



**UNIVERSIDAD DEL AZUAY**  
**FACULTAD DE CIENCIA Y TECNOLOGÍA**  
**ESCUELA DE INGENIERÍA ELECTRÓNICA**

**“Desarrollo de un software para la detección de crisis convulsivas mediante la señal de un sensor de fotopletismografía”**

**Trabajo de graduación previo a la obtención del título de:**

**INGENIERO ELECTRÓNICO**

**Autores:**

**EDISON FERNANDO BONILLA PALAGUACHI**

**XAVIER MAURICIO FALCONI UYAGUARI**

**Director:**

**Ing. ESTEBAN JAVIER MORA TOLA**

**CUENCA, ECUADOR**

**2023**

# DESARROLLO DE UN SOFTWARE PARA LA DETECCIÓN DE CRISIS CONVULSIVAS MEDIANTE LA SEÑAL DE UN SENSOR DE FOTOPLETISMOGRAFÍA

## RESUMEN

En este trabajo se presenta el desarrollo de un software para la detección de crisis convulsivas mediante fotopletismografía, empleando el brazalete Empatica E4 para la obtención de las señales. Éstas se analizan como series temporales utilizando un método de entrenamiento de características de audio y uno de entrenamiento de parámetros HRV para comparar sus resultados. Se inicia con el procesamiento de las señales antes de extraer sus características relevantes e ingresarlas a entrenamiento con redes neuronales. La validación del software se realiza ingresando 4 segmentos de señal que contienen eventos epilépticos y 4 que no los contienen. Finalmente, los resultados indican que la detección de un evento epiléptico se efectúa con una precisión de 87.5% cuando se utiliza el modelo de entrenamiento de características de audio, mientras que utilizando el método de entrenamiento de parámetros HRV se alcanza una precisión de 37.5%.

**Palabras Clave:** Epilepsia, convulsión, detección, dispositivo vestible, brazalete inteligente, fotopletismografía.

---

Ing. Esteban Javier Mora Tola

**Director de Tesis**



---

Edison Fernando Bonilla Palaguachi

**Autor**



---

Xavier Mauricio Falconi Uyaguari

**Autor**

# DEVELOPMENT OF SOFTWARE FOR THE DETECTION OF CONVULSIVE SEIZURES USING PHOTOPLETHYSMOGRAPHY SENSOR SIGNAL

## ABSTRACT

In this work, we present a software development for the detection of convulsive seizures based on photoplethysmography using the Empatica E4 wristband for signal acquisition. These signals are analyzed as time series using an audio feature training method and an HRV parameter training method for result comparison. It begins with the signals processing before extracting their relevant features to introduce them into the neural network training system. Software validation is carried out by entering 4 signal segments containing epileptic events and 4 segments without epileptic events. Finally, the results indicate that the detection of an epileptic event is achieved with 87.5% accuracy when using the audio feature training model, whereas using the HRV parameter training method results in a 37.5% accuracy.

**Keywords:** Epilepsy, seizure, detection, wearable device, smart bracelet, photoplethysmography.

---

Ing. Esteban Javier Mora Tola

**Thesis Director**

**Translated by**



---

Edison Fernando Bonilla Palaguachi

**Author**

**Translated by**



---

Xavier Mauricio Falconi Uyaguari

**Author**

# “Desarrollo de un software para la detección de crisis convulsivas mediante la señal de un sensor de fotopletismografía”

Edison Fernando Bonilla Palaguachi  
Escuela de Ingeniería Electrónica  
Universidad del Azuay,  
Cuenca, Ecuador  
[edisonbonilla@es.uazuay.edu.ec](mailto:edisonbonilla@es.uazuay.edu.ec)

Xavier Mauricio Falconi Uyaguari  
Escuela de Ingeniería Electrónica  
Universidad del Azuay  
Cuenca, Ecuador  
[7alco98@es.uazuay.edu.ec](mailto:7alco98@es.uazuay.edu.ec)

**Resumen**—En este trabajo se presenta el desarrollo de un software para la detección de crisis convulsivas mediante fotopletismografía, empleando el brazalete Empatica E4 para la obtención de las señales. Éstas se analizan como series temporales utilizando un método de entrenamiento de características de audio y uno de entrenamiento de parámetros HRV para comparar sus resultados. El proceso comienza con la realización del preprocesamiento de las señales antes de extraer sus características relevantes e ingresarlas a entrenamiento con redes neuronales. La validación del software se realiza ingresando 4 segmentos de señal que contienen eventos epilépticos y 4 que no los contienen. Finalmente, los resultados indican que la detección de un evento epiléptico se efectúa con una precisión de 87.5% cuando se utiliza el modelo de entrenamiento de características de audio, mientras que utilizando el método de entrenamiento de parámetros HRV se alcanza una precisión de 37.5%.

**Palabras clave**— *Epilepsia, convulsión, detección, dispositivo vestible, brazalete inteligente, Fotopletismografía.*

## I. INTRODUCCIÓN

La epilepsia es una enfermedad cerebral que afecta a personas de todas las edades y que está presente desde la niñez. Al tratarse de uno de los trastornos neurológicos más comunes, se estima que afecta al 1% de la población mundial y si se tiene en cuenta que los medicamentos antiepilépticos brindan solo un tratamiento adecuado para alrededor del 70% de pacientes con esta patología, se puede considerar este trastorno como un tema importante que requiere mayor atención [1-5].

Fuera del hospital, es necesaria una evaluación del tratamiento y un seguimiento de la enfermedad, que se basa en el autoinforme de los pacientes y familiares. Éste generalmente no es confiable debido a la falta de información, convulsiones que se pasan por alto y dificultades de los pacientes para recordarlas [6].

En la actualidad, la electroencefalografía (EEG) sigue siendo el estándar de referencia para la detección de convulsiones y ataques epilépticos. Se aplica exclusivamente en un entorno hospitalario, debido a que se requieren equipos

especializados para la adquisición de este tipo de señales y su análisis necesita la presencia de un profesional capacitado, lo que también consume mucho tiempo. Por estas razones un examen EEG no llega a ser una opción de un sistema portátil de detección de convulsiones en el hogar. [7-11].

Con el avance de la tecnología se han encontrado posibilidades de detectar diferentes anomalías en enfermedades relacionadas con trastornos cerebrales, a través del análisis de diversas señales biomédicas, las mismas que pueden ser obtenidas y analizadas mediante dispositivos portátiles que permiten el monitoreo remoto de varias enfermedades. Estos dispositivos se implementan con mayor frecuencia en el entorno doméstico para ayudar a las personas con epilepsia en su vida diaria. Entre los dispositivos existentes se incluyen los que se colocan en la muñeca, en el brazo, en el pecho, entre otros, ya que no son estigmatizantes y son bien tolerados por los pacientes durante un uso prolongado [12-18].

Una de las señales biomédicas que adquieren los dispositivos mencionados anteriormente, es la de fotopletismografía (PPG por sus siglas en inglés), que se trata de una técnica que utiliza ondas de luz reflejadas para detectar cambios volumétricos en la sangre arterial. La cantidad de luz reflejada desde el lecho vascular es inversamente proporcional a la absorbida por la sangre en el tejido. Por lo tanto, a medida que aumenta el volumen de sangre en el tejido, se absorbe más luz y se refleja menos. Esta caída en la intensidad de la luz reflejada se traduce en una caída en la amplitud de la señal. A medida que los cambios en las señales de PPG reflejan variaciones en los índices cardiovasculares, como la frecuencia cardíaca (FC) y tono vascular, podrían significar alteraciones relacionadas con las convulsiones, lo que ayudaría a detectar crisis epilépticas [19][20].

En [21] se presentó el monitoreo de epilepsia basado en internet de las cosas (IOT por sus siglas en inglés). En este estudio el microcontrolador recopila la información de dos acelerómetros, un sensor de temperatura y un sensor detector de sonido para luego enviar estos datos de forma remota a la pantalla de un especialista a través de un modem de radiofrecuencia (RF). Se miden diferentes parámetros como identificación de caídas, sacudida de manos, temperatura corporal y detección de sonidos internos del pecho del paciente. Para ello, los sensores se colocan en el cuerpo del

paciente y las señales se envían a la computadora que las registra para su posterior seguimiento.

En [22] se presenta un estudio en el que se utiliza otro dispositivo portátil para evaluar la epilepsia. El sistema consiste en el uso de un telémetro y un teléfono. El telémetro recibe la señal de un electrocardiograma (ECG) a través de un circuito de entrada analógica que amplifica la señal y reduce el ruido. El telémetro también permite medir los intervalos RR, que es el tiempo transcurrido entre dos ondas R del complejo QRS en un ECG. El teléfono efectúa, en tiempo real, el análisis de la variabilidad de FC (HRV por sus siglas en inglés), que es la variación en tiempo entre cada latido del corazón a partir de los intervalos RR.

La información mostrada en [23], enfocada en el uso de ECG, se refiere a la “Detección de ataques epilépticos a partir de señales fisiológicas”. En esta investigación, se evaluaron diferentes sistemas de reconocimiento de ataques epilépticos a través de señales de ECG, utilizando características de HRV y características morfológicas, implementadas en un dispositivo que registra una señal ECG en tiempo real. En este caso, los resultados de los clasificadores fueron satisfactorios.

Por otro lado, en [24] se presenta un trabajo en el que se utilizaron sensores para medir la actividad electrodérmica (conductancia de la piel), movimiento y electromiografía (EMG). El aporte consiste en el diseño e implementación de un sistema para la detección y alerta de crisis epilépticas a partir de mediciones de señales fisiológicas y de movimiento. Para este proyecto se implementó un prototipo funcional, que consistió en una manilla localizada en el antebrazo. Dado que existen diferentes tipos de crisis, el proyecto se enfocó en las crisis generalizadas tónico-clónicas y/o mioclónicas.

En [25] se investigaron 62 convulsiones focales de 28 pacientes con evidencia de taquicardia ictal (TI) analizada por ECG. Las convulsiones se dividieron en tres subgrupos: aquellas sin movimientos epilépticos, las que implicaban movimientos epilépticos que no afectaban las extremidades y aquellas con movimientos epilépticos que afectaban las extremidades. Se calculó la FC mediante PPG, derivada de un dispositivo de muñeca. La TI se identificó en el 60% de convulsiones (9/19, 7/8 y 21/35 en los tres grupos, respectivamente). En resumen, se observó que la identificación de TI, por medio de un sensor PPG portátil, es posible no solo para las crisis no motoras sino también para las crisis motoras.

El trabajo realizado en [26] buscó evaluar la variabilidad de las señales de PPG y su valor en la detección de cambios peri-ictales en pacientes con convulsiones focales con alteración de la conciencia (FIAS). Los datos de PPG se registraron utilizando un sensor portátil colocado en la muñeca o el tobillo de niños con epilepsia. Se analizaron los datos de PPG en cuatro períodos diferentes: libre de convulsiones, preictal, ictal y postictal. Se extrajeron automáticamente múltiples características de la señal PPG como la frecuencia, duración, amplitud, pendientes crecientes y decrecientes, suavidad y área bajo la curva (AUC por sus siglas en inglés). Se usó esta información para identificar cambios preictales, ictales o postictales comparándolos con ataques, períodos libres y entre sí, mediante el uso de un modelo lineal de efectos mixtos. Se encontraron cambios significativos en la PPG durante el período ictal en todas las características; durante el período preictal en amplitud,

duración, pendiente creciente y AUC; y durante el período postictal en pendiente decreciente.

En [27] evaluaron las alteraciones en las señales de PPG en relación con la aparición de convulsiones tónico-clónicas generalizadas (GTCS por sus siglas en inglés) en pacientes con epilepsia para evaluar la viabilidad de la detección de convulsiones. Los pacientes llevaban sensores de pulseras portátiles en sus muñecas o tobillos que registraban señales PPG. Se analizaron las señales de PPG durante tres períodos de tiempo: línea de base, período anterior a la convulsión y período posterior a la convulsión; además se seleccionaron cinco segmentos de control aleatorios durante períodos libres de convulsiones. Las características de PPG, incluida la frecuencia, la amplitud, la duración, la pendiente, la suavidad y el AUC, se calcularon automáticamente. Se usó un modelo lineal de efectos mixtos para evaluar los cambios en las características del PPG entre diferentes períodos de tiempo en un intento de identificar los cambios de señal que detectan las convulsiones.

Los estudios realizados en [26] y [27] son muy similares, se le da todo el protagonismo a la señal de PPG y se evalúan cambios en sus características utilizando el mismo método de análisis, a pesar de que en [26] se enfoca en pacientes con FIAS, mientras que en [27] en la aparición de GTCS, se concluyó para ambos estudios que el monitoreo de las señales de PPG puede ayudar en la detección de convulsiones en pacientes con epilepsia.

En [28], por otro lado, se hace uso de diferentes señales biomédicas como EEG, las corrientes eléctricas generadas en los músculos por EMG y PPG. En este estudio se utilizaron redes neuronales (ANN) para la detección automática de ataques epilépticos antes de su aparición. Se concluyó que, para el monitoreo en tiempo real, el número de neuronas debe correlacionarse con el tiempo de respuesta y el consumo de energía utilizados en los dispositivos portátiles.

En el trabajo realizado en [29], se comparó el rendimiento de dos dispositivos portátiles basados en ECG y PPG, con el ECG hospitalario utilizando un algoritmo de detección de convulsiones existente, este algoritmo clasifica las convulsiones en función de las características del aumento de la frecuencia cardíaca. Mientras que el rendimiento de la detección de convulsiones con el dispositivo PPG de muñeca fue considerablemente más bajo, se demostró que el rendimiento con el ECG portátil es similar al del ECG del hospital.

En [30], se hace uso de la pulsera Empatica E4 y también de un modelo de aprendizaje automático para la detección de condiciones ictales y preictales. Se utilizan todos los sensores del brazalete y se extraen las características de las señales tomando segmentos de la información durante las condiciones convulsivas, previas a las convulsiones e interictales (sin convulsiones). Estas funciones se utilizaron en la máquina de vectores de soporte (SVM-RBF por sus siglas en inglés), el árbol de decisiones (DTC por sus siglas en inglés) y el entrenamiento supervisado basado en regresión logística (LRC por sus siglas en inglés) para condiciones ictales frente a no ictales y preictales frente a interictales. Se concluye que la mayor precisión se obtiene con DTC tanto para el clasificador de detección de convulsiones como para el clasificador de detección de inicio de convulsiones previo.

La particularidad de este estudio, en comparación a los anteriormente presentados, radica en que las características

extraídas se obtienen al considerar a la señal de PPG como una señal de audio y también al conseguir los parámetros de FC a partir de la señal original. En este trabajo se presenta la adquisición de la señal PPG de un sujeto patológico y su respectivo procesamiento, con la intención de encontrar un patrón que pueda detectar un ataque epiléptico, mediante el uso de la pulsera Empatica E4. En la siguiente sección se detalla la metodología usada para el procesamiento de la señal PPG y los algoritmos de reconocimiento de patrones. En la sección III se indican los resultados obtenidos con los distintos algoritmos usados. En la sección IV se detallan las conclusiones obtenidas en esta investigación. Finalmente, en la sección V se mencionan los trabajos futuros que se esperan alcanzar a partir de este estudio.

## II. METODOLOGÍA

Los dispositivos vestibles (*wearable devices*) son elementos electrónicos que se pueden usar en el cuerpo, generalmente como accesorios o prendas. Estos dispositivos están equipados con varios sensores, tecnologías y funcionalidades que permiten recopilar datos o realizar tareas específicas.

En la Fig. 1 se observa el hardware utilizado para este estudio, que consiste en una pulsera inteligente de la marca EMPATICA modelo E4. La pulsera está enfocada en monitorear la salud humana a través de sensores portátiles y es capaz de realizar la adquisición de datos de una persona en tiempo real, lo que ha permitido la realización de varios estudios científicos enfocados en el monitoreo de señales fisiológicas.



Fig. 1. Sensores del Empática E4 [37].

La pulsera está equipada con sensores que permiten recopilar datos de alta calidad, como se aprecia en la Fig. 1. Combina sensores de actividad electrodérmica (EDA) y PPG para medir simultáneamente la actividad del sistema nervioso y la frecuencia cardíaca. También dispone de un acelerómetro

de 3 ejes que permite obtener la actividad relacionada con el movimiento y una termopila infrarroja que lee la temperatura periférica de la piel.

Para objeto de este estudio se utilizó únicamente el sensor PPG. Éste mide el pulso del volumen sanguíneo (BVP por sus siglas en inglés), del cual se puede derivar la HRV. Estos sensores constan de dos componentes principales: diodos emisores de luz (LED) y fotodetectores (FD). Los FD se encargan de detectar cambios volumétricos en la sangre, causados por la presión cardíaca, al absorber la iluminación de los LED a través de la piel. La señal del PPG se puede adquirir en modo de reflexión o transmisión.

En el modo de transmisión, se detecta la luz que atraviesa el cuerpo, mientras que en el modo de reflexión se detecta la luz reflejada como se observa en la Fig. 2. La ubicación de los FD en el modo de transmisión está limitada por la delgadez del sujeto. Por otro lado, en el modo de reflexión, los LED y los FD están integrados en un mismo plano [31].




Fig. 2. Modos de adquisición de la señal PPG [38]. (A) Transmisión (B) Reflexión.

Una gran ventaja que tiene esta pulsera, es que permite un modo de grabación para un posterior análisis de las señales además de un modo de transmisión de datos vía Bluetooth para un análisis de la información en tiempo real como se muestra en la Fig. 3(a). El modo de grabación de la pulsera permite capturar una serie de acontecimientos durante un período de más de 48 horas, posteriormente se la debe conectar a un ordenador a través de un cable de datos con puerto Mini-USB. En el ordenador, la aplicación E4 development permite subir los datos a una nube, para así desocupar la memoria interna. Se pueden visualizar los datos en tiempo real en dispositivos móviles utilizando el modo de transmisión Bluetooth como se muestra en la Fig. 3(b), además los datos se cargan de forma automática a la nube para su posterior apreciación.




Fig. 3. (a) Modo de grabación de la pulsera (b) Modo de transmisión Bluetooth de la pulsera [36].

Para acceder a los datos en la nube se ingresa a la página de Empatica E4 connect, donde se pueden almacenar todas las señales obtenidas por los diferentes sensores de la pulsera, ya sea por el modo de grabación como por el modo de transmisión Bluetooth. Desde esta página se pueden visualizar todas las gráficas tiempo-amplitud de estas señales con una escala de microsegundos como se observa en la Fig. 4.




Fig. 4. Visualización de señal PPG en la página de Empatica.

En la Fig. 5 se observa que también se pueden descargar las muestras en un archivo .csv en caso de requerirlo. En éstas se especifica en tiempo unix el momento en el que se comenzó a obtener las señales en la pulsera y el tiempo en el que se dejó de grabar las señales.

Nombre	Tipo
ACC	Archivo de valores...
BVP	Archivo de valores...
EDA	Archivo de valores...
HR	Archivo de valores...
IBI	Archivo de valores...
info	Documento de te...
tags	Archivo de valores...
TEMP	Archivo de valores...

Fig. 5. Señales descargadas en formato csv desde la página de Empatica.

El tiempo Unix es una medida de tiempo que se cuenta en segundos a partir de una fecha específica. En los sistemas operativos que lo utilizan, esa fecha corresponde al 1 de enero de 1970 a las cero horas.

#### A. Toma de datos

A fin de verificar el correcto funcionamiento de la pulsera y garantizar la veracidad de la información recopilada por la misma, se realizaron múltiples pruebas previa a la toma de datos; ensayos de funcionamiento en la pulsera para determinar la duración de la batería, el correcto desempeño del sensor PPG tanto en reposo como en actividad y la correcta grabación de las señales.

Para las pruebas se utilizó a la pulsera en el modo de transmisión Bluetooth para comprobar el funcionamiento del sensor PPG ya que se podía apreciar en tiempo real la variación de las señales en la interfaz de un dispositivo móvil. Se realizaron también pruebas en el modo de grabación usando la pulsera por días completos, durante actividades de la vida diaria, al hacer ejercicio y al descansar; esto para determinar la durabilidad de la batería y que los datos se graben correctamente.

La dificultad para obtener los permisos para la recolección de muestras medicas en centros hospitalarios dificultó la posibilidad de disponer de un número alto de sujetos de prueba. Por esta razón, se trabajó únicamente con una paciente de género femenino de 5 años como sujeto de prueba, y se obtuvo el consentimiento informado de su representante para llevar a cabo el estudio. Una vez obtenida la autorización, se creó un manual de usuario detallando la forma de colocar, utilizar y cuidar la pulsera. El manual también incluye instrucciones sobre cómo cargar la batería y cómo marcar el inicio y el final de eventos relevantes en el brazalete.

De esta manera se colocó la pulsera en el sujeto de prueba, la cual fue utilizada por aproximadamente un mes. Durante este periodo se obtuvieron 21 muestras, las cuales fueron eventos marcados por el representante de la paciente, aunque solo se observaron variaciones importantes en la señal BVP en algunas de ellas debido a que habían eventos marcados erróneamente. Se consideró la variación significativa en el parámetro de amplitud de todas las señales entregadas por el brazalete y se determinó que solo 16 muestras eran válidas para el entrenamiento y validación del algoritmo.

Después de recolectar las muestras del sujeto de prueba, se llevó a cabo el proceso completo para desarrollar el algoritmo de detección de epilepsia, el cual se muestra en el diagrama de flujo a continuación



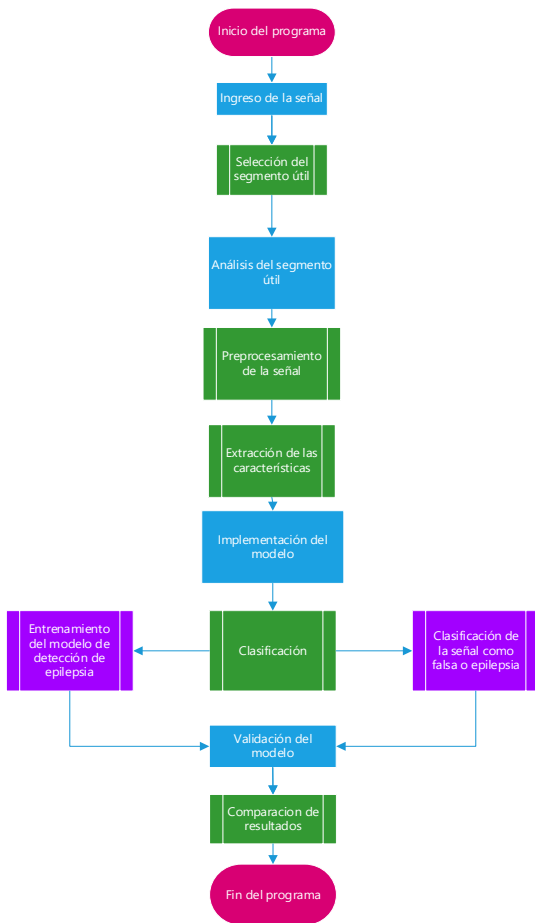
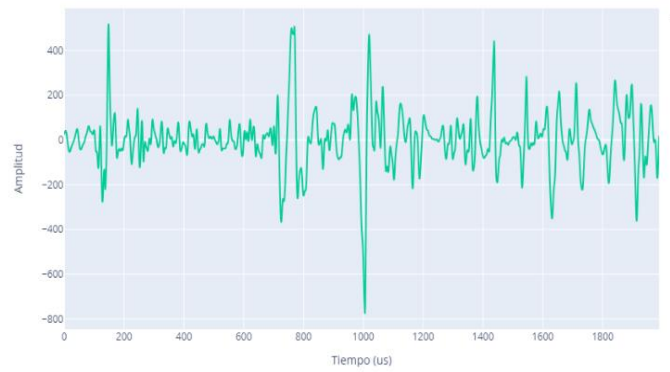


Fig. 6. Diagrama del proceso de creación del programa.


### B. Ingreso de las señales BVP

Las muestras obtenidas duran entre 8 y 36 horas. La señal es muy grande y contiene una gran cantidad de datos, lo que prolonga el tiempo de procesamiento y entrenamiento. Además, muchos de estos datos no son útiles ya que contiene información de actividades de la vida diaria y periodos largos sin un evento epiléptico. Por esta razón, se consideró que esas porciones de cada señal no son relevantes para el análisis y fue necesario seleccionar únicamente el periodo de la señal en el que se producía el evento de epilepsia. De las 16 señales obtenidas con un evento positivo, 12 se utilizaron para el entrenamiento mientras que los 4 restantes para la validación del modelo.

Para seguir el procedimiento planteado se comenzó seleccionando el segmento útil (señal con evento epiléptico) de las señales para su posterior análisis, como se observa en la Fig. 7(a). Cada vez que se marca algún evento en la pulsera, se indica con una línea roja vertical el momento en el que inicia éste, como se aprecia en la Fig. 7(b).




(a)




(b)

Fig. 7. (a) Segmento seleccionado manualmente (b) Señal de BVP con el evento marcado en la pulsera

Para la selección de los segmentos que contienen epilepsia fue necesaria la apreciación de cada una de las 12 señales que se apartaron para entrenamiento, se determinó visualmente la duración de la crisis convulsiva, a partir de la línea marcada hasta que la amplitud de la señal se normaliza, como se observa en la Fig. 8 obteniendo 12 segmentos de diferente duración y tamaño, esto porque las señales que presentan convulsión, debido a la propia patología, no tienen la misma duración en cada evento.



(a)

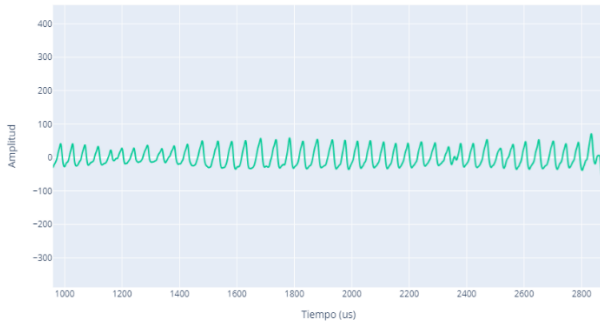


(b)


Fig. 8. Segmentos que contienen epilepsia con diferente duración.



Fue necesario seleccionar información que no contenga un evento epiléptico para que el clasificador también aprenda cómo es la señal en este caso. Se utilizaron segmentos con duración de 30 segundos de las 12 señales de entrenamiento, ya sean estos tramos antes o después de ocurrida la crisis convulsiva como se observa en la Fig. 9, obteniendo 12 segmentos con igual duración.



(a)



(b)

Fig. 9. Segmentos que no contienen evento epiléptico con la misma duración.

### C. Preprocesamiento de los segmentos seleccionados

La pulsera E4 entrega señales biomédicas de alta calidad, sin embargo, se realizó un preprocesamiento a todas las señales ingresadas para obtener mejores resultados. Para esto, se hizo uso de la librería `scipy.signal` que permite realizar diferentes tipos de preprocesamientos a las señales, en este caso se realizó un filtro pasa bajo a 40 Hz, con lo cual se elimina ruido innecesario para el procesamiento de la señal como se observa en la Fig. 10. Un filtrado adicional permite apaciguar el ruido miocinético que contiene el PPG, así se identifica con mayor precisión los picos y valles que ofrece la señal [40].

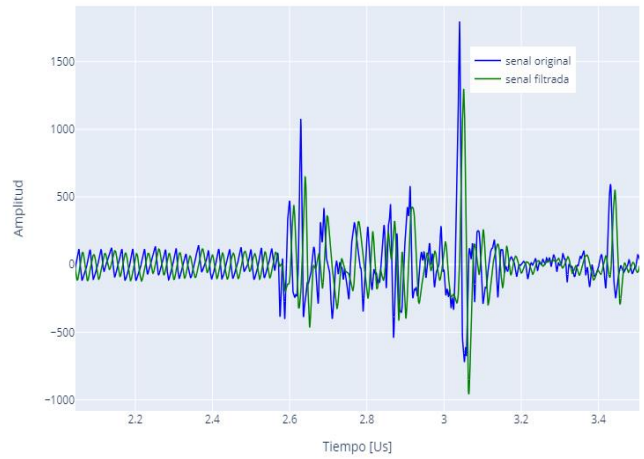


Fig. 10. Segmento BVP filtrado

### D. Extracción de las características de los segmentos filtrados.

Una vez obtenidos los segmentos filtrados, se procedió a obtener las características o parámetros de estos para ingresarlas al entrenamiento. Para ello se desarrollaron dos métodos, como se puede apreciar en el diagrama de la Fig. 11

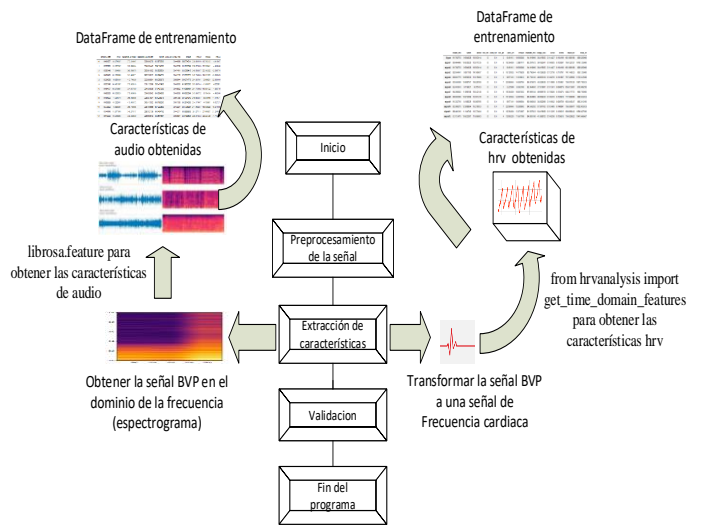


Fig. 11. Diagrama de los métodos para la obtención de las características de la señal.

#### a) Método de obtención de características de audio

El primer método busca analizar el segmento como serie de tiempo mediante extracción de características de audio de la señal BVP. Al ser las señales de los eventos epilépticos y las señales de audio una variación temporal, los métodos de análisis ocupados en el uno pueden servir para el otro [41].

Para la obtención de las características de audio del segmento se utilizó la librería *librosa*. Ésta es una herramienta muy útil para trabajar con señales de audio en Python, y es ampliamente utilizada en aplicaciones como el procesamiento de señales de música y habla, así como en la creación de sistemas de recomendación de música.

El primer paso para la obtención de las características es convertir el segmento de BVP que se encuentra en el dominio del tiempo a un segmento en el espectro de la frecuencia, utilizando la librería mencionada como se observa en la Fig. 12.

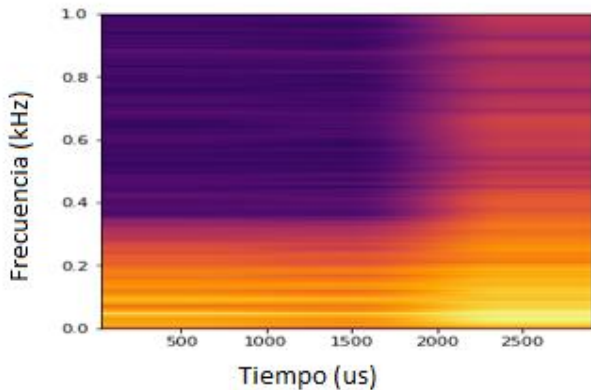


Fig. 12. Espectrograma de la señal BVP.

Ya con el segmento útil en el espectro de la frecuencia se obtienen los componentes principales de éste. Librosa permite la obtención de varios parámetros importantes relacionados con el audio, mediante la realización de diferentes procesos.

Los coeficientes cepstrales en las frecuencias de Mel (MFCC por sus siglas en inglés), se refieren a un conjunto de características que se utilizan comúnmente en el procesamiento de señales de audio y en la identificación del habla. El modelo obtiene 20 de estos coeficientes mediante el cálculo de la transformada de Fourier de la señal, la aplicación de un banco de filtros en escala Mel y la aplicación de una transformada cepstral [32] [33].

El valor RMS (root mean square) de una señal de audio es una medida de la energía total de ésta y se calcula como la raíz cuadrada de la media de los cuadrados de las muestras de la señal. Se utiliza comúnmente para detectar cambios en la energía de la señal a lo largo del tiempo.

El croma es una representación de la distribución de energía espectral de una señal de audio en 12 notas musicales diferentes y se utiliza comúnmente en aplicaciones de procesamiento de estas señales para representar la información tonal de audio y para detectar patrones armónicos y tonales en la música. Se puede utilizar para clasificar géneros musicales, analizar acordes y armonías, y para el reconocimiento de canciones. El modelo toma como entrada una señal y calcula el croma utilizando la transformada de Fourier de tiempo corto (STFT) de la señal.

Otros parámetros relacionados con el audio que se obtienen para el entrenamiento del modelo son: el centroide espectral que es una medida de la frecuencia promedio de una señal de audio ponderada por su amplitud espectral; el ancho de banda espectral que es una medida de la anchura de la

distribución espectral de una señal de audio; el roll-off espectral que es una medida de la frecuencia por encima de la cual se encuentra una cantidad determinada de energía espectral y la tasa de cruce por cero que se utiliza en el entrenamiento y es una medida de la cantidad de veces que una señal cruza el eje horizontal en un marco temporal determinado [33].

El modelo toma como entrada una señal y calcula cada uno de estos parámetros en un marco temporal determinado, el resultado es un conjunto de vectores que contienen estos valores calculados de la señal. En el estudio realizado, este marco temporal es de 120 segundos. Finalmente se obtiene un dataframe con 24 filas que comprenden las 12 señales de entrenamiento con un evento y 12 señales que no contienen ningún evento, y 27 columnas con las características obtenidas anteriormente como se muestra en la Fig. 13. Esta es la base de datos final con las características obtenidas que se introdujo en el modelo de aprendizaje de red neuronal.

	chroma_sft	rms	spectral_centroid	spectral_bandwidth	rolloff	zero_crossing_rate	mfcc1	mfcc2	mfcc3	mfcc4	...
0	0.481567	88.074087	373.210997	339.959276	625.976562	0.044889	388.774611	238.605479	10.759313	-3.115087	...
1	0.583015	95.362637	337.049264	334.979445	634.114583	0.043359	361.015699	238.073883	13.203841	-4.959940	...
2	0.383148	71.614681	360.508878	292.901852	562.825521	0.047461	333.398415	245.562657	22.190362	-12.099754	...
3	0.427473	101.508888	351.438071	296.260213	605.794271	0.045150	378.886073	242.238053	19.321503	-15.008570	...
4	0.324388	46.051124	412.749326	323.808951	693.359375	0.050944	294.371775	254.927891	2.099821	-22.981019	...
5	0.625140	104.401087	376.928319	339.112299	663.411458	0.048665	416.903208	263.397914	-1.507617	-8.229011	...
6	0.484127	160.073667	334.007050	294.309605	579.427083	0.040592	414.966161	251.755962	19.858122	-4.805759	...
7	0.498528	100.328824	370.904635	334.828842	643.554888	0.049056	404.562844	243.598702	6.760434	-4.432846	...
8	0.401892	44.254976	396.462936	325.387604	654.296875	0.051758	307.981340	249.630397	5.507615	-14.144571	...
9	0.409636	61.292411	410.493372	342.413082	660.156250	0.051758	342.814283	234.174067	4.792861	-9.027273	...

Fig. 13. DataFrame que ingresa al entrenamiento

### b) Método de obtención de parámetros de HRV

Este segundo método está basado en el análisis como serie de tiempo de una señal biomédica de frecuencia cardíaca (HR por sus siglas en inglés), la cual se puede obtener a partir de la señal de BVP entregada por el brazalete.

Utilizando algoritmos de detección de picos, se identifican los puntos máximos locales en el segmento de la señal de PPG. Estos picos corresponden a los latidos cardíacos, después se calcula el intervalo de tiempo entre los picos sucesivos de la señal de PPG, también conocido como intervalo RR. La frecuencia cardíaca se puede obtener dividiendo 60 segundos entre el intervalo RR. En la Fig. 14 se puede observar la señal conformada por todos los parámetros HR obtenidos previamente.




Fig. 14. Señal HRV.

Una vez conseguida la FC se procedió a encontrar los factores de HRV de la señal BVP, para esto se obtuvieron los parámetros de HRV en el dominio de la frecuencia, que comprende un grupo de características que se utilizan en el entrenamiento del modelo. A continuación, se definen los más importantes.

La raíz cuadrada de la media de las diferencias cuadráticas sucesivas (RMSSD por sus siglas en inglés) refleja la variabilidad en los cambios de duración de los intervalos RR y está influenciado principalmente por la actividad del sistema nervioso parasimpático. Cuanto mayor sea el valor de RMSSD, mayor será la variabilidad en los intervalos RR y, por lo tanto, mayor será la actividad vagal. Primero, se calculan las diferencias sucesivas entre los intervalos RR y luego se toma la raíz cuadrada de la media de los cuadrados de esas diferencias.

La desviación estándar de los intervalos NN (o intervalos RR) proporciona una medida de la variabilidad total de los intervalos NN y refleja la actividad combinada del sistema nervioso autónomo, incluyendo tanto la influencia vagal (parasimpática) como la influencia simpática. Un valor alto de SDNN indica una mayor variabilidad en los intervalos NN y, por lo tanto, mayor variabilidad en la actividad cardíaca. Se calcula mediante la fórmula estándar para la desviación estándar. Se toman los intervalos NN sucesivos y se calcula su media. Luego, se calcula la desviación estándar de estos intervalos respecto a su media (median\_nni).

Alta Frecuencia (HF por sus siglas en inglés) es un parámetro utilizado en el análisis de la HRV que se refiere a la banda de frecuencia alta en su espectro. Representa la contribución de las oscilaciones rápidas de la frecuencia cardíaca y está relacionado con la modulación vagal. Se calcula mediante técnicas de análisis de frecuencia, como la transformada de Fourier, aplicadas a los intervalos RR.

Baja Frecuencia (LF por sus siglas en inglés) representa la potencia o la cantidad de energía presente en la banda de frecuencia baja del espectro de la HRV. Al igual que en el caso de HF, se utiliza la transformada de Fourier para descomponer la señal de la frecuencia cardíaca en diferentes componentes de frecuencia. Estos componentes de frecuencia se agrupan en bandas, que para LF generalmente se define de 0.04 a 0.15 Hz [34][35].

Finalmente se obtiene un dataframe con dimensiones de 24 filas que corresponden a 12 señales con evento y 12 señales sin evento, y 17 columnas que muestran las características de la señal, como se puede observar en la Fig. 15. Esta es la base de datos final con las características obtenidas que se introdujo en el modelo de aprendizaje de red neuronal para su entrenamiento.

	mean_nni	sdnn	sdsd	nni_50	pnni_50	nni_20	pnni_20	rmssd	median_nni	range_nni	cvsd	cvnni
Signal	91.788753	9.564326	10.503014	0	0.0	2	6.451613	10.503080	94.119909	36.415363	0.114427	0.104199
signal1	80.494495	10.335225	12.877235	0	0.0	6	19.354839	12.881117	83.297572	39.162641	0.160025	0.128397
signal2	91.788753	9.564326	10.503014	0	0.0	2	6.451613	10.503080	94.119909	36.415363	0.114427	0.104199
signal3	92.054941	9.501195	14.169657	0	0.0	5	16.129032	14.175629	83.706344	43.126528	0.172758	0.115791
signal4	80.801776	10.650220	11.815860	0	0.0	3	9.677419	11.818912	81.739130	40.893019	0.146270	0.131807
signal5	83.644049	10.495747	14.628760	0	0.0	7	22.580645	14.636764	84.675678	44.328438	0.174989	0.125481
signal6	92.418918	9.119821	9.355163	0	0.0	1	3.225806	9.362100	92.364836	37.810681	0.101301	0.098679
signal7	94.266892	11.696108	16.842148	0	0.0	6	19.354839	16.857322	97.959184	49.909176	0.178926	0.124074
signal8	84.963568	10.273589	12.591279	0	0.0	5	16.129032	12.601632	84.864469	48.459330	0.148318	0.120918

Fig. 15. DataFrame que ingresa al entrenamiento.

### E. Entrenamiento del modelo

De la misma manera que para la obtención de las características, para el entrenamiento se emplearon dos formas de habitar los datos. Si bien se utilizó el mismo tipo de red neuronal, se aplicaron diferentes librerías, como se puede apreciar en el diagrama de la Fig. 16.

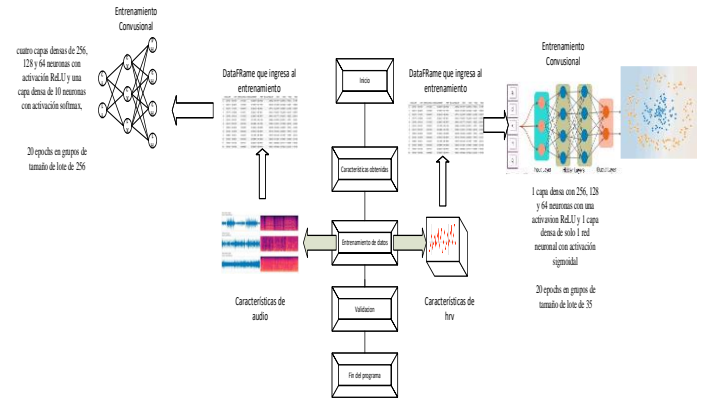


Fig. 16. Diagrama de entrenamiento del modelo

Para los dos grupos de parámetros obtenidos se consideró utilizar una red neuronal convolucional (CNN, por sus siglas en inglés) que es un tipo de arquitectura de red neuronal profunda que se utiliza principalmente para tareas de visión por computadora, como el reconocimiento de imágenes, la detección de objetos y la segmentación semántica.

A diferencia de las redes neuronales tradicionales, las CNN están especialmente diseñadas para procesar datos estructurados en forma de matrices bidimensionales, como imágenes. Su estructura se basa en el concepto de convolución, que es una operación matemática que permite extraer características relevantes de una imagen.

#### a) Entrenamiento con características de audio.

Para la ejecución de la red neuronal con las características de audio se utilizó la librería de Keras junto con sklearn. Se aplicó un modelo con cuatro capas densas de 256, 128 y 64 neuronas con activación ReLU y una de 10 neuronas con activación softmax, ya que esto permite obtener un aprendizaje que esté en su totalidad conectado a la red.

Para su compilación se utilizó un optimizador Adan con una función de pérdida de entropía cruzada y una métrica de precisión. Con estos parámetros se obtiene un modelo de red eficiente, preciso y con pérdidas mínimas.

Los datos de entrenamiento pasaron por 20 epochs (iteraciones completas del conjunto de entrenamiento) en grupos de tamaño de lote de 256. Estas variables de epochs y lote se obtuvieron con un análisis experimental de prueba-error, consiguiendo así los valores que permitan abarcar todos los datos ingresados.

### b) Entrenamiento con parámetros de HRV

Para la ejecución de la red neuronal con las características de HRV se utilizó la librería Keras junto con la librería TensorFlow, que permiten realizar cálculos matemáticos con una gran cantidad de datos a partir de grafos, ejecutando redes neuronales de gran profundidad mediante machine learning. El programa utiliza un código de capa densa con 256, 128 y 64 neuronas con una activación ReLU y una capa densa de solo 1 red neuronal con activación sigmoideal que posibilita una clasificación binaria.

Para entrenar el modelo, los datos de entrenamiento se sometieron a 20 epochs en lotes de 35. Estos datos fueron obtenidos mediante un análisis experimental, donde se demostró que utilizando estos parámetros se logra un análisis completo de todos los factores involucrados en el entrenamiento.

Para su compilación también se utilizó un optimizador Adam con una función de pérdida de entropía cruzada y una métrica de precisión. Con estos parámetros se obtiene un modelo de red eficiente, preciso y con pérdidas mínimas.

Como parte del entrenamiento, en los dos métodos desarrollados era necesario indicarle a la red neuronal qué señal ingresada contenía un evento epiléptico y qué señal no la contenía, por ello fue que inicialmente se guardaron los segmentos seleccionados en distintas carpetas con nombres establecidos para añadir una etiqueta a la matriz de entrenamiento que permita a la red diferenciar las señales y memorizarlas.

### III. PRUEBAS Y RESULTADOS

Con el propósito de validar el modelo, se tuvo prevista la inclusión de 4 segmentos que presentaban eventos epilépticos y otros 4 segmentos que carecían de eventos epilépticos. Esta estrategia se empleó con el fin de evaluar la capacidad de reconocimiento del modelo. Se ingresaron las 8 señales que no tenían ningún tipo de entrenamiento previo y se realizó el mismo preprocesamiento que a las señales entrenadas, posteriormente se obtuvieron sus características con los dos métodos implementados y finalmente se validó el modelo.

En la Fig. 17(a) se observa la matriz de confusión del entrenamiento de características de audio, en ésta se aprecia que se detectaron 3 señales como epilepsia de 4 posibles. También se ve que no se obtuvieron falsos positivos pues, las señales que no contenían un evento epiléptico no las detectó como epilepsia. Mientras que en la Fig. 17(b) el modelo solo detectó 1 señal de epilepsia de 4 y detectó también como positivas a 2 señales que no contenían un evento epiléptico.

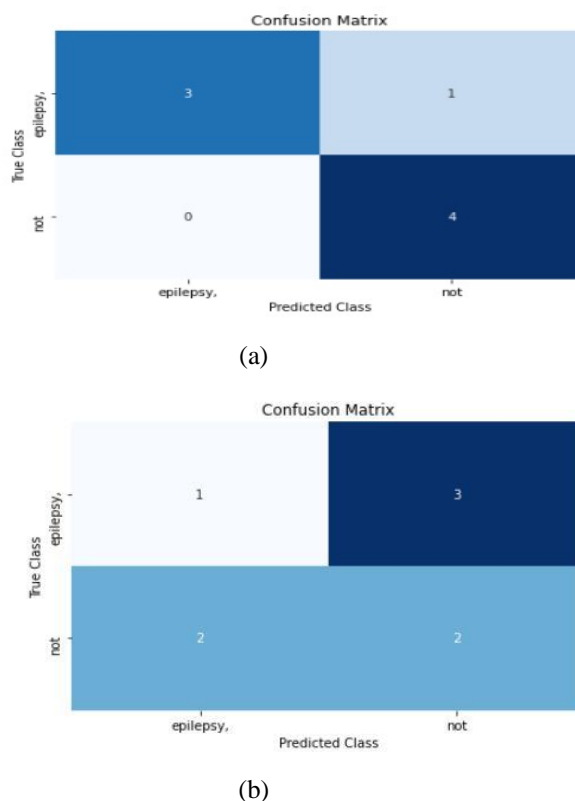


Fig. 17. (a) matriz de confusión del método de características de audio. (b) matriz de confusión del método de parámetros HRV

Finalmente, se ingresaron 4 señales combinadas que contienen una sección con el evento epiléptico y otra sección sin ningún evento. Esto para que el programa identifique en una señal real los segmentos que contienen y los que no contienen epilepsia. En el caso de detectar epilepsia el programa señala de color rojo el tramo de la señal en el que se encontró la crisis convulsiva. En la Fig. 18 se muestran los resultados obtenidos al ingresar estas señales para su detección.



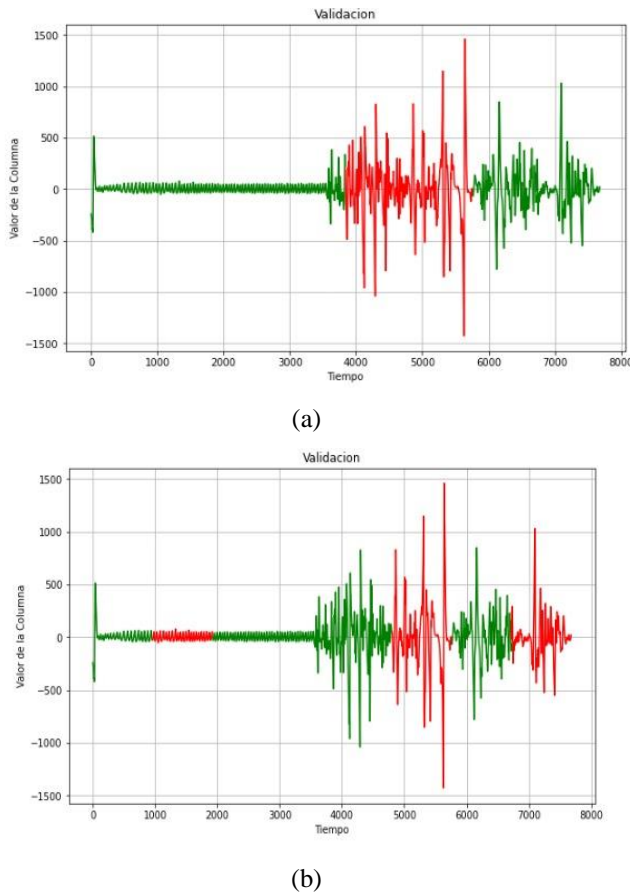


Fig. 18. Validación de diferentes señales combinadas. (a) Entrenamiento de características de audio. (b) Entrenamiento de parámetros HRV.

En la Fig. 18. (a) se realiza la validación del entrenamiento de características de audio. Se observa que no se detectan falsos positivos, sin embargo, no se pudo detectar como epilepsia toda la señal con evento epiléptico, solo una parte de ella. Mientras que en la Fig. 18. (b) se observa que en la validación del entrenamiento de parámetros HRV si se detectan falsos positivos y tampoco se detectó todo el evento epiléptico como epilepsia.

Los resultados se resumen en la Tabla I, en la que se muestra que el método que entrena las características de audio obtuvo una precisión del 87.5% mientras que el método que entrena parámetros de HRV obtuvo una precisión del 37.5%. También se puede observar en la tabla la cantidad de señales detectadas correcta e incorrectamente por cada método utilizado.

Tabla I. Resultados obtenidos con la aplicación de los métodos.

	Método de análisis de audio	Método de análisis de frecuencia cardiaca
Señales con evento		
S1	VERDADERO	VERDADERO
S2	VERDADERO	FALSO
S3	VERDADERO	FALSO
S4	FALSO	FALSO
Señales sin evento		
S1	FALSO	VERDADERO
S2	FALSO	VERDADERO
S3	FALSO	FALSO
S4	FALSO	FALSO
	Precisión=87.5%	Precisión=37.5%

#### IV. CONCLUSIONES

A partir de los resultados obtenidos, se concluye que la detección de crisis convulsivas mediante la señal de un sensor de fotopletiografía se puede lograr con éxito, proyectando a este sensor como una herramienta muy útil, teniendo en cuenta que se trata de un sensor no invasivo y que puede ser llevado en todo momento.

Se obtuvo un porcentaje de precisión aceptable; sin embargo, para mejorar aún más la detección de eventos epilépticos, se recomienda aumentar la cantidad de señales recopiladas de diversos sujetos de prueba, lo que permitirá construir una base de datos de entrenamiento extensa para el modelo. Además, se podría considerar la inclusión de más sensores biomédicos, como los que se encuentran integrados en la misma pulsera, esto proporcionaría una mayor cantidad de parámetros para entrenar y reconocer patrones, lo que podría contribuir a una mejora en la precisión general del sistema de detección de eventos epilépticos.

El modelo desarrollado permite detectar una crisis convulsiva con mayor precisión, utilizando el método de entrenamiento de las características de audio en comparación al entrenamiento con parámetros de HRV. En ambos casos el modelo es capaz de generar una base de datos que se podrían utilizar en estudios posteriores y enviar una alerta en forma de cuadro de diálogo si llega a detectar un evento epiléptico.

#### V. TRABAJO FUTURO

Mediante el desarrollo de este proyecto, se busca brindar una herramienta que permita alertar al paciente y a los especialistas encargados de su cuidado sobre la ocurrencia de un ataque epiléptico, lo que garantizaría la seguridad del paciente.

Se propone seguir desarrollando el software para que se integren otras bioseñales como las que entregan los sensores acelerómetro, EDA y la termopila infrarroja que contiene el hardware utilizado para este estudio y de esta manera obtener una base de datos más amplia que permitiría entrenar al modelo de mejor manera. También se podría utilizar otros métodos de obtención de parámetros y de entrenamiento que entreguen resultados más precisos.

## VI. BIBLIOGRAFÍA

- [1] World Health Assembly, 68. (2015). Global burden of epilepsy and the need for coordinated action at the country level to address its health, social and public knowledge implications. World Health Organization.
- [2] Beghi E. The epidemiology of epilepsy. *Neuroepidemiology*.2020;54(2):185–91.
- [3] Sander JW. The epidemiology of epilepsy revisited. *Curr Opin Neurol*. 2003;16(2):165–70.
- [4] Forsgren, L.; Beghi, E.; Oun, A.; Sillanpää, M. The epidemiology of epilepsy in Europe—A systematic review. *Eur. J. Neurol*. 2005, 12, 245–253.
- [5] French, J.A. Refractory epilepsy: Clinical overview. *Epilepsia* 2007, 48, 3–7.
- [6] Fisher, R.S.; Blum, D.E.; DiVentura, B.; Vannest, J.; Hixson, J.D.; Moss, R.; Herman, S.T.; Fureman, B.E.; French, J.A. Seizure diaries for clinical research and practice: Limitations and future prospects. *Epilepsy Behav*.2012, 24, 304–310
- [7] Hoppe, C.; Feldmann, M.; Blachut, B.; Surges, R.; Elger, C.E.; Helmstaedter, C. Novel techniques for automated seizure registration: Patients’ wants and needs. *Epilepsy Behav*. 2015, 52, 1–7. [CrossRef] [PubMed]
- [8] Bruno, E.; Simblett, S.; Lang, A.; Biondi, A.; Odoi, C.; Schulze-Bonhage, A.; Wykes, T.; Richardson, M.P. Wearable technology in epilepsy: The views of patients, caregivers, and healthcare professionals. *Epilepsy Behav*. 2018, 85, 141–149. [CrossRef]
- [9] Bruno, E.; Biondi, A.; Böttcher, S.; Lees, S.; Schulze-Bonhage, A.; Richardson, M.P. Day and night comfort and stability on
- [10] Shih JJ, Fountain NB, Herman ST, Bagic A, Lado F, Arnold S, et al. Indications and methodology for video-electroencephalographic studies in the epilepsy monitoring unit. *Epilepsia*. 2018;59(1):27–36.
- [11] Van De Vel, A.; Cuppens, K.; Bonroy, B.; Milosevic, M.; Jansen, K.; Van Huffel, S.; Vanrumste, B.; Lagae, L.; Ceulemans, B. Non-EEG seizure-detection systems and potential SUDEP prevention: State of the art. *Seizure* 2013, 22, 345–355.
- [12] Ulate-Campos, A.; Coughlin, F.; Gaínza-Lein, M.; Fernández, I.S.; Pearl, P.L.; Loddenkemper, T. Automated seizure detection systems and their effectiveness for each type of seizure. *Seizure* 2016, 40, 88–101. [CrossRef] [PubMed] *Sensors* 2021, 21, 6017 17 of 19
- [13] Van de Vel, A.; Cuppens, K.; Bonroy, B.; Milosevic, M.; Jansen, K.; Van Huffel, S.; Vanrumste, B.; Cras, P.; Lagae, L.; Ceulemans, B. Non-EEG seizure detection systems and potential SUDEP prevention: State of the art: Review and update. *Seizure* 2016, 41, 141–153. [CrossRef] [PubMed]
- [14] Ramgopal S, Thome-Souza S, Jackson M, Kadish NE, Sánchez Fernández I, Klehm J, et al. Seizure detection, seizure prediction, and closed-loop warning systems in epilepsy. *Epilepsy Behav*. 2014;37:291–307.
- [15] Bruno E, Simblett S, Lang A, Biondi A, Odoi C, Schulze-Bonhage A, et al. Wearable technology in epilepsy: the views of patients, caregivers, and healthcare professionals. *Epilepsy Behav*. 2018;85:141–9.
- [16] Ulate-Campos A, Coughlin F, Gaínza-Lein M, Fernández IS, Pearl PL, Loddenkemper T. Automated seizure detection systems and their effectiveness for each type of seizure. *Seizure*. 2016;40:88–101.
- [17] Simblett SK, Biondi A, Bruno E, Ballard D, Stoneman A, Lees S, et al. Patients' experience of wearing multimodal sensor devices intended to detect epileptic seizures: a qualitative analysis. *Epilepsy Behav*. 2020;102:e106717.
- [18] Beniczky S, Karoly P, Nurse E, Ryvlin P, Cook M. Machine learning and wearable devices of the future. *Epilepsia*. 2021;62(S2):e16555.
- [19] Allen J. Photoplethysmography and its application in clinical physiological measurement. *Physiol Meas*. 2007;28:R1–39.
- [20] Murray WB, Foster PA. The peripheral pulse wave: information overlooked. *J Clin Monit*. 1996;12:365–77.
- [21] P. T. Jagtap and N. P. Bhosale, "IOT Based Epilepsy Monitoring using Accelerometer sensor," 2018 International Conference on Information , Communication, Engineering and Technology (ICICET), 2018, pp. 1-3, doi: 10.1109/ICICET.2018.8533869.
- [22] Yamakawa, T., Miyajima, M., Fujiwara, K., Kano, M., Suzuki, Y., Watanabe, Y., ... & Maehara, T. (2020). Wearable epileptic seizure prediction system with machine-learning-based anomaly detection of heart rate variability. *Sensors*, 20(14), 3987.
- [23] Carrizosa Botero, S. (2019). Detección de ataques epilépticos a partir de señales fisiológicas.
- [24] Duplat Molano, C. Diseño e implementación de un sistema para la detección y alerta de crisis epilépticas a partir de mediciones de señales fisiológicas y de movimiento (Bachelor's thesis, Uniandes).
- [25] Glasstetter, M., Böttcher, S., Zabler, N., Epitashvili, N., Dümpelmann, M., Richardson, M. P., & Schulze-Bonhage, A. (2021). Identification of Ictal Tachycardia in Focal Motor-and Non-Motor Seizures by Means of a Wearable PPG Sensor. *Sensors*, 21(18), 6017.
- [26] El Atrache, R., Tamilia, E., Mohammadpour Touserani, F., Hammond, S., Papadelis, C., Kapur, K., ... & Loddenkemper, T. (2020). Photoplethysmography: A measure for the function of the autonomic nervous system in focal impaired awareness seizures. *Epilepsia*, 61(8), 1617-1626.

- [27] Mohammadpour Touserani, F., Tamilya, E., Coughlin, F., Hammond, S., El Atrache, R., Jackson, M., ... & Loddenkemper, T. (2020). Photoplethysmographic evaluation of generalized tonic - clonic seizures. *Epilepsia*, 61(8), 1606-1616.
- [28] Aileni, R. M., Pasca, S., & Florescu, A. (2020). EEG-brain activity monitoring and predictive analysis of signals using artificial neural networks. *Sensors*, 20(12), 3346.
- [29] Vandecasteele, K., De Cooman, T., Gu, Y., Cleeren, E., Claes, K., Van Paesschen, W., ... & Hunyadi, B. (2017). Automated epileptic seizure detection based on wearable ECG and PPG in a hospital environment. *Sensors*, 17(10), 2338.
- [30] Gaurav, G., Shukla, R., Singh, G., & Sahani, A. K. (2022). A Machine Learning Approach to the Smartwatch-based Epileptic Seizure Detection System. *IETE JOURNAL OF RESEARCH*.
- [31] McIlwraith, D., Wong, D., & Rubin, J. (2018). Wearable photoplethysmography devices. *Sensors*, 18(6), 1714.
- [32] Logan, B. (2000). Mel Frequency Cepstral Coefficients for Music Modeling. En *Proceedings of the International Symposium on Music Information Retrieval (ISMIR)* (pp. 69-74).
- [33] McFee, B., Raffel, C., Liang, D., Ellis, D. P., McVicar, M., Battenberg, E., ... & Moore, B. E. (2015). *librosa: Audio and music signal analysis in python*. En *Proceedings of the 14th python in science conference* (Vol. 8, pp. 18-25).
- [34] Shaffer, F., & Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. *Frontiers in public health*, 5, 258. <https://doi.org/10.3389/fpubh.2017.00258>
- [35] Laborde, S., Mosley, E., & Thayer, J. F. (2017). Heart rate variability and cardiac vagal tone in psychophysiological research – Recommendations for experiment planning, data analysis, and data reporting. *Frontiers in psychology*, 8, 213. <https://doi.org/10.3389/fpsyg.2017.00213>.
- [36] “MedicalExpo - the B2B marketplace for medical equipment: Medical Material, medical imagery, hospital furniture, laboratory equipment, etc..,” The B2B marketplace for medical equipment, <https://www.medicalexpo.com/>.
- [37] ENGAGE-DEM: A Model of Engagement of People with Dementia (PhD Thesis) - Scientific Figure on ResearchGate. Available from: [https://www.researchgate.net/figure/E4-wristband-overview-of-sensors-adapted-from-Empatica\\_com\\_fig7\\_341379123](https://www.researchgate.net/figure/E4-wristband-overview-of-sensors-adapted-from-Empatica_com_fig7_341379123).
- [38] Adaptation of the Learning Process using the Internet of Things - Scientific Figure on ResearchGate. Available from: [https://www.researchgate.net/figure/Principles-of-PPG-left-reflection-mode-and-right-transmission-mode-Benezeth-et-al\\_fig2\\_353998261](https://www.researchgate.net/figure/Principles-of-PPG-left-reflection-mode-and-right-transmission-mode-Benezeth-et-al_fig2_353998261)
- [39] “E4 wristband: Real-time Physiological signals: Wearable ppg, Eda, temperature, motion sensors,” Empatica, <https://www.empatica.com/research/e4/>.
- [40] Ruth V. Acero, Ezequiel Acero, Bersain A. Reyes (2017). Análisis de Variabilidad de la Frecuencia Cardíaca durante Estrés y Relajación empleando Señales Adquiridas con un Smartphone
- [41] Emmanouil Benetos, Mathieu Lagrange, Simon Dixon. Characterisation of Acoustic Scenes using a Temporally Constrained Shift-Invariant Model. *DAFx*, Sep 2012, York, United Kingdom.