

Interfaz Cerebro-Computadora de Tiempo Real para Comunicación por Parpadeo Voluntario con Señales EEG

Jesús Joshua Muñoz-Pacheco, Juan Alberto Ramírez-Quintana, Luis Octavio Méndez-Valles
Tecnológico Nacional de México / I.T. Chihuahua
Ave. Tecnológico No. 2909, 31310, Chihuahua, Chih., México, (614)2026511
{l23061083, juan.rq, l19060757}@chihuahua.tecnm.mx

RESUMEN.

Los artefactos por parpadeo en señales de Electroencefalografía (EEG) son distorsiones causadas por el movimiento de párpados y los músculos oculares. La detección de estos artefactos representa una oportunidad de comunicación para las personas que sufren algún tipo de discapacidad, ya que estas distorsiones son consistentes en personas sanas y con diversos padecimientos, lo que provee información que puede ser usada para el desarrollo de sistemas de habla silenciosa. Por ello, en este artículo se propone una interfaz cerebro-computadora embebida y de tiempo real que detecte artefactos por parpadeo utilizando redes neuronales artificiales. De acuerdo con la experimentación, el modelo de red utilizado obtuvo un resultado de 98% de precisión en el reconocimiento de artefactos por parpadeo. Aunado a esto, se ha realizado un sistema en tiempo real funcional el cual trabaja con dicho modelo.

Palabras Clave: electroencefalografía, habla silenciosa, interfaz cerebro-computadora, artefactos por parpadeo.

ABSTRACT.

Eye-blink artifacts in Electroencephalography (EEG) signals are distortions caused by the movement of the eyelids and ocular muscles. Detecting these artifacts represents a communication opportunity for people with some disability since these distortions are consistent in healthy people and with various conditions, providing information that can be used to develop silent speech systems. Therefore, this article proposes a real-time embedded brain-computer interface that detects blink artifacts using artificial neural networks. According to the experimentation, the network model obtained a result of 98% accuracy in recognizing blinking artifacts. On the other hand, a functional real-time system that works with said model has been created.

Keywords: electroencephalography, silent speech, brain-computer interface, eye-blink artifacts.

1. INTRODUCCIÓN

Las Interfaces Cerebro-Computadora (BCI por sus siglas en inglés) son sistemas que permiten la comunicación directa entre el cerebro y un dispositivo externo. Una forma barata y no invasiva de realizar esta comunicación es mediante señales EEG que son obtenidas directamente de un sujeto. Además, este tipo de sistemas se utilizan generalmente en el tratamiento de personas que sufren de alguna vulnerabilidad fisiológica [1]. Para interpretar las señales EEG en BCI se recurre a los neuroparadigmas (como Potenciales Evocados Visuales en Estado Estable, Imaginación motora, del habla, etc.). Sin embargo, estas formas de interpretación tienen una alta varianza inter-sujeto y entre personas sanas y enfermas.

Aparte de las señales obtenidas por los neuroparadigmas, existen los artefactos, los cuales son distorsiones eléctricas no cerebrales en la señal EEG que se originan de fuentes tanto internas (por ejemplo: movimientos oculares, movimientos

musculares) como externas (por ejemplo, interferencias eléctricas, movimientos del electrodo) [2]. Entre estos, el artefacto por parpadeo es una distorsión producida por los movimientos del párpado o los músculos alrededor del ojo. Existen trabajos que buscan caracterizar y remover los artefactos de señales EEG mediante diversas técnicas, por ejemplo: mediante algoritmos de aprendizaje no supervisado y técnicas de análisis de espectro singular [3] o mediante clasificación con técnicas como *k-nearest neighbor* (KNN) [4].

Por otro lado, los artefactos por parpadeo voluntario son distorsiones de la señal EEG que se generan por el movimiento controlado de apertura y cierre del párpado. Los artefactos por parpadeo voluntario tienen una baja varianza entre diferentes sujetos, y no difiere entre sujetos sanos o enfermos. De esta manera, los artefactos por parpadeo voluntario proveen información útil para entrenar y validar modelos de aprendizaje automático aplicados a tecnologías de habla silenciosa. Las tecnologías de habla silenciosa son sistemas de comunicación verbal viable en ausencia de una señal acústica audible [5]. Actualmente, existen diversas tecnologías aplicadas al habla silenciosa utilizando, por ejemplo, implementación de modelos de reconocimiento automático para la traducción de señales EEG [6] o implementación de tecnologías como lo son el *transfer learning* para la clasificación de palabras leídas en silencio [7]. Sin embargo, el utilizar señales EEG para tecnologías aplicadas al habla silenciosa conlleva una serie de problemas relacionado a que muchos elementos de las señales EEG pueden variar entre sujetos sanos o enfermos. Entre estos problemas se encuentra el trastorno médico que los sujetos presenten y dificultades físicas que un sujeto pueda tener para si quiera movilizar algún elemento facial. Por lo que el uso de artefactos por parpadeo para la realización de un BCI en sistemas de habla silenciosa genera una oportunidad de aportación científica a este ámbito.

De acuerdo con la literatura, la detección de artefactos por parpadeo se ha llevado a cabo utilizando técnicas como máquinas de vectores de soporte o SVM por sus siglas en inglés [8], segmentación semántica [9] y Redes Neuronales Convolucionales o CNN por sus siglas en inglés [10][11]. Sin embargo, el uso de redes tan complejas se justifica cuando se tiene una amplia base de datos y la cantidad de señales EEG que se toman en cuenta para la clasificación de sus modelos. Por estas razones, en este artículo se propone un algoritmo basado en red neuronal directa para detección de artefactos voluntarios para sistema de computación afectiva de tiempo real.

El resto del artículo se organiza de la siguiente manera: la sección 2 describe el sistema embebido de tiempo real para detección de parpadeo voluntario con señales EEG y la base de datos para los experimentos. La sección 3 muestra los resultados obtenidos y la sección 4 las conclusiones a este trabajo.

2. DESARROLLO

La Figura 1 muestra el diagrama final del sistema. La entrada del sistema son las señales EEG procedentes de los electrodos colocados en el sujeto para el registro de señales eléctricas digitalizadas mediante la tarjeta Cyton. El sistema de cómputo hace referencia a cualquier sistema de cómputo general o específico capaz de correr Python y que pueda realizar una conexión serial. Estos datos se guardan en un buffer para aplicar un filtro pasa bajas y así obtener los componentes más significativos para la detección de artefactos por parpadeo. Posteriormente, se encuentran sus componentes de frecuencia con la transformada rápida de Fourier. Finalmente, se utilizan estos componentes como entrada a una red perceptrón multicapa (MLP por sus siglas en inglés) para detectar un artefacto por parpadeo voluntario.




Figura 1. Diagrama general del sistema.

2.1 Protocolo de adquisición de datos y hardware utilizado

Las señales EEG se adquieren con un protocolo que le indica al usuario si debe parpadear o no. Este protocolo se realizó con el objetivo de conocer si la BCI de tiempo real reconoce adecuadamente el parpadeo mientras está funcionando.

El primer punto del protocolo es la adquisición de los datos EEG, se utilizan tres electrodos de copa de oro y la tarjeta de

adquisición Cyton de OpenBCI®. La Figura 2 muestra la manera en la que los electrodos deben ser colocados en el sujeto, donde el electrodo que es colocado en el lóbulo de la oreja derecha es la referencia común mejorando así la relación señal/ruido de la adquisición de datos, el electrodo de la oreja izquierda estabiliza la señal pues es la más alejada de la mayor parte de la actividad cerebral y muscular. Por último, el electrodo que se coloca por arriba de la ceja izquierda realiza el trabajo de recibir la señal EEG en un punto donde se encuentra el séptimo nervio facial, el cual es autónomo al resto de las terminaciones nerviosas relacionadas al parpadeo, por lo que cualquier sujeto sano o enfermo puede tener una lectura clara en ese punto. A su vez, los electrodos deberán ir hacia los puertos de la tarjeta Cyton de la manera que indica la Tabla 1.

Tabla 1. Lugar de conexión de los electrodos.

Puerto de la tarjeta Cyton	Posición del sistema 10-10
BIAS.	A1
SRB.	A2
N1P	FP1




Figura 2. Conexión de los electrodos en el sujeto de pruebas.

El siguiente punto del protocolo es el procedimiento para probar el parpadeo en tiempo real. La Figura 3 muestra la interfaz que se realizó para este propósito. Dicha interfaz pide el nombre del sujeto y sigue los siguientes criterios:

- A lo largo de la prueba se realizarán 2 parpadeos en 4 secuencias diferentes. La interfaz se encargará de mostrar cuando el sujeto debe realizar dichos parpadeos.
- Los parpadeos deben ser naturales, es decir, el movimiento del parpadeo no debe ser forzado en rapidez, fuerza o duración.




Figura 3. Interfaz BCI.

Estos criterios se implementan con los siguientes pasos:

1. Se inicia el procedimiento oprimiendo el botón “Comenzar prueba” en la interfaz, para este punto se debe contener el parpadeo hasta que aparezca el número uno en la interfaz como se ve en la Figura 4.




Figura 4. Primer parpadeo.

2. Un segundo parpadeo debe realizarse en el momento que aparezca el número dos en la interfaz como se ve en la Figura 5.




Figura 5. Segundo parpadeo.

3. Para finalizar se contendrá el parpadeo hasta mostrar el número cero como se ve en la Figura 3 significando que se finalizó la toma de muestras.

2.2 Preprocesamiento y transformada de Fourier

Las señales EEG que se adquieren se definen como $x(t)$, donde t representa el tiempo. Estas señales son preprocesadas para eliminar frecuencias no deseadas con un filtro pasa bajas Butterworth con frecuencia de corte de 8 Hz. La salida son datos EEG definida como $y(t)$. La frecuencia de corte del filtro se debe a que típicamente los artefactos por parpadeo se encuentran por debajo de los 4 Hz [12], pero se decidió establecer un rango más amplio.

Posteriormente, se utilizó la transformada de Fourier para obtener 50 elementos de frecuencia, esto se define por:

$$z(k) \subseteq y(k), k = 0, \dots, 49 \quad (1)$$

Para ello, se empleó el algoritmo de la transformada rápida de Fourier o FFT por sus siglas en inglés, el cual optimiza el cálculo de la transformada discreta de Fourier aprovechando que el número de muestras N es una potencia de 2. La DFT está definida por la siguiente ecuación:

$$z(k) = \frac{1}{N} \sum_{t=0}^{N-1} y(t) e^{-j \frac{2\pi kt}{N}} \quad (2)$$

Donde N es el número de muestras y k representa el índice de frecuencia discreta.

2.3 Modelo de red neuronal

Para la clasificación de los datos se realizó un modelo de red neuronal basado en un perceptrón multicapa con tres capas siendo estas la capa de entrada, oculta y salida, este modelo esta dado por:

$$g = \omega z(k) + \omega_0 \quad (3)$$

Donde ω representa los pesos de la conexión entre las neuronas de la capa de entrada y las neuronas de la capa oculta, y ω_0 es el sesgo.

La capa de entrada contiene 50 elementos que corresponden a los datos obtenidos de las amplitudes de las señales anteriormente preprocesadas.

La siguiente capa, que está completamente interconectada con la capa de entrada, es una capa oculta densa de 20 neuronas, siendo esta cantidad determinada mediante experimentación, con función de activación ReLU la cual se define por:

$$\text{ReLU}(x) = \max(0, g) \quad (4)$$

La capa de salida es del tipo densa y contiene una sola neurona que dictara si se encuentra o no un artefacto por parpadeo en la señal de entrada del modelo, esta capa utiliza una función de activación sigmoide la cual se define por:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

Donde x es el valor que se pasa a la función sigmoide, el cual se calcula mediante una combinación lineal de las salidas de la capa oculta.

La Figura 6 muestra la arquitectura final de la red MLP propuesta en este trabajo.




Figura 6. Arquitectura de la red MLP.

2.4 Sistema en tiempo real

Se realizó una aplicación para la detección de artefactos por parpadeo en tiempo real. Esta aplicación corre mediante Python y puede ser utilizada en cualquier sistema operativo que pueda mostrar una aplicación gráfica mediante Python y tenga comunicación serial con dispositivos externos.

El sistema funciona en tiempo real a través de hilos utilizando la librería *threading* de Python, en el cual cada uno de estos hilos va ligado a un proceso con un orden de importancia establecido.

El primero de estos hilos toma el papel de la adquisición de los datos EEG mediante la tarjeta *Cyton*, para posteriormente almacenar dichos datos en un buffer, por lo que es necesario que se realicen las conexiones de los electrodos de la misma manera que se vio en el protocolo de adquisición de datos.

El segundo hilo realiza la tarea de procesar las muestras en cuando el buffer de información del hilo anterior se llena, realizando el mismo proceso de filtrado y cambio de dominio (Fourier) de los datos visto en el protocolo de adquisición de datos, esto se hace para que las características sean del mismo tipo de las que uso el modelo para su entrenamiento. Este mismo hilo pasa dichas características al modelo de red neuronal pre entrenado para predecir si ha ocurrido un parpadeo utilizando el modelo almacenado posterior a su entrenamiento mediante un archivo con formato especial de *tensorflow*, en caso de que esto sea verdadero, se actualiza un contador que muestra el número de parpadeos que se han detectado y un cambio en la imagen de la interfaz gráfica.

El tercer hilo muestra y actualiza la interfaz gráfica, esta interfaz muestra una imagen de un ojo abierto que representa que no se detecta un artefacto por parpadeo, como se puede ver en la Figura 7, mientras que la imagen con el ojo cerrado muestra que se ha detectado un artefacto por parpadeo, como se puede ver en la Figura 8, además dicha interfaz muestra el contador de parpadeos obtenidos durante la sesión.



Figura 7. Representación de no detección de un artefacto por parpadeo en la aplicación.



Figura 8. Representación de detección de un artefacto por parpadeo en la aplicación.

3. RESULTADOS

La red MLP utilizada para el sistema fue entrenada con un equipo de cómputo con las características que se pueden ver en la Tabla 2.

La precisión alcanzó el 98.66% en entrenamiento y 92.45% en prueba. La red se entrenó con una base de datos conformada por diez sujetos, donde cada uno de estos realizó cuatro pruebas utilizando el protocolo diseñado. El entrenamiento se realizó utilizando el optimizador Adam con un radio de aprendizaje de 0.001 y asignando el 20% de los datos al conjunto de prueba, y el 80% restante al conjunto de entrenamiento, esta base de datos es más pequeña que otras utilizadas en la literatura para modelos de redes neuronales [10][11]. Sin embargo, hay que tomar en cuenta que estos modelos mencionados (CNN) tuvieron una mayor complejidad, en modelos más simples [13] suele ser suficiente bases de datos con pocos sujetos. En el caso específico de nuestro modelo, esta base de datos fue suficiente para el entrenamiento del modelo ya que es un modelo con un alto grado de simpleza, esto es a propósito debido a que el modelo debe ser adecuado a un sistema en tiempo real.

La Figura 9 muestra la gráfica de precisión del modelo a lo largo de las épocas de entrenamiento, tanto para el conjunto de datos de entrenamiento como para el de validación.

La curva azul representa la precisión en el conjunto de entrenamiento y la curva naranja representa la precisión en el conjunto de validación.

Tabla 2. Componentes de la PC utilizada para el entrenamiento de la red MLP.

Recurso	Componente
GPU	RTX 4060
CPU	Ryzen 7 7700
RAM	DDR5 32 GB




Figura 9. Precisión del modelo MLP.

La gráfica presentada en la Figura 10 muestra la función de pérdida del modelo e ilustra la evolución de esta durante el entrenamiento y la validación de un modelo. La proximidad entre la pérdida de validación y la de entrenamiento sugiere que el modelo generaliza bien a datos nuevos y no sufre de sobreajuste. Este comportamiento es indicativo de un buen rendimiento del modelo, que está aprendiendo correctamente y mejorando su capacidad predictiva con el tiempo.




Figura 10. Función de pérdida.

La Figura 11 muestra la matriz de confusión, la interpretación de esta nos dice que el modelo identifica todas las muestras de ambas clases sin errores, lo cual es un excelente resultado. Sin embargo, un resultado perfecto como este puede indicar que el

conjunto de prueba es pequeño o que los datos son muy fáciles de clasificar, es decir, que hay muy poca variabilidad.




Figura 11. Matriz de confusión del modelo MLP

Para colaborar la hipótesis anteriormente mencionada, se obtuvieron los datos estadísticos sobre las amplitudes de las señales, se obtuvo una media de 0.035 y una desviación estándar de 0.099 lo que indica que, efectivamente, los datos son muy poco variados, además se obtuvo un histograma de las características de entrada del modelo como se puede ver en a Figura 12.




Figura 12. Distribución de las características de entrada del modelo MLP.

El histograma muestra una alta concentración de las amplitudes en un rango cercano a 0 lo que indica, nuevamente, que los datos tienen muy poca variabilidad. Esto explica el porque se alcanza una precisión alta rápidamente, y es que los patrones de los datos poder ser fácilmente detectados por el modelo.

4. CONCLUSIONES

Este artículo presenta una interfaz cerebro-computadora embebida de tiempo real para detección de parpadeo voluntario mediante señales EEG. Para analizar las señales EEG, se utiliza

la transformada de Fourier, un filtro Butterworth y una MLP de 20 neuronas en la capa oculta y una neurona en la capa de salida.

De acuerdo con los resultados obtenidos y las pruebas realizadas, el sistema logro un desempeño del 98% en la precisión del modelo MLP al detectar artefactos por parpadeo mediante las frecuencias de las señales EEG tratadas. Por otro lado, en la detección de parpadeos en tiempo real mediante el sistema basado en procesos paralelos haciendo uso de hilos se obtuvo una latencia tan baja que no fue posible realizar una medición exacta. Esto se debe a que el modelo MLP fue diseñado de tal manera que se obtuviera la mayor precisión utilizando las menores capas y neuronas posibles para realizar un modelo de red neuronal adecuado a un sistema que debe trabajar en tiempos determinados. Además, debido a que los elementos utilizados son *OpenSource*, replicar este sistema en diversos equipos de cómputo se vuelve un proceso sencillo y también multiplataforma puesto que el sistema puede ser implementado en cualquier sistema de cómputo que puede utilizar Python, comunicación serial e interfaces gráficas, por lo que es posible su implementación tanto en sistemas de cómputo de bajos recursos como un sistema Raspberry Pi® o NVIDIA Jetson® como en sistemas computacionales más robustos.

Como trabajo futuro, se pretende mejorar el rendimiento y realizar un sistema de interpretación de la detección de parpadeos para un sistema de habla silenciosa que pueda ser utilizados en sujetos con alguna discapacidad severa de movimiento y comunicación.

RECONOCIMIENTOS

Los autores agradecen a Tecnológico Nacional de México por el apoyo TecNM 19182.24-P para la realización de este trabajo.

REFERENCIAS

- [1] Shen, M., Wen, P., Song, B., & Li, Y. (2022). An EEG based real-time epilepsy seizure detection approach using discrete wavelet transform and machine learning methods. *Biomedical Signal Processing and Control*, 77, 103820. <https://doi.org/10.1016/j.bspc.2022.103820>.
- [2] Sutter, R., Kaplan, P. W., & Schomer, D. L. (2017). *Historical Aspects of Electroencephalography* (D. L. Schomer & F. H. Lopes da Silva, Eds.). Oxford University Press. <https://doi.org/10.1093/med/9780190228484.003.0001>.
- [3] Maddirala, A. K., & Veluvolu, K. C. (2021). Eye-blink artifact removal from single channel EEG with k-means and SSA. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-021-90437-7>.
- [4] Ghosh, R., Phadikar, S., Deb, N., Sinha, N., Das, P., & Ghaderpour, E. (2023). Automatic Eye-blink and Muscular Artifact Detection and Removal from EEG Signals using k-Nearest Neighbour Classifier and Long Short-Term Memory Networks. *IEEE Sensors Journal*, 1. <https://doi.org/10.1109/jsen.2023.3237383>.
- [5] Freitas, J., Teixeira, A., Dias, M. S., & Silva, S. (2017). *An Introduction to Silent Speech Interfaces*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-40174-4>.
- [6] G. Krishna, C. Tran, M. Carnahan, and A. Tewfik. (2020). Continuous Silent Speech Recognition using EEG', arXiv [eess.AS]. <https://doi.org/10.48550/arXiv.2002.03851>.
- [7] M. Rekrut, A. Fey, M. Nadig, J. Ihl, T. Jungbluth and A. Krüger. (2022). Classifying Words in Natural Reading Tasks Based on EEG Activity to Improve Silent Speech BCI Training in a Transfer Approach, 2022 IEEE International Conference on Metrology for Extended Reality, Artificial Intelligence and Neural Engineering (MetroXRINE), Rome, Italy, 2022, pp. 703-708, doi: 10.1109/MetroXRINE54828.2022.9967665.
- [8] Ghosh, R., Sinha, N., & Biswas, S. K. (2019). Automated eye blink artefact removal from EEG using support vector machine and autoencoder. *IET Signal Processing*, 13(2), 141–148. <https://doi.org/10.1049/iet-spr.2018.5111>.
- [9] Tosun, M., & Kasim, Ö. (2020). Novel eye-blink artefact detection algorithm from raw EEG signals using FCN-based semantic segmentation method. *IET Signal Processing*, 14(8), 489–494. <https://doi.org/10.1049/iet-spr.2019.0602>.
- [10] Amanda F., Ana Carolina de Sousa Silva, Aldrumont F., Jessica Monique de Toledo & Gustavo V. (2021). EEG multipurpose eye blink detector using convolutional neural network. arXiv <https://doi.org/10.48550/arXiv.2107.14235>
- [11] Jurczak M, Kołodziej M and Majkowski A (2022) Implementation of a Convolutional Neural Network for Eye Blink Artifacts Removal From the Electroencephalography Signal. *Front. Neurosci.* 16:782367. doi: 10.3389/fnins.2022.782367
- [12] M. Fatourehchi, A. Bashashati, R. K. Ward y G. E. Birch, "EMG and EOG artifacts in brain computer interface systems: A survey", *Clin. Neurophysiol.*, vol. 118, n.º 3, pp. 480–494, marzo de 2007. Accedido el 18 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.1016/j.clinph.2006.10.019>.
- [13] M. Lo Giudice *et al.*, "1D Convolutional Neural Network approach to classify voluntary eye blinks in EEG signals for BCI applications," 2020 *International Joint Conference on Neural Networks (IJCNN)*, Glasgow, UK, 2020, pp. 1-7, doi: 10.1109/IJCNN48605.2020.9207195