
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





**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 Nosedá

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 <i>Deep Learning</i> 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 <i>explainable artificial intelligence</i> (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

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

S. Pérez Velasco¹, D. Marcos-Martínez¹, E. Santamaría-Vázquez^{1,2}, V. Martínez-Cagigal^{1,2}, S. Moreno-Calderón¹, R. Hornero^{1,2}

¹ Grupo de Ingeniería Biomédica (GIB), Universidad de Valladolid, Valladolid, España, sergio.perez@gib.tel.uva.es

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

Resumen

El uso de la imaginación motora (MI) para controlar interfaces cerebro ordenador (BCI) se ha realizado generalmente a través de la señal eléctrica del cerebro registrada mediante electrograma (EEG). En concreto, a partir de los ritmos sensoriomotres (SMR) presentes en la señal de los electrodos centrales C3 y C4. A partir de los SMR se ha fundamentado la clasificación de MI tradicional basada en métodos de machine learning. Sin embargo, recientemente las redes convolucionales (CNN), una clase de red de deep learning, se han mostrado como una alternativa superior para la decodificación del EEG. Esta superioridad puede radicar en la extracción de características consideradas anteriormente irrelevantes. En este trabajo presentamos una herramienta de explainable artificial intelligence basada en shapley additive explanations (SHAP). Con ella representamos la información que ha sido más relevante para la decodificación de MI a partir del EEG en una red CNN. Nos basamos en la implementación abierta de EEGSym para obtener los valores SHAP en una base de datos de 109 sujetos para los eventos de MI de mano derecha e izquierda. Gracias a esta herramienta, descubrimos que EEGSym presta más atención a la señal de los electrodos frontales F7 y F8. Asociamos esta relevancia a la decodificación de la planificación motora que se da en esa región del cerebro. Estos hallazgos pueden mejorar la selección de canales en la decodificación de MI y permitir el uso de sistemas más eficientes.

1. Introducción

La actividad eléctrica cerebral se puede registrar de manera no invasiva con la electroencefalografía (EEG) a través de electrodos colocados en el cuero cabelludo del usuario. Las interfaces cerebro ordenador (BCI) hacen uso del EEG para crear un camino de comunicación alternativo entre el cerebro y el entorno [1]. La facilidad de uso, alta resolución temporal y bajo coste relativo del EEG con respecto a sus alternativas, ha llevado a su amplio uso en la investigación del cerebro [1]. Sin embargo, el EEG también es muy ruidoso y tiene baja resolución espacial, por lo que los sistemas BCI tradicionalmente utilizan señales de control, que se activan a través de estrategias conocidas como paradigmas que aumenten la señal frente a este ruido siempre presente en los registros [1].

En este trabajo nos centramos en el paradigma de imaginación motora (MI) [1], en concreto en la imaginación del movimiento de mano izquierda o derecha, recientemente implementado en terapias de rehabilitación de ictus con prometedores resultados [2]. A pesar del uso

de un paradigma como MI para conseguir una señal de control discernible del ruido presente en el EEG, decodificar la intención del usuario sigue teniendo margen de mejora. Para solventar los problemas de variabilidad inter-sesión e inter-sujeto presentes en los sistemas de clasificación tradicionales basados en machine learning (ML), se ha investigado aprovechar la capacidad de generalización de los sistemas de deep learning (DL) [3]. En nuestro anterior trabajo presentamos EEGSym, una red convolucional (CNN) que permite clasificar con gran precisión la intención de nuevos usuarios [3].

A pesar de las ventajas que ofrecen las nuevas técnicas de DL frente a ML, se considera que son una “caja negra” de la cual no se puede extraer información sobre su proceso de decisión. El campo de investigación de explainable artificial intelligence (XAI) surge para dar respuesta a este problema, permitiendo descubrir en qué información se basan para realizar su clasificación. Para los registros de EEG, se han adaptado herramientas XAI basadas en métodos de propagación como layerwise relevance propagation [4] y Grad-CAM [5], o métodos de perturbación como easyPEASI [6] y oclusión sensitivity analysis [7]. Pero estas aplicaciones no cumplen ciertos principios matemáticos que aseguren la obtención de una única atribución de importancia de los datos usados para la clasificación. Otros investigadores [8] han usado ya la herramienta shapley additive explanations (SHAP) [9] para registros de EEG. Sin embargo, se usaba sobre un clasificador basado en árboles de decisión, que tiene una capacidad más limitada que las redes de DL. En este trabajo adaptamos la herramienta SHAP, para explicar una red de DL entrenada con registros de EEG durante MI. SHAP unifica previos métodos de XAI y asegura que la explicación de la clasificación realizada sea única y no dependa de parámetros de inicialización.

El objetivo de este trabajo es representar los valores SHAP asociados a la toma de decisiones de EEGSym en una base de datos de 109 sujetos [10]. Mediante esta representación, observaremos qué información es más relevante para EEGSym a la hora de clasificar eventos de MI.

2. Métodos

2.1. Dataset

Se ha analizado la base de datos pública Physionet [10]. Esta base de datos cuenta 109 usuarios y entre 42 y 46

eventos de MI por sujeto. Tras un aviso sonoro, una flecha indicaba el tipo de MI a realizar (i.e., imaginación de apertura y cierre de mano izquierda o derecha) durante los siguientes 3 segundos de manera continuada. Se realizaba una única sesión en la que no se les presentaba realimentación de la tarea mental que estaban realizando.

2.2. EEGSym

Se utiliza la implementación abierta de EEGSym [3] para 16 canales. EEGSym es una nueva red CNN de clasificación de MI inter-sujeto. Incluye nuevos avances en la aplicación de las técnicas de DL: conexiones residuales, técnicas de *data augmentation*, *transfer learning* entre sujetos y una disposición siamesa de la red que aprovecha la simetría del cerebro en el plano sagital medio.

La red ha demostrado ser significativamente superior a cuatro redes previas en la tarea de clasificación de un problema binario de MI inter-sujeto [3]. Junto con el conjunto de novedosas técnicas de DL con las que se aplica establece unos resultados que son un nuevo estado del arte en este tipo de clasificación binaria.

Para obtener las representaciones de importancia de las zonas del EEG en la clasificación de MI, utilizamos los pesos de EEGSym adaptados a la base de datos de Physionet [10]. Para ello, partimos de la inicialización disponible en la implementación abierta para 16 canales, y con ella realizamos una etapa de *fine tuning* a la base de datos de Physionet [10], como en el artículo original.

2.3. SHAP

La herramienta SHAP en Python [9] ha tenido gran aceptación debido a unificar y adaptar previas herramientas de XAI. Utiliza una adaptación de herramientas populares de XAI para producir una aproximación de valores Shapley, haciendo que estos cumplan tres propiedades: precisión local, pérdidas, y consistencia [9]. Cumpliendo estas propiedades, se obtiene una representación única de la importancia de las características de entrada.

Se utiliza la herramienta del paquete SHAP llamada “GradientExplainer”, una adaptación de *integrated gradients* y SmoothGrad para obtener una aproximación de los valores Shapley. En modelos de DL no se pueden aplicar los métodos exactos por a su alto coste computacional y es necesario el uso de un cálculo aproximado. Esta herramienta calcula el gradiente (i.e., cambio en la predicción) entre el *background* (en nuestro caso un EEG con señal 0 en todos los canales e instantes temporales), la señal de entrada y las diferentes representaciones intermedias resultantes de interpolar entre *background* y señal. El cambio entre la predicción realizada y la esperada se atribuye a este gradiente por cada punto de interpolación. Sumando todas las atribuciones intermedias se obtiene los valores SHAP para esa señal. Posteriormente, se hace la media para todas estas matrices de valores SHAP obtenidas para una misma clase de MI en toda la base de datos. Solo se incluyen los ejemplos correctamente clasificados, es decir, aquellos ejemplos en los que la red predice correctamente la clase a explicar.

Las matrices de valores SHAP se corresponden con el EEG usado para la clasificación. En el eje vertical se representan los distintos canales, y en el eje horizontal la magnitud de tiempo. Gracias a ello, esta representación tiene una correspondencia directa con los canales y periodos de tiempo. Los valores SHAP positivos incrementan la probabilidad de predecir la clase a explicar, mientras que los valores SHAP negativos reducen la probabilidad de predecir dicha clase. Con estos valores se puede calcular la importancia relativa que tiene cada canal o instante temporal en la predicción de cada clase.

3. Resultados

Podemos observar en la Figura 1 a y b, la representación de los valores SHAP obtenidos para los eventos de MI de mano izquierda y mano derecha, respectivamente. Como hemos explicado anteriormente, se representan las explicaciones de la predicción obtenida sólo en los eventos en los que la red neuronal ha acertado. En Physionet, EEGSym tenía una precisión inter-sujeto de 88.6 ± 9.0 , por lo que se representa la media para casi todos los eventos disponibles en esta base de datos. Cada evento contiene los tres primeros segundos tras el *onset* de MI para los 16 canales usados en la predicción. De las figuras, se obtiene información tanto a nivel temporal como a nivel espacial.

En rojo se representan los valores positivos SHAP y en azul los valores negativos. Además, incluye también las medias por canales con un porcentaje que indica cuánto influye ese canal a la predicción en valores absolutos, ya sea por incrementar la probabilidad de predecir esa clase o por disminuirla. En el eje temporal, también se representa la media que todos estos valores tienen en todos los canales. Las medias temporal y espacial nos permiten observar la influencia que los distintos instantes de tiempo y los distintos canales tienen en la clasificación.

3.1. Análisis temporal

Se observa que, para la clasificación binaria, la región temporal más determinante para clasificar la señal con EEGSym se encuentra en el primer segundo de la señal. Más concretamente, se puede observar cómo la mayor contribución a la clasificación se encuentra entre 0.2 y 0.4 segundos, que coincide con el rango de tiempo de reacción humana. Los últimos dos segundos, aunque en algunos canales tienen una influencia similar a los primeros segundos, de manera global son menos relevantes al anularse las aportaciones positivas de unos canales con las aportaciones negativas de otros.

Analizando temporalmente cada canal observamos que ese primer segundo es el más relevante en la mayoría, sin embargo, en los canales C3 y C4 se extiende hasta segundo y medio tras el *onset*. Este comportamiento también se observa en F7 y F8, cuya aportación negativa a la predicción de clase izquierda y clase derecha, respectivamente, se encuentra entre los 0.7 y 2.2 segundos.

3.2. Análisis espacial

Los porcentajes presentados para cada canal representan la importancia absoluta relativa de cada canal en la predicción. A partir de esta información descubrimos que




Figura 1. Representación de las atribuciones de valores SHAP para eventos de imaginación motora (MI) en Physionet. En el eje vertical se representan los 16 canales del sistema 10-20. En el eje horizontal los tres segundos correspondientes al evento de MI tras el onset. En rojo se indican los valores SHAP positivos, que indican que esa región tiempo-espacial contribuye positivamente a la predicción de la clase. En azul se indican los valores SHAP negativos, que por el contrario indican que contribuye negativamente a la predicción de esa clase. a) MI de mano izquierda b) MI de mano derecha

EEGSym encuentra los canales frontales, F7 y F8, cómo los más determinantes para determinar la clase de MI realizada. Después se fija en los canales centrales, C3 y C4. El resto de canales realizan aportaciones netas más marginales a estos cuatro canales, que concentran el 60% de la influencia sobre la decisión de clasificación. Los siguientes canales en importancia serían F3, F4, T7 y T8.

Para ambos eventos de MI, utiliza una atribución prácticamente simétrica de los canales. Para clasificar mano izquierda, EEGSym encuentra a F8 y C3 como los canales más importantes. Mientras que la señal de los canales F7 y C4 de manera neta disminuye la probabilidad de predecir dicha clase. En cambio, para mano derecha, este comportamiento es exactamente el contrario.

4. Discusión

A la hora de interpretar estos mapas de valores SHAP nos encontramos con que, a diferencia de la literatura previa, EEGSym encuentra como más relevantes los canales frontales F7 y F8 frente a los canales C3 y C4 típicamente escogidos. Tradicionalmente, cuando se aplican métodos de clasificación de ML se debe realizar una etapa previa de selección de características que no suele ser automática. Los eventos de MI se relacionan con la presencia de los ritmos sensoriomotores (SMR), una señal presente en la actividad eléctrica del surco central del cerebro, que para eventos de MI de mano izquierda y derecha se encontraba presente en la señal de los electrodos C4 y C3,

respectivamente. Los SMR se caracterizaban por un evento de desincronización en el electrodo contralateral, seguido de un evento de sincronización [1], que se puede observar de manera visual al promediar la señal de varios eventos de MI. De esta manera, los métodos de ML confiaban en los SMR y utilizaban la señal de los canales C3 y C4 (y en ocasiones también de los adyacentes) para realizar la clasificación de MI. Gracias a la combinación de XAI con la red EEGSym de DL, podemos observar cómo, al menos en esta base de datos de 109 usuarios, hay información incluso más relevante en los electrodos frontales F7 y F8. La decisión de predicción con respecto a estos canales se podría realizar incluso más rápido que el tradicional uso de C3 y C4, ya que la mayor parte de la aportación a la decisión se encuentra en el primer segundo, con respecto a la señal de C3 y C4 más distribuida durante segundo y medio. Estos descubrimientos se podrían aplicar para realizar clasificación de MI con épocas de menor duración.

Hemos visto como el mapa de valores SHAP obtenido para el registro de EEG utilizado en la clasificación es útil para obtener información de qué regiones espacio-temporales son importantes para clasificar eventos de MI con EEGSym. EEGSym recientemente ha conseguido un rendimiento superior a los modelos anteriores en la clasificación de MI inter-sujeto, lo que da mayor seguridad de la generalización de estas interpretaciones [3]. Estos valores SHAP nos permiten tener información de la relevancia espacio-temporal de los registros de EEG de MI.

Así encontramos como para EEGSym es más relevante el primer segundo de registro, y espacialmente la señal de los canales F7 y F8 seguidos de C3 y C4. En concreto, la señal que se obtiene de F7 y F8 está relacionada con la planificación del movimiento [11]. Es posible que EEGSym haya aprendido a identificar en la señal EEG de estos dos electrodos cómo se codifica la decisión del movimiento a imaginar. De la misma manera que los SMR de la zona central, esta decisión entre planificación de mano izquierda y mano derecha parece presentarse de manera simétrica en F7 y F8. Si nos fijamos temporalmente, la decisión en estos dos electrodos es más rápida que la de los electrodos C3 y C4, que contendrían la señal del SMR asociado a la imaginación del movimiento.

Una línea futura de investigación a partir de estos resultados, sería comprobar como un clasificador centrado en la señal de estos cuatro canales pueda alcanzar valores similares de clasificación a los obtenidos con estos 16 canales. En la publicación original de EEGSym con 8 canales se conseguía una precisión de 84.5% frente a la de 88.6% de 16 canales. Estos 8 canales no incluían los electrodos F7 y F8, que tan determinantes son en la clasificación de 16 electrodos, por lo que es muy probable que con una elección de 8 canales que los incluya, la precisión pueda llegar a ser más semejante con solo 8 canales. Además, también se podría intentar reducir el tiempo de clasificación a ese primer segundo que se ha mostrado como el más importante en la clasificación de MI sin realimentación. Por otro lado, también sería interesante estudiar si los valores SHAP son similares entre MI con realimentación y sin ella. Además, al haber encontrado en el paradigma de MI la correspondencia con el conocimiento previo, se podrían extraer información de las redes DL en otros paradigmas menos estudiados.

A pesar de estos interesantes resultados y su correlación con conocimientos previos sobre los eventos de MI, este trabajo tiene algunas limitaciones que es necesario apuntar. Para aprovechar el trabajo previo realizado, se han utilizado los 16 canales presentes en la publicación de EEGSym que buscaban homogeneizar los presentes en las 5 bases de datos sobre las que trabajaba. Sería interesante comprobar con los 62 electrodos presentes en la base de datos de Physionet si ciertamente F7, F8, C3 y C4 son los electrodos más óptimos para realizar la clasificación, o hay algún otro que pueda introducir más información relevante respecto a los 16 elegidos en la publicación original. Por otro lado, la red ha sido entrenada con señales que comparten el mismo *onset*. En este tipo de registros la información de la planificación motora presente en F7 y F8 puede estar sobrerrepresentada con respecto a eventos de MI, que no contengan un inicio compartido.

5. Conclusión

La herramienta XAI presentada para DL aplicado a EEG permite obtener los valores SHAP con correspondencia directa con la distribución espacial y temporal de un EEG. Gracias a estas representaciones, se observa como para EEGSym los instantes temporales más relevantes a la hora de realizar una clasificación de MI están concentrados en el primer segundo tras el *onset* de MI. Además, identifica

los canales frontales F7 y F8 como los más importantes para su decisión, seguidos de C3 y C4. Esta herramienta de XAI nos permite descubrir como las redes de DL se fijan en características que habían pasado desapercibidas en el uso tradicional de ML para la clasificación de MI.

Agradecimientos

Este estudio ha sido financiado por los proyectos PID2020-115468RB-I00, RTC2019-007350-1 y PDC2021-120775-I00 del Ministerio de Ciencia e Innovación/Agencia Estatal de Investigación/10.13039/501100011033/ y FEDER Una forma de hacer Europa; por el proyecto I+D+i ‘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 FEDER; y por ‘Centro de Investigación Biomédica en Red en Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN)’ a través de ‘Instituto de Salud Carlos III’. Diego Marcos-Martínez, Eduardo Santamaría-Vázquez y Sergio Pérez-Velasco son beneficiarios de una ayuda PIF de la Consejería de Educación de la Junta de Castilla y León.

Referencias

- [1] J. R. Wolpaw *et al.*, *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press, 2012.
- [2] M. Sebastián-Romagosa *et al.*, “Brain Computer Interface Treatment for Motor Rehabilitation of Upper Extremity of Stroke Patients—A Feasibility Study,” *Front. Neurosci.*, vol. 14, no. October, pp. 1–12, 2020.
- [3] S. Perez-Velasco *et al.*, “EEGSym: Overcoming Inter-Subject Variability in Motor Imagery Based BCIs With Deep Learning,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 30, pp. 1766–1775, 2022.
- [4] I. Sturm *et al.*, “Interpretable deep neural networks for single-trial EEG classification,” *J. Neurosci. Methods*, vol. 274, pp. 141–145, 2016.
- [5] H. Choi *et al.*, “Non-human primate epidural ECoG analysis using explainable deep learning technology,” *J. Neural Eng.*, vol. 18, no. 6, p. 066022, Dec. 2021.
- [6] D. O. Nahmias *et al.*, “Easy Perturbation EEG Algorithm for Spectral Importance (easyPEASI),” in *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, Aug. 2020, pp. 2398–2406.
- [7] C. Ieracitano *et al.*, “A novel explainable machine learning approach for EEG-based brain-computer interface systems,” *Neural Comput. Appl.*, vol. 0123456789, no. DI, Mar. 2021.
- [8] H. Alsuradi *et al.*, “Explainable Classification of EEG Data for an Active Touch Task Using Shapley Values,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 12424 LNCS, 2020, pp. 406–416.
- [9] S. Lundberg *et al.*, “A Unified Approach to Interpreting Model Predictions,” *NIPS 2017*, vol. 32, no. 2, pp. 1208–1217, May 2017.
- [10] A. L. Goldberger *et al.*, “PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals,” *Circulation*, vol. 101, no. 23, Jun. 2000.
- [11] E. Beam *et al.*, “A data-driven framework for mapping domains of human neurobiology,” *Nat. Neurosci.*, vol. 24, no. 12, pp. 1733–1744, 2021.