

Un estudio exploratorio para clasificación de electrocorticogramas en estado basal y crisis epilépticas a través de redes neuronales

Ángel Luis Yoval¹, Martha Lorena Avendaño-Garrido¹, Porfirio Toledo¹,
María-Leonor López-Meraz²

¹ Universidad Veracruzana,
Facultad de Matemáticas,
México

² Universidad Veracruzana,
Instituto de Investigaciones Cerebrales,
México

zs20016134@estudiantes.uv.mx, maravendano@uv.mx, ptoledo@uv.mx
leonorlopez@uv.mx

Resumen. Las señales electrocorticográficas (ECoG) registran la actividad eléctrica del cerebro a lo largo del tiempo, por lo que son ampliamente utilizadas para el estudio y análisis de crisis epilépticas. En este trabajo se utiliza un modelo de aprendizaje estadístico basado en redes neuronales artificiales para la clasificación de muestras de estas señales en estados basal y de crisis epiléptica. A través de un enfoque de aprendizaje automático supervisado, se ajusta un modelo de perceptrón multicapa entrenado con muestras de una señal ECoG obtenida de una rata. El modelo ajustado logra identificar patrones característicos de las muestras, permitiendo discriminarlas en estado basal de la actividad eléctrica cerebral y la presencia de crisis epiléptica.

Palabras clave: electrocorticograma, redes neuronales artificiales, crisis epiléptica, clasificación, aprendizaje supervisado.

Application of Neural Networks to EEG Signal Classification

Abstract. This study presents a statistical learning model using artificial neural networks aimed at the classification of EEG signals. EEG signals are a time-based recording of the brain's electrical activity; these signals are of utmost importance in the detection, diagnosis, and monitoring of epileptic seizures. Through a machine learning framework based on supervised learning techniques, a model is developed that balances computational time and accuracy, capable of learning and recognizing the characteristics of the basal, intermediate, and seizure phases that compose an EEG signal.

Keywords: EEG signals, neural networks, epilepsy, classification, supervised learning.

1. Introducción

La Organización Mundial de la Salud reconoce que la epilepsia es una enfermedad cerebral crónica no transmisible que afecta a unos 50 millones de personas en todo el mundo. Se caracteriza por crisis recurrentes, algunas de las cuales son episodios breves de movimiento involuntario que pueden involucrar una parte del cuerpo (parcial) o todo el cuerpo (generalizado), lo que tradicionalmente se conoce como convulsiones; en ocasiones se acompañan de pérdida de conciencia y control de la función intestinal o vesical [26]. Según estimaciones del gobierno federal, en México, de 10 a 20 personas de cada 1000 sufren epilepsia [11].

Hay diferentes signos y síntomas asociados a esta enfermedad, el más reconocible es la aparición de crisis; estos pueden variar y dependen de la zona del cerebro en la que inicia la alteración. La importancia de investigar esta enfermedad radica en poder ofrecer una mejor calidad de vida a quienes la padecen.

Algunos estudios y análisis de la epilepsia se realizan con datos provenientes de modelos animales, los cuales son clave en la investigación biomédica porque se pueden replicar procesos biológicos o enfermedades. Se busca evitar la realización de estos experimentos y tratamientos en pacientes humanos hasta contar con resultados suficientes que garanticen su seguridad. En modelos animales, las señales electrocorticográficas (ECoG) permiten registrar la actividad eléctrica por medio de electrodos colocados sobre la corteza cerebral. Estos registros son útiles si se desea analizar los patrones característicos de las crisis y localizar las zonas afectadas del cerebro [15].

Los patrones en estas señales son indicadores importantes que ayudan en el diagnóstico y clasificación de los tipos de epilepsia, por lo cual es importante reconocerlos. De acuerdo con Niedermeyer y Lopes da Silva [16] algunos de los patrones característicos son:

- *Punta-onda generalizada*. Este patrón es característico de epilepsias generalizadas. Las descargas de punta-onda suelen aparecer de manera sincrónica en ambos hemisferios cerebrales, indicando una afectación global en la actividad cerebral.
- *Descargas focales*. Comunes en epilepsias parciales, estas descargas se limitan a una región específica del cerebro, como el lóbulo temporal. Este patrón resulta especialmente útil para localizar el foco epileptogénico, ayudando a los médicos a identificar la zona cerebral donde se originan las crisis.
- *Picos repetitivos*. Este patrón se observa con frecuencia en algunos tipos de epilepsia del lóbulo frontal, siendo un indicador de actividad eléctrica irregular que puede acompañar a movimientos o espasmos.

El análisis y clasificación de estas señales juega un papel fundamental en la identificación de los distintos estados asociados a las crisis epilépticas. Una clasificación adecuada permitiría desarrollar mejores diagnósticos y estrategias de atención efectivas.

En este contexto, los avances en las herramientas computacionales permiten la implementación de técnicas de aprendizaje en el reconocimiento automático de patrones en estas señales. El uso de redes neuronales artificiales ha ganado relevancia por su capacidad de extraer características de forma automática, sin requerir gran manipulación de los datos [20], brindando aportes significativos a la clasificación de estas señales en comparación con enfoques tradicionales. Estos modelos han sido aplicados en la predicción de la edad cerebral [6], el diagnóstico de la esquizofrenia [19], el reconocimiento de emociones [10], la clasificación de estados de sueño y la interpretación de potenciales relacionados con eventos [7], así como en la detección de crisis epilépticas [25].

La identificación automática de patrones asociados a crisis epilépticas puede apoyar a los profesionales de la medicina a manejar grandes volúmenes de información, para realizar con mayor rapidez y precisión la detección de anomalías en las señales.

A lo largo de este estudio, se utilizarán muestras de señales de las áreas frontal y parietal del cerebro de una rata, como fuente de datos para el entrenamiento y validación del modelo. La corteza frontal está implicada en el control y aprendizaje motor, así como en la atención, mientras que la corteza parietal es un área sensorial multimodal, involucrada principalmente en la navegación en el espacio y en la memoria espacial (ver [3,14,18,23]). Los experimentos clásicos del grupo de Turski y Cavalheiro (ver [4,24]), mostraron que la pilocarpina induce *status epilepticus* (SE) de crisis motoras en ratas, asociadas a actividad electrográfica inicialmente en el hipocampo, misma que se propaga rápidamente hacia las cortezas occipital y sensoriomotora. En este contexto se ha observado que la región fronto-parietal de la corteza cerebral de la rata se activa durante el SE generado por pilocarpina [22]. Se sabe que la corteza frontal es altamente sensible a los cambios bioquímicos generados por el SE y que pueden derivar en daño neuronal (ver [5,9]). No obstante, la corteza parietal también presenta afectación celular debida al SE [24]. Lo anterior es relevante considerando que ambas presentan hiperactividad neuronal sostenida, lo que las hace más sensibles a procesos neurodegenerativos. Sin embargo, existen más detalles sobre la respuesta de la corteza frontal durante las crisis que la de la corteza parietal. De hecho, cuando se presenta el SE, existe una interacción aumentada y aberrante entre el hipocampo y la corteza frontal, siendo dicha interacción crítica para la generación y progresión de las descargas epilépticas [8].

En este trabajo se presenta una estrategia de clasificación de muestras de señales ECoG de una rata con el objetivo de contribuir al desarrollo de herramientas eficientes en el estudio de la epilepsia, lo que potencialmente podría mejorar la toma de decisiones clínicas.

La organización del presente documento se establece de la siguiente manera: en la sección 2, se detalla la metodología aplicada, incluyendo el procedimiento

para la obtención de las muestras de las señales tanto en estado basal como en crisis epiléptica. Se aborda también las características principales de las redes neuronales artificiales empleadas en el desarrollo del experimento computacional. En la sección 3, se presentan los experimentos computacionales realizados y sus resultados. Finalmente, en la sección 4 se presenta una discusión sobre los hallazgos obtenidos.

2. Metodología

En esta sección se describen los datos experimentales utilizados, el procedimiento para su adquisición y procesamiento, así como las características del modelo computacional empleado para su análisis.

2.1. Datos

Los datos estudiados fueron obtenidos en el Instituto de Investigaciones Cerebrales de la Universidad Veracruzana. Estos provienen de una rata Wistar, como sujeto experimental, alojada junto con otros especímenes en condiciones ambientales controladas de temperatura y humedad (20–28°C y 40–70% HR, respectivamente), con ciclos de luz-oscuridad de 12/12 horas (07:00–19:00) y acceso ilimitado a agua y alimento. Para la adquisición de datos, se implantaron en el cráneo dos electrodos de acero inoxidable con forma de clavo de manera estereotáxica en la corteza frontal (anteroposterior = 1.5 mm, lateral a la línea media = ± 3 mm, respecto al bregma) y corteza parietal (anteroposterior = -3.5 mm, lateral a la línea media = ± 3 mm, respecto al bregma). El procedimiento quirúrgico se llevó a cabo bajo condiciones completamente asépticas, utilizando isoflurano como anestesia (1.5–2%, marca Vedco, Inc., USA). La temperatura corporal se mantuvo con un sistema de regulación térmica (marca FHC, modelo 41-90-D8). Tras la cirugía, el espécimen fue rehidratado con solución salina glucosada (equivalente al 5% del peso corporal, vía subcutánea). Durante el periodo posoperatorio, se administraron un analgésico (meclumina, 2.5 mg/kg, s.c., por 2 días) y un antimicrobiano (enrofloxacina, 5 mg/kg, s.c., por 5 días). La rata fue sometida al protocolo experimental 5 días después de la cirugía.

Respecto a la elección de estas señales cerebrales, estudios previos que emplean el modelo experimental SE usado en este trabajo, han mostrado que la corteza cerebral presenta actividad eléctrica paroxística (indicativa de un estado de hiperexcitabilidad e hipsincronía neuronal) asociada con las manifestaciones motoras propias de las crisis epilépticas (ver [4,5,8,24]). Este patrón es similar a la actividad eléctrica de las neuronas corticales que se detecta con el electroencefalograma (EEG) en humanos (ver [17,21]).

Para inducir las crisis epilépticas en el sujeto experimental, se utilizó la pilocarpina, el cual es un fármaco parasimpaticomimético (ver [24,27]), que estimula los receptores, denominados M1, en el sistema nervioso central provocando actividad epiléptica sostenida similar a los pacientes con esta enfermedad. Para nuestro caso, se administró a la rata cloruro de litio (3 mEq/kg

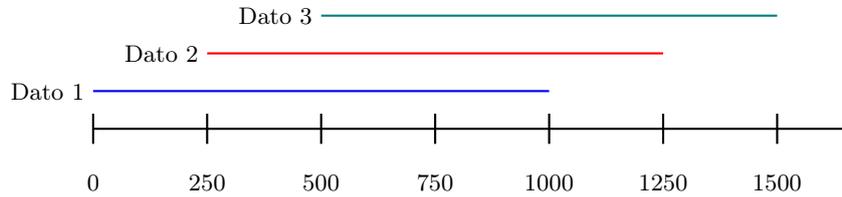


Fig. 1. Muestras con traslape y con etiqueta.

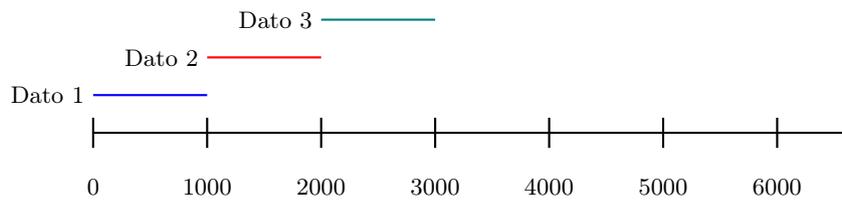


Fig. 2. Muestra sin traslape y sin etiqueta.

i.p., Sigma) y, 24 horas después, se inyectó clorhidrato de pilocarpina (30 mg/kg s.c., Sigma). El cloruro de litio potencia los efectos convulsivos de la pilocarpina facilitando el SE. Este modelo experimental se utiliza ampliamente en la investigación de la epilepsia, pues permite replicar aspectos de la enfermedad, en particular los episodios de crisis recurrentes no autolimitadas o SE.

Bajo el procedimiento descrito se obtuvieron dos señales de 40 minutos, correspondientes a la corteza frontal y la parietal, que iniciaban en un estado basal (independiente de la administración de pilocarpina y en libre movimiento) y terminaban en episodios de crisis epilépticas. En total se obtuvieron 781,000 mediciones aproximadamente, de cada una de las dos señales.

Para el ajuste y validación del modelo de aprendizaje supervisado, se tomaron muestras de la señal correspondientes a los 10 minutos iniciales (clase/etiqueta: *estado basal*) y muestras de los 10 minutos finales (clase/etiqueta: *estado en crisis*) de las señales. Las muestras corresponden a una partición de estos segmentos de 10 minutos en secciones de dimensión 1000, con un traslape de 250 mediciones, como se ilustra en la Figura 1. Con lo anterior se obtuvo un total de 1200 muestras etiquetadas por señal (frontal y parietal).

A cada muestra se le asignó una etiqueta, dependiendo del fragmento de la señal al que pertenecía; 0 si provenía de los primeros 10 minutos (clase: *estado basal*) o 1 si era de los últimos 10 (clase: *estado en crisis*).

Posterior a la validación del modelo, para analizar las señales completas, estas fueron divididas en muestras de tamaño 1000 siguiendo un proceso similar al anterior, con la particularidad de que no se utilizó traslape entre ellas, como se ilustra en la Figura 2. De esta forma, se obtuvo un total de 781 datos sin etiqueta.

2.2. Redes neuronales

En el ámbito de redes neuronales existen diferentes tipos de modelos como las redes monocapa, redes convencionales o recurrentes. En este trabajo se decidió utilizar el modelo de perceptrón multicapa, ya que es capaz de resolver problemas de clasificación no linealmente separables (ver [1] y [2]). Esta característica lo convierte en una opción adecuada para alcanzar los objetivos planteados.

Se emplearon diferentes funciones de activación para la red, todas comparten la característica de que su rango sea el intervalo $[0, 1]$, lo cual nos permite interpretar los resultados en términos probabilísticos. Entre las funciones utilizadas se encuentran la *sigmoide*, *ReLU* y *tanh* [12]. Se utilizó el algoritmo de optimización *Adaptive Moment Estimation* (Adam) [13].

2.3. Desarrollo

Para la búsqueda y análisis de las mejores arquitecturas se realizaron 100 ajustes independientes. Para el entrenamiento de la red se utilizó una proporción del 70 % de los datos etiquetados y para la evaluación se tomó el 30 % restante, obteniendo el promedio de tasa de error.

Una vez seleccionada la arquitectura con menor tasa de error, se volvió a ajustar la red con la muestra completa de datos etiquetados y, finalmente, se analizó la señal completa sin etiquetas. Se graficó el número de secuencia de la muestra de la serie de tiempo (consecutivamente) versus la probabilidad de que se corresponda con la clase *estado en crisis*.

Cabe señalar que se muestra la probabilidad de algunos datos que fueron utilizados en el entrenamiento del modelo, correspondientes al estado basal y al estado en crisis. No obstante, el interés principal radica en la sección intermedia de la señal, con el objetivo de visualizar el comportamiento de las probabilidades a lo largo del tiempo.

3. Experimentos

Los códigos para la experimentación fueron creados en el lenguaje de programación *Python* haciendo uso de las librerías *tensorflow*, *sklearn*, *pandas* y *numpy*. Se probaron múltiples configuraciones de redes neuronales, como se detalla en las Tablas 1 y 2. Los experimentos incluyeron redes con diferentes cantidades de capas, neuronas y funciones de activación. En las tablas se muestran las más destacadas. Cabe observar que, en el caso de la señal parietal, la única función sobresaliente fue la *sigmoide*.

Como se observa, las arquitecturas más eficaces para los datos considerados fueron las integradas por la función de activación *sigmoide*. En el caso de la señal frontal, la mejor arquitectura evaluada fue la compuesta por tres capas ocultas, con 30 neuronas por capa, la cual tiene un error promedio de 0.331472 y una varianza de 0.000180. Por su parte, para la señal parietal, la arquitectura de tres capas y 25 neuronas por capa alcanzó un error promedio de 0.205194 y una varianza de 0.000098.

Tabla 1. Resultados de la red neuronal para la señal frontal.

Función	#Capas	#Neuronas por capa	Error promedio	Varianza
Sigmoide	2	30	0.338278	0.000184
Sigmoide	3	15	0.364944	0.000645
Sigmoide	3	20	0.351056	0.000437
Sigmoide	3	25	0.338556	0.000216
Sigmoide	3	30	0.331472	0.000180
Tanh	3	15	0.382444	0.001915
Tanh	3	20	0.375250	0.001813
Tanh	3	25	0.378778	0.002199
Tanh	3	30	0.381472	0.002658
ReLu	3	10	0.368444	0.002972
ReLu	3	15	0.361222	0.002335
ReLu	3	20	0.378889	0.002402
ReLu	3	25	0.392833	0.002141
ReLu	3	30	0.398417	0.001714

Tabla 2. Resultados de la red neuronal para la señal parietal.

Función	#Capas	#Neuronas por capa	Error promedio	Varianza
Sigmoide	3	10	0.230278	0.000501
Sigmoide	3	15	0.217000	0.000240
Sigmoide	3	20	0.207250	0.000163
Sigmoide	3	25	0.205194	0.000098
Sigmoide	3	30	0.206583	0.000106
Tanh	3	10	0.439389	0.015284
Tanh	3	15	0.446194	0.013166
Tanh	3	20	0.430361	0.013939
Tanh	3	25	0.449194	0.016075
Tanh	3	30	0.465000	0.015932
ReLu	3	10	0.447722	0.003660
ReLu	3	15	0.464000	0.003229
ReLu	3	20	0.480222	0.002040
ReLu	3	25	0.489917	0.002786
ReLu	3	30	0.506444	0.001634

3.1. Análisis de las señales completas

Para el análisis de la señal completa, la red fue entrenada con la totalidad de los datos etiquetados con el fin de aprovechar toda la información disponible.

Para analizar la señal frontal se ajustó una red con tres capas ocultas con 30 neuronas por capa y todas con función de activación *sigmoide*. Los resultados obtenidos se muestran en la Figura 3, en donde se integra la señal para visualizar la ubicación temporal de los datos del ECoG y su probabilidad de pertenecer a la clase *estado en crisis*. Los puntos en rojo presentan probabilidades superiores a 0.5, mientras que los puntos en azul corresponden a probabilidades menores a dicho umbral, lo anterior de muestras sin etiqueta. Además los puntos en negro corresponden a las probabilidades de algunos datos etiquetados utilizados en el ajuste del modelo.

En la primera sección de la gráfica que corresponde a los primeros datos etiquetados (puntos negros), se observa cómo las probabilidades se agrupan cerca

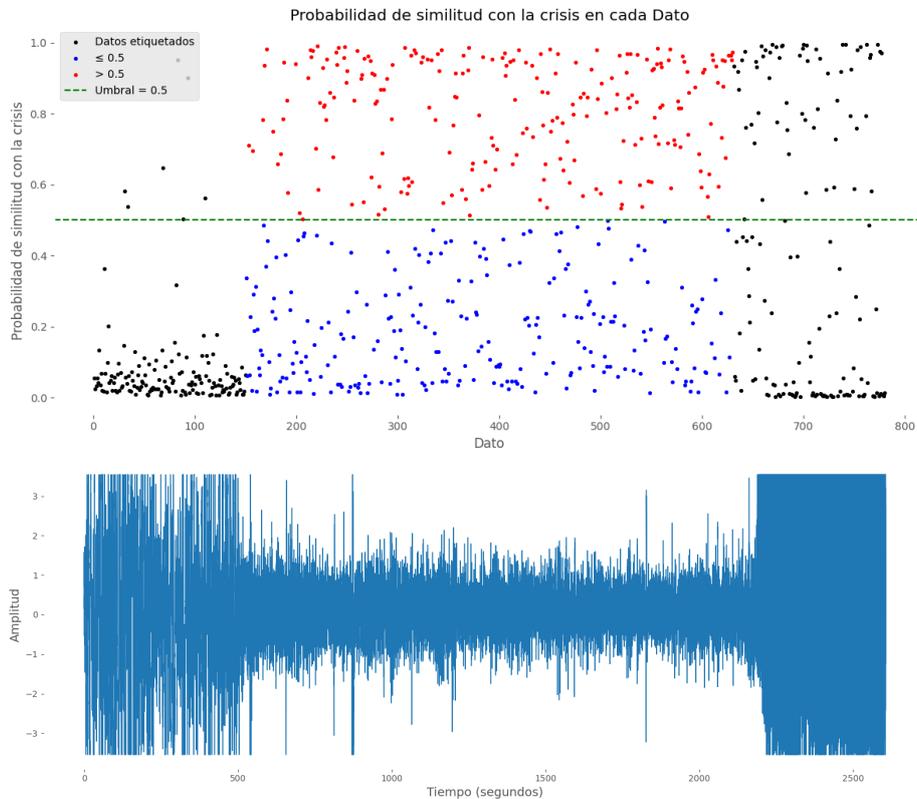


Fig. 3. Señal frontal.

de 0, lo cual indica que la red clasifica correctamente el *estado basal*. En la sección intermedia, correspondiente a los datos 181 al 601, las probabilidades muestran una mayor dispersión, lo cual refleja la transición entre los estados. Finalmente, los datos etiquetados (puntos negros) posteriores a 601, las probabilidades se distribuyen entre 0 y 1, con una predominancia de valores cercanos a 1 sobre los que están cerca de 0; es decir, los datos se clasifican en el *estado en crisis*.

Los resultados obtenidos para la señal parietal se presentan en la Figura 4. En este caso se ajustó una red con tres capas ocultas con 25 neuronas por capa y todas con función de activación *sigmoide*. En los datos del 1 al 180 (puntos negros, que se corresponden con datos etiquetados), las probabilidades se mantienen cercanas a 0, lo que indica una clasificación de los datos en *estado basal*, como se esperaba.

También se observa que la probabilidad de los datos entre 181 y 600 tiene mayor variabilidad; sin embargo, hay más datos con poca probabilidad del *estado en crisis*. Finalmente, a partir del dato 601 (puntos negros correspondientes a datos etiquetados), se nota un incremento en las probabilidades hasta que se

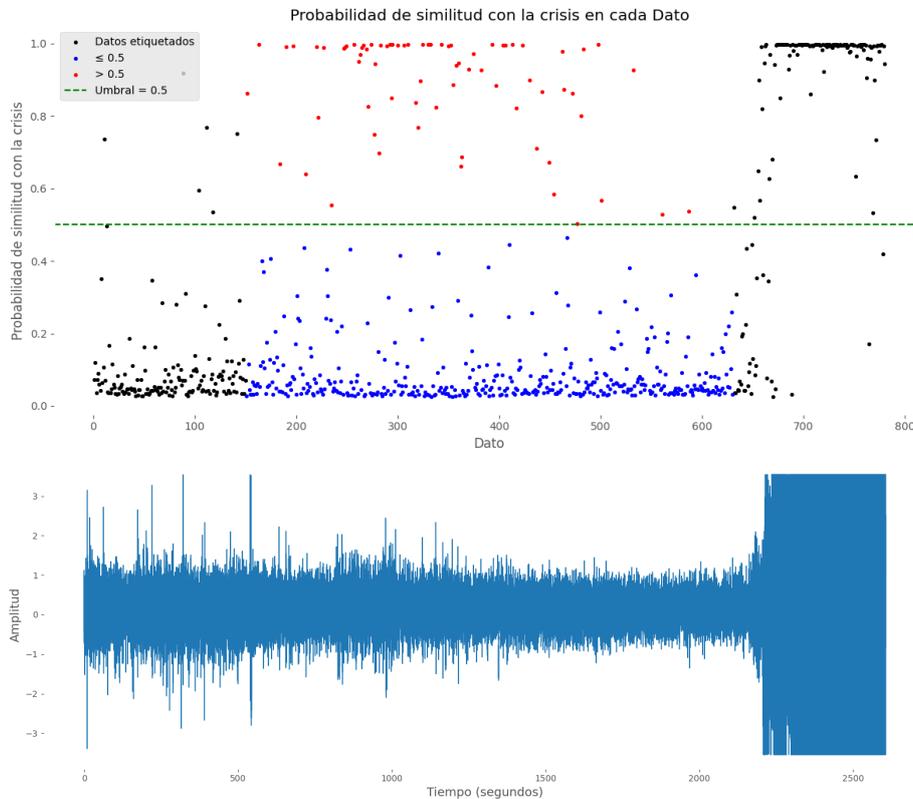


Fig. 4. Señal parietal.

agrupan en torno a 1, correspondiéndose a los datos con *estado en crisis*.

4. Discusión

Las técnicas de aprendizaje estadístico del tipo supervisado permiten ajustar modelos que logran un equilibrio adecuado entre precisión, varianza y flexibilidad. Un aspecto clave en este tipo de modelos es el uso de métodos de optimización, como el algoritmo Adam, que acelera y estabiliza la convergencia hacia un mínimo de la función de pérdida. Como se observa en los resultados obtenidos, las redes neuronales artificiales son eficaces para reconocer los patrones presentes en los ECoG.

Se utilizaron señales de las áreas frontal y parietal del cerebro de una rata, previamente descritas en la sección de metodología. Se sabe que estas señales presentaron diferencias significativas, por lo que tuvieron que implementarse arquitecturas diferentes para su análisis.

En cuanto a los resultados obtenidos, se observó que la señal proveniente de la corteza frontal presentó una mayor dispersión en las probabilidades asignadas por la red neuronal al *estado basal* y *estado en crisis*. Esto podría estar relacionado con la propia actividad motora de las ratas que se encuentran en libre movimiento, o bien con la hiperactividad e hiperconectividad cortical propias de esta región durante las crisis. Por otro lado, estos fenómenos podrían manifestarse de forma más discreta en la corteza parietal, lo cual se reflejó en una señal con menor variabilidad y una mayor proporción de datos clasificados con alta probabilidad de pertenecer al *estado en crisis*. No obstante, es necesario analizar un mayor número de datos provenientes de otros sujetos experimentales para corroborar este hallazgo.

El método computacional propuesto analiza las señales para identificar diferencias entre los dos estados, con el objetivo de distinguir la transición del *estado basal* al *estado en crisis* epiléptica. Su aplicación en un entorno clínico podría contribuir al monitoreo de la estimulación cerebral profunda. Sin embargo, se identificaron algunos desafíos, como la necesidad de recopilar una mayor cantidad de datos para mejorar el entrenamiento de la red y aumentar su fiabilidad, así como la creación de arquitecturas más precisas para disminuir la tasa de error de clasificación. Asimismo, transitar de un modelo animal a uno humano permitiría tener una aplicación directa en la práctica médica.

En la actualidad, el EEG sigue siendo el estándar de oro para el diagnóstico de epilepsia. La posibilidad de contar con diferentes configuraciones, desde la forma no invasiva hasta aquella que, siendo invasiva como el ECoG, permite registrar la actividad eléctrica de regiones subcorticales, lo ha convertido en una herramienta diagnóstica y de seguimiento al tratamiento de gran utilidad. Sin embargo, desde el punto de vista técnico, se requiere de equipamiento especializado, así como de personal capacitado para la realización de los registros y su interpretación. Además, es relevante considerar que existen múltiples grafoelementos en el registro, dependiendo del tipo de epilepsia o síndrome epiléptico en cuestión. Es un método que tampoco está exento de artefactos propios del movimiento, por ejemplo. A lo anterior se suma el hecho de que el manejo de estrategias matemáticas, como la presentada en este trabajo, para el análisis de datos derivados del EEG aún no es de dominio general. Por su parte, la presente propuesta requiere alimentarse de un mayor número de datos, pues solo se empleó la señal de un sujeto y un único modelo experimental, lo que implica seguir incorporando diferentes señales epileptiformes que mejoren su capacidad de discriminación. Así, aún existen barreras técnicas que limitan el uso de redes neuronales en la práctica clínica, aunque esta aproximación permite visualizar su futura implementación.

Este estudio muestra el potencial de la inteligencia artificial en la investigación de la epilepsia, ofreciendo una herramienta útil a médicos e investigadores que facilita el análisis de las señales ECoG. Lo anterior podría contribuir a la identificación temprana de crisis epilépticas, mejorando el diagnóstico, tratamiento y calidad de vida de los pacientes.

Referencias

1. Andrade Tepán, E. C. (2013). *Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación*. Universidad Politécnica Salesiana, Ecuador. Recuperado de <http://dspace.ups.edu.ec/handle/123456789/4098>
2. Arenas, F., Pérez, R., & Vivas, H. (2016). Un modelo de redes neuronales para complementariedad no lineal. *Revista Integración*, 34(2), 169–185. <https://doi.org/10.18273/revint.v34n2-2016005>
3. Bailey, K. R., & Mair, R. G. (2007). Effects of frontal cortex lesions on action sequence learning in the rat. *European Journal of Neuroscience*, 25(9), 2905–2915. <https://doi.org/10.1111/j.1460-9568.2007.05492.x>
4. Cavalheiro, E. A., Silva, D. F., Turski, W. A., Calderazzo-Filho, L. S., Bortolotto, Z. A., & Turski, L. (1987). The susceptibility of rats to pilocarpine-induced seizures is age-dependent. *Developmental Brain Research*, 37(1–2), 43–58. [https://doi.org/10.1016/0165-3806\(87\)90227-6](https://doi.org/10.1016/0165-3806(87)90227-6)
5. Clifford, D. B., Olney, J. W., Maniotis, A., Collins, R. C., & Zorumski, C. F. (1987). The functional anatomy and pathology of lithium-pilocarpine and high-dose pilocarpine seizures. *Neuroscience*, 23(3), 953–968. [https://doi.org/10.1016/0306-4522\(87\)90171-0](https://doi.org/10.1016/0306-4522(87)90171-0)
6. Cook, Z., Zhao, C., Murray, L., Kesan, J., Belacel, N., Doesburg, S. M., Medvedev, G., Vakorin, V. A., & Xi, P. (2024). Decoding Brain Age: A Self-Supervised Graph Neural Network Framework for EEG Analysis. *2024 IEEE SENSORS*, 1–4. <https://doi.org/10.1109/SENSORS60989.2024.10784646>
7. Craik, A., He, Y., & Contreras-Vidal, J. L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: A review. *Journal of Neural Engineering*, 16(3), 031001. <https://doi.org/10.1088/1741-2552/ab0ab5>
8. Cui, Y., Liu, J., Luo, Y., He, S., Xia, Y., Zhang, Y., Yao, D., & Guo, D. (2020). Aberrant connectivity during pilocarpine-induced status epilepticus. *International Journal of Neural Systems*, 30(05), 1950029. <https://doi.org/10.1142/S0129065719500291>
9. Eraković, V., Župan, G., Varljen, J., Laginja, J., & Simonić, A. (2000). Lithium plus pilocarpine induced status epilepticus — biochemical changes. *Neuroscience Research*, 36(2), 157–166. [https://doi.org/10.1016/S0168-0102\(99\)00120-0](https://doi.org/10.1016/S0168-0102(99)00120-0)
10. Henni, K., Mezghani, N., Mitiche, A., Abou-Abbas, L., & Benazza-Ben Yahia, A. (2025). An effective deep neural network architecture for EEG-based recognition of emotions. *IEEE Access*, 13(January), 4487–4498. <https://doi.org/10.1109/ACCESS.2025.3525996>
11. Instituto Nacional de Neurología y Neurocirugía (INNN). (2024). *Día Internacional de la Epilepsia*. Recuperado de <https://www.gob.mx/innn/articulos/dia-internacional-de-la-epilepsia-294613>
12. Izaurieta, F., & Saavedra, C. (2000). *Redes neuronales artificiales*. Departamento de Física, Universidad de Concepción, Chile.
13. Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. <https://arxiv.org/pdf/1412.6980>
14. Kolb, B. (1984). Functions of the frontal cortex of the rat: A comparative review. *Brain Research Reviews*, 8(1), 65–98. [https://doi.org/10.1016/0165-0173\(84\)90018-3](https://doi.org/10.1016/0165-0173(84)90018-3)
15. López-Meraz, M. L., Rocha, L., Miquel, M., Hernández, M. E., Toledo Cárdenas, R., Coria-Ávila, G. A., García, L. I., Pérez Estudillo, C. A., Aranda Abreu, G. E., & Manzo, J. (2009). Conceptos básicos de la epilepsia. *Revista Médica de La Universidad Veracruzana*, 9(2), 31–37.

16. Niedermeyer, E., & Lopes da Silva, F. H. (2005). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* (5^a ed.). Lippincott Williams & Wilkins.
17. Noachtar, S., & Rémi, J. (2009). The role of EEG in epilepsy: A critical review. *Epilepsy & Behavior*, *15*(1), 22–33. <https://doi.org/10.1016/j.yebeh.2009.02.035>
18. Pal, D., Dean, J. G., Liu, T., Li, D., Watson, C. J., Hudetz, A. G., & Mashour, G. A. (2018). Differential role of prefrontal and parietal cortices in controlling level of consciousness. *Current Biology*, *28*(13), 2145–2152.e5. <https://doi.org/10.1016/j.cub.2018.05.025>
19. Poddar, K., Sharma, B., Gupta, S., & Angra, S. (2024). Optimizing Convolutional Neural Networks for EEG Classification in Schizophrenia Diagnosis. *2024 4th International Conference on Sustainable Expert Systems (ICSES)*, 1286–1290. <https://doi.org/10.1109/ICSES63445.2024.10763226>
20. Rajwal, S., & Aggarwal, S. (2023). Convolutional Neural Network-Based EEG Signal Analysis: A Systematic Review. *Archives of Computational Methods in Engineering*, *30*(6), 3585–3615. <https://doi.org/10.1007/s11831-023-09920-1>
21. Ríos, P. L., & Álvarez, D. C. (2013). Aporte de los distintos métodos electroencefalográficos (eeg) al diagnóstico de las epilepsias. *Revista Médica Clínica Las Condes*, *24*(6), 953–957. [https://doi.org/10.1016/S0716-8640\(13\)70249-9](https://doi.org/10.1016/S0716-8640(13)70249-9)
22. Scorza, F. A., Arida, R. M., Priel, M. R., Calderazzo, L., & Cavalheiro, E. A. (2002). Glucose utilisation during status epilepticus in an epilepsy model induced by pilocarpine: A qualitative study. *Arquivos de Neuro-Psiquiatria*, *60*(2A), 198–203. <https://doi.org/10.1590/S0004-282X2002000200003>
23. Torrealba, F., & Valdés, J. L. (2008). The parietal association cortex of the rat. *Biological Research*, *41*(4). <https://doi.org/10.4067/S0716-97602008000400002>
24. Turski, W. A., Cavalheiro, E. A., Schwarz, M., Czuczwar, S. J., Kleinrok, Z., & Turski, L. (1983). Limbic seizures produced by pilocarpine in rats: Behavioural, electroencephalographic and neuropathological study. *Behavioural Brain Research*, *9*(3), 315–335. [https://doi.org/10.1016/0166-4328\(83\)90136-5](https://doi.org/10.1016/0166-4328(83)90136-5)
25. Wani, F. M., & Karki, M. V. (2024). EEG signal analysis for epilepsy detection using deep neural networks. *2024 5th International Conference on Circuits, Control, Communication and Computing (I4C)*, 213–218. <https://doi.org/10.1109/I4C62240.2024.10748439>
26. World Health Organization. (2024). *Epilepsy*. Recuperado de <https://www.who.int/es/news-room/fact-sheets/detail/epilepsy>
27. Zavala-Tecuapetla, C., & López-Meraz, M. L. (2011). Modelos experimentales de epilepsia en ratas en desarrollo. *Revista ENeurobiología*, *2*(4), 190811.