

**Detección de Artefactos Oculares en Señales Electroencefalográficas Usando Redes Neuronales**  
**Detection of Ocular Artifacts in Electroencephalographic Signals Using Neural Networks**

Julián Andrés Ramírez Ramírez  
Universidad Tecnológica Latinoamericana en Línea (UTEL)

Noé Amir Rodríguez Olivares  
Universidad Tecnológica Latinoamericana en Línea (UTEL)

**RESUMEN**

Este artículo aborda de manera teórica la dificultad que representa para el correcto análisis e interpretación de las señales de electroencefalograma (EEG); la presencia de los artefactos oculares tales como el parpadeo entre otros. Esta condición se manifiesta porque los movimientos oculares se reflejan en la señal EEG como un ruido o interferencia que afecta la información de interés, dificultando así el diagnóstico e identificación de patologías neurológicas tales como la epilepsia. Las interferencias involuntarias en las señales de EEG a las que se hace alusión, son conocidas como artefactos (López et al., 2014).

Es necesario entonces desarrollar algoritmos que permitan detectar estos eventos no deseados. Este artículo presenta el diseño, entrenamiento y validación de una red neuronal aplicada como clasificador, que permite la identificación de artefactos producidos por movimientos oculares. Así mismo, se evaluó el desempeño de dicha red mediante una matriz de confusión y a partir de esta, se analizó el desempeño del algoritmo de clasificación comparándolo con otras técnicas utilizadas en la solución del problema que aquí se plantea y se obtuvieron métricas como la exactitud, la sensibilidad y la especificidad entre otros.

Las señales fueron obtenidas a partir de exámenes de electroencefalograma (EEG) realizados en diferentes pacientes con diagnóstico de epilepsia, el set de datos comprende 184 señales de las cuales 120 fueron usadas para el entrenamiento de la red neuronal y 64 para la prueba de la misma (INDEC, 2017). Finalmente se presentan gráficas que muestran el desempeño de la red y se presentan las conclusiones del trabajo de investigación.

**Palabras clave:** *Electroencefalograma, Artefactos, Red neuronal, Matriz de confusión, Movimiento ocular.*

**ABSTRACT**

This paper addresses in a theoretical way the difficulty that represents the correct analysis and interpretation of electroencephalogram (EEG) signals and the presence of ocular artifacts such as blinking, among others. This difficulty is manifested because eye movements are reflected in the EEG signal as noise or interference that affects the information of interest, thus hindering the diagnosis and identification of neurological pathologies such as epilepsy. The involuntary interferences in EEG signals are known as artifacts (Lopez et al., 2014).

It is necessary to develop algorithms to detect these unwanted events. This article presents the design, training and validation of a neural network applied as a classifier, which allows the identification of artifacts produced by eye movements. Likewise, the performance of this network was evaluated by means of a confusion matrix. From this, the performance of the classification algorithm was analyzed by comparing it with other techniques used in the solution of the problem presented here. Metrics such as accuracy, sensitivity and specificity, among others, were obtained.

The signals were obtained from electroencephalogram (EEG) examinations performed on different patients diagnosed with epilepsy. The dataset comprises 184 signals, of which 120 were used for neural network training and 64 for neural network testing (INDEC, 2017).

Finally, graphs showing the network's performance are presented, and the conclusions of the research work are presented.

**Keywords:** *Electroencephalogram, artifacts, neural network, confusion matrix, eye movement.*

## **Introducción**

En 1929, Hans Berger acuñó el término electroencefalograma (EEG) para describir las fluctuaciones eléctricas en el cerebro captadas por unos electrodos fijados en el cuero cabelludo (Ramos-Argüelles et al., 2009). El EEG es un examen que se caracteriza por permitir la medición de los potenciales que reflejan la actividad eléctrica del cerebro humano, razón por la cual es una de las herramientas más importantes para diagnosticar desórdenes neurológicos como la epilepsia entre otros (Pérez Sánchez, 2021). Las señales EEG son resultado de la actividad sináptica de las neuronas y entrega como resultado la medición de las corrientes eléctricas que fluyen durante la sinapsis entre neuronas piramidales en la corteza cerebral; aunque la magnitud de estas corrientes es muy pequeña, la suma de las actividades de muchas neuronas genera un campo eléctrico que es medible sobre la superficie del cuero cabelludo (Delgado Saa, 2009).

La identificación y caracterización de la actividad cerebral por medio de un EEG constituye un modo particular de entender, no solo la actividad mental del ser humano, sino también la actividad motora del mismo (Maureira Cid & Flores Ferro, 2018). Esto permite descifrar el origen de comportamientos motores normales y anormales, con lo cual se pueden describir y entender algunas patologías del sistema nervioso. Dicho de otro modo, la actividad eléctrica cerebral es la responsable, entre otras cosas, de funciones básicas del movimiento tales como la contracción y relajación muscular (Alagia Gimeno, 2018); y en ese sentido, es de esperar que los movimientos normales de cualquier ser humano puedan percibirse con

ciertos patrones de onda eléctrica en la señal cerebral; sin embargo cuando hay presencia de eventos motores anormales como los generados por patologías como la epilepsia, los patrones de las señales resultan alterados y esto ayuda a entender la enfermedad y a definir métodos diagnósticos más exactos (CORDIS, s.f).

Si bien es posible realizar la medición de la actividad eléctrica cerebral, es claro que dichas señales en su forma natural tienen múltiples perturbaciones que pueden distorsionar la información realmente importante del EEG. Estas distorsiones, en la mayoría de los casos son producidas por otras señales eléctricas propias del paciente o de otros dispositivos; estas distorsiones se denominan artefactos (López et al., 2014).

El problema que presentan los EEG ante la presencia de artefactos se debe a que este es un registro de una señal que posee una resolución temporal muy alta por lo cual resulta fácil de contaminar con señales no deseadas, esto dificulta el diagnóstico de enfermedades o la construcción de interfaces cerebro computador que se elaboran a partir de señales EEG, en otras palabras, los artefactos son un obstáculo que es necesario evitar para potencializar el análisis e interpretación de la señal eléctrica cerebral (Jiang Xiao et al., 2019).

Actualmente, los equipos de registro de EEG poseen filtros digitales para prevenir la contaminación de las señales, sin embargo, estas siguen siendo afectadas especialmente por otras señales motoras provenientes del paciente tales como las producidas por los artefactos generados por el movimiento ocular entre otros (Rodríguez Aldana et al., 2013).

Las interferencias involuntarias en las señales de EEG o artefactos, en la mayoría de los casos están relacionados con movimientos corporales de la persona que se realiza el examen; así mismo, constituyen una fuente de ruido que empeora los resultados del análisis de la señal; puede decirse que un artefacto es cualquier potencial eléctrico que no se origina en el cerebro sino en otras áreas del cuerpo o incluso en fuentes externas al mismo. Esto implica que pueden distinguirse al menos dos tipos de artefactos, los fisiológicos que son producidos por el funcionamiento normal del cuerpo y los no fisiológicos que son producidos por ruido ambiente (López et al., 2014).

Los artefactos de interés para el presente trabajo son los fisiológicos, específicamente, aquellos que son generados por los movimientos oculares, estos son los más comunes y aparecen en la mayoría de los registros EEG durante algunos minutos y hacen que se presente una distorsión en el espectro de la señal, llevando a la detección de trascendentes no estacionarios que son difíciles de distinguir de los eventos epileptiformes u otros (Rodríguez Aldana et al., 2013).

La información anterior constituye un argumento lo suficientemente fuerte como para afirmar que la detección y corrección de los artefactos resulta fundamental para mejorar la interpretación de los resultados de un EEG, es en este punto donde resulta interesante abordar el problema que aquí se plantea.

Algunos de las técnicas computacionales que se han utilizado para el procesamiento de señales de la actividad eléctrica cerebral incluyen algoritmos de inteligencia artificial (Agudelo Maldonado et al., 2022) y técnicas para la extracción de las características que consisten en diferentes combinaciones y transformaciones sobre la señal cerebral adquirida

(Pérez Sánchez, 2021); algunas técnicas incluyen el análisis de componentes independientes, patrones espaciales comunes, transformada de Fourier, filtros adaptativos, entre otros (Henríquez Muñoz, 2014). En cualquiera de los casos, de acuerdo a lo que se pretenda detectar en un EEG mediante un sistema computacional, es necesario lograr que la señal de actividad eléctrica cerebral se adapte a condiciones estándares que permitan el correcto funcionamiento de los algoritmos. Para tal fin antes de realizar cualquier procesamiento, es necesario garantizar que la señal está libre de contaminación y es apta para el análisis.

Con el objetivo de detectar los artefactos producidos por movimientos oculares, en el presente trabajo se plantea el diseño y entrenamiento de una red neuronal capaz de detectarlos en señales electroencefalográficas; dicha red fue entrenada y su efectividad en la tarea de clasificación de las señales fue analizada mediante la construcción de una matriz de confusión que permita extraer las principales métricas del algoritmo desarrollado. En las siguientes secciones se presentan los fundamentos teóricos que soportan el presente trabajo, la metodología utilizada para el desarrollo del mismo, los resultados obtenidos y finalmente se presentan la discusión y las conclusiones más relevantes que se obtuvieron después de realizar el desarrollo propuesto.

### ***Fundamentos Teóricos***

En su forma más simple, un artefacto es una señal de ruido que altera y afecta el contenido de una señal biomédica. Se denominan artefactos a las alteraciones que se observan en la señal y que realmente no son producidos por la actividad eléctrica de interés, sino que se generan por agentes externos tales como la disposición de los electrodos, el continuo movimiento del paciente entre otros (Palma Bustamante, 2020). Para el caso del EEG, un artefacto es una onda en el trazado que no es de origen cerebral (Sánchez & Hernández, 2017). Pueden clasificarse en artefactos de origen no fisiológico que se generan por campos electromagnéticos fuera del cuerpo y fisiológico que se generan a partir de la actividad normal del cuerpo por ejemplo movimiento de parpadeo, la respiración, el movimiento de la lengua, el potencial de la piel, el temblor en el cuerpo, la actividad cardiaca, la actividad muscular, las glándulas sudoríparas, el pulso en los tejidos, la contracción de los músculos del cuero cabelludo, la cara, la mandíbula y el cuello. (Quintero Rincón et al., 2012).

Existen una variedad de técnicas eficientes para la eliminación de artefactos de origen fisiológicos; estas técnicas han sido descritas en diversas publicaciones y su buen desempeño ha sido demostrado en diversas áreas (Jiang Xiao et al., 2019). No obstante, este artículo pretende probar el desempeño de una técnica simple que mediante el uso de métricas estadísticas tales como el promedio, la varianza, la mediana, la desviación estándar entre otras; combinada con el diseño entrenamiento de una red neuronal, pretende identificar la presencia de artefactos de origen ocular en canales específicos de una señal electroencefalográfica.

Los artefactos más comunes, que se desean detectar mediante el trabajo que se presenta en este artículo, son los causados por los movimientos involuntarios del cuerpo. Entre estos se destacan los causados por el movimiento del globo ocular al momento de producirse un evento de parpadeo.

## ***Artefactos por Movimiento Ocular***

El artefacto producido por el parpadeo es consecuencia del fenómeno de Bell (Schomer & López Da Silva, 2011), el globo ocular actúa como un dipolo: el polo positivo orientado anteriormente, en la córnea y el polo negativo orientado posteriormente, en la retina. Cuando un individuo parpadea, el globo ocular rota hacia arriba, generando una corriente alternante de alta amplitud que es detectada por cualquier electrodo ubicado cerca de los ojos, es decir en la región frontal (Sánchez & Hernández, 2017). Estos cambios afectan principalmente los electrodos FP1, FP2, F3, F4 y F7 induciendo en ellos frecuencias altas y bajas dependiendo de la duración del parpadeo (Quintero Rincón et al., 2012).

Dicho de otro modo, los artefactos oculares aquí presentados se deben a que en el globo ocular existe una diferencia de potencial entre la córnea (positiva), en el polo anterior y el epitelio pigmentario de la retina (negativo), en el polo posterior (Perez, 1998). Esa diferencia de potencial permite considerar al ojo como un dipolo y representarlo como un vector sobre su eje anteroposterior. El campo eléctrico generado por este dipolo es el que se registra mediante electrodos ubicados alrededor de la órbita del ojo (Gila et al., 2009).

La Figura 1 muestra la representación gráfica del dipolo formado por la córnea y la retina del ojo

*Figura 1. Modelo del ojo como un dipolo Tomado de Evaluación de los problemas vestibulares. Movimientos oculares normales y sistemas que participan (p.5), Por. (Pereira & Porras, s.f.).*

*Un artefacto producido por movimiento ocular aparece en la señal EEG en una forma igual o similar a la de la Figura 2.*

*Figura 2. Artefactos producidos por movimiento ocular en el registro electroencefalográfico de un paciente con diagnóstico de epilepsia.*

La Figura 3 corrobora la forma de los eventos eléctricos producidos por el movimiento ocular es presentada por (Estupinan Donoso, 2009) en la cual se puede observar en primer lugar el artefacto por movimiento ocular, la señal de referencia y una señal EEG corregida o sin la presencia de artefactos oculares.

*Figura 3. Señal de movimiento ocular obtenida a partir de electrooculograma (EOG), señal de EEG contaminado por artefacto ocular y señal EEG libre de artefactos. Tomado de Reducción de Artefactos Oculares en Señales EEG: Filtrado Adaptativo Como Alternativa a la Regresión Lineal (p.3), Por Estupinan Donoso, A. 2009. Hall Open Science*

Este tipo de artefactos son los que en este trabajo se caracterizan mediante métricas estadísticas tales como la media, la varianza, la mediana y la desviación estándar entre otras; para posteriormente detectarlos mediante una red neuronal multicapa tipo MISO (por la descripción en inglés de *Múltiple Input Single Output*).

## **Metodología**

En el presente trabajo se desarrolló e implementó una red neuronal tipo perceptrón multicapa de múltiples entradas y una sola salida, que permite detectar artefactos producidos por movimientos oculares en diferentes señales EEG. Para tal fin se utilizaron 184 señales las cuales contienen información de la actividad eléctrica cerebral entre en el canal FP1 y F7 (INDEC, 2017). Pese a que el equipo utilizado para la adquisición de las señales puede registrar hasta 22 canales de información, distribuidos en las regiones parietal, occipital, temporal y frontal de la cabeza; se seleccionaron los canales ya mencionados dado que es en la región frontopolar y frontal anterior donde aparecen la mayoría de los artefactos por movimientos oculares (Morrillo, s.f.).

Las señales EEG usadas en el estudio fueron obtenidas con un equipo Clínica EEG Admin Cadwell Easy III de 22 canales, el cual permite la obtención de señales sincronizadas con video, permitiendo así una fácil identificación del momento del parpadeo para contrastarlo visualmente con los cambios en la señal. El set de datos utilizado no había sido usado previamente en otros trabajos de investigación pues este se obtuvo en tiempo real de la mano de especialistas en neurología.

Todas las señales obtenidas tienen características que fueron predeterminadas por el equipo electroencefalográfico o por los usuarios al momento de extraer las muestras directamente desde el software.

Dichas características son las siguientes

- Señales a usar en el estudio: 184
- Canal Utilizado: FP1 - F7
- Tiempo total de la señal: 10 segundo
- Tiempo de muestreo: 250 muestras/s
- Formato de la señal: edf (European Data File)

Adicionalmente, el equipo de registro de EEG, realizó un proceso de filtrado de supresión de banda tipo Notch con el cual se hace una eliminación de los artefactos no fisiológicos. En el grupo de las 184 señales bajo estudio, 94 presentaban artefactos por movimiento ocular y las otras 90 estaban libres de este tipo de artefacto.

Para ilustrar visualmente la diferencia en las señales que se desea identificar con la red neuronal; en la Figura 4 se presenta una señal con un artefacto por movimiento ocular tipo parpadeo y una señal libre de dicho artefacto

*Figura 4. Ejemplo de señales con y sin presencia de artefactos oculares en el registro electroencefalográfico de un paciente con diagnóstico de epilepsia.*

Para la detección de este tipo de artefactos en las señales EEG, se diseñó una red neuronal que puede realizar una clasificación a partir de ciertas variables que ingresan a su capa de entrada. Resulta útil mencionar que la entrada de la red neuronal no puede ser la totalidad de la señal, dado que los registros utilizados cuentan con 2500 muestras y hacer uso de la

totalidad de las mismas para el diseño de la red supone un costo computacional muy alto que no representa un beneficio real en aplicaciones prácticas.

Por lo anterior, fue necesario extraer un número limitado de características de cada señal para alimentar la red neuronal. Se decidió poner a prueba un método alternativo el cual no aparece en ninguno de los documentos consultados pero que resulta útil para lograr los fines de este trabajo y proponer alternativas computacionales que resuelvan el problema que aquí se plantea de manera simple y con un costo computacional relativamente bajo.

El método consistió en extraer variables estadísticas a cada una de las 184 señales EEG utilizadas en el estudio. Las variables estadísticas extraídas fueron la desviación estándar, varianza, moda, mínimo, promedio y mediana. Estas variables fueron utilizadas como señal de entrada a la red neuronal y a partir de allí se hizo una clasificación que permitió detectar la presencia de artefactos oculares en dichos registros EEG.

Para poner a prueba el funcionamiento y la clasificación de la red neuronal implementada, se determinó que la salida de dicha red neuronal sería mayor o igual a 1 para las señales que contenían artefactos por movimientos oculares y en el caso contrario la salida sería 0 o muy cercana a este valor. De las 184 señales disponibles, se utilizaron 120 señales para entrenamiento y se dejaron 64 señales más para poner a prueba la red neuronal. Con este conjunto de datos disponible, se procedió a definir la configuración de la red para seguidamente iniciar la etapa de entrenamiento.

La Figura 5 muestra la representación de una red neuronal con una capa oculta, múltiples entradas y una sola salida, también denominada Single Layer Perceptron que fue utilizada para el desarrollo del estudio.

*Figura 5. Red neuronal Single Hidden Layer o perceptrón de una sola capa oculta.*

De manera general, a nivel matemático la red neuronal de la Figura 5 se comporta de la siguiente forma:

Según (Fernández Casal et al., 2021) La salida de cada neurona  $H$ , es decir los nodos que conforman la capa oculta, está dada por la siguiente expresión.

$$H_m = 1m \times 1 + 2m \times 2 + 3m \times 3 + 4m \times 4 + \dots + pm \times p + b$$

Donde  $m$  es el número de neuronas y  $p$  el número de señales de entrada.

La salida de cada entrada es transformada por una función de activación que típicamente es una función sigmoide

$$(u) = \frac{1}{1 + e^{-u}} = \frac{e^u}{1 + e^u}$$

La idea del clasificador es que cada neurona “aprende” un resultado binario y de este modo se tiene que dependiendo la función de activación, cada neurona podría activarse según el siguiente modelo, que depende de la función (u).

$$H_m(x) = \phi(1m \times 1 + 2m \times 2 + 3m \times 3 + 4m \times 4 + \dots + pm \times p + b)$$

La red neuronal es capaz de tomar decisiones de clasificación en función de los pesos y las funciones de activación. Sin embargo, es necesario tener la forma de minimizar el error de tal modo que los pesos se ajusten de tal forma que la salida se ajuste a lo esperado de acuerdo al set de datos de entrenamiento.

De esa forma, la estimación de los parámetros (el aprendizaje) se realizó minimizando una función de pérdidas. (Matich, 2001) menciona que el aprendizaje por corrección de error consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida del error, es decir, en función del error cometido en la salida, esta es la regla de aprendizaje del perceptrón utilizada en la red del mismo nombre desarrollada por Rosenblatt en 1958 (Rosenblatt, 1958). Esta regla es muy simple, para cada neurona en la capa de salida se calcula la desviación a la salida respecto al objetivo como el error, y este luego se utiliza para cambiar los pesos sobre las conexiones precedentes.

En este artículo se muestra cómo las redes neuronales de tipo perceptrón multicapa, son útiles para las tareas de clasificación y reconocimiento de patrones. Resulta apropiado evaluar el desempeño de este tipo de red en la detección de artefactos oculares en señales EEG. A continuación, se presentan las características de la red neuronal, los resultados de las pruebas y el análisis de desempeño de la misma.

### ***Características de la red neuronal***

Se diseñó y probó una red neuronal con una capa oculta y función de activación sigmoideal, la cual posee 6 entradas correspondientes a los seis parámetros estadísticos ya mencionados que fueron extraídos de cada señal; la red posee una única salida la cual toma valores cercanos o iguales a 1 o 0 dependiendo de si hay o no presencia de artefactos por movimiento ocular.

La determinación del número de neuronas en la capa oculta se hizo mediante el análisis del comportamiento del error cuadrático medio durante la etapa de entrenamiento, prueba y validación de la red. Para tal fin se probaron configuraciones con 10, 20, 25, 40, 50, 60 y 70 neuronas; después de realizar 10 ciclos de entrenamiento, se obtuvieron resultados que permitieron concluir que la configuración más adecuada para solucionar el problema abordado es una red neuronal con 6 entradas, una capa oculta con 50 neuronas y una única salida.

La Tabla 1 presenta el valor promedio del error obtenido después de realizar 10 ciclos de entrenamiento a la red neuronal, variando el número de neuronas en la capa oculta con lo cual se determinó en cuál de los casos el promedio del error resulto ser el más bajo.

Tabla 1. Promedio del Error para 10 Ciclos de Entrenamiento con Diferente Número de Neuronas en la capa Oculta

La Figura 6 presenta un diagrama de cajas con la representación de la información de la Tabla 1.

*Figura 6. Diagrama de cajas para el valor de error obtenido con diferente número de neuronas en la capa oculta.*

El comportamiento del error para cada una de las configuraciones de la red que fueron entrenadas se presenta en la Figura 7.

*Figura 7. Error cuadrático medio para configuraciones con diferente número de neuronas en la capa oculta.*

Durante la fase de entrenamiento de la red se ajustaron los pesos sinápticos para aproximar la salida esperada con el patrón de entrada. Los valores del error permitieron durante la fase de entrenamiento ajustar los pesos de tal modo que dicho ajuste obedeciera a la búsqueda de una dirección de descenso en el valor del error, dicho de otro modo, el entrenamiento fue un proceso de optimización en búsqueda de un mínimo; en este caso el mínimo debió ser igual o cercano al error admisible en la salida de la red.

La red neuronal fue entrenada y probada con el set de datos ya mencionado. Los datos de prueba utilizados incluyen 34 señales del canal FP1 F7 que contienen artefactos por movimientos oculares y 30 que carecen de dicho evento anormal en la señal. Lo anterior implica la existencia de dos clases las cuales son precisamente el conjunto de clasificación para el cual se diseñó y entrenó la red neuronal

La Figura 7 muestra la curva de separación en un plano, que permite diferenciar los dos tipos de señales que se clasificaron. Los puntos azules corresponden a la información asociada a señales EEG que contienen artefactos por movimiento ocular tipo parpadeo y los puntos color naranja corresponden a los que no poseen este tipo de artefactos.

*Figura 7. Ubicación de dos tipos de datos clasificados mediante la red neuronal.*

Después de realizado el entrenamiento de la red, se observó que el error alcanzó un valor que osciló alrededor del 8% en los diferentes ciclos de entrenamiento. Para evaluar con mejor nivel de detalle el comportamiento de la red neuronal se elaboró una matriz de confusión la cual se explica de la siguiente manera:

La matriz de confusión que se observa en la Tabla 2. se construyó incluyendo los resultados de la red en los diferentes cuadrantes de la siguiente manera:

- En el cuadrante superior izquierdo se escribieron los verdaderos positivos, es decir valores identificados por la red como positivos y que en realidad son positivos.
- En el cuadrante superior derecho se escribieron los falsos positivos, es decir valores identificados por la red como positivos pero que en realidad son negativos.
- En el cuadrante inferior izquierdo se escribieron los falsos negativos es decir valores identificados por la red como negativos pero que en realidad son positivos.
- En el cuadrante inferior derecho se escribieron los verdaderos negativos, es decir valores identificados por la red como negativos y que en realidad son negativos.

Tabla 2. Matriz de Confusión

En esta matriz, los valores de la diagonal principal corresponden a los valores estimados correctamente por el modelo construido, por su parte, la otra diagonal corresponde a los datos en los cuales el modelo falló (Recuero, 2020). Así las cosas, se observó que, para el caso de este trabajo, el modelo funcionó correctamente con 55 conjuntos de datos de prueba y fallo en 9 casos.

A partir de dicha interpretación se extrajeron diferentes métricas que ayudaron a comprender el desempeño de la red y generan las siguientes conclusiones.

### ***Discusión***

La red neuronal diseñada para la detección de artefactos producidos por movimiento ocular demostró tener una exactitud aceptable para la aplicación desarrollada. No obstante, si se compara con los resultados que se obtienen mediante algoritmo de detección y supresión tales como aquellos que se basan en el uso de filtros adaptativos, los resultados no son tan buenos, pues éstos algoritmo alcanzan una exactitud en la detección de hasta 97.34% (Estupinan Donoso, 2009,) mientras que la red neuronal objeto del presente trabajo sólo alcanzó una exactitud del 85.94%.

Por otra parte, si se compara la exactitud y el comportamiento la red neuronal diseñada con el que se obtiene mediante la utilización de análisis de componentes independientes (ICA); se aprecia que la red neuronal tiene un mejor comportamiento comparado con los métodos basados en la utilización de ICA pues mediante estos últimos solo se alcanza un 70% de exactitud, comparado con el 85.94% de la red neuronal. Pese a lo anterior, se debe mencionar que mediante el uso de ICA se puede lograr de manera inmediata la corrección de los artefactos (López et al., 2014), mientras que con la red neuronal no se puede hacer esto de manera directa. Aun así, la exactitud de la red puede hacer de esta una mejor alternativa para la corrección si se le compara con ICA.

La Tabla 3 presenta los resultados de exactitud en la detección de la red neuronal desarrollada comparados con los resultados obtenidos a través de otras técnicas.

Tabla 3. Comparación de la exactitud según diferentes técnicas utilizadas

<b>Método Usado para Detección de Artefactos</b>	<b>Exactitud</b>
Red Neuronal del presente trabajo	85.94%
Técnicas basadas en ICA	70.00%
Técnicas con Filtros adaptativos	97.34%

Respecto a la precisión de la red, para el modelo definido se obtuvo un valor del 92.59%, esto implica que la predicción de la red siempre está muy cerca de una predicción del valor verdadero. La precisión corresponde a la dispersión del conjunto de valores obtenidos a partir de mediciones repetidas de una magnitud. Una mayor precisión implica una menor dispersión (Barrios, 2019).

La red neuronal tuvo una sensibilidad cuyo valor es de 78.13% esto indica que su habilidad para detectar casos relevantes es relativamente aceptable pese a que existe una posibilidad de que a la predicción se le escape cerca del 21% de los resultados positivos.

La tasa de verdaderos negativos, es decir, la proporción entre los casos negativos bien clasificados por el modelo respecto al total de negativos es muy buena, la red tiene una especificidad de 93.75% lo cual quiere decir que su desempeño para detectar verdaderos negativos es satisfactorio.

Otras formas que han probado ser más efectivas que la red neuronal para la detección de artefactos son las wavelets pues estas son ampliamente usadas para la detección de patrones de formas de onda conocidas contra una señal de ruido de fondo. Sin embargo, las wavelets utilizadas en el análisis de EEG, han probado ser más útiles en la detección de espigas que indican la presencia de epilepsia que en la detección de artefactos (Quintero Rincón et al., 2012) es de anotar que la detección de espigas que indiquen actividad epileptiforme está fuera del alcance de este trabajo.

La matriz de confusión ha mostrado que la red neuronal diseñada es más precisa que exacta en la detección de artefactos por movimiento ocular. Lo anterior implica que el resultado siempre está muy cerca del resultado de una predicción de valor verdadero debido a que la

precisión toma la exactitud de los datos correctos y los compara con el total de los datos arrojados, sean exactos o no.

### **Conclusiones**

Este trabajo permite concluir que las redes neuronales artificiales resultan útiles y adecuadas para la detección de artefactos producidos por movimiento ocular en señales EEG. La implementación de dichas redes a nivel de algoritmia y programación resulta sencilla si se le compara con otras técnicas de procesamiento digital de señales; por tal razón, la técnica aquí descrita puede ser fácilmente implementable en software; esto implica que su utilidad práctica en aplicaciones de neurología es una posibilidad viable que podría servir a los profesionales de la salud para tener información y señales más limpias que permitan realizar diagnósticos más exactos, cuando los mismos se realizan a partir de señales EEG.

### **Referencias**

- Agudelo Maldonado, A., Miranda, A., Londoño, A., Fontalvo, A., Ortiz Miranda, M., Manjarres Tejada, V., Batista Bovea, V. A. (2022). *La Inteligencia Artificial y la Neuropsicología*. Universidad Simón Bolívar.
- Alagia Gimeno, R. A. (2018). *Procesamiento de artefactos en EEG para aplicaciones de comunicación y control*. Universidad Politécnica de Valencia. <https://riunet.upv.es/bitstream/handle/10251/104163/ALAGIA%20-%20Procesamiento%20de%20artefactos%20en%20EEG%20para%20aplicaciones%20de%20comunicaci%C3%B3n%20y%20control.pdf?sequence=1&isAllowed=y>
- Barrios, J. I. (2019). *La matriz de confusión y sus métricas – Inteligencia Artificial –*. Juan Barrios. Retrieved January 12, 2023, from <https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/>
- Delgado Saa, J. F. (2009). *Clasificación de Señales EEG Para Aplicaciones en El Desarrollo de Interfaces Cerebro - Computadora* (Universidad del Norte ed.) [Tesis de maestría]. Universidad del Norte. Retrieved Diciembre 31, 2022, from <https://manglar.uninorte.edu.co/bitstream/handle/10584/8632/91916.doc?sequence=1&isAllowed=y>
- Estupinan Donoso, A. (2009, septiembre). Reducción de Artefactos Oculares en Señales EEG: Filtrado Adaptativo Como Alternativa a la Regresión Lineal. *HAL Open Science*. <https://hal.archives-ouvertes.fr/hal-00419918>
- Fernández Casal, R., Costas Bouzas, J., & De la Fuente, M. O. (2021). *Aprendizaje Estadístico*. [https://rubenfcasal.github.io/aprendizaje\\_estadistico](https://rubenfcasal.github.io/aprendizaje_estadistico).
- Gila, L., Villanueva, A., & Cabezas, R. (2009). Fisiopatología y técnicas de registro de los movimientos oculares. *Anales del Sistema Sanitario de Navarra*, 32(3), 9-26. [https://scielo.isciii.es/scielo.php?script=sci\\_arttext&pid=S1137-66272009000600002](https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272009000600002)

- Gurney, K. N., & Gurney, K. (1997). *An introduction to neural networks*. Taylor & Francis.
- Henríquez Muñoz, C. N. (2014, marzo). *Estudio de Técnicas de análisis y clasificación de señales EEG en el contexto de Sistemas BCI (Brain Computer Interface)* (Universidad Autónoma de Madrid ed.) [Tesis de Fin de Máster]. Madrid, España. <http://hdl.handle.net/10486/660477>
- INDEC. (2017). *Señales EEG de pacientes con Epilepsia*. Medellín, Colombia.
- Jiang Xiao, Gui-Bin, B., & Zean, T. (2019). Removal of Artifacts from EEG Signals: A Review. *Sensors*, 19(987), 1-18. <https://doi.org/10.3390/s19050987>
- La Peña, I. D. (2016). *El problema de la caja negra: por qué la inteligencia artificial es una amenaza*. [https://blogs.elconfidencial.com/tecnologia/tribuna/2016-12-06/caja-negra-software-big-data-ai-informatica\\_1299837/](https://blogs.elconfidencial.com/tecnologia/tribuna/2016-12-06/caja-negra-software-big-data-ai-informatica_1299837/)
- Lopez, B., Úbeda, A., Planelles, D., Pérez-Vidal, C., Iañez, E., & Azorín, J. M. (2014, Septiembre 3). *Aplicación de ICA para la eliminación de artefactos oculares y mandibulares en señales EEG durante la realización de tareas mentales* [Acta de las XXXV Jornadas de Automática]. Comité Español de Automática. [http://www.ja2014.upv.es/wp-content/uploads/papers/paper\\_15.pdf](http://www.ja2014.upv.es/wp-content/uploads/papers/paper_15.pdf)
- López Callejo, P. (2019). *Análisis de artefactos oculares en electroencefalogramas mediante wavelets*. Universidad Politécnica de Madrid. <https://oa.upm.es/56803/>
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. [https://www.fro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monograis/matich-redesneuronales.pdf](https://www.fro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograis/matich-redesneuronales.pdf)
- Maureira Cid, F., & Flores Ferro, E. (2018). Electroencefalografía (EEG) y Diversas Manifestaciones del Movimiento: Una Revisión del 2000 al 2017. *Revista Digital de Educación Física*, 9(51), 48-63. <https://dialnet.unirioja.es/descarga/articulo/6360322.pdf>
- Mora Flórez, J. J., Granada Echeverri, M., & Marón Castañeda, L. S. (2005). Los métodos de representación del conocimiento en inteligencia artificial y su integración en sistemas híbridos de localización de fallas. *Tecnura*, 9(17), 98-109.
- Morrillo, L. E. (s.f.). *Análisis Visual del Electroencefalograma*.
- Palma Bustamante, D. A. (2020). *Extracción de Artefactos Oculares de EEG Mediante Análisis de Componentes Independientes* [Proyecto Fin de Grado]. Madrid, España. [https://oa.upm.es/67423/1/TFG\\_DANIELA\\_ALEJANDRA\\_PALMA\\_BUSTAMANTE.pdf](https://oa.upm.es/67423/1/TFG_DANIELA_ALEJANDRA_PALMA_BUSTAMANTE.pdf)
- Pereira, W., & Porras, F. (s.f.). *Evaluación de los problemas vestibulares. Movimientos oculares normales y sistemas que participan*. CentroEquilibra.com. [https://www.centroequilibra.com/uploads/2/1/2/3/2123449/movimientos\\_oculares\\_normales.pdf](https://www.centroequilibra.com/uploads/2/1/2/3/2123449/movimientos_oculares_normales.pdf)
- Perez, B. J. (1998). *El sistema vestibular y sus alteraciones*. Masson.

- Pérez Alberruche, B. (2022, septiembre). *Procesamiento de Señales de Electroencefalograma mediante Wavelets para la Eliminación de Artefactos Cardíacos* [Trabajo de Fin de Grado]. Universidad Politécnica de Madrid. <https://oa.upm.es/71888/>
- Pérez Sánchez, A. V. (2021, Agosto). *Detección anticipada de eventos epilépticos empleando características no lineales* [Tesis de Maestría]. Universidad Autónoma de Queretaro. Retrieved diciembre 31, 2022, from <http://ri-ng.uaq.mx/bitstream/123456789/3412/1/IGMAC-211581-0821-921-Andrea%20Viana%20P%20a9rez%20S%20a1nchez%20%20-A.pdf>
- Quintero Rincón, A., Risk, M., & Liberczuk, S. (2012). Preprocesamiento de EEG con Filtros Hampel. *IEEE Latin Americas Transactions*, 2012(89), 1-6. [https://www.researchgate.net/publication/232709754\\_Preprocesamiento\\_de\\_EEG\\_con\\_Filtros\\_Hampel](https://www.researchgate.net/publication/232709754_Preprocesamiento_de_EEG_con_Filtros_Hampel)
- Ramos-Argüelles, F., Morales, G., Egozcue, S., Pabón, R. M., & Alonso, M. T. (2009, Noviembre 12). Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas. *Anales Sis San Navarra*, 32(3), 69-82. [http://scielo.isciii.es/scielo.php?script=sci\\_arttext&pid=S1137-66272009000600006&lng=es&nrm=iso](http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272009000600006&lng=es&nrm=iso)
- Recuero, P. (2020, septiembre 10). *Cómo interpretar la matriz de confusión: ejemplo práctico*. Think Big Empresas. <https://empresas.blogthinkbig.com/como-interpretar-la-matriz-de-confusion-ejemplo-practico/>
- Relación entre la actividad cortical y la actividad muscular.* (s.f). CORDIS. <https://cordis.europa.eu/article/id/155354-linking-cortical-and-muscular-activities/es>
- Rodriguez Aldana, Y., Marañón Reyes, E. J., & Puebla Iglesias, T. M. (2013). *Corrección de artefactos oculares en el electroencefalograma con modos empíricos* [Computability In Europa]. CIE2013. Retrieved diciembre 17, 2022, from [https://d1wqtxts1xzle7.cloudfront.net/43826830/Correccion\\_de\\_artefactos\\_oculares\\_en\\_el\\_electroencefalograma\\_con\\_modos\\_empiricos-libre.pdf?1458237442=&response-content-disposition=inline%3B+filename%3DCorreccion\\_de\\_artefactos\\_oculares\\_en\\_el.pdf&Expires=1672](https://d1wqtxts1xzle7.cloudfront.net/43826830/Correccion_de_artefactos_oculares_en_el_electroencefalograma_con_modos_empiricos-libre.pdf?1458237442=&response-content-disposition=inline%3B+filename%3DCorreccion_de_artefactos_oculares_en_el.pdf&Expires=1672)
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>
- Sánchez, F., & Hernández, A. M. (2017). Modelado autorregresivo de señales electroencefalográficas para simuladores médicos. *Ingeniería y Desarrollo*, 35(2), 337-356.
- Schomer, D. L., & López Da Silva, F. (2011). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* (6th ed.). Lippincott Williams & Wilkins.
- Velasque Burgos, B. M., De Cleves, N. R., & Calle Márquez, M. G. (2009). El cerebro que aprende. *Tabula Rasa*, 11, 329-347.

[http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S1794-24892009000200014&lng=en&tlng=es](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1794-24892009000200014&lng=en&tlng=es).