

Modelo de red neuronal para evaluar convulsiones epilépticas utilizando señales neuro-fisiológicas, en grupos específicos de personas

Neural Network Model for the Evaluation of Epileptic Seizures Using Neurophysiological Signals in Targeted Population Groups

Elinar Carrillo Riveros¹

Universidad Nacional de San Cristóbal de Huamanga, Ayacucho
<https://orcid.org/0000-0002-4687-362X>
elinar.carrillo@unsch.edu.pe

Edith F. Guevara Morote²

Universidad Nacional de San Cristóbal de Huamanga, Ayacucho
<https://orcid.org/0000-0003-4237-7861>
edith.guevara@unsch.edu.pe

Juan Carlos Carreño Gamarra³

Universidad Nacional de San Cristóbal de Huamanga, Ayacucho
<https://orcid.org/0000-0001-9403-8170>
juan.carrenno@unsch.edu.pe

José Elías Yauri Vidalón⁴

Universidad Nacional de San Cristóbal de Huamanga, Ayacucho
<https://orcid.org/0000-0001-6287-7797>
jose.yauri@unsch.edu.pe

Instituto de instigación: FIMGC, Grupo de investigación: Inteligencia Artificial, Área de investigación: Ingeniería de Sistemas, Línea de Investigación: Inteligencia Artificial

Resumen

Este artículo presenta un modelo de red neuronal para evaluar convulsiones epilépticas utilizando señales neurofisiológicas registradas mediante electroencefalogramas (EEG). La investigación utiliza el Dataset público CHB-MIT, que contiene más de 980 horas de grabaciones EEG de 24 pacientes epilépticos.

Se implementaron dos enfoques de evaluación: validación cruzada y evaluación a nivel de población de pacientes. Los resultados muestran un rendimiento excepcional en validación cruzada (96.22% de sensibilidad y 99.6% de especificidad), mientras que a nivel de población se alcanzó una sensibilidad de 81.35% y especificidad de 88.57% excluyendo el 20% de pacientes con alta variabilidad.

1 Maestro en Ingeniería de Sistemas Mención en Informática.

2 Maestro en Ingeniería de Sistemas Mención en Informática.

3 Maestro en Ingeniería de Sistemas Mención en Informática.

4 Doctor en el programa de Doctorado en Informática

El modelo propuesto supera significativamente a trabajos previos, especialmente en métricas críticas como la Precisión+. Esta investigación revela tanto el potencial como las limitaciones de los sistemas automatizados para el diagnóstico de epilepsia, destacando la heterogeneidad neurológica individual como el principal desafío para la generalización algorítmica.

Palabras claves: Red neuronal, convulsiones epilépticas, electroencefalogramas (EEG)

Abstract

This article presents a neural network model to assess epileptic seizures using neurophysiological signals recorded by electroencefalogramas (EEG). The research uses the public CHB-MIT dataset, which contains more than 980 hours of EEG recordings from 24 epileptic patients.

Two evaluation approaches were implemented: cross-validation and patient population-level evaluation. The results show exceptional performance in cross-validation (96.22% sensitivity and 99.6% specificity), while at the population level a sensitivity of 81.35% and specificity of 88.57% were achieved excluding 20% of patients with high variability.

The proposed model significantly outperforms previous work, especially in critical metrics such as Accuracy+. This research reveals both the potential and limitations of automated systems for epilepsy diagnosis, highlighting individual neurological heterogeneity as the main challenge for algorithmic generalization.

Keywords: Neural network, epileptic seizures, electroencefalogramas (EEG)

I. Introducción

La epilepsia representa uno de los trastornos neurológicos más prevalentes en el mundo, afectando aproximadamente a 50 millones de personas según la Organización Mundial de la Salud (WHO, 2024). Esta condición se caracteriza por convulsiones súbitas acompañadas frecuentemente de pérdida de consciencia, desmayos y salivación, circunstancias que requieren atención inmediata para evitar complicaciones mayores (Cascino et al., 2021). La falta de atención oportuna incrementa significativamente el riesgo de muerte por epilepsia (Louis et al., 2016). Aunque la epilepsia no es contagiosa, persiste una considerable desinformación que ha contribuido a una elevada estigmatización y exclusión social de los pacientes (Bandstra et al., 2008; Kaculini et al., 2021). Este estigma social, junto con las limitaciones en la actividad diaria que impone la enfermedad, reduce drásticamente la calidad de vida de quienes la padecen (Kerr, 2012). La detección temprana de la epilepsia juega un papel crucial en el manejo efectivo de la condición. Según

datos de la OMS, aproximadamente el 70% de los pacientes diagnosticados con epilepsia podrían evitar las convulsiones siguiendo un tratamiento adecuado (Silvani et al., 2016). Sin embargo, el diagnóstico preciso de esta condición representa un desafío significativo debido a la variabilidad en sus manifestaciones clínicas y neurofisiológicas. La electroencefalografía (EEG) es actualmente la técnica más accesible y común para el diagnóstico de epilepsia y otras enfermedades cerebrales, debido a su bajo costo tanto en equipamiento como en pruebas (Louis et al., 2016). No obstante, la interpretación manual de los EEG es un proceso que consume tiempo y requiere especialistas altamente capacitados, además de estar sujeto a variabilidad entre observadores. En este contexto, los avances en inteligencia artificial, particularmente en el campo del aprendizaje profundo, ofrecen una prometedora alternativa para automatizar y mejorar el proceso de detección de patrones epilépticos en señales EEG (Rim et al., 2020). Los modelos de redes neuronales han demostrado capacidad para reconocer

patrones complejos en diversos tipos de datos, incluyendo señales neurofisiológicas.


Este estudio describe y caracteriza un modelo de red neuronal para diagnosticar convulsiones epilépticas mediante señales neurofisiológicas recolectadas utilizando EEG. La investigación es de tipo aplicada, a nivel explicativo, con un diseño experimental de tipo preexperimental en un grupo específico de pacientes. Para evaluar la factibilidad del modelo neuronal propuesto, se utiliza el dataset público de epilepsia CHB-MIT (Shoeb & Guttag, 2010), que contiene más de 980 horas de grabación EEG recolectados de 24 pacientes epilépticos de diferentes edades.

II. Materiales y métodos

La investigación se enmarca en el nivel explicativo, empleando métodos experimentales de aprendizaje profundo. El objetivo central fue proponer un modelo de red neuronal capaz de diagnosticar patrones epilépticos mediante un aprendizaje significativo de los datos. Así mismo, la muestra de estudio estuvo conformada por 24 pacientes diagnosticados con epilepsia, cuyos datos fueron obtenidos de la Base de Datos de EEG Escalp de CHB-MIT.

Arquitectura del modelo neuronal

El modelo de red neuronal propuesto integra componentes para el procesamiento espacial y temporal de las señales EEG.



Diseño experimental

Se realizaron dos experimentos principales para validar la propuesta:

- Selección del mejor método de fusión de canales EEG:** En este experimento se evaluaron las cinco estrategias de fusión mencionadas para determinar cuál proporcionaba el mejor rendimiento en la detección de epilepsia.
- Clasificación de señales EEG:** Una vez identificada la mejor estrategia de fusión, se realizaron experimentos adicionales para determinar qué combinación de bandas de frecuencia proporcionaba los mejores resultados.

Enfoque de evaluación

El modelo se evaluó mediante dos enfoques distintos:

- Validación cruzada:** Se implementó una validación cruzada con $k=5$ para evaluar el

desempeño general del modelo utilizando la mayor cantidad de datos posible. En este enfoque no se consideró la pertenencia de los datos a pacientes específicos.

- Evaluación a nivel de población:** Se utilizó un esquema de dejar un paciente fuera para evaluar la capacidad de generalización del modelo. Los datos de un paciente se utilizaron como conjunto de prueba mientras que los datos de los pacientes restantes se emplearon para el entrenamiento.

Parámetros de entrenamiento

Los modelos se entrenaron utilizando la función de coste de entropía cruzada, implementando una ponderación para compensar el desequilibrio entre las clases. Se utilizó el optimizador Adam con un tamaño de lote de 128. Cada modelo se entrenó durante 100 épocas con una tasa de aprendizaje de 0.00001.

Métricas de evaluación

El rendimiento del modelo se evaluó mediante las siguientes métricas:

- Sensibilidad (capacidad para detectar correctamente convulsiones)
- Especificidad (capacidad para identificar correctamente ausencia de convulsiones)
- Precisión+ (precisión en la detección de convulsiones)
- Precisión- (precisión en la detección de no-convulsiones)

- F1+ (media armónica de precisión y sensibilidad para la clase positiva)
- F1- (media armónica de precisión y especificidad para la clase negativa)
- Exactitud (proporción total de predicciones correctas)

III. Resultados y discusión**Resultados a nivel de validación cruzada**

El modelo propuesto demostró un desempeño excepcional en la evaluación mediante validación cruzada.

Tabla 1

Resultados de la clasificación a nivel de validación cruzada

Sensibilidad (%)	Especificidad (%)	Precisión+ (%)	Precisión- (%)	F1+ (%)	F1- (%)	Exactitud (%)
96.22±0.37	99.6±0.02	95.39±0.21	99.67±0.03	95.8±0.14	99.63±0.01	99.32±0.02

Como se muestra en la tabla 1 el modelo posee una capacidad sobresaliente para discriminar entre segmentos con convulsiones y sin convulsiones cuando se evalúa mediante validación cruzada. La alta sensibilidad (96.22%) sugiere que el modelo rara vez falla en detectar convulsiones, mientras que la alta especificidad (99.6%) indica que raramente

clasifica incorrectamente segmentos normales como convulsiones.

Resultados a nivel de población de pacientes

El modelo muestra un desempeño con mayor variabilidad, como era esperado debido a la heterogeneidad en los patrones epilépticos entre pacientes.

Tabla 2

Resultados resumidos a nivel de población (100% de pacientes)

Sensibilidad (%)	Especificidad (%)	Precisión+ (%)	Precisión- (%)	F1+ (%)	F1- (%)	Exactitud (%)
68.03±30.74	90.71±17.26	45.05±36.27	99.33±0.86	42.21±30.63	93.67±13.23	90.25±16.9

La Tabla 2 resume los resultados para todos los pacientes (100%), estos resultados individuales, se identificaron 5 pacientes (20% del total) que presentaban una alta

variabilidad en la sensibilidad. Estos fueron clasificados como “pacientes difíciles” y excluidos del análisis final.

Tabla 3

Resultados de la clasificación en 80% de la población

Sensibilidad (%)	Especificidad (%)	Precisión+ (%)	Precisión- (%)	F1+ (%)	F1- (%)	Exactitud (%)
81.35±15.8	88.57±18.89	42.41±33.18	99.52±0.61	47.45±30.55	92.34±14.65	88.34±18.6

Comparación con métodos previos

El modelo propuesto fue comparado con tres arquitecturas neuronales recientes: Chakrabarti et al. (2021), Gao et al. (2019), y Hossain et al. (2019). La comparación se realizó tanto a nivel de validación cruzada como a nivel de población de pacientes.

A nivel de validación cruzada, el rendimiento de Chakrabarti et al. (2021)

fue similar al del modelo propuesto, aunque ligeramente superior en sensibilidad. Sin embargo, nuestro modelo lo superó en Precisión+. Los otros dos métodos mostraron un desempeño inferior en todas las métricas.

A nivel de población de pacientes, nuestro modelo superó significativamente a los tres métodos comparados, especialmente en sensibilidad y Precisión+. La Tabla 4 resume esta comparación.

Tabla 4

Nivel de población en 80% de pacientes: comparación con métodos recientes

Autor	Sensibilidad (%)	Especificidad (%)	Precisión+ (%)	Precisión- (%)	F1+ (%)	F1- (%)	Exactitud (%)
Nuestro	81.35±15.8	88.57±18.8	42.41±33.1	99.52±0.6	47.45±30.5	92.34±14.6	88.34±18.6
Chakrabarti et al. (2021)	70.22±25.1	89.76±12.6	21.43±14.9	99.3±0.83	30.1±18.83	93.77±7.89	89.32±12.2
Gao et al. (2019)	79.08±15.6	81.77±21.0	20.21±19.1	99.41±0.7	28.15±20.3	87.96±16.4	81.75±20.6
Hossain et al. (2019)	76.67±21.02	86.34±15.64	19.66±14.63	99.43±0.75	28.91±19.62	91.56±10.65	86.11±15.27

IV. Discusión

Los resultados obtenidos revelan varias implicaciones relevantes. En primer lugar, la marcada diferencia entre el rendimiento en validación cruzada (96.22% de sensibilidad) y el alcanzado a nivel de población (81.35% de sensibilidad) pone de manifiesto las limitaciones inherentes de los métodos de validación cruzada cuando se aplican a problemas clínicos complejos. Este hallazgo coincide con las observaciones de Birhane (2021), quien advierte que los procedimientos de validación aparentemente neutrales pueden encubrir sesgos estructurales que afectan la fiabilidad de los resultados.

Asimismo, la elevada variabilidad observada entre pacientes confirma la naturaleza heterogénea de la epilepsia y sus manifestaciones neurofisiológicas. La exclusión del 20% de los pacientes debido a su alta variabilidad refleja un desafío fundamental en el desarrollo de sistemas automatizados de diagnóstico: la diversidad neurobiológica individual que resiste la estandarización algorítmica y limita la

generalización de los modelos.

A pesar de estas dificultades, el modelo propuesto superó de manera consistente a los métodos previos, especialmente en métricas críticas como la Precisión+. Este rendimiento mejorado puede atribuirse a la estrategia de fusión de canales implementada y al enfoque de evaluación a nivel de paciente, que en conjunto proporcionan una perspectiva más realista sobre el desempeño del sistema en escenarios clínicos.

Por último, aunque el modelo demuestra un potencial significativo para la detección automática de convulsiones epilépticas, la persistencia de falsos positivos y falsos negativos, en particular en ciertos pacientes, resalta la necesidad de concebir estos sistemas como herramientas de apoyo al diagnóstico médico y no como sustitutos de la evaluación clínica. Esta postura se alinea con la perspectiva de Mitchell (2021), quien sostiene que “la búsqueda del equilibrio óptimo entre generalización y especificidad no constituye un problema meramente técnico, sino un terreno de disputa donde se negocian

implícitamente visiones contrapuestas sobre qué tipos de conocimiento merece ser representados y reproducidos” (p. 56).

V. Conclusiones

El modelo de red neuronal propuesto demuestra una capacidad significativa para diagnosticar convulsiones epilépticas a través de señales EEG. Los resultados revelan una arquitectura que supera a los modelos de referencia en términos de sensibilidad y precisión, particularmente en la métrica crítica de Precisión+ donde casi duplica el rendimiento de los métodos alternativos.

La evaluación a nivel de validación cruzada muestra un rendimiento excepcional con 96.22% de sensibilidad y 99.6% de especificidad. Sin embargo, esta validación también revela las limitaciones epistemológicas inherentes a dichos métodos cuando se descontextualizan de la heterogeneidad clínica real.

La evaluación a nivel de población demuestra una sensibilidad de 81.35% y una especificidad de 88.57% excluyendo el 20% de pacientes con alta variabilidad. Este desempeño, significativamente superior a los modelos comparados, revela tanto las capacidades como las limitaciones del enfoque propuesto.

Los resultados evidencian que la variabilidad entre pacientes constituye el principal desafío para la generalización del modelo. Esta heterogeneidad no representa meramente un obstáculo técnico sino una manifestación de la diversidad neurológica inherente que resiste la estandarización algorítmica.

VI. Agradecimiento

Los autores agradecen a la Universidad Nacional de San Cristóbal de Huamanga por el apoyo institucional, y al equipo de PhysioNet por el acceso al dataset CHB-MIT, esencial para esta investigación. Se reconoce también la contribución de estudios previos que sustentaron la metodología y las valiosas sugerencias de los revisores anónimos.

VII. Contribuciones de los autores

Elinar Carrillo Riveros concibió y formuló la idea de investigación, además de diseñar la metodología y la arquitectura del modelo neuronal. También coordinó la ejecución del proyecto y realizó la supervisión general del estudio.

Edith F. Guevara Morote participó en la revisión y sistematización del marco teórico, contribuyó en la redacción de la introducción y discusión, y se encargó de la revisión crítica del manuscrito para garantizar su coherencia académica.

Juan Carlos Carreño Gamarra se responsabilizó de la implementación técnica del modelo neuronal, el procesamiento de las señales EEG y la ejecución de los experimentos computacionales.

José Elías Yauri Vidalón desarrolló el análisis estadístico de los resultados, elaboró las tablas comparativas y colaboró en la interpretación de los hallazgos, además de participar en la revisión final del documento.

VIII. Referencias

- Bandstra, N. F., Camfield, C. S., & Camfield, P. R. (2008). Stigma of Epilepsy. *Canadian Journal of Neurological Sciences*, 35(4), 436–440. <https://doi.org/10.1017/S0317167100009082>
- Birhane, A. (2021). Algorithmic injustice: A relational ethics approach. *Patterns*, 2(2), 100205.
- Cascino, G., Sirven, J. I., & Tatum, W. O. (2021). *Epilepsy* (2nd ed.). Wiley.
- Chakrabarti, S., Swetapadma, A., & Pattnaik, P. K. (2021). LSTM based epileptic seizure detection using EEG signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 927-936. <https://doi.org/10.1109/TNSRE.2021.3072145>
- D'Ignazio, C., & Klein, L. F. (2020). *Data feminism*. MIT Press.
- Gao, H., Yüce, A., & Thiran, J. P. (2019). Detecting temporal and spatial features of EEG signals for driver

- fatigue detection. *IEEE Transactions on Biomedical Engineering*, 66(4), 977-987. <https://doi.org/10.1109/TBME.2018.2864853>
- Hossain, M. S., Amin, S. U., Alsulaiman, M., & Muhammad, G. (2019). Applying deep learning for epilepsy seizure detection and brain mapping visualization. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 15(1), 1-17. <https://doi.org/10.1145/3241056>
- Kaculini, C. M., Tate-Looney, A. J., & Seifi, A. (2021). The History of Epilepsy: From Ancient Mystery to Modern Misconception. *Cureus*, 13(3). <https://doi.org/10.7759/CUREUS.13953>
- Kerr, M. P. (2012). The Impact of Epilepsy on Patients' Lives. *Acta Neurologica Scandinavica*, 126(S194), 1–9. <https://doi.org/10.1111/ANE.12014>
- Louis, E. K. St., Frey, L. C., Britton, J. W., Frey, L. C., Hopp, J. L., Korb, P., Koubeissi, M. Z., Lievens, W. E., Pestana-Knight, E. M., & Louis, E. K. St. (2016). *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*. American Epilepsy Society.
- Mitchell, M. (2021). *Artificial intelligence: A guide for thinking humans*. Penguin Books.
- Rim, B., Sung, N., Min, S., & Hong, M. (2020). Deep Learning in Physiological Signal Data: A Survey. *Sensors*, 20(4), 969. <https://doi.org/10.3390/s20040969>
- Shoeb, A., & Guttag, J. (2010). Application of Machine Learning to Epileptic Seizure Detection. *ICML'10: Proceedings of the 27th International Conference on International Conference on Machine Learning*, 975-982.
- Silvani, A., Calandra-Buonaura, G., Dampney, R. A. L., & Cortelli, P. (2016). *Brain-Heart Interactions: Physiology and Clinical Implications*. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 374(2067). <https://doi.org/10.1098/RSTA.2015.0181>
- World Health Organization. (2024). *Epilepsy*. Health Topics. <https://www.who.int/news-room/fact-sheets/detail/epilepsy>

