

# Comparación de Algoritmos de Detección de Crisis Epilépticas: Evaluación de Eficiencia y Precisión.

Tamara Martínez<sup>1</sup>, Natalia Garay<sup>2,3</sup>, and Franco Simini<sup>3</sup>

<sup>1</sup>Estudiante del XXXIII Seminario de Ingeniería Biomédica 2024.

<sup>2</sup>Conferencista del Seminario del día 12/06/24 de título “Factibilidad de la inhibición no invasiva de focos epilépticos: CENEPSIA”

<sup>3</sup>Docentes del XXXIII Seminario de Ingeniería Biomédica 2024.

## Resumen

En este estudio se comparan dos algoritmos de detección de crisis epilépticas, Energy y Coastline, utilizando señales de actividad eléctrica cerebral obtenidas de una base de datos. El objetivo es evaluar cuál de estos algoritmos es más eficaz para detectar crisis epilépticas en pacientes con epilepsia. Para abordar este problema, se implementaron los algoritmos en Python y se aplicaron a segmentos de señales de electrocortigografía, utilizando criterios de umbral para la detección automática de eventos anormales. Los resultados muestran que el algoritmo Coastline supera significativamente a Energy en términos de precisión de detección, con una mayor área bajo la curva ROC (AUROC). Coastline demostró una gran capacidad para identificar descargas epilépticas, disminuyendo los falsos positivos y aumentando los verdaderos positivos. Estos hallazgos sugieren que Coastline es una herramienta prometedora para la detección automática de descargas epilépticas en entornos clínicos. Las conclusiones destacan la importancia de seleccionar adecuadamente los algoritmos de detección según las características de las señales y la naturaleza de los eventos a detectar. Este estudio proporciona una base sólida para futuras investigaciones en la mejora de algoritmos de detección, con el potencial de mejorar los sistemas de monitoreo y tratamiento de pacientes con epilepsia refractaria.

## Palabras clave

Epilepsia, ~~convulsión~~, foco epiléptico, algoritmos de detección, EEG, neuroestimulación, AUROC, rendimiento.

## I. INTRODUCCIÓN

La epilepsia es una afección cerebral crónica ~~no contagiosa~~ que afecta a aproximadamente 50 millones de personas a nivel mundial. Se manifiesta mediante ~~convulsiones~~ recurrentes, las cuales son episodios breves de movimientos involuntarios que pueden afectar una parte del cuerpo (parciales) o todo el cuerpo (~~generalizadas~~), y a veces se acompañan de pérdida de la conciencia y del control de las funciones intestinales o vesicales [1].

Las ~~convulsiones~~ son provocadas por descargas eléctricas ~~excesivas~~ en un grupo de neuronas del cerebro, pudiendo ocurrir en diversas áreas cerebrales. Estas ~~convulsiones~~ pueden manifestarse de diferentes formas, desde episodios muy breves de ausencias o contracciones musculares hasta ~~convulsiones~~ prolongadas y severas. La frecuencia de las ~~convulsiones~~ puede variar significativamente, desde menos de una al año hasta varias al día [1].

Aunque la epilepsia puede tener diversas causas, en muchos casos no se logra identificar una causa subyacente. Algunos factores que pueden contribuir al desarrollo de la epilepsia incluyen lesiones cerebrales traumáticas, accidentes cerebrovasculares, tumores cerebrales, trastornos genéticos y condiciones médicas como la esclerosis temporal mesial [2].

La epilepsia de inicio focal es la forma más común de esta condición. El tratamiento principal para los pacientes con este tipo de epilepsia es la farmacoterapia. Los fármacos antiepilépticos logran controlar las crisis epilépticas en aproximadamente un 60 % de las personas con epilepsia de inicio parcial. No obstante, existe una proporción significativa de pacientes que continúan experimentando convulsiones a pesar de la medicación. La neuroestimulación se presenta como una opción para aquellos con epilepsia refractaria (resistente a los medicamentos) que no son candidatos a cirugía resectiva o para quienes la cirugía no ha sido exitosa [3]. Sin embargo, en Uruguay este tratamiento aún no se encuentra disponible.

El electroencefalograma (EEG) es una herramienta para medir la actividad eléctrica del cerebro, la cual representa gráficamente la diferencia de voltaje entre dos puntos del cerebro a lo largo del tiempo. Aunque un solo electrodo mide la diferencia entre dos puntos, el EEG utiliza al menos 20 electrodos para proporcionar una visión más completa de la actividad cerebral. La electroencefalografía se refiere al estudio de estas señales eléctricas generadas en la corteza cerebral.

Actualmente hay dos tipos de EEG, el extracraneal que ofrece una visión general de la actividad eléctrica en ambos hemisferios cerebrales, y el intracraneal que proporciona un registro más preciso al utilizar electrodos implantados quirúrgicamente en áreas específicas del cerebro. Esta técnica puede revelar información sobre disfunciones cerebrales, ya sean difusas o focales, la presencia de descargas epileptiformes interictales (IED) o patrones significativos específicos [4]. Para la obtención de señales intracraneales, los electrodos se insertan de manera que el extremo del mismo quede localizado en el foco epiléptico o lo más próximo al mismo. Esta técnica proporciona senales que tienen una relación señal a ruido excepcionalmente altas, menos susceptibilidad a artefactos y una alta resolución espacial y temporal, a diferencia del EEG extracraneal que suele tener resoluciones espaciales, temporales y relaciones señal a ruido bajas[5].

Actualmente hay dos terapias de neuroestimulación para el tratamiento de la epilepsia: la estimulación del nervio vago (VNS) y la estimulación cortical receptiva (RNS). El *RNS System* es el primer dispositivo comercial que ofrece estimulación cerebral en un bucle cerrado. Este sistema cuenta con un neuroestimulador programable que se implanta en el cráneo y monitorea constantemente el electrocorticograma mediante uno o dos electrodos profundos ubicados en el foco epiléptico. Cuando se identifican patrones anormales de actividad electrográfica, el neuroestimulador envía pulsos eléctricos al foco de la epilepsia a través de los electrodos implantados, con el objetivo de interrumpir la crisis epiléptica. Los algoritmos de detección que utiliza el neuroestimulador están diseñados para ser altamente eficientes desde el punto de vista computacional y realizan la detección de patrones ECoG (técnica invasiva de electrocorticografía que implica la medición de señales eléctricas cerebrales mediante electrodos que se implantan subduralmente en la superficie del cerebro) en tiempo real. Estas herramientas de detección son ajustables y pueden ser configuradas por el médico para cada paciente, identificando cambios en la señal electrográfica en términos de amplitud y frecuencia [3].

Se toma como antecedente el siguiente artículo [6], el cual implementa diferentes algoritmos de detección de crisis epilépticas que utilizan herramientas similares a las implementadas en el *RNS System*. En ese artículo, se presenta una evaluación de algoritmos de detección de crisis epilépticas con el fin de optimizar su diseño, considerando tanto la eficacia de la detección como el costo en términos de consumo de energía y área del circuito. Las funciones de detección se examinan por su capacidad para identificar crisis electrográficas a partir de datos obtenidos de ratas tratadas con kainato, utilizando microelectrodos para la adquisición de datos.

## II. ALGORITMOS DE DETECCIÓN A IMPLEMENTAR

Para el desarrollo de esta monografía, se implementarán en Python dos de los algoritmos mencionados. Posteriormente, se evaluará el rendimiento de cada algoritmo aplicándolos a señales de actividad eléctrica cerebral extraídas de una base de datos. Con base en los resultados obtenidos, se discutirá cuál de los algoritmos es más eficaz para la detección de crisis electrográficas.

### II-A. Energy

Esta característica refleja la potencia instantánea de la señal utilizando la energía acumulada. Se utilizó una ventana rectangular deslizante para calcular la energía instantánea según se describe en la Ecuación 1 [6].

$$E = \frac{1}{N} \sum_{i=1}^N x[i]^2 \quad (1)$$

En este caso,  $x[i]$  representa la  $i$ -ésima muestra de la señal  $x$ . Este promedio se realiza para cada ventana de manera de recorrer toda la señal.

### II-B. Coastline

La característica representa la suma del valor absoluto de las distancias entre puntos de datos consecutivos [6].

$$CL = \sum_{i=1}^N |x[i] - x[i-1]| \quad (2)$$

## III. SEÑALES INVOLUCRADAS

Para la implementación en Python, se toma una señal proveniente de una base de datos, la cual se obtuvo de la API de Python para IEEG [7]. Cada señal descargada cuenta anotaciones que representan el comienzo y el término de cada crisis electrográfica. En este caso, se descarga una señal correspondiente a un estudio de un individuo y se utiliza la misma a lo largo del proceso.




Figura 1: Señal descargada de la base de datos.

#### IV. DESARROLLO Y RESULTADOS OBTENIDOS

En primer lugar se debió elegir un umbral para realizar una comparación. Para ello, se recortó la señal teniendo en consideración que la misma debía contener actividad eléctrica normal y actividad eléctrica anormal. Aplicando los algoritmos a los tramos y en base a las amplitudes obtenidas, se definió un umbral de detección (Figura 2a y Figura 2b). Luego se verificó que bajo ese umbral, las detecciones fueran correctas (Véase Figura 3 y Figura 4). En el caso del Energy, si bien se probó con diferentes valores de umbrales, el elegido no solo detecta en las zonas etiquetadas sino que también hay detecciones fuera de ellas, siendo estos falsos positivos. En el caso del Coastline, para el umbral definido, el algoritmo detecta correctamente en las zonas etiquetadas.

Para realizar una comparación entre ambos algoritmos se utiliza una curva ROC, la cual consiste en un gráfico que muestra el rendimiento de los algoritmos implementados en todos los umbrales de clasificación. Esta curva representa dos parámetros [8]:

- Tasa de verdaderos positivos (TPR)
- Tasa de falsos positivos (FPR)

Las mismas se definen como:

$$\begin{aligned} TPR &= \frac{TP}{TP + FN} \\ FPR &= \frac{FP}{FP + TN} \end{aligned} \quad (3)$$

En base a estos gráficos mostrados en la Figura 5a y Figura 5b se calculó el área debajo de cada curva (AUROC) de manera de evaluar dichos algoritmos (Ver Tabla I). A mayor área, mayor rendimiento tendrá el algoritmo.

| Algoritmo | AUROC |
|-----------|-------|
| Energy    | 0.556 |
| Coastline | 0.969 |

Tabla I: AUROC para cada algoritmo.

Los resultados obtenidos muestran que si bien ambos algoritmos realizan una correcta detección con el umbral definido, el Coastline tiene un mayor rendimiento, ya que la AUROC es mayor y por ende su detección es más precisa.




Figura 2: Salida de algoritmos.




Figura 3: Detección de convulsiones con algoritmo Energy. Se utiliza un umbral de 50000. Los puntos rojos indican los índices donde el algoritmo detecta una crisis epiléptica. La zona verde corresponde a un intervalo de tiempo donde se da una crisis epiléptica de acuerdo a la etiqueta de la base de datos.




Figura 4: Detección de convulsiones con algoritmo Coastline. Se utiliza un umbral de 20. Los puntos rojos indican los índices donde el algoritmo detecta una crisis epiléptica. La zona verde corresponde a un intervalo de tiempo donde se da una crisis epiléptica de acuerdo a la etiqueta de la base de datos.




Figura 5: Curvas ROC de algoritmos

## V. CONCLUSIONES

En este estudio se implementaron y evaluaron dos algoritmos de detección de crisis electrográficas, Energy y Coastline, utilizando señales de EEG obtenidas de una base de datos. Ambos algoritmos fueron aplicados a segmentos de señales que incluían tanto actividad normal como patológica, utilizando criterios específicos de umbral para la detección de crisis epilépticas.

Los resultados obtenidos indican que el algoritmo Coastline mostró una mayor eficacia al algoritmo Energy en términos de precisión de detección. Esto se evidenció mediante el análisis de la curva ROC, donde el área bajo la curva (AUROC) fue considerablemente mayor para Coastline (0.969) en comparación con Energy (0.556). Este resultado sugiere que Coastline es más efectivo para identificar patrones característicos asociados con descargas epileptiformes en las señales evaluadas. Asimismo, se observó que Coastline demostró una buena capacidad para discriminar entre señales de actividad normal y convulsiva, minimizando la tasa de falsos positivos y maximizando la tasa de verdaderos positivos en las detecciones realizadas.

En conclusión, este estudio destacó la importancia de seleccionar adecuadamente los algoritmos de detección según el tipo de señal y la naturaleza de los eventos a detectar. Los resultados respaldan la eficacia de Coastline como una herramienta prometedora en la detección automática de episodios epilépticos, subrayando la relevancia de su implementación en sistemas de monitoreo y tratamiento de pacientes con epilepsia refractaria.

Estos hallazgos proporcionan una base sólida para futuras investigaciones orientadas a mejorar aún más la precisión y la eficiencia de los algoritmos de detección de crisis epilépticas, con el objetivo de ofrecer opciones terapéuticas más efectivas y personalizadas para los pacientes afectados.

## REFERENCIAS

- [1] <https://www.who.int/es/news-room/fact-sheets/detail/epilepsy>, Online accessed July 3rd 2024.
- [2] I. Osorio, H. P. Zaveri, M. Frei y S. Arthurs, *Epilepsy. The Intersection of neurosciences, biology, mathematics, engineering, and physics*. Boca Raton, Florida: Taylor y Francis Group, LLC, 2011.
- [3] F. T. Sun y M. J. Morrell, "The RNS System: responsive cortical stimulation for the treatment of refractory partial epilepsy," *Expert Review of Medical Devices*, 2014. dirección: <https://doi.org/10.1586/17434440.2014.947274>.
- [4] W. O. T. IV, A. M. Husain, S. R. Benbadis y P. W. Kaplan, *Handbook of EEG Interpretation*. Demos.
- [5] N. J. Hill, D. Gupta, P. Brunner et al., "Recording Human Electrocorticographic (ECoG) Signals for Neuroscientific Research and Real-time Functional Cortical Mapping," *Jove Journal Neuroscience*, 2012. dirección: <https://doi.org/10.3791/3993>.
- [6] S. Raghunathana, S. K. G. b, K. R. Himanshu S. Markandeya y P. P. Irazoqui, "A hardware-algorithm co-design approach to optimize seizure detection algorithms for implantable applications," *Journal of Neuroscience Methods*, 2010. dirección: <http://10.1016/j.jneumeth.2010.08.008>.
- [7] <https://github.com/ieeg-portal/ieegpy>, Online accessed June 29 2024.
- [8] <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc?hl=es-419>, Online; accessed 21 February 2024.