CASEIB 2022

XL Congreso Anual de la Sociedad Española de Ingeniería Biomédica

40 AÑOS UNIENDO FUERZAS PARA IMPULSAR LA INGENIERÍA BIOMÉDICA

23–25 NOVIEMBRE 2022 | VALLADOLID

LIBRO DE ACTAS

GRUPO DE INGENIERÍA BIOMÉDICA
UNIVERSIDAD DE VALLADOLID

Sociedad Española de INGENIERIA BIOMEDICA

CASEIB 2022

XL Congreso Anual de la Sociedad Española de Ingeniería Biomédica

23-25 NOVIEMBRE 2022 | **VALLADOLID**

XL Congreso Anual de la Sociedad Española de Ingeniería Biomédica CASEIB 2022

Los trabajos incluidos en esta publicación han sido evaluados por el Comité Científico que en ella se relaciona y según el procedimiento que se recoge en *www.caseib.es/2022/*

Presidente del Comité Organizador:
Roberto Hornero Sánchez

Secretarios del Comité Organizador:
Jesús Poza Crespo
Carlos Gómez Peña

Editores:
Roberto Hornero Sánchez
Jesús Poza Crespo
Carlos Gómez Peña
María García Gadañón

Maquetación:
Aarón Maturana Candelas
Carlos Gómez Peña

Diseño de portada:
Sandra Martínez Cagigal
Víctor Martínez Cagigal

ISBN: 978-84-09-45972-8

Libro de Actas del XL Congreso Anual de la Sociedad Española de Ingeniería Biomédica
Se distribuye bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional.

Jueves, 24 de noviembre de 2022, a las 8:30

Sesión oral: Biomecánica

Moderadores: Abraham Otero Quintana y Pablo F. Viñas Noseda

Design and development of a robotic hand for finger spelling 258

A virtual reality application for the assessment and training of neck sensorimotor control 262

Efecto del entrenamiento de la anastomosis microquirúrgica experimental en la calidad del procedimiento y la ergonomía del cirujano 266

Automatización del método RULA para análisis ergonómico con sensores inerciales vestibles 270

Biomechanical modelling of the behaviour of the human breast under the effect of gravity for tumor detection 274

Estudio preliminar de la variación del rango de movimiento y la actividad muscular en pacientes de avanzada edad usando el andador SWalker 278

Sesión oral: Señales Biomédicas II

Moderadores: Javier Gómez Pilar y Víctor Martínez Cagigal

Improving the quality of combined TMS-EEG neural recordings: artefact removal and time analysis 283

Análisis espectral de la actividad electroencefalográfica basal a nivel de fuente para la diferenciación de subtipos de migraña 287

Protocolo de registro de EEG para identificación de patrones cerebrales asociados a la anosmia por COVID-19 291

Sincronía, metaestabilidad y dimensión fractal del EEG durante diferentes estados conscientes 295

Cognitive stimulation leads to a long-term brain activation with a spectral shift to higher frequencies in Rett syndrome patients 299

Aplicación de *Deep Learning* para el procesado automático de componentes ICA de registros de magnetoencefalografía 303

Sesión oral: Neurotecnologías II

Moderadores: Eduardo Rocón De Lima y Ana de los Reyes Guzmán

Evaluación del nivel de atención durante el entrenamiento de una BMI con un exoesqueleto de miembro inferior 308

Neuroprótesis para evaluar el efecto de estimulación vibratoria mecánica en el freezing de pacientes con Parkinson 312

Caracterización espacio-temporal de la clasificación de imaginación motora con herramientas de *explainable artificial intelligence* (XAI) 316

Diseño de una BCI mediante redes convolucionales profundas para la detección de la intención de parar ante un obstáculo inesperado 320

Evaluación de un videojuego multijugador basado en Brain Computer Interfaces utilizando c-VEPs 324

Rehabilitación de la marcha asistida por un sistema híbrido personalizable en dos casos de lesión medular incompleta 328

Señales Biomédicas II

Jueves, 24 de noviembre de 2022

Aplicación de *Deep Learning* para el procesado automático de componentes ICA de registros de magnetoencefalografía

L. Gutiérrez-de Pablo[1], S. Pérez-Velasco[1,2], V. Rodríguez-González[1,2], V. Gutiérrez-de Pablo[1,2], C. Gómez[1,2], J. Poza[1,2,3]

[1] Grupo de Ingeniería Biomédica, Universidad de Valladolid, Valladolid, España, laura.gutierrez.pablo@alumnos.uva.es

[2] Centro de Investigación Biomédica en Red en Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN), España

[3] IMUVA, Instituto de Investigación en Matemáticas, Universidad de Valladolid, Valladolid, España

Resumen

La magnetoencefalografía (MEG) permite registrar los campos magnéticos inducidos por la actividad neuronal. Sin embargo, los registros MEG están contaminados por señales procedentes de fuentes no neuronales. Para un posterior análisis de los datos es necesario mitigar la presencia de estos artefactos. El análisis de componentes independientes (ICA) es un método estadístico que permite separar las diferentes componentes que forman los datos MEG. Sin embargo, ICA no realiza la clasificación de dichas componentes; esta tarea la realiza normalmente un técnico mediante un análisis visual, por lo que el grado de subjetividad es elevado. Para solucionar este problema, en este trabajo se ha diseñado un sistema de Deep Learning, basado en la red EEG-Inception, para diferenciar entre componentes ICA de origen cerebral y componentes contaminadas por artefactos. Para ello se utilizó una base de datos de componentes ICA ya etiquetadas, procedentes de 473 registros de actividad MEG espontánea. Los resultados de la clasificación binaria de componentes muestran una precisión del 87% mientras que en la clasificación multiclase se obtuvo una precisión del 85%. Un posterior análisis visual de una selección aleatoria de las muestras mal clasificadas por la red mostró que algunas de ellas estaban mal etiquetadas en la base de datos. Estos resultados sugieren que el uso de la herramienta propuesta podría también mejorar el etiquetado manual de los técnicos.

1. Introducción

La magnetoencefalografía (MEG) y la electroencefalografía (EEG) son técnicas que permiten estudiar la dinámica electrofisiológica del cerebro de forma no invasiva. La primera hace referencia al estudio de los campos biomagnéticos emitidos por las corrientes eléctricas del cerebro, mientras que la segunda hace referencia al estudio de la actividad bioeléctrica cerebral [1], [2]. La MEG se emplea para estudiar diferentes enfermedades neurológicas como la epilepsia, para la planificación de la extracción de tumores cerebrales, para la valoración de pacientes con enfermedades cerebrovasculares, etc. [3]. Para poder analizar las señales de actividad MEG, es necesario un preprocesado previo debido a que normalmente están contaminadas por artefactos de diverso origen. Estos artefactos son interferencias indeseadas que pueden sesgar la interpretación de los resultados obtenidos a partir de las señales MEG y, por ello, es necesaria su eliminación. Los artefactos de MEG se pueden clasificar en dos categorías distintas: artefactos no biológicos, que pueden deberse a problemas técnicos en la colocación de los sensores o interferencias externas; y artefactos relacionados con ruido biológico, que no depende de la actividad eléctrica cerebral y que englobarían a artefactos oculares o electrooculograma (EOG), artefactos cardíacos o electrocardiograma (ECG), movimientos de la cabeza del paciente, actividad muscular, etc.

Para un posterior procesado de las señales MEG, se requiere identificar los distintos tipos de ruido para posteriormente eliminarlos. Uno de los grandes problemas de la identificación de artefactos es que, en la mayor parte de los casos, se lleva a cabo de manera visual por un técnico especializado. Si el registro es adquirido con pocos canales y, además, es de corta duración, el análisis de la señal y la identificación de sus artefactos son relativamente sencillos. Sin embargo, si se utiliza un sistema de gran densidad en canales para el registro, además de ser este de larga duración, el preprocesado se convierte en una tarea compleja y que consume mucho tiempo. Por ello, son necesarias técnicas que faciliten esta tarea. Un método estadístico muy utilizado para solucionar este problema es el análisis de componentes independientes (ICA). Este método se basa en extracción y separación de fuentes estadísticamente independientes de señales biomédicas como EEG y MEG, pudiendo de esta forma diferenciar entre componentes con actividad cerebral y componentes contaminadas por artefactos.

Otro gran problema a la hora de preprocesar señales biomédicas es el posible sesgo a la hora de identificar artefactos, debido a la subjetividad inherente a su identificación manual. Es por ello que los métodos automáticos de clasificación han crecido en popularidad en este ámbito. Actualmente existen sistemas que son capaces de solucionar este problema, al menos con señales EEG, pero son sistemas basados en *Machine Learning* (ML) [5]. En campos como la visión artificial o el procesamiento natural del lenguaje, el ML ha sido sobrepasado por los sistemas basados en *Deep Learning* (DL), debido a que pueden llegar a conseguir resultados más precisos en tareas de reconocimiento de patrones, como lo es el etiquetado de componentes ICA. A día de hoy sólo encontramos trabajos, en los que se utilicen *higher order statistics* y medidas de entropía o *Deep Learning* para realizar clasificaciones de un simple tipo de artefacto, como EOG o ECG, y no una clasificación multiclase entre componentes MEG con varios artefactos [6]-[8].

El objetivo de este trabajo es implementar un sistema de *Deep Learning* utilizando la red EEG-Inception [9], adaptándola a señales MEG, de forma que consiga diferenciar entre componentes ICA correspondientes a actividad cerebral o asociadas a artefactos.

2. Materiales y métodos

2.1. Bases de datos

La base de datos que se ha empleado está compuesta por componentes ICA de 473 registros, de cinco minutos cada uno. Estos registros se realizaron en el hospital de Hokuto (Obihiro, Japón) mediante un sistema de 160 canales (MEG Vision PQ1160C, Yokogawa Electric). La frecuencia de muestreo original fue de 1000 Hz. Para cada sujeto se disponía de una matriz de datos que incluía las 160 componentes ICA obtenidas con el algoritmo Extended Infomax ICA. Cada componente ICA estaba etiquetada por un técnico especialista, con más de tres años de experiencia, como actividad cerebral o artefacto: "0" para componentes cerebrales, "1" para componentes cardíacas, "2" para componentes de red eléctrica, "3" para componentes oculares y, por último, "4" para otro tipo de componentes artefactuadas. La figura 1 ilustra algunas de estas componentes. Todos estos datos fueron analizados con MATLAB®.

2.2. EEG- Inception

EEG-Inception es una red neuronal convolucional (CNN) utilizada para el procesamiento de EEG y la detección de potenciales relacionados a eventos [9]. Aunque originalmente esta red fue diseñada para el procesado de señales EEG, en este trabajo se ha extendido su uso para clasificar componentes ICA extraídas de señales MEG. Para ello, se realizaron varios cambios en su estructura, que se resumen en la figura 2:

- Bloque I. En este bloque se aplican tres convoluciones 2D de 100 × 1, 50 × 1 y 25 × 1, respectivamente, utilizando las mismas ventanas temporales que en la configuración inicial de EEG-Inception. En este caso, se ha eliminado la convolución *depthwise* debido a que en este caso sólo tenemos un canal de entrada.
- Bloque II. La estructura de este bloque es igual a la del anterior. Su función es extraer características temporales adicionales en un mayor nivel de abstracción, debido a que se aplican los mismos filtros que en el bloque I, pero sobre la señal transformada que pasa al bloque II.
- Bloque III. Está compuesto por dos convoluciones y dos *average pooling*. Este bloque consigue extraer los patrones más complejos usados en la clasificación final.

3. Resultados y discusión

3.1. Clasificación binaria

La primera aproximación de la red tuvo como objetivo la clasificación binaria de las componentes ICA. Esta clasificación necesitaba que la red fuera capaz de diferenciar entre componentes correspondientes a actividad cerebral y componentes correspondientes a artefactos, sin que tuviera que diferenciar entre los diferentes tipos de estos.

Para obtener los valores de precisión de realizó *k-fold* con 5 *splits*, de manera que la precisión obtenida fuera para todas las muestras presentes en la base de datos. Para evitar el *overfitting* de la red, en cada conjunto de entrenamiento se usó *early-stopping*, al igual que se hacía en la implementación original de EEG-Inception. Este se aplicó cuando no había mejora en la función de pérdidas

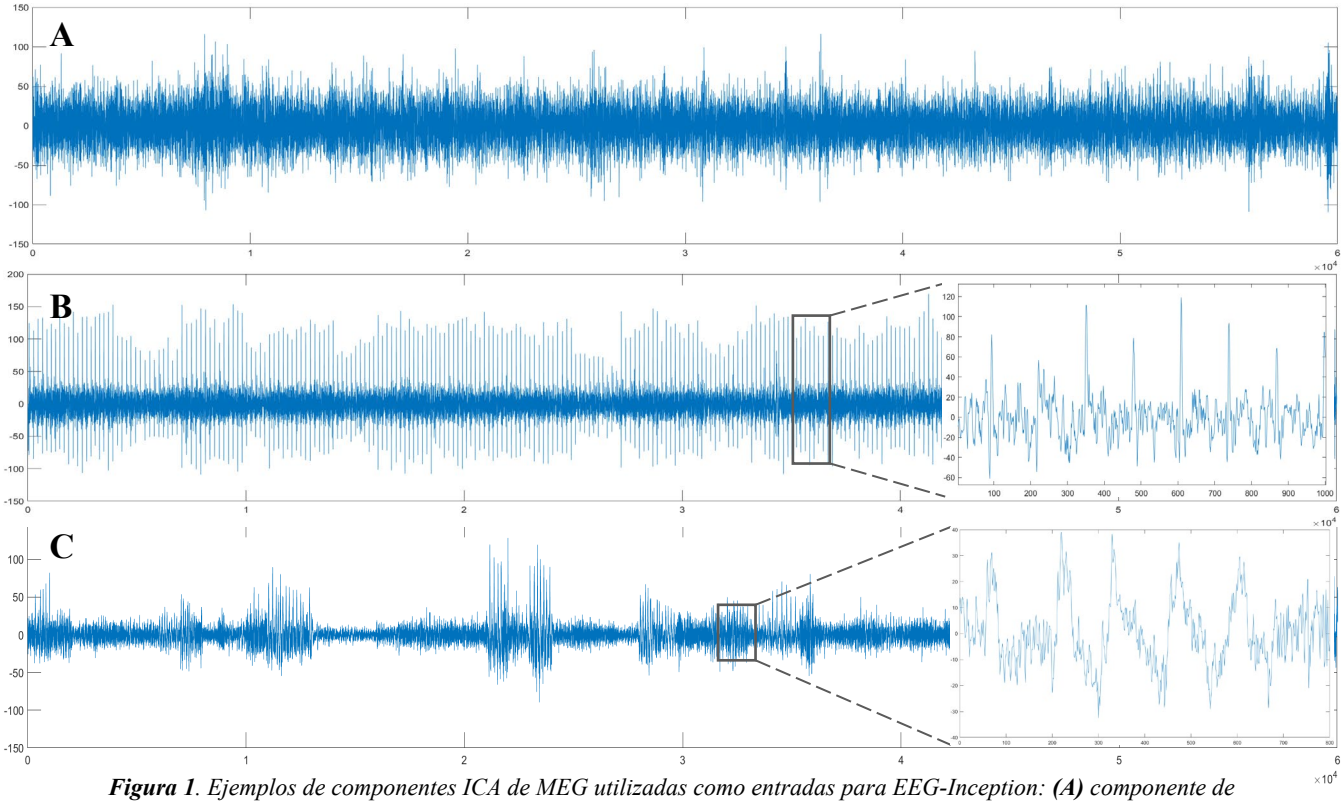

***Figura 1**. Ejemplos de componentes ICA de MEG utilizadas como entradas para EEG-Inception: **(A)** componente de actividad cerebral, **(B)** componente de actividad cardíaca y **(C)** componente de actividad ocular.*

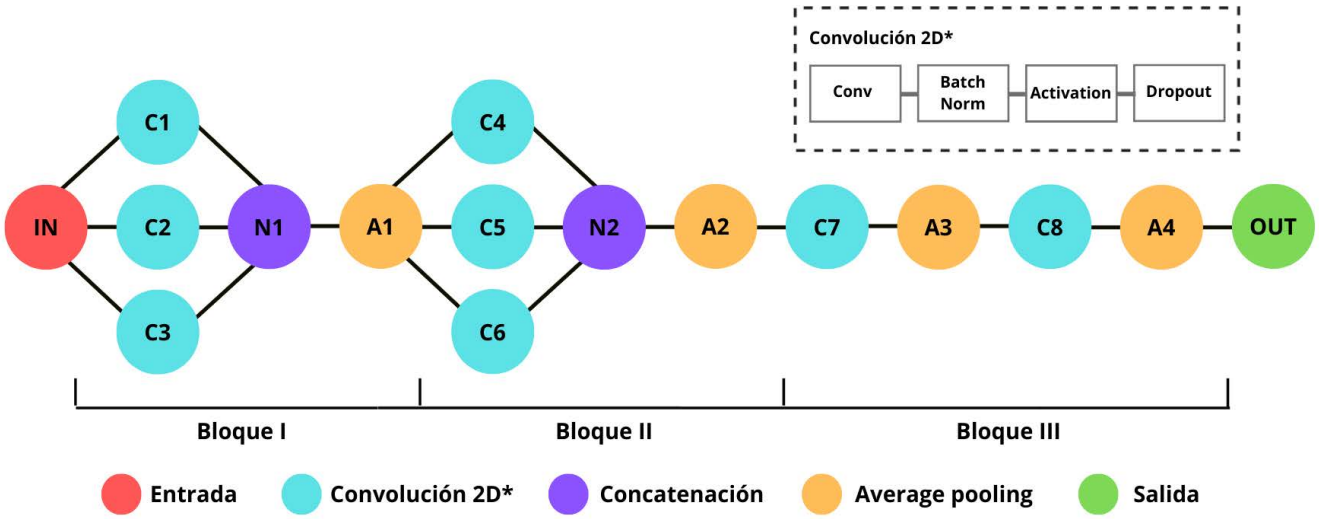

***Figura 2**. Arquitectura de la red EEG-Inception para la clasificación de componentes ICA de origen cerebral y artefactuadas a partir de datos MEG.*

sobre un conjunto aleatorio de validación correspondiente a un 20% del conjunto de entrenamiento. Por otra parte, se hicieron múltiples pruebas para analizar el comportamiento de la red ante distintos valores de los hiperparámetros; sin embargo, los mejores resultados se obtuvieron con la configuración original de la red. Por último, antes de empezar el entrenamiento de la red, se normalizaron los datos como técnica de regularización adicional.

Durante el entrenamiento de la red se balancearon las clases, dándole más peso a las componentes contaminadas por artefactos, debido a que eran una minoría en comparación con las componentes de origen cerebral. Asignar un peso diferente en la función de pérdidas a las distintas clases permitió evitar que la red predijese todas las componentes como actividad cerebral. Una vez finalizado el entrenamiento de la red, se analizó el comportamiento de la misma sobre el conjunto de test. La matriz de confusión se muestra en la figura 3; puede observarse que la red tuvo una sensibilidad del 81% y una especificidad del 87%. La precisión final obtenida fue de un 87% Para comprobar el rendimiento final de la red, se seleccionaron de forma aleatoria 40 componentes de los falsos negativos; un segundo análisis visual por un técnico reveló que el 72,5% de las componentes fueron clasificadas de forma correcta por la red, y pasadas por alto por el técnico que primeramente las clasificó. Lo mismo pasó con los falsos positivos, de los cuales se eligieron 20 componentes, y se observó que el 70% parecían haber sido predichas de forma correcta por la red. Esto nos indica que la precisión real de la red podría ser mucho mayor que ese 87% que se obtuvo en un primer momento.

3.2. Clasificación multiclase

Otra aproximación consistió en entrenar a la red con las cinco clases inicialmente detalladas, es decir, una clase para las componentes con actividad neuronal y las otras cuatro clases para los distintos artefactos. Se utilizaron los mismos parámetros que en la clasificación binaria. El objetivo de esta clasificación fue entrenar a la red con distintos tipos de artefactos y observar cambios en el rendimiento de la red. Los resultados finales se pueden encontrar en la figura 4. Tras la clasificación multiclase se obtuvo una precisión del 85%. De nuevo, para comprobar el rendimiento final de la red, un técnico analizó aleatoriamente 35 componentes de cada una de las cinco clases clasificadas por la red como falsos positivos. Los resultados fueron los siguientes: un 67% de las componentes cardíacas, un 86% de las componentes con red eléctrica, un 80% de las componentes oculares y un 89% de los artefactos de otro tipo, fueron etiquetados de forma correcta por la red, aunque previamente pasados por alto por el primer técnico que las clasificó.

En estudios previos se propuso realizar una clasificación multiclase de componentes a partir del estudio de *higher-order statistics* y medidas de entropía [6]. Finalmente N. Kamal Al-Qazzaz *et al.* mostraron que la técnica conjunta de ICA con la Transformada Wavelet Discreta conseguía en gran medida conservar la actividad cerebral tras la eliminación de artefactos. Otros autores han estudiado el rechazo de artefactos a partir componentes ICA mediante el uso de redes neuronales, utilizando a su vez las señales de ECG o EOG tomadas al mismo tiempo que las de MEG para acelerar el preprocesado de las señales [7], de esta forma se obtuvo una correcta eliminación de los artefactos, preservando el contenido frecuencial de las señales con actividad cerebral. Garg *et al.* emplearon redes neuronales para clasificar un solo tipo de artefacto, en este caso el ocular sin el uso de EOG [8], obteniendo una precisión del 99%. En este estudio se han conseguido

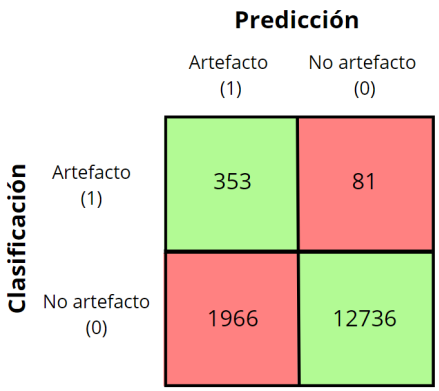

***Figura 3.** Matriz de confusión obtenida sobre el conjunto de test para la clasificación binaria de componentes ICA.*

Clasificación \ Predicción	(1)	(2)	(3)	(4)	(0)
(1)	157	17	10	5	35
(2)	1	32	11	5	9
(3)	0	6	9	2	7
(4)	25	21	28	24	30
(0)	308	768	417	579	12630

Figura 4. *Matriz de confusión obtenida sobre el conjunto de test para la clasificación multiclase de componentes ICA.*

unos resultados muy satisfactorios sin el uso de esas dos señales, lo que disminuye el número de datos a utilizar. Además, sabe destacar que se han conseguido diferenciar entre cuatro tipos de artefactos, a diferencia de los estudios comentados anteriormente.

3.3. Limitaciones y líneas futuras

A pesar de la ayuda que la herramienta supone para mejorar el preprocesado de señales MEG, hay que tener en cuenta que las componentes ICA han sido etiquetadas por un solo investigador, lo cual puede implicar cierto sesgo. Por ello, sería interesante observar la precisión final que se obtiene con la red, tras un primer entrenamiento de la esta y una posterior inspección visual de las componentes mal etiquetadas. Un paso más allá podría ser un estudio comparativo entre el etiquetado de varios profesionales y el etiquetado de un solo profesional ayudado de esta herramienta. Por otra parte, este estudio podría extrapolarse al preprocesado de señales EEG, sobre todo porque la red neuronal utilizada fue originalmente creada para el uso de este tipo de señales. Este posible nuevo estudio podría ahorrar mucho tiempo de preprocesado a todos los investigadores que trabajan con esta señal. Por último, sería muy interesante aplicar métodos de inteligencia artificial explicable (XAI) para comprender el funcionamiento interno de la red, aumentando así la confianza en este tipo de sistemas [10].

4. Conclusiones

En este estudio se ha adaptado la red neuronal EEG-Inception para el análisis de componentes ICA obtenidas a partir de señales MEG, con el objetivo de diferenciar los diferentes tipos de componentes. Las precisiones obtenidas han sido de un 87% para la clasificación binaria y de un 85% para la multiclase. Además, cabe destacar que en el posterior análisis visual de los falsos positivos y negativos se pudo observar que la red había clasificado de forma correcta en torno a un 70% de las componentes que en el primer etiquetado no fueron correctamente clasificadas, lo que muestra que un uso conjunto del etiquetado del profesional junto con el uso de DL podría mejorar la detección de artefactos.

Agradecimientos

Este estudio ha sido financiado por el 'Ministerio de Ciencia e Innovación – Agencia Estatal de Investigación' y el Fondo Europeo de Desarrollo Regional (FEDER) bajo el proyecto PGC2018-098214-A-I00, por la Comisión Europea y el FEDER bajo el proyecto 'Análisis y correlación entre la epigenética y la actividad cerebral para evaluar el riesgo de migraña crónica y episódica en mujeres' ('Programa de Cooperación Interreg V-A España-Portugal POCTEP 2014-2020'), y por el CIBER en Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN) a través del Instituto de Salud Carlos III. S. Pérez-Velasco, V. Gutiérrez-de Pablo y V. Rodríguez-González son beneficiarios de una ayuda PIF-UVa de la Universidad de Valladolid.

Referencias

[1] M. X. Cohen.Where Does EEG Come From and What Does It Mean?,*Trends in Neurosciences*, vol. 40, pp. 208–218, 2017. doi: 10.1016/j.tins.2017.02.004.

[2] P. Mandal, A. Banerjee, M. Tripathi, A. Sharma, A comprehensive review of magnetoencephalography (MEG) studies for brain functionality in healthy aging and Alzheimer's disease (AD), *Frontiers in Computational Neuroscience*, vol. 12, 2018. doi: 10.3389/fncom.2018.00060.

[3] Fred, A.L.; Kumar, S.N.; Kumar Haridhas, A.; Ghosh, S.; Purushothaman Bhuvana, H.; Sim, W.K.J.; Vimalan, V.; Givo, F.A.S.; Jousmäki, V.; Padmanabhan, P.; et al. A Brief Introduction to Magnetoencephalography (MEG) and Its Clinical Applications. Brain Sci. 2022, 12, 788. https://doi.org/ 10.3390/brainsci12060788.

[4] V. Rodríguez-González, C. Gómez, H. Hoshi, Y. Shigihara, R. Hornero, J. Poza, Exploring the Interactions Between Neurophysiology and Cognitive and Behavioral Changes Induced by a Non-pharmacological Treatment: A Network Approach, *Front Aging Neuroscience*, vol. 13, 2021, doi: 10.3389/fnagi.2021.696174.

[5] L. Pion-Tonachini, K. Kreutz-Delgado, S. Makeig, ICLabel: An automated electroencephalographic independent component classifier, dataset, and website, *Neuroimage*, vol. 198, pp. 181–197, 2019, doi: 10.1016/j.neuroimage.2019.05.026.

[6] N. Kamal Al-Qazzaz, S. Hamid Bin Mohd Ali, S. Anom Ahmad, M. Shabiul Islam, and J. Escudero, Automatic artifact removal in EEG of normal and demented individuals using ICA-WT during working memory tasks, *Sensors (Switzerland)*, vol. 17, no. 6, 2017, doi: 10.3390/s17061326.

[7] L. Breuer, J. Dammers, T. P. L. Roberts, and N. J. Shah, Ocular and cardiac artifact rejection for real-time analysis in MEG, *J Neurosci Methods*, vol. 233, pp. 105–114, 2014, doi: 10.1016/j.jneumeth.2014.06.016.

[8] P. Garg, E. Davenport, G. Murugesan, B. Wagner, C. Whitlow, J. Maldijan, A. Montillo, Using convolutional neural networks to automatically detect eye-blink artifacts in magnetoencephalography without resorting to electrooculography, in *Lecture Notes in Computer Science*, vol. 10435 LNCS, pp. 374–381, 2017, doi: 10.1007/978-3-319-66179-7_43.

[9] E. Santamaria-Vazquez, V. Martinez-Cagigal, F. Vaquerizo-Villar, R. Hornero, EEG-Inception: A Novel Deep Convolutional Neural Network for Assistive ERP-Based Brain-Computer Interfaces, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 28, pp. 2773–2782, 2020, doi: 10.1109/TNSRE.2020.3048106.

[10] P. Linardatos, V. Papastefanopoulos, S. Kotsiantis, Explainable AI: A Review of Machine Learning Interpretability Methods, *Entropy*, vol. 23, pp. 18, 2021, doi: 10.3390/e23010018.

CASEIB 2022

XL Congreso Anual de la Sociedad Española de Ingeniería Biomédica

ISBN 978-84-09-45972-8

9 788409 459728