradas han sido validadas y corroboradas por la neuropediatra,

**Figura 2.**

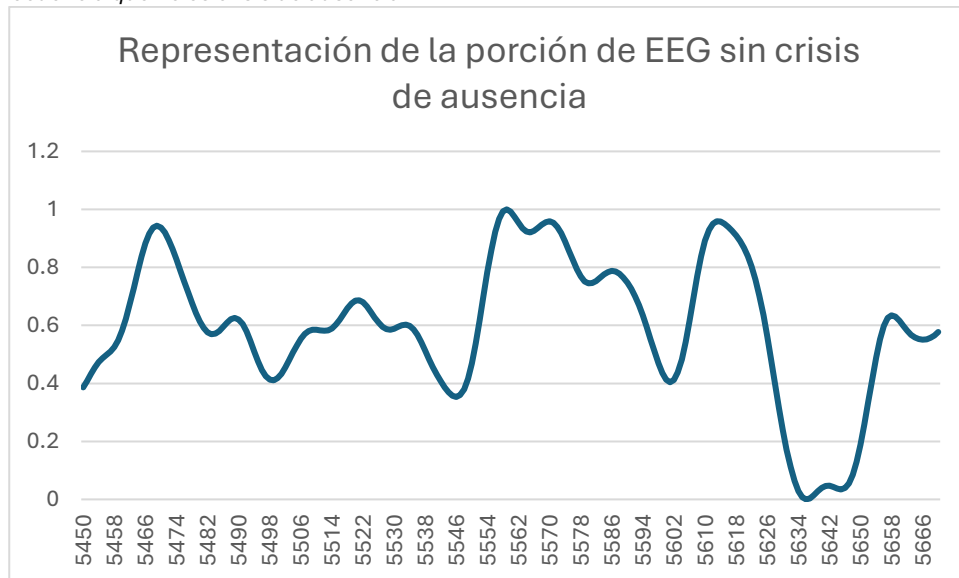
*Crisis de ausencia en porciones de frecuencias de cada electroencefalograma, generado por BWAnalysis*



## Negativas

El conjunto de frecuencias (por cada segundo) que no son identificados como crisis de ausencia, toman el valor 0 o ‘sin crisis’, tal como se muestra en la Figura 3, considerando que esta es la gran mayoría de casos en el electroencefalograma.

**Figura 3.**  
Porción de 500 frecuencia que no es crisis de ausencia



## Previos

Los datos que son considerados como ‘previos’ (que no son crisis de ausencia), pero están 5 segundos antes de ‘con crisis’, tomando el valor 2. Donde estos datos también serán considerados como parte del entrenamiento a los modelos basados en inteligencia artificial.

### 3.7. Consideraciones éticas

Tomando en cuenta que para la presente investigación es necesario la información diagnóstica de pacientes infantiles, por tanto, es necesario considerar los siguientes aspectos éticos:

Según el Colegio Médico (2021), considera la autonomía de la persona obliga a que a información debe ser obtenido de manera obligatoria bajo el consentimiento y respetar la decisión, en consonancia con sus valores personales y culturales. Siendo respetada de manera obligatoria por el galeno.

Certificación de Conducta Responsable en Investigación (2019), propuesto por el CONCYTEC, exige una serie de requisitos y condiciones para la realización de investigaciones científicas en el Perú, principalmente si los objetos de estudios son seres humanos.

Cabe resaltar que los datos del paciente en todo momento se consideran como anónimo, basándose en el código de ética del Colegio Médico (2021) y las fuentes que lo contemplan.

## IV. RESULTADOS

### 4.1. Contrastación de hipótesis

Para la contrastación de hipótesis se ha considerado los siguientes supuestos en base a los objetivos específicos planteados:

#### **Hipótesis general**

- Ho: El modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias no mejora en la detección de convulsiones de crisis de ausencia en pacientes infantiles neuropediátricos.
- Ha: El modelo de aprendizaje de señales electroencefalograma con el filtro Gabor a las frecuencias mejora en la detección de convulsiones de crisis de ausencia en pacientes infantiles neuropediátricos.

Para encontrar los índices de especificidad, sensibilidad y nivel de exactitud aplicando el nuevo modelo de aprendizaje a las señales electroencefalograma, previamente se tiene que aplicar el filtro Gabor a las frecuencias, necesariamente para el proceso de entrenamiento como para las pruebas o testeos de casos de crisis de ausencia, considerando que se cuenta con una base de datos de 5434 segundos de información, donde por cada segundo tiene 500 frecuencias (2 717 000 frecuencias por 18 canales) ósea 48 906 000 frecuencias totales para procesar, y que en su interior contiene 7 episodios de crisis de ausencia para detectar (ver Figura 6), el cual identifica un desencadenamiento eléctrico y se representa en valores de frecuencia obtenidas en una sesión con los equipos necesarios (Software BWAnalysis versión 1.103.0.62 x64 PVD06), tal como se refleja en detalle el proceso atención en el Anexo 1.

## 4.2. Creación del modelo de aprendizaje.

En base al modelo de EEGLab (2025) de Matlab para el análisis de frecuencias de tipo EEG entre otros, el nuevo modelo de la presente investigación toma como referencia algunos de estos pasos, adicionalmente se ha considerado nuevos pasos como ‘Create patterns for learning’, ‘Confusion Matrix compare between all methods’ remarcada en la Figura 4 en referencia a la Figura 5, de los cuales ha sido necesario aplicar en los lenguajes de programación científicos dedicados al EEG como Python mne y Matlab EEGLab.

- ‘Import raw data’, las frecuencias han sido extraídas del archivo ‘09eeg\_7uV\_1p00s\_35Hz.edf’ (ver Figura 7), considerando que los datos de las frecuencias se encuentra bajo el estándar internacional 10-20 en la colocación de los electrodos al paciente infante.
- ‘Downsample the data’, para mostrar las frecuencias de todos los canales, ha sido necesario aplicar el prePipeline, para poder visualizar el estado actual del paciente en relación las Frecuencias con el Power  $10 \cdot \log(uV^2/Hz)$  tal como se muestra en la Figura 6, del cual ha sido necesario aplicar el ‘Perform ica decomposition’.
- ‘High-Pass filter the data’, para extraer las características resaltantes de las frecuencias del electroencefalograma, para ser usados posteriormente con algún modelo (ejemplo basado en inteligencia artificial), es necesario realizar un filtro, obviamente sometido a criterio o necesidad del análisis que requiera, Por defecto el software del fabricante del equipo (equipo de 32 canales marca Neuro Virtual modelo BWIII) ofrece el FFT, pero para la presente investigación se realiza el Filtro Gabor.
- ‘Detect and Reject bad channels’, necesario para poder tomar en cuenta cuál de los canales aporta a la investigación y cuáles no. Se ha aplicado la correlación  $R^2$ , similaridad y varianza entre las frecuencias, Para poder identificar algún suceso importante que aporte a la investigación.

- ‘Create patterns for learning’, en cada segundo de haber realizado la identificación de crisis de manera visual por parte de la neuropediatra, se ha tomado los valores de salida 0, 1, 2. Cabe resaltar que como son pocos los sucesos de crisis de ausencia frente a la cantidad total de frecuencias, se considerado repetir hasta en 500 veces más los mismos datos de entrada y salida para ‘con crisis’ y ‘previo’, esto para que en el aprendizaje no lo tome como ruido.
- ‘Fit equivalent current dipolos’, se va a considerar los modelos de machine learning para el entrenamiento como la red neuronal supervisada, red neuronal SOM, vecino más cercano, árbol de decisión y random forest, ya que en estos modelos se puede usar los mismos patrones de entrada y salida deseada (a excepción de la red SOM). Para el aprendizaje de las salidas deseadas de cada registro con ‘sin crisis’, ‘con crisis’ y ‘previo’ se ha considerado los valores 0, 1, 2 respectivamente.
- ‘Confusion Matrix compare between all methods’, una vez realizado el aprendizaje y comprobación de los datos, con los mismos datos de aprendizaje, es necesario saber la sensibilidad, especificidad y la precisión de cada modelo para poder realizar la comparación y ver que modelo es el que proporciona mejor resultado, considerando que para las pruebas se han realizado con archivo llamado ‘27eeg\_7uV\_1p00s\_35Hz.edf’ del mismo paciente.

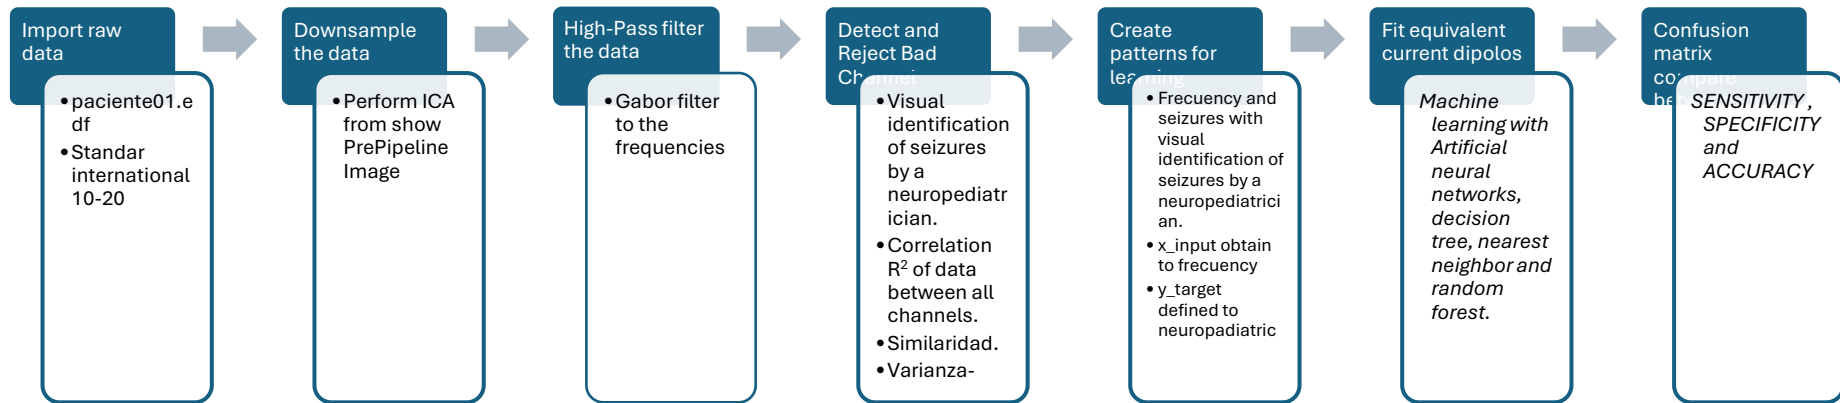
Cabe resaltar que el paso ‘Re-Reference’ del modelo original no se ha considerado, ya que no tenemos un sector específico para analizar (parte específica de los canales del EEG o parte del cerebro), ya que en la presente investigación se realiza el análisis del total de los canales (18 canales). Así también no se ha considerado al paso ‘Extract Data Epoch’ porque se ha tomado el tiempo total de la sesión en etapa de sueño, mas no actividades específicas (como leyendo, estado de ánimos, impresión, etc). Tampoco se ha considerado al paso ‘Reject Noisy Data’ porque la neuropediatra con su experiencia ha tenido cuidado que los datos de tipo encefalograma sean tomados correctamente, y no ha presentado posibles errores como

desconexión de un electrodo, ruido abrupto externo, etc. ‘Perform ICA decomposition’ con ‘Select ICA components’, ya que para el presente caso no ha sido necesario para presentación grafica del escenario ya que según EElab requiere computación paralela, por tanto, un hardware de mayor característica y dicho de paso licencia de EEGLab para el funcionamiento de estos pasos. Así tampoco el paso ‘Save the data’ ya que almacenar los datos procesados (en algún formato o extensión en particular) requeriría un modelo de software adicional para abrir y visualizar, además es innecesario para el objetivo planteado en la presente investigación.

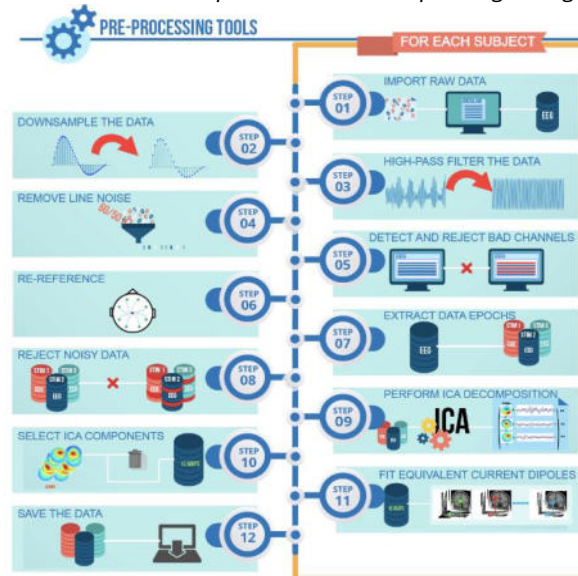
Cabe resaltar que el paciente ha seguido un tratamiento de valproato de sodio a prescripción de la neuropediatra, por ello en el archivo ‘09eeg\_7uV\_1p00s\_35Hz.edf’ (que está en la etapa inicial de la detección de convulsiones) presenta mayor cantidad de crisis de ausencia (4 detectados en 2256 segundos), a comparación del segundo archivo solo hubo 3 detecciones en 1588 segundos.

**Figura 4.**

Procesos para la detección de convulsiones de crisis de ausencia en pacientes infantiles neurológicos


**Figura 5.**

Modelo de herramienta de preprocesamiento de datos para el análisis de en datos de tipos EEG. Fuente <https://eeglab.org/>.



**Figura 6.**

Chanel spectral and maps, de 18 canales con 1128000 valores de frecuencias de 09eeg\_7uV\_1p00s\_35Hz.edf, fuente:elaborado en eegLab de Matlab



#### 4.2.1. Aprendizaje de modelos basados en inteligencia artificial.

Uno de los pasos más resaltantes del modelo propuesto en la presente investigación es ‘Fit equivalent current dipolos’ donde se aplica los diferentes modelos basados en inteligencia artificial. En este paso los valores de las frecuencias pasan a ser patrones de entrada para el proceso de entrenamiento de la red neuronal BackPropagation, red neuronal SOM, vecino más cercano, árbol de decisión de tipo CART y random forest,

Para el aprendizaje de las salidas deseadas de cada registro con ‘sin crisis’, ‘con crisis’ y ‘previo’ se ha considerado los valores 0,1,2 respectivamente.

La estrategia para la extracción de características de cada grupo de frecuencias se ha utilizado el filtro Gabor en el paso ‘High-Pass filter the data’, ya que es sensible a las frecuencias, el cual utiliza señales sinusoidales a partir de una función gaussiana (Gabor, 1946), por tanto, a cada segundo (500 valores de frecuencia) de cada canal (18 canales) se va a aplicar el filtro, siendo insumo como patrones de entrada para el aprendizaje de los diferentes modelos basados en inteligencia artificial. Entonces, para cada patrón de entrada será de dimensión 18x500. Tomando en cuenta que se tiene 2256 registros para el aprendizaje, donde solo 4 segundos (en momentos distintos) son identificado como ‘con crisis’ y 20 valores ‘previo’ (5 segundos antes de cada crisis), se ha adicionado la réplica de 500 veces para cada uno de estos casos, quedando con 14255 registros. La distribución de la frecuencia para el aprendizaje y el testeo ha sido de manera aleatoria, aplicando la función ‘train\_test\_split’ de ‘sklearn.model\_selection’, con 80% y 20% respectivamente. De manera similar para la representación de patrones, el segundo archivo se tiene 1588 registros de 18x500.

**Figura 7.***Extracción de frecuencias de cada electroencefalograma*

```

raw_train = mne.io.read_raw_edf(
    "09eeg_7uV_1p00s_35Hz.edf",
    stim_channel="Event marker",
    infer_types=True,
    preload=True,
    verbose="error", # ignore issues with stored filter settings
)
print(raw_train.get_data().shape)
#(18, 1128000)

```

```
(18, 1128000)
```

```

raw_test = mne.io.read_raw_edf(
    "27eeg_7uV_1p00s_35Hz.edf",
    stim_channel="Event marker",
    infer_types=True,
    preload=True,
    verbose="error", # ignore issues with stored filter settings
)
print(raw_test.get_data().shape)
#(18, 794500)

```

```
(18, 794500)
```

- **RED NEURONAL ARTIFICIAL BACKPROPAGATION**

Después de realizar las diferentes pruebas y encontrar el valor más idóneo para poder tener un mejor resultado respecto a la sensibilidad, especificidad y precisión, en pacientes diagnosticados con crisis de ausencia y para lograr ello se ha utilizado la librería tensorflow en python. Dentro de la estructura de la red neuronal, Blum & Rivest (1992) se define el tamaño de patrones de entrada con 18x500, 3 capas ocultas de 800 neuronas cada una de ellas, con la función de activación en cada capa de tipo 'relu', y 3 neuronas en la capa de salida ( $\{1,0,0\}:0$ ,  $\{0,1,0\}:1$ ,  $\{0,0,1\}:2$ ) con la función de activación de tipo 'softmax', definiendo de acuerdo al valor de salida si es que se identifica como si hay presencia de 'sin crisis', 'con crisis' y 'previo', así también se ha usado para el entrenamiento 20 épocas,

configurado con una pérdida de tipo ‘SparseCategoricalCrossentropy’, optimizador ‘adam’ y métrica ‘accuracy’. Al aplicar esta estructura con 11404 registros para el entrenamiento y para el testeo con 2851 registros del mismo archivo, también para el testeo con el segundo archivo son 1588 registros para obtener un crecimiento de score, tal como se muestra en la Figura 8.a. Se ha obtenido una sensibilidad, especificidad y exactitud respecto a la identificación de ‘sin crisis’, ‘con crisis’ y ‘previo’ con 0.0, 1.0, 2.0 para el testeo del mismo archivo y 0.99, 1.0, 0.99 para el testeo del segundo archivo, tal como se muestra en la Figura 9.a la matriz de confusión.

- **RED NEURONAL SOM**

Para aplicar este modelo en un escenario colab se utilizó la librería minisom, para los patrones de entrada ha sido necesario estirar cada registro de 18x500 a 1x9000, 5000 épocas para el entrenamiento, un Alpha\_max de 0.5, topology de vecindad 'hexagonal', función de afectación 'gaussian', distancia 'euclidean', la dimensión de la matriz competitiva se ha evaluado en un rango de 10 al 40, encontrando el mejor resultado con una dimensión de 20x20, tal como se muestra en la Figura 8.b. Se ha obtenido una sensibilidad, especificidad y exactitud respecto a la identificación de ‘sin crisis’, ‘con crisis’ y ‘previo’ con 0.0, 1.0, 2.0 para el testeo del mismo archivo y 0.99, nan, 0.99 para el testeo del segundo archivo. Tal como se muestra en la Figura 9.b la matriz de confusión.

- **VECINO MÁS CERCANO (KNN)**

Realizando las diferentes pruebas y encontrar el valor más idóneo para poder tener un mejor resultado respecto a la sensibilidad, especificidad y precisión, en pacientes diagnosticados con crisis de ausencia y para lograr ello se ha utilizado la librería sklearn en python. Dentro de la estructura del vecino más cercano se usó la creación de pesos iniciales de manera ‘uniform’, una métrica de ‘minkowski’, se define el tamaño de datos de entrada de 9000, para los 2255 sucesos, con salida de tipo ‘sin crisis’, ‘con crisis’ y ‘previo’, y

vecinos de 2 a 7, encontrando el mejor resultado con una vecindad de 2, tal como se muestra en la Figura 8.c. Se ha obtenido una sensibilidad, especificidad y exactitud respecto a la identificación de ‘sin crisis’, ‘con crisis’ y ‘previo’ con 0.0, 1.0, 2.0 para el testeo del mismo archivo y 0.99, 0.0, 0.99 para el testeo del segundo archivo. Tal como se muestra en la Figura 9.c.

- **ÁRBOL DE DECISIÓN**

Realizando las diferentes pruebas para encontrar el valor más idóneo y tener un mejor resultado respecto a la sensibilidad, especificidad y precisión, en pacientes diagnosticados con crisis de ausencia y lograr ello se ha utilizado la librería sklearn en python. Dentro de la estructura del árbol de decisión de tipo CART (Classification and Regression Trees) (L. Breiman, 1984), se define el tamaño de datos de entrada de 9000, con criterio de tipo ‘entropy’, para los 2255 registros para el entrenamiento, con salida de un tipo ‘sin crisis’, ‘con crisis’ y ‘previo’, con una mejor profundidad de 16, tal como se muestra en la Figura 8.d. Obteniendo un resultado de 0.99, 0.0, 0.99 para sensibilidad, especificidad y exactitud respectivamente para el testeo del segundo archivo, tal como se muestra en la Figura 9.d.

- **RANDOM FOREST**

Los valores de las frecuencias (en porciones de 18x500), así como la calificación respectiva de crisis de ausencia, se tomaron como fuente para el modelo de tipo Random Forest (Breiman, 2001; Jesús, 2020), dicho de paso son los mismos aplicados en los otros modelos basados en inteligencia artificial, a partir de estos datos se va a realizar el entrenamiento y los parámetros especificados lo maneja de manera interna la librería ‘scipy’, logrando un mejor hiperparámetro con una máxima profundidad de 16 y un estimador de 419, obteniendo como salida de un tipo ‘sin crisis’, ‘con crisis’ y ‘previo’, obteniendo un resultado de 0.99, 0.0, 0.99 para sensibilidad, especificidad y exactitud respectivamente para el testeo del segundo archivo, tal como se muestra en la Figura 9.e.

La presente investigación realiza dentro del nuevo modelo el aprendizaje de señales electroencefalograma para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantiles neuropediátricos, aplicando el filtro Gabor a las frecuencias del electroencefalograma para obtener los patrones de entradas, para poder aplicar modelos basados en inteligencia artificial, indicando que el modelo basado en inteligencia artificial si reconoce los ‘sin crisis’ , ‘con crisis’ y ‘previo’, a comparación de los otros modelos solo reconocen casos ‘sin crisis’, tal como se muestra en la Tabla 1.


**Tabla 6.**

Resultado de aplicar los modelos basado en inteligencia artificial para la identificación de crisis de ausencia con datos de otro archivo con 1588 registros


	<i>Sensibilidad</i>	<i>Especificidad</i>	<i>Exactitud</i>	<i>Accuracy</i>	<i>Recall</i>	<i>F1-score</i>
<i>Back propagation</i>	0.99	1.0	0.99	0.93	0.94	0.97
<i>Red Neuronal SOM</i>	0.99	nan	0.99	0.99	1.0	0.99
<i>KNN</i>	0.99	0.0	0.99	0.97	0.98	0.98
<i>Árbol de decisión</i>	0.99	0.0	0.99	0.97	0.99	0.99
<i>Random Forest</i>	0.99	nan	0.99	0.97	0.98	0.99

**Figura 8.**

Aprendizaje y comprobación con 1588 sucesos para ‘sin crisis’, ‘con crisis’ y ‘previo’, elaborado en Python. Imagen usando a) Red neuronal backpropagacion, b) Red neuronal SOM, c) Vecino más cercano, d) Árbol de decisión



**Figura 9.** Matriz de confusión con 1588 sucesos para ‘sin crisis’, ‘con crisis’ y ‘previo’, elaborado en Python. Imagen usando a) Red neuronal backpropagacion, b) Red neuronal SOM, c) Vecino más cercano, d) Árbol de decisión, e) Random forest



#### 4.2.2. *Generación de nuevo conocimiento.*

En base al nuevo modelo propuesto por la presente investigación, se logró identificar 04 nuevos conocimientos, implicando que la presente tesis será referenciada en futuras investigaciones, en campo médico neuropediátrico, el campo de las ciencias de la computación, así también en otras áreas involucradas en resolver casos de crisis de ausencia en pacientes neuropediátricos, ayudando a tener un diagnóstico más fino, de los cuales dicho nuevos conocimientos (ver en detalle gráficamente en Anexo 7) son:

**Primer aporte:** En los momentos de crisis de ausencia se identificó en las valuaciones de las frecuencias en los canales del electroencefalograma una coherencia de 0.63 para los canales P4-O2 con T6-O2, ósea el canal T6-O2 depende de P4-O2, tal como se muestra en la Figura 10.a (más detalle de las valuaciones en el anexo 3), resaltando que en los momentos de crisis todos los canales siguen un mismo patrón común, corroborados en la Figura 6. Basado en la coherencia de frecuencias entre las señales  $x(t)$  e  $y(t)$  es el cuadro de la densidad de frecuencias cruzadas, por tanto, es una técnica estándar en el procesamiento y análisis de señales de tipo frecuencias y, en neurociencia. (Klimesch, 2018)

**Segundo aporte:** Tomando como fuente Moore (2004) donde menciona el grado de asociación entre dos variables, midiendo que tan alto es el grado de vínculo, en este caso serían los 18 canales, por tanto, se identificó en los momentos de crisis un coeficiente de correlación  $R^2 = 0.77$  específicamente en los canales 'C3-P3' con 'P4-O2' y un  $R^2$  mínimo de 0.57 entre los otros canales, indicando que existe una similaridad de las frecuencias en el momento de cada crisis, tal como se muestra en la Figura 10.b (detalle de la valuación obtenida en el anexo 5). Corroborando a (Ramos-Argüelles, 2009), donde considera que las crisis parciales complejas se originan en el lóbulo temporal, los parietales P3 y P4 están cerca de los temporales.

**Tercer aporte:** Se identificó una desviación estándar muy alto en los momentos de crisis de ausencia, resaltando los polipunto-cola con más de 5 picos por segundo en cada canal de las frecuencias, donde resalta la valuación más alta (47.49) en el canal ‘T6-O2’, implicando que en el momento de crisis de ausencia la perdida de conciencia pronta se refleja en el área Temporal (T6) y Occipital (O2) del lado derecho, tal como se muestra en la Figura 11, donde se muestra una comparativa entre todos los canales posicionados según el estándar internacional 10-20. (Hald, 1998).

**Cuarto aporte:** Implica que aplicando el nuevo modelo para el aprendizaje de señales electroencefalograma propuesto en la presente investigación, se puede aplicar para el entrenamiento de diferentes modelos de aprendizaje de la inteligencia artificial.

**Figura 10.**

En los momentos de crisis se ha identificado a) Coherencia de canales, b)  $R^2$ . Elaborado en seaborn de Python


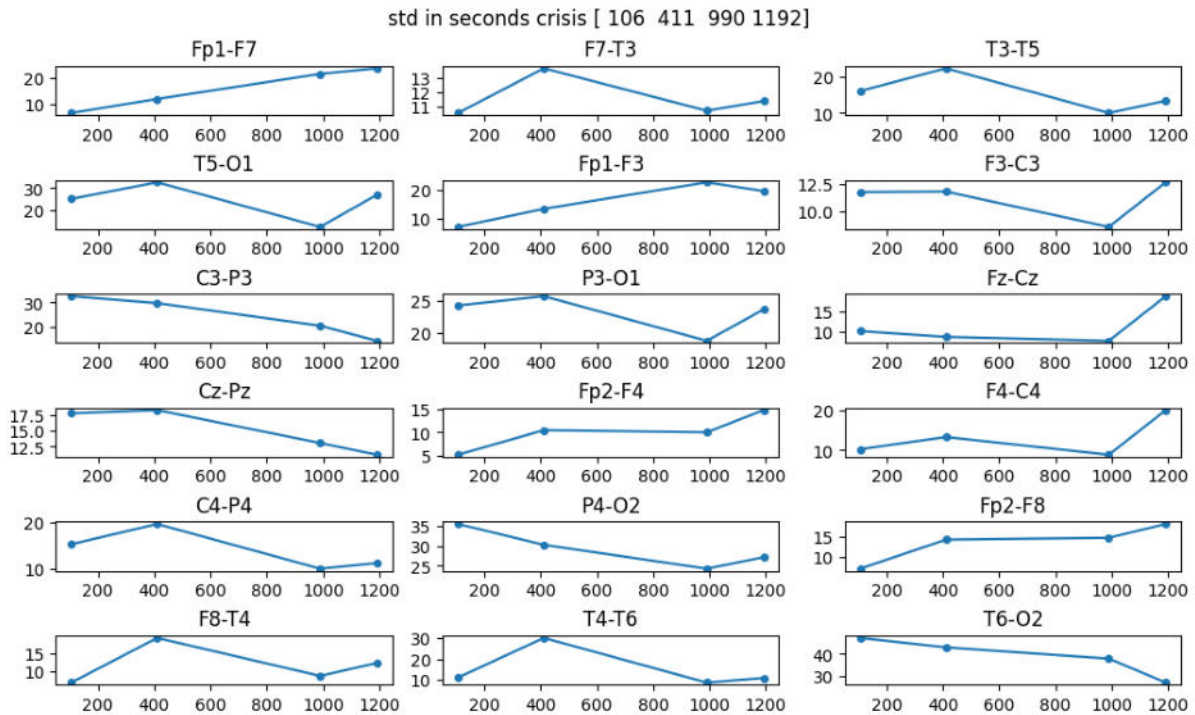


Figura 11.

Desviación estándar máximo por cada momento de crisis de ausencia, elaborado en Python



#### 4.2.3. Complejidad computacional.

Para el análisis respecto a la complejidad computacional, se ha tomado en cuenta el tipo de red neuronal aplicada a la presente investigación, es un problema de tipo NP-completo también lo demuestra Blum & Rivest (1992) donde realiza el análisis de una red neuronal de dos capas y 3 neuronas, cabe resaltar que si es que este modelo se extiende en capas y neuronas por cada capa, se hace más complejo y difícil de analizar, ya que parte de un conjunto de datos como patrones de entrada variable y pesos sinápticos de manera aleatoria, por tanto no está garantizado la cantidad de épocas necesarias para llegar a un error mínimo estimado, a pesar que en la capa de salida es una salida binaria, donde se presenta la calificación de persona con crisis de ausencia o no, de esta manera se ha realizado el aprendizaje para las diferentes frecuencias como 'Fp1-F3', 'F3-C3', 'C3-P3', 'P3-O1', 'Fp2-F4', 'F4-C4', 'C4-P4', 'C4-O2', 'Fz-Cz', 'Cz-Pz', 'Fp1-F7', 'F7-T3', 'T3-T5', 'T5-O1', 'Fp2-F8', 'F8-T4', 'T4-T6' y 'T6-O2', por tanto la estructura de la red neurona el cual consta de 1 capa de entrada, 3 capas ocultas y una capa de salida. Esto a diferencia de Ors Quixal & Castells Ramón (2023) donde aplica una red

neuronal convolucional para este mismo escenario de electroencefalogramas, donde encuentra una complejidad de  $O(N \times V \times K \times D)$ , donde depende de los Núcleos (N), de los volúmenes de los tensores (V), el tamaño de los kernel (K) y un coeficiente de reducción (D), tomando en cuenta que este modelo obtiene una precisión de 93.0% en el mejor de sus casos.

Con respecto a la complejidad del algoritmo de Random Forest, se considera la fórmula propuesta por Xiaorou Zheng (2021), donde en su investigación representa a la complejidad la siguiente fórmula,  $O(v \cdot n \log(n))$ , donde  $n$  es el número de registros y  $v$  es el número de variables o atributos el cual se desea clasificar, aplicando esta fórmula presentada se va a considerar los 1922000 registros (de 3844 segundos), 3 variables o atributos de los cuales se considera que si es que ‘lo padece’, ‘no lo padece’ y ‘previo’ a la crisis de ausencia, por tanto la complejidad de la presente investigación quedaría en  $O(3 \cdot 1922000 \log(1922000))$  del cual equivale a 95 766 000, por tanto hay que tener en cuenta que estos valores pueden cambiar, puesto que la cantidad de datos obtenidos es por cada electroencefalograma, por tanto este valor puede cambiar si es que el análisis es mayor (mayor de electroencefalogramas), así como como registros por cada una de ellas.

#### **4.2.4. Prueba de hipótesis.**

Para el análisis estadístico de los resultados obtenidos en la presente investigación, se realiza las siguientes pruebas.

##### **Hipótesis general**

**HG:** El modelo de aprendizaje de señales electroencefalograma aplicando el filtro Gabor a las frecuencias mejora en la detección de convulsiones de crisis de ausencia en pacientes neuropediátricos.

Para la contrastación de hipótesis se ha considerado los siguientes supuestos en base a los objetivos específicos planteados:

### **Hipótesis específica**

HE1: Mediante modelo de aprendizaje de señales electroencefalograma aplicando el filtro Gabor a las frecuencias incrementa el nivel de sensibilidad en la detección de convulsiones de crisis de ausencia en una institución neuropediátrica.

Se ha logrado una detección en los 3844 segundos de duración, en el testeado de los modelos basados en inteligencia artificial se obtuvo en sensibilidad para cada modelo respecto para la identificación que no son crisis, si son crisis y previos a crisis como red neuronal artificial de tipo back propagation los valores de 0.99 para la red neuronal SOM 0.99, para el vecino más cercano 0.99, para árbol de decisión 0.99 y random forest 0.99.

HE2: Mediante modelo de aprendizaje de señales electroencefalograma aplicando filtro Gabor a las frecuencias incrementa el nivel de especificidad en la detección de convulsiones de crisis de ausencia en una institución neuropediátrica.

Se ha logrado una detección en los 3844 segundos de duración, en el testeado de los modelos basados en inteligencia artificial se obtuvo en especificidad para cada modelo respecto para la identificación que no son crisis, si son crisis y previos a crisis como red neuronal artificial de tipo back propagation los valores de 1.0, para el vecino más cercano 0.0 y para árbol de decisión 0.0.

HE3: Mediante modelo de aprendizaje de señales electroencefalograma aplicando el filtro Gabor a las frecuencias incrementa el nivel de exactitud en la detección de convulsiones de crisis de ausencia en una institución neuropediátrica.

Se ha logrado una detección en los 3844 segundos de duración, en el testeado de los modelos basados en inteligencia artificial se obtuvo en exactitud para cada modelo respecto para la identificación que no son crisis, si son crisis y previos a crisis como red neuronal artificial

de tipo back propagation los valores de 0.99 para la red neuronal SOM 0.99, para el vecino más cercano 0.99, para árbol de decisión 0.99 y random forest 0.99.

#### **4.3.Análisis e interpretación**

En el testeo de los modelos basados en inteligencia artificial se obtuvo en sensibilidad, especificidad, exactitud y accuracy para cada modelo respecto para la identificación que no son crisis, si son crisis y previos a crisis para la red neuronal artificial de tipo back propagation los valores de 0.99, 1.0, 0.99, 0.93, para la red neuronal SOM 0.99, nan, 0.99, 0.99, para el vecino más cercano 0.99, 0.0, 0.99, 0.97, para árbol de decisión 0.99, 0.0, 0.99, 0.97 y random forest 0.99, nan, 0.99, 0.97 respectivamente. Por tanto, concluye que hay una correcta recolección y tratamiento de datos con los modelos de aprendizaje a identificar convulsiones.

## V. DISCUSIÓN DE RESULTADOS

Comparando con investigaciones internacionales encontramos a Anuragi, Sisodia, & Pachori (2021) el cual usó una estrategia de aplicar a las frecuencias del EEG la serie de Fourier-Bessel, donde ha obtenido una precisión de 99.84% para 2 posibilidades de respuesta, frente a la presente investigación se obtuvo una precisión de 93.0% usando red neuronal supervisada, aplicando el filtro Gabor para 3 posibilidades de respuesta, dando valores de precisión muy similares, implicando que se puede usar cualquiera de estos métodos. En la investigación realizada por Malkov (2025), donde ha aplicado el modelo regresión lineal (LR) obteniendo como resultado para 2 posibilidades de respuesta una precisión de 93.2%, superando en 0.2% a la presente investigación donde tiene 3 posibilidades de respuesta. En la investigación realizada por Suat Tas (2025) donde usa la estrategia llamada Patrón Transformador de 3 cuerpos (TBP) para extraer características resaltantes de cada canal del EEG, logrando una precisión de 90%, considerando que tiene hasta 5 posibilidades de respuestas representadas en géneros musicales (clásica, popular, rap, balada y música en reposo), lo cual lo hace más compleja el aprendizaje. También en la publicación de Kantipudi (2024) donde ha usado como estrategia la combinación de modelos como wavelets de Haar Lineal Finito (FLHF), Dimension Fractal (DF), Optimización de Enjambre Bioinspirada por Grasshopper (GBSO) y Red Neuronal Expansiva de Activación Temporal (TAENN) para la detección de convulsiones de epilepsia a partir de señales EEG, logrando un rendimiento de 99.6% para 2 posibilidades de respuesta (si padece de crisis o no), con la técnica de Red Neuronal Convolutiva (CNN) para reconocer convulsiones epilépticas a partir de señales de EEG.

Cabe resaltar que ninguno de los investigadores citados, han logrado identificar el nivel de coherencia, la correlación  $R^2$ , así como la desviación estándar para poder resaltar sucesos en particular en los segundos de crisis de ausencia.

## VI. CONCLUSIONES

Se concluye que aplicando el nuevo modelo propuesto de aprendizaje de señales electroencefalograma detecta las convulsiones de crisis de ausencia en pacientes infantiles neuropediátricos, aplicando el filtro de Gabor a las frecuencias electroencefalograma para obtener los patrones de entrada a los modelos de aprendizaje, se ha obtenido el mejor resultado con las redes neuronales supervisada (93% de precisión), detectando los casos de 'sin crisis' y 'con crisis', frente a los otros modelos donde sólo detecta los 'sin crisis', mas no los 'con crisis' y 'previo', por tanto, aplicando esta estrategia tiene un impacto significativo en la detección de convulsiones de crisis de ausencia en el análisis de tipo electroencefalograma. También se concluye que el modelo propuesto genera nuevos conocimiento, tal como la existencia del vínculo de ciertos canales en los segundos de crisis de ausencia, como en la coherencia con un valor alto de 0.63 para los canales 'P4-O2' con 'T6-O2', para el coeficiente de correlación  $R^2$  se ha obtenido un valor de alto de 0.77, implicando una similaridad de frecuencias de los canales 'C3-P3' con 'P4-O2' y desviación estándar para resaltar que tanto se altera las frecuencias en los momentos de crisis específicamente en el canal 'T6-O2'.

## VII. RECOMENDACIONES

La aplicación del modelo propuesto para el aprendizaje de señales electroencefalograma para la detección de convulsiones de crisis de ausencia en pacientes infantiles neuropediátricos, debería tener mayor cantidad de casos de porciones de frecuencias en el cual aprenda e identifique como un caso positivo a crisis de ausencia, ya que el balance de casos negativos es mayor que los casos positivos en el aprendizaje, y esto se ve en los diferentes algoritmos aplicados tal como red neuronal artificial back propagation, árbol de decisión, red neuronal artificial de tipo SOM, vecino más cercano y algoritmo de random forest.

Se puede mejorar el aprendizaje usando otros canales de las frecuencias, en el formato internacional 10-20, el cual hace referencia de las mismas posiciones de los electrodos para la toma de frecuencias e identificación de la crisis de ausencia, esto aplicado para los diferentes modelos utilizados en la presente investigación.

Se recomienda para futuras investigaciones aplicar el aprendizaje en la frecuencia en tiempos más prolongados, hasta 15 segundos, implicando el tamaño de patrón de entrada a la red de 4500 frecuencia, considerando la extensión puede requerir más recursos de máquina, se puede aplicar este modelo en tiempo real considerando como herramienta para el testeo, los valores de los pesos sinápticos (en caso de redes neuronales) ya aprendidos, así también las reglas generadas para el árbol de decisión y para random forest.

Aplicar estos modelos como referencia para el proceso de aprendizaje y el testeo, no tan solo para el análisis de frecuencias de tipo electroencefalograma, sino también para casos de manejo de frecuencias obtenidas como frecuencias de tipo cardiológicos, u otros donde se obtenga datos que se pueda representar en frecuencias o valores frecuenciales.

Aplicar no tan solo los métodos del filtro de Gabor en un conjunto de frecuencias, también se puede aplicar para algoritmos como transformada de Fourier, filtro escalado, así como otros modelos matemáticos para el majo de frecuencias.

## VIII. REFERENCIAS

- Altman D.G., B. J. (1994). *Statistics Notes: Diagnostic tests 1: sensitivity and specificity*. *BMJ*, 308, <https://doi.org/10.1136/bmj.308.6943.1552>.
- Altman DG, B. J. (1994). *Diagnostic tests 1: Sensitivity*. *BMJ*, 308.
- Andrew, D., Sanch, K., Lisa, F., & Dipti, P. (2019). To err is human: Clinical incident calls to a national travel health advice line. *Vaccine*, 37(52), 7535-7538.
- Anton E. Malkov, A. V. (2025). *Multiparametric machine learning for predicting epileptic hyperexcitability from interictal eeg background activity, communications in nonlinear science and numerical simulation*. *Communications in Nonlinear Science and Numerical Simulation*.
- Anuragi, A., Sisodia, S. D., & Pachori, B. R. (1 de 7 de 2021). Automated FBSE-EWT based learning framework for detection of epileptic seizures using time-segmented EEG signals. *Computers in Biology and Medicine*, 136, 104708: <https://www.sciencedirect.com/science/article/abs/pii/S0010482521005023>
- AprendeIA. (12 de 12 de 2020). *Aprendizaje no supervisado*. <https://aprendeia.com/aprendizaje-no-supervisado-machine-learning/>
- Arti, A., Dilip, S. S., & Ram, B. P. (2021). Automated FBSE-EWT based learning framework for detection of epileptic seizures using time-segmented EEG signals. *Computers in Biology and Medicine*, 136.
- B.Duckrow, R., Ceolini, E., & P. Zaveri, H. (2021). Artificial neural network trained on smartphone behavior can trace epileptiform activity in epilepsy. *iScience*, 102538.
- Bennett, W., Arsalan, D., & Sanjay, V. (2018). Diagnostic Errors and the Bedside Clinical Examination. *Medical Clinics of North America*, 453-464. <https://www.intramed.net/contenidover.asp?contenidoid=93599>
- Berger, H. (1929). from psychic energy to the EEG. *Perspectivas en biología y medicina*, 44(4), 522-42. <https://doi.org/10.1353/pbm.2001.0070>
- Breiman, L. (2001). *Random Forests. Machine Learning*. Springer Nature.
- Brett, J., Alyssa, S., & Robert, K. (2017). Overcoming Diagnostic Errors in Medical Practice. *The Journal of Pediatrics*, 19-25.e1.
- Brownlee, J. (2020). *Data Preparation for Machine Learning*. Machine Learning Mastery.

- Chris Liu, K., & Friedman, D. (2024). Artificial intelligence/machine learning for epilepsy and seizure diagnosis. *Epilepsy & Behavior*, 109736.
- Colegio Médico del Perú (30 de 10 de 2021). *Código de ética y deontología*.  
<https://www.cmp.org.pe/wp-content/uploads/2020/01/CODIGO-DE-ETICA-Y-DEONTOLOG%C3%8DA.pdf>
- company, T. a. (2025). *What Is the 10-20 System for EEG?* The Netherlands: TMSi.
- Cristóvão Ferreira, A., Moniz Dionísio, J., Ferreira, R., & Coelho, J. (2024). Epileptic seizure or parasomnia? From knowledge to recognition. Sleep-related hypermotor epilepsy. *Anales de Pediatría*, 386-387.
- Dan C. Cireşan, U. M. (2011). *Flexible, High Performance Convolutional Neural Networks for Image Classification*. Twenty-Second International Joint Conference on Artificial Intelligence, Switzerland.
- Epilepsy, I. L. (04 de 04 de 2024). *Epilepsis Diagnosis*. Obtenido de Diagnostico epileptico: <https://epilepsydiagnosis.org/syndrome/cae-eeg.html>
- Fitri, O., Jeffri, H., Winnugroho, W., & Astri, B. (2021). Altered mental status in moderate-severe traumatic brain injury in Indonesia: the clinical manifestation and EEG features of non-convulsive status epilepticus. *Heliyon*, 7.
- Galaviz, R. S. (2021). *Análisis con electroencefalografía (eeg) de la escucha de música para el estudio de estrés académico*. [Tesis de grado, Instituto Nacional De Astrofísica, Óptica Y Electrónica]. Repositorio INAOE.  
<https://inaoe.repositorioinstitucional.mx/jspui/handle/1009/2048>
- Gleichgerrcht, E., C. Munsell, B., & Alhusaini, S. (2021). Artificial intelligence for classification of temporal lobe epilepsy with ROI-level MRI data: A worldwide ENIGMA-Epilepsy study. *NeuroImage: Clinical*, 102765.
- Gómez, R. (2013). *La inteligencia Artificial ¿Hacia dónde nos lleva? ¿Cómo lo vez?* Universidad Nacional Autónoma de México.
- Hald, A. (1998). *A History of Mathematical Statistics*. Wiley.
- Hernández, S. (2014). *Metodología de la Investigación*. McGraw-Hill.
- Hikmat, H., Maha, A., & Enas, A. (2019). Automated identification for autism severity level: EEG analysis using empirical mode decomposition and second order difference plot. *Behavioural Brain Research*, 240-248.
- Homan, R. W. (1987). *Cerebral Location of International 10-20 System Electrode Placement*. Electroencephalography and Clinical Neurophysiology.

- Instituto Nacional del Cáncer [INC] (12 de 12 de 2021). *Electroencefalograma*.  
<https://www.cancer.gov/espanol/publicaciones/diccionarios/diccionario-cancer/def/electroencefalograma>
- Instituto Nacional de Salud del Niño [INSN] (2020). *Guía de práctica clínica para el diagnóstico y tratamiento de la epilepsia en pediatría unidad de atención integral especializada sub unidad de atención integral especializada pediátrica y sub especialidades neurología pediátrica*. MINSA.
- Jesús, E.-Z. J. (2020). *Application of Random Forest and XGBoost algorithms based on a credit card*. Grupo Financiero Ve por Más S.A. de C.V.
- Kantipudi, M. K. (2024). An improved GBSO-TAENN-based EEG signal classification model for epileptic seizure detection. *Scientific Reports*, 14, 843.
- Kidshealth. (10 de 10 de 2021). *Crisis de ausencia por epilepsia en la infancia*.  
<https://kidshealth.org/es/parents/childhood-absence-epilepsy.html>
- Klimesch. (2018). *The frequency architecture of brain and brain body oscillations: an analysis*. Euro: J Neurosci.
- Kuhn, M., & Kjell, J. (2013). *Applied predictive modeling*. Springer.
- L. Blum, A., & L. Rivest, R. (1992). Training a 3-node neural network is NP-complete. *Neural Networks*, 117-127.
- L. Breiman, J. F. (1984). *Classification and Regression Trees*. Wadsworth.
- Lennart Oelschläger. (2023). *Centering and Scaling of Numeric Data*. CRAN.
- López, P. L. (2020). *Población muestra y muestreo*. *Punto Cero*, 9(8), 69-74.  
<http://www.scielo.org.bo/pdf/rpc/v09n08/v09n08a12.pdf>
- María de Lourdes Gutiérrez Cordero, M. J.-V. (2017). Análisis del Riesgo de Caída de Cartera en Seguros Metodologías de “Inteligencia Artificial” vs “Modelos Lineales Generalizados”. *Economía Informa*, 69.
- Marlon Igor, M. B., & Guillermo, T. G. (2006). *Conceptos Básicos de electroencefalografía*. Universidad de Magdalena.
- Márquez, F. C. (2003). *El proyecto de investigación y su esquema de elaboración*. Editorial Uyapar.
- Mediciclopedia. (2021). *Clasificación Internacional de las enfermedades icd-10*. Instituto Químico Biológico.
- Mediciclopedia. (2021). *Clasificación Internacional de las enfermedades, icd-10*. Instituto Químico Biológico.


- Millard, P. (2003). *Comparing texture analysis methods through classification*. Photogrammetric Engineering and Remote Sensing.
- Miyara, F. (2004). *Filtros activos*. Universidad Nacional del Rosario.
- ORPHANET. (2 de 2 de 2021). *Síndrome de Burnout*. Epilepsia de ausencia infantil: [https://www.orpha.net/consor/cgi-bin/OC\\_Exp.php?lng=ES&Expert=64280](https://www.orpha.net/consor/cgi-bin/OC_Exp.php?lng=ES&Expert=64280)
- Ors Quixal, R., & Castells Ramón, F. (2023). *Desarrollo de un modelo basado en inteligencia artificial para estimar la recuperación neurológica del estado de coma tras paro cardíaco*. Universitat Politècnica de València.
- Padilla Gallegos, L. S. (2018). *Características clínicas y epidemiológicas en pacientes diagnosticados de epilepsia, en el Servicio de Pediatría del Hospital Regional Honorio Delgado Espinoza*. [Tesis de grado, Universidad Nacional de San Agustín de Arequipa]. Repositorio UNSA. <http://repositorio.unsa.edu.pe/handle/UNSA/8161>
- Palomino, L. A. (2021). *Correlación entre los hallazgos de videoelectroencefalograma prolongado y resonancia magnética nuclear protocolo epilepsia en pacientes con epilepsia focal refractaria del hospital rebagliati*. [Tesis de grado, Universidad Peruana Cayetano Heredia]. Repositorio UPCH. <https://hdl.handle.net/20.500.12866/9738>
- Pawlaczyk, L., Pucicki, D., & Serafinczuk, J. (2021). Fast and efficient approach for multi-component quantum wells analysis based on FFT. *Measurement*, 186.
- Quinlan, J. (1993). *C4. 5: programs for machine learning*. Morgan Kaufmann.
- Ramos-Argüelles, F. M. (2009). *Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas*. Anales del Sistema Sanitario de Navarra.
- Ratnaprabha RavindraBorhade, M. S. (2020). *Modified Atom Search Optimization-based Deep Recurrent Neural Network for epileptic seizure prediction using electroencephalogram signals*. Biocybernetics and Biomedical Engineering.
- Rodríguez Rodríguez, C., Breña Oré, J., & Esenarro Vargas, D. (2021). *Las variables en la metodología de la investigación científica*. 3ciencias.
- Romero Barzola, Y., & Pujol Salud, J. (2023). El tratamiento y seguimiento de la epilepsia. *FMC - Formación Médica Continuada en Atención Primaria*, 139-143.
- Roser, B. (2015). *Diseños cuasi-experimentales y longitudinales*. Departamento de Metodología de las Ciencias del Comportamiento.
- Sean, L., Rongxing, L., Yunguo, G., & Songnian, Z. (2024). BloomDT - An improved privacy-preserving decision tree inference scheme. *Journal of Information and Intelligence*, 2.

- Sean, L., Rongxing, L., Yunguo, G., & Songnian, Z. (2024). BloomDT - An improved privacy-preserving decision tree inference scheme. *Journal of Information and Intelligence*, 130-147.
- Sebamai, P., Ranjeeta, B., P.K., D., & Mrutyunjaya, S. (2021). Deep long short term memory based minimum variance kernel random vector functional link network for epileptic EEG signal classification. *Engineering Applications of Artificial Intelligence*, 105.
- Sergio Alexander Villazana León, A. A. (2017). *Detección de cambios abruptos en señales epilépticas del EEG*. Arch Neurocién.
- Shih, J., Chia, J., Yi, C., Yean, R., Ying, S., Shou, Z., & Kuo, K. (2016). Comparison of FFT and marginal spectra of EEG using empirical mode decomposition to monitor anesthesia. *Computer Methods and Programs in Biomedicine*, 77-85.
- Shoeb, A. (2009). *Application of machine learning to epileptic seizure onset detection and treatment*. MIT Health Sciences and Technology Division.
- Sollee, J., Tang, L., & Bienfait Igiraneza, A. (2022). Artificial intelligence for medical image analysis in epilepsy. *Epilepsy Research*, 106861.
- Structure, B. I. (05 de 05 de 2022). *Electroencephalography*. Obtenido de <https://bids-specification.readthedocs.io/en/stable/04-modality-specific-files/03-electroencephalography.html>
- Suat Tas, D. T. (2025). *TBP-XFE: A transformer-based explainable framework for EEG music genre classification with hemispheric and directed lobish analysis*. Applied Acoustics.
- Sunao, U., Irwin, F., Jonathan, D., Yoshikata, A., & Tom, M. (1999). A Comparison of Period Amplitude Analysis and FFT Power Spectral Analysis of All-Night Human Sleep EEG. *Physiology & Behavior*, 121-131.
- Teuvo, K. (1989). *Self-organizing maps*. Springer.
- Thierer, D. J. (10 de 10 de 2021). *Que son sensibilidad y especificidad*. Sociedad Argentina de cardiología: <https://www.sac.org.ar/cuestion-de-metodo/que-son-sensibilidad-y-especificidad/>
- Torres-Gaona, G., Aledo-Serrano, Á., & García-Morales, I. (2023). Artificial intelligence system, based on mjn-SERAS algorithm, for the early detection of seizures in patients with refractory focal epilepsy: A cross-sectional pilot study. *Epilepsy & Behavior Reports*, 100600.
- Valderrama, S. (2002). *Pasos para elaborar proyectos de investigación científica*. Universidad de Ciencias y Humanidades.

- Weifeng Ma, Y. G. (2021). *A channel-mixing convolutional neural network for motor imagery EEG decoding and feature visualization*. Biomedical Signal Processing and Control.
- Weifeng, M., Yifei, G., Gongxue, Z., Yang, L., Lei, Z., & Boxian, H. (2021). A channel-mixing convolutional neural network for motor imagery EEG decoding and feature visualization. *Biomedical Signal Processing and Control*, 70.
- World Health Organization [WHO]. (12 de diciembre de 2019). *International statistical classification of diseases and related health problems*. Obtenido de ICD-10 Version:2019: <https://icd.who.int/browse10/2019/en#G40.5>
- Xiaorou Zheng, J. J. (2021). *Full parameter time complexity (FPTC): A method to evaluate the running time of machine learning classifiers for land use/land cover classification*. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, China.
- Xie, J., Zhong, C., Tian, Y., & Pan, T. (2025). *Robust density clustering based on density peak regions and K-nearest neighbors*. Pattern Recognition.

## IX. ANEXOS

### Anexo 1: Paciente en el momento de evaluación, y se identifica crisis de ausencia en un electroencefalograma



## Anexo 2: Matriz de consistencia

Problema Principal	Objetivo General	Hipótesis General	Variables	Indicadores
<p><b>Problema General</b> ¿Cómo el <b>modelo de aprendizaje</b> de señales electroencefalograma aplicando el filtro de Gabor a las frecuencias mejora en la <b>detección de convulsiones de crisis de ausencia</b> en pacientes infantes neuropediátricos?</p> <p><b>Problemas específicos.</b></p> <p>a. ¿Cómo incrementar el nivel de sensibilidad en la <b>detección de convulsiones de crisis de ausencia</b> en pacientes infantes neuropediátricos basado en un modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias?</p> <p>b. ¿Cómo incrementar el nivel de especificidad en la <b>detección de convulsiones de crisis de ausencia</b> en pacientes infantes neuropediátricos basado en un modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias?</p> <p>c. ¿Cómo incrementar el nivel de exactitud en la <b>detección de convulsiones de crisis de ausencia</b> en pacientes infantes neuropediátricos basado en un modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias?</p>	<p><b>Objetivo general</b> Desarrollar un <b>modelo de aprendizaje</b> de señales electroencefalograma para mejorar la <b>detección de convulsiones de crisis de ausencia</b> con el filtro de Gabor aplicado a las frecuencias para la detección de convulsiones de en pacientes infantes neuropediátricos.</p> <p><b>Objetivos específicos</b></p> <p>a. Incrementar el <i>nivel de sensibilidad</i> mediante un modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.</p> <p>b. Incrementar el <i>nivel de especificidad</i> mediante un modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias para mejorar la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.</p> <p>c. Incrementar el <i>nivel de exactitud</i> mediante un modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias para mejorar la detección de convulsiones de crisis de ausencia</p>	<p><b>Hipótesis general</b> El <b>modelo de aprendizaje</b> de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias mejora la <b>detección de convulsiones de crisis de ausencia</b> en pacientes infantes neuropediátricos.</p> <p><b>Hipótesis específica</b></p> <p>a. Mediante modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias incrementa el nivel de sensibilidad en la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.</p> <p>b. Mediante modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias incrementa el nivel de especificidad en la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.</p> <p>c. Mediante modelo de aprendizaje de señales electroencefalograma con el filtro de Gabor aplicado a las frecuencias incrementa el nivel de exactitud en la detección de convulsiones de crisis de ausencia en pacientes infantes neuropediátricos.</p>	<p><b>Variable Independiente</b> e: Modelo de aprendizaje.</p> <p><b>Variable Dependiente:</b> Detección de convulsiones de crisis de ausencia</p>	<p>a. Presencia Ausencia.</p> <p><b>Nivel de sensibilidad</b> <b>Sensibilidad</b> <math display="block">= \frac{VP}{VP + FN}</math></p> <p><b>Nivel de especificidad</b> <b>Especificidad</b> <math display="block">= \frac{VN}{VN + FP}</math></p> <p><b>Nivel de exactitud</b> <b>Exactitud</b> <math display="block">= \frac{VP + VN}{VP + FP + FN + VN}</math></p> <p>Donde: VP: Verdaderos Positivos FP: Falsos positivos FN: Falsos negativos VN: Verdaderos negativos</p>

	en pacientes infantiles neuropediátricos.			
--	--	--	--	--

.

**Anexo 3: Resultado de aplicar la Coherencia en Python, en un entorno Colab**

	<b>Fp1-F7</b>	<b>F7-T3</b>	<b>T3-T5</b>	<b>T5-O1</b>	<b>Fp1-F3</b>	<b>F3-C3</b>	<b>C3-P3</b>	<b>P3-O1</b>	<b>Fz-Cz</b>	<b>Cz-Pz</b>	<b>Fp2-F4</b>	<b>F4-C4</b>	<b>C4-P4</b>	<b>P4-O2</b>	<b>Fp2-F8</b>	<b>F8-T4</b>	<b>T4-T6</b>	<b>T6-O2</b>
<b>Fp1-F7</b>	0.00	0.52	0.52	0.51	0.56	0.51	0.51	0.51	0.53	0.51	0.54	0.51	0.52	0.52	0.54	0.52	0.53	0.51
<b>F7-T3</b>	0.52	0.00	0.55	0.53	0.54	0.53	0.52	0.52	0.51	0.54	0.53	0.54	0.51	0.51	0.50	0.52	0.51	0.50
<b>T3-T5</b>	0.52	0.55	0.00	0.55	0.51	0.53	0.54	0.52	0.55	0.53	0.51	0.54	0.54	0.53	0.51	0.51	0.52	0.55
<b>T5-O1</b>	0.51	0.53	0.55	0.00	0.51	0.52	0.55	0.59	0.53	0.54	0.52	0.54	0.53	0.58	0.51	0.53	0.56	0.56
<b>Fp1-F3</b>	0.56	0.54	0.51	0.51	0.00	0.55	0.51	0.51	0.51	0.51	0.51	0.53	0.56	0.52	0.55	0.51	0.51	0.52
<b>F3-C3</b>	0.51	0.53	0.53	0.52	0.55	0.00	0.55	0.54	0.54	0.54	0.55	0.51	0.53	0.53	0.51	0.51	0.52	0.52
<b>C3-P3</b>	0.51	0.52	0.54	0.55	0.51	0.55	0.00	0.55	0.56	0.57	0.51	0.52	0.53	0.56	0.51	0.50	0.51	0.53
<b>P3-O1</b>	0.51	0.52	0.52	0.59	0.51	0.54	0.55	0.00	0.54	0.53	0.49	0.54	0.52	0.56	0.53	0.54	0.54	0.56
<b>Fz-Cz</b>	0.53	0.51	0.55	0.53	0.51	0.54	0.56	0.54	0.00	0.56	0.54	0.53	0.54	0.52	0.51	0.52	0.53	0.52
<b>Cz-Pz</b>	0.51	0.54	0.53	0.54	0.51	0.54	0.57	0.53	0.56	0.00	0.50	0.52	0.56	0.55	0.51	0.52	0.53	0.53
<b>Fp2-F4</b>	0.54	0.53	0.51	0.52	0.51	0.55	0.51	0.49	0.54	0.50	0.00	0.53	0.53	0.53	0.57	0.54	0.55	0.51

	<b>Fp1-F7</b>	<b>F7-T3</b>	<b>T3-T5</b>	<b>T5-O1</b>	<b>Fp1-F3</b>	<b>F3-C3</b>	<b>C3-P3</b>	<b>P3-O1</b>	<b>Fz-Cz</b>	<b>Cz-Pz</b>	<b>Fp2-F4</b>	<b>F4-C4</b>	<b>C4-P4</b>	<b>P4-O2</b>	<b>Fp2-F8</b>	<b>F8-T4</b>	<b>T4-T6</b>	<b>T6-O2</b>
<b>F4-C4</b>	0.51	0.54	0.54	0.54	0.53	0.51	0.52	0.54	0.53	0.52	0.53	0.00	0.57	0.57	0.56	0.52	0.55	0.54
<b>C4-P4</b>	0.52	0.51	0.54	0.53	0.56	0.53	0.53	0.52	0.54	0.56	0.53	0.57	0.00	0.57	0.55	0.52	0.53	0.55
<b>P4-O2</b>	0.52	0.51	0.53	0.58	0.52	0.53	0.56	0.56	0.52	0.55	0.53	0.57	0.57	0.00	0.52	0.54	0.56	0.63
<b>Fp2-F8</b>	0.54	0.50	0.51	0.51	0.55	0.51	0.51	0.53	0.51	0.51	0.57	0.56	0.55	0.52	0.00	0.54	0.53	0.52
<b>F8-T4</b>	0.52	0.52	0.51	0.53	0.51	0.51	0.50	0.54	0.52	0.52	0.54	0.52	0.52	0.54	0.54	0.00	0.57	0.54
<b>T4-T6</b>	0.53	0.51	0.52	0.56	0.51	0.52	0.51	0.54	0.53	0.53	0.55	0.55	0.53	0.56	0.53	0.57	0.00	0.56
<b>T6-O2</b>	0.51	0.50	0.55	0.56	0.52	0.52	0.53	0.56	0.52	0.53	0.51	0.54	0.55	0.63	0.52	0.54	0.56	0.00

max values and channel coherence: 0.63 ==> P4-O2 with T6-O2

**Anexo 4: Resultado de aplicar la Desviación Estándar en Python, en un entorno Colab**

0 max std: 47.490435878684075 T6-O2

1 max std: 35.39617941909285 P4-O2

2 max std: 32.56928835542551 T5-O1

3 max std: 32.56464091826343 C3-P3

4 max std: 30.165781142731742 T4-T6

5 max std: 25.634181693419226 P3-O1

6 max std: 23.737252866391767 Fp1-F7

7 max std: 22.71593462307844 Fp1-F3

8 max std: 22.26865448811886 T3-T5

9 max std: 20.007808283567822 F4-C4

10 max std: 19.70055260918247 C4-P4

11 max std: 19.26291536313454 F8-T4

12 max std: 18.730712934831068 Fz-Cz

13 max std: 18.289393806016594 Cz-Pz

14 max std: 18.05850779218249 Fp2-F8

15 max std: 14.753804528558161 Fp2-F4

16 max std: 13.71976944053866 F7-T3

17 max std: 12.611291150802483 F3-C3

min std in crisis moment: 12.611291150802483

**Anexo 5: Resultado de aplicar R2 en Python, en un entorno Colab**

max similarity of frecuency crisis moment: 0.77

	<b>Fp1-F7</b>	<b>F7-T3</b>	<b>T3-T5</b>	<b>T5-O1</b>	<b>Fp1-F3</b>	<b>F3-C3</b>	<b>C3-P3</b>	<b>P3-O1</b>	<b>Fz-Cz</b>	<b>Cz-Pz</b>	<b>Fp2-F4</b>	<b>F4-C4</b>	<b>C4-P4</b>	<b>P4-O2</b>	<b>Fp2-F8</b>	<b>F8-T4</b>	<b>T4-T6</b>	<b>T6-O2</b>
<b>Fp1-F7</b>	0.00	0.00	0.00	0.00	0.76	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.13	0.00	0.00	0.00
<b>F7-T3</b>	0.00	0.00	0.03	0.00	0.33	0.18	0.00	0.00	0.03	0.00	0.20	0.00	0.08	0.00	0.43	0.23	0.00	0.00
<b>T3-T5</b>	0.00	0.03	0.00	0.00	0.17	0.55	0.43	0.00	0.35	0.49	0.18	0.30	0.36	0.00	0.11	0.13	0.28	0.00
<b>T5-O1</b>	0.00	0.00	0.00	0.00	0.18	0.31	0.49	0.66	0.20	0.24	0.20	0.21	0.45	0.02	0.01	0.29	0.30	0.00
<b>Fp1-F3</b>	0.76	0.33	0.17	0.18	0.00	0.20	0.00	0.00	0.20	0.00	0.31	0.04	0.00	0.00	0.28	0.00	0.00	0.00
<b>F3-C3</b>	0.00	0.18	0.55	0.31	0.20	0.00	0.00	0.00	0.58	0.43	0.37	0.23	0.25	0.00	0.00	0.04	0.34	0.00
<b>C3-P3</b>	0.00	0.00	0.43	0.49	0.00	0.00	0.00	0.00	0.25	0.70	0.18	0.31	0.57	0.77	0.07	0.09	0.20	0.58
<b>P3-O1</b>	0.00	0.00	0.00	0.66	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.11	0.00	0.00	0.26	0.06	0.00
<b>Fz-Cz</b>	0.00	0.03	0.35	0.20	0.20	0.58	0.25	0.00	0.00	0.00	0.40	0.50	0.00	0.00	0.25	0.14	0.30	0.00

	<b>Fp1-F7</b>	<b>F7-T3</b>	<b>T3-T5</b>	<b>T5-O1</b>	<b>Fp1-F3</b>	<b>F3-C3</b>	<b>C3-P3</b>	<b>P3-O1</b>	<b>Fz-Cz</b>	<b>Cz-Pz</b>	<b>Fp2-F4</b>	<b>F4-C4</b>	<b>C4-P4</b>	<b>P4-O2</b>	<b>Fp2-F8</b>	<b>F8-T4</b>	<b>T4-T6</b>	<b>T6-O2</b>
<b>Cz-Pz</b>	0.00	0.00	0.49	0.24	0.00	0.43	0.70	0.00	0.00	0.00	0.13	0.39	0.68	0.25	0.00	0.00	0.20	0.00
<b>Fp2-F4</b>	0.00	0.20	0.18	0.20	0.31	0.37	0.18	0.00	0.40	0.13	0.00	0.07	0.00	0.00	0.22	0.06	0.18	0.00
<b>F4-C4</b>	0.00	0.00	0.30	0.21	0.04	0.23	0.31	0.06	0.50	0.39	0.07	0.00	0.32	0.00	0.39	0.31	0.46	0.00
<b>C4-P4</b>	0.00	0.08	0.36	0.45	0.00	0.25	0.57	0.11	0.00	0.68	0.00	0.32	0.00	0.00	0.00	0.28	0.39	0.00
<b>P4-O2</b>	0.00	0.00	0.00	0.02	0.00	0.00	0.77	0.00	0.00	0.25	0.00	0.00	0.00	0.00	0.04	0.00	0.09	0.67
<b>Fp2-F8</b>	0.13	0.43	0.11	0.01	0.28	0.00	0.07	0.00	0.25	0.00	0.22	0.39	0.00	0.04	0.00	0.05	0.05	0.00
<b>F8-T4</b>	0.00	0.23	0.13	0.29	0.00	0.04	0.09	0.26	0.14	0.00	0.06	0.31	0.28	0.00	0.05	0.00	0.19	0.00
<b>T4-T6</b>	0.00	0.00	0.28	0.30	0.00	0.34	0.20	0.06	0.30	0.20	0.18	0.46	0.39	0.09	0.05	0.19	0.00	0.00
<b>T6-O2</b>	0.00	0.00	0.00	0.00	0.00	0.00	0.58	0.00	0.00	0.00	0.00	0.00	0.00	0.67	0.00	0.00	0.00	0.00

Value to  $R^2$  where exist similary beetwen frecuency in moment to crisis

0 Value to  $R^2$ : 0.77 of C3-P3 with P4-O2

- 1 Value to  $R^2$ : 0.77 of C3-P3 with P4-O2
  - 2 Value to  $R^2$ : 0.76 of Fp1-F7 with Fp1-F3
  - 3 Value to  $R^2$ : 0.76 of Fp1-F7 with Fp1-F3
  - 4 Value to  $R^2$ : 0.7 of C3-P3 with Cz-Pz
  - 5 Value to  $R^2$ : 0.7 of C3-P3 with Cz-Pz
  - 6 Value to  $R^2$ : 0.68 of Cz-Pz with C4-P4
  - 7 Value to  $R^2$ : 0.68 of Cz-Pz with C4-P4
  - 8 Value to  $R^2$ : 0.67 of P4-O2 with T6-O2
  - 9 Value to  $R^2$ : 0.67 of P4-O2 with T6-O2
  - 10 Value to  $R^2$ : 0.66 of T5-O1 with P3-O1
  - 11 Value to  $R^2$ : 0.66 of T5-O1 with P3-O1
  - 12 Value to  $R^2$ : 0.58 of F3-C3 with Fz-Cz
  - 13 Value to  $R^2$ : 0.58 of F3-C3 with Fz-Cz
  - 14 Value to  $R^2$ : 0.58 of F3-C3 with Fz-Cz
  - 15 Value to  $R^2$ : 0.58 of F3-C3 with Fz-Cz
  - 16 Value to  $R^2$ : 0.57 of C3-P3 with C4-P4
  - 17 Value to  $R^2$ : 0.57 of C3-P3 with C4-P4
- Min  $R^2$  in crisis moments : 0.57

**Anexo 6: Resultado de aplicar el conteo de picos en el momento de crisis en Python, en un entorno Colab**

cantidad de picos en crisis: 5

cantidad de picos en crisis: 14

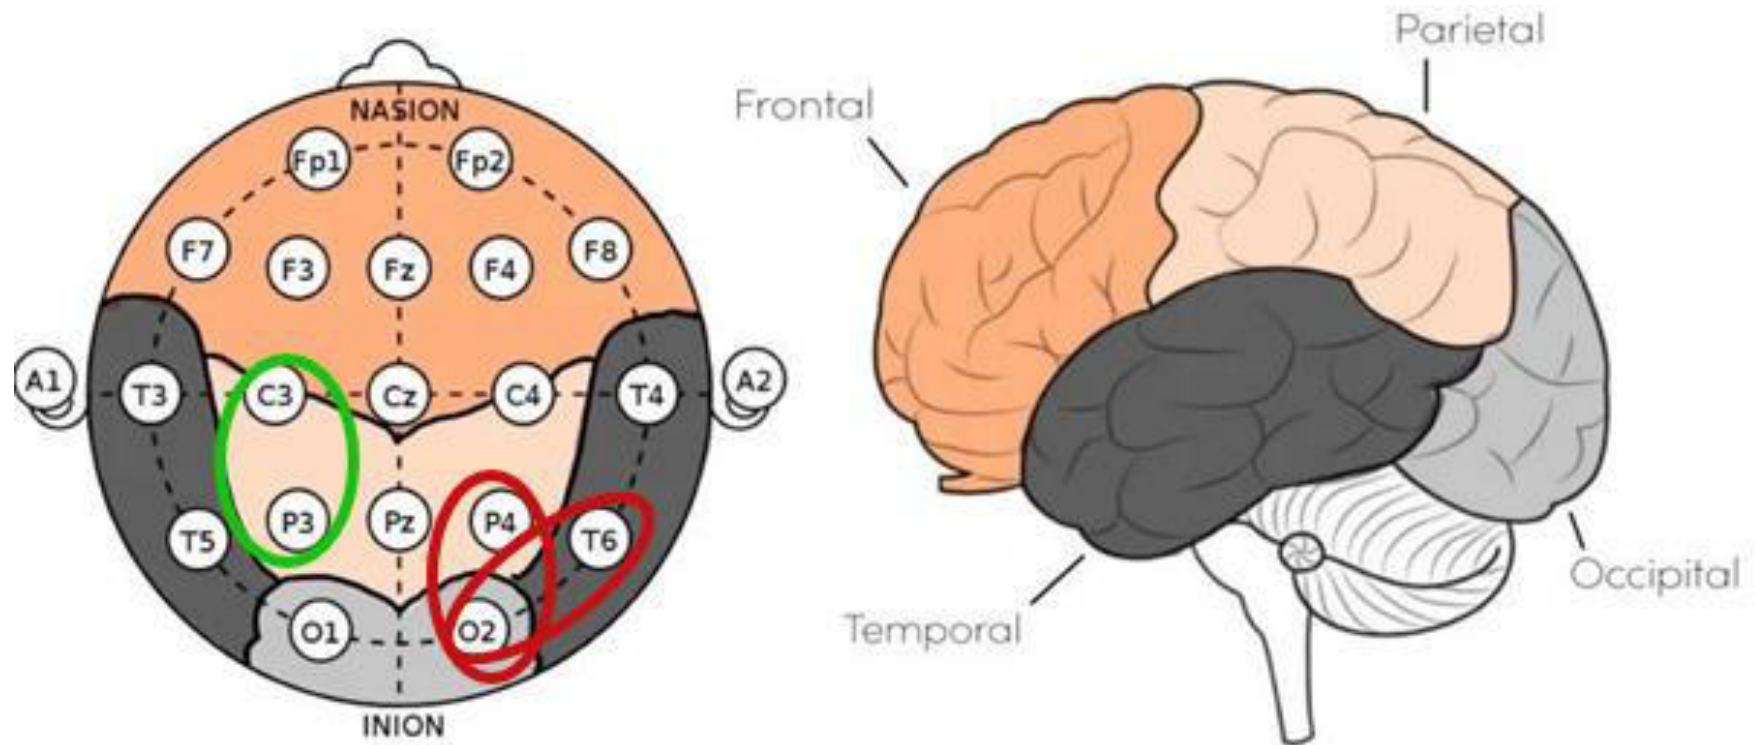
cantidad de picos en crisis: 4

cantidad de picos en crisis: 5

### Anexo 7: Afectación específica del paciente en el momento de crisis de ausencia.

#### Generación de nuevo conocimiento:

- Primer aporte  $\rightarrow$  Coherencia  $\rightarrow 0.63 \rightarrow$  'T6-O2' depende de 'P4-O2'
- Segundo aporte  $\rightarrow R^2 \rightarrow$  similaridad del canal  $\rightarrow 0.77 \rightarrow$  'C3-P3' con 'P4-O2'
- Tercer aporte  $\rightarrow$  Desviación estándar  $\rightarrow 47.49 \rightarrow$  'T6-O2'
- Cuarto aporte  $\rightarrow$  Con el modelo se obtuvo detalle particular del paciente,



Fuente: Modificado de (company, 2025)