




CASEIB
2021
XXXIX

XXXIX CONGRESO ANUAL DE LA SOCIEDAD ESPAÑOLA DE INGENIERÍA BIOMÉDICA



LIBRO DE ACTAS

ORGANIZAN:



UNIVERSIDAD
POLITÉCNICA
DE MADRID



federación española
de empresas de
TECNOLOGÍA SANITARIA





CASEIB
2021
XXXIX

Congreso Anual
de la Sociedad
Española de
Ingeniería
Biomédica

LIBRO DE ACTAS

Madrid, 25 y 26 de noviembre de 2021

XXXIX Congreso Anual de la Sociedad Española de Ingeniería Biomédica

Presidente del Comité Organizador:

Enrique J. Gómez Aguilera

Secretaria del Comité Organizador:

Patricia Sánchez González

Editores:

Paloma Chausa Fernández

Gema García Sáez

Enrique J. Gómez Aguilera

M. Elena Hernando Pérez

Patricia Sánchez González

Diseño de portada:

Sandra Martínez

ISBN: 978-84-09-36054-3



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

ORGANIZADORES

Grupo de Bioingeniería y Telemedicina
Escuela Técnica Superior de Ingenieros de Telecomunicación
Universidad Politécnica de Madrid

Sociedad Española de Ingeniería Biomédica



SOCIEDADES INTERNACIONALES QUE AUSPICIAN EL CONGRESO

European Alliance for Medical and Biological Engineering & Science

International Federation for Medical and Biological Engineering



COLABORADORES



EMPRESAS COLABORADORAS DE LA SEIB



BIENVENIDA

Estimados compañeros y amigos de la Ingeniería Biomédica participantes en CASEIB2021:

En nombre del Comité Organizador, es un placer presentar el XXXIX Congreso Anual de la Sociedad Española de Ingeniería Biomédica (CASEIB 2021). La nueva edición de nuestro congreso tiene un formato virtual, tal como hicimos el año pasado, pero en un formato más reducido que el congreso tradicional y con una serie de nuevas propuestas que esperamos sean de interés.

El congreso se celebra los días 25 y 26 de noviembre de 2021, y está organizado por el Grupo de Bioingeniería y Telemedicina de la Universidad Politécnica de Madrid y la Sociedad Española de Ingeniería Biomédica (SEIB), en colaboración con la Federación de Empresas de Tecnología Sanitaria (FENIN) y el nodo español del European Institute of Innovation & Technology in Health (EIT Health Spain).

El objetivo principal de esta nueva edición de CASEIB 2021 es potenciar aún más la participación de los estudiantes de Ingeniería Biomédica, tanto de grado, máster y doctorado. CASEIB 2021 tiene un enfoque muy dirigido hacia la innovación y el emprendimiento como áreas fundamentales en nuestra disciplina, en línea con el lema propuesto: “La Ingeniería Biomédica en la transformación digital de la sanidad”.

El primer día del congreso, organizado conjuntamente con FENIN, se centra en conocer y analizar la visión de la industria de la tecnología sanitaria sobre el papel presente y futuro de las nuevas generaciones de ingenieros biomédicos en la transformación digital de la sanidad. En la agenda de este primer día se incluyen las sesiones de las competiciones de los estudiantes de grado de los renombrados “Premios FENIN - Competición de estudiantes de Grado en Ingeniería Biomédica” y los “Premios Prof. José M^a Ferrero Corral” para estudiantes de máster y doctorado. El segundo día, organizado conjuntamente con EIT Health Spain, se desarrolla en inglés, y se centra en la innovación y emprendimiento en tecnologías sanitarias. Incluye una sesión dedicada al nuevo “Premio EIT Health Spain a la innovación y emprendimiento en Ingeniería Biomédica” para estudiantes de grado, máster y doctorado. Gracias a la fructífera colaboración establecida entre SEIB, FENIN y EIT Health Spain, se otorgan tres premios dotados económicamente a los mejores trabajos de las 3 competiciones del congreso.

CASEIB 2021, es una edición especial para todos los estudiantes de ingeniería biomédica, y en esta edición no se ha realizado la llamada habitual de trabajos ni la celebración de sesiones científicas de presentación de trabajos, con la excepción de las sesiones de finalistas de las distintas competiciones.

En este libro de actas se han incluido todos los trabajos presentados en los “Premios FENIN - Competición de estudiantes de Grado en Ingeniería Biomédica” (seleccionados por cada uno de los Grados), así como los trabajos aceptados por el Comité Científico para su participación en los “Premios Prof. José M^a. Ferrero Corral”, con independencia de su selección como finalistas. Finalmente, los trabajos presentados a este último, y aceptados por el Comité Científico, podrán optar, si lo desean, a ser valorados para su publicación en ediciones especiales de las revistas “Sensors” y “Entropy”, con las condiciones establecidas en congresos anteriores.

Nuestros sinceros agradecimientos a FENIN, EIT Health Spain, Universidad Politécnica de Madrid, y a todas las empresas colaboradoras de la SEIB que nos han brindado su apoyo en el congreso.

Con la ilusión de volver al formato habitual del congreso CASEIB en el próximo año 2022, y en el convencimiento que esta edición especial siga siendo el gran foro de conocimiento en Ingeniería Biomédica en España, os enviamos un afectuoso saludo.

A handwritten signature in blue ink, appearing to read 'Enrique J. Gómez Aguilera', with a long horizontal line extending to the right.

Enrique J. Gómez Aguilera

Presidente del Comité Organizador del CASEIB2021

COMITÉ ORGANIZADOR

Presidente

Enrique J. Gómez Aguilera

Secretaria

Patricia Sánchez González

Vocales GBT-SEIB

Paloma Chausa Fernández

José Manuel Iniesta Chamorro

Gema García Sáez

Ignacio Oropesa García

M. Elena Hernando Pérez

Julio Ignacio Piquero Cabañero

Vocales FENIN

Sergio Muñoz

Jorge Fuentes

Sofía Romero

Vocales EIT Health

Montse Delgado

Lilisha Burris

Mara Belluco

COMITÉ CIENTÍFICO

Presidente

Enrique J. Gómez
Aguilera
*Universidad Politécnica
de Madrid*

Secretaria

M. Elena Hernando
Pérez
*Universidad Politécnica
de Madrid*

Co-Secretaria

Patricia Sánchez
González
*Universidad Politécnica
de Madrid*

Vocales

Begoña Acha Piñero. <i>Universidad de Sevilla</i>	Roberto Hornero Sánchez. <i>Universidad de Valladolid</i>
Raúl Alcaraz Martínez. <i>Universidad de Castilla-La Mancha</i>	Raimon Jané Campos. <i>Universidad Politécnica de Cataluña</i>
Erik Alonso. <i>Universidad del País Vasco</i>	Pablo Laguna Lasaosa. <i>Universidad de Zaragoza</i>
Elisabete Aramendi Ecenarro. <i>Universidad del País Vasco</i>	María Jesús Ledesma. <i>Universidad Politécnica de Madrid</i>
José Luis Arce Diego. <i>Universidad de Cantabria</i>	Maite Mujika Garmendia. <i>CEIT-TECNUN, San Sebastián</i>
M ^a Gloria Bueno García. <i>Universidad de Castilla-La Mancha</i>	Jesús Poza Crespo. <i>Universidad de Valladolid</i>
Manuel Desco Menéndez. <i>Universidad Carlos III de Madrid</i>	Gema Prats Boluda. <i>Universidad Politécnica de Valencia</i>
Félix Fanjul Vélez. <i>Universidad de Cantabria</i>	Javier Reina Tosina. <i>Universidad de Sevilla</i>
Javier García Casado. <i>Universidad Politécnica de Valencia</i>	Ana de los Reyes Guzmán. <i>Servicio de Salud de Castilla-La Mancha</i>
María García Gadañón. <i>Universidad de Valladolid</i>	José Joaquín Rieta Ibáñez. <i>Universidad Politécnica de Valencia</i>
Beatriz F. Giraldo Giraldo. <i>Universidad Politécnica de Cataluña</i>	Isabel Román Martínez. <i>Universidad de Sevilla</i>

Francisco Javier Sáiz Rodríguez.
Universidad Politécnica de Valencia

Francisco M. Sánchez Margallo. *C.C.M.I.*
Jesús Usón

Daniel Sánchez Morillo. *Universidad de*
Cádiz

Andrés Santos Lleó. *Universidad*
Politécnica de Madrid

Carmen Serrano Gotarredona.
Universidad de Sevilla

Abel Torres Cebrián. *Universidad*
Politécnica de Cataluña

PROGRAMA - JUEVES 25 DE NOVIEMBRE DE 2021

- 9:00 **Acto Inaugural**
- *- D. Guillermo Cisneros, Rector Magnífico de la UPM*
9:30 *- Dña. Margarita Alfonso, Secretaria General de FENIN*
- Dña. Cristina Bescós, Directora General de EIT Health Spain
- D. Enrique J. Gómez, Presidente CASEIB2021 y presidente SEIB

- 9:30 **Charla: «La Transformación Digital en la Sanidad»**
- Ponente:
10:30 *- D. Luis Javier Bonilla, Director General de la compañía CGM en España, multinacional del sector de salud digital*

Moderadora: *Dña. M^a Elena Hernando Pérez, Catedrática Universidad Politécnica de Madrid*

- 10:30 **Mesa redonda: «Ingeniería Biomédica y Transformación Digital»**
- Ponentes:
11:30 *- D. Javier Arribas Pastor, Digital Solutions Expert en Siemens Health, Siemens-healthineers*
- Dña. Carmen Carrillo, Directora de ID&D, Matachana
- D. Lluís Blanch, Coordinador ITEMAS, Director Institut d'Investigació i Innovació Parc Taulí - I3PT
- D. Javier Reina, Catedrático Univ. Sevilla, Secretario General de SEIB

Moderador: *D. Sergio Muñoz, Director Innovación de FENIN*

- 11:30 *Descanso*
-
11:45

11:45 **Premios FENIN para alumnos GIB**

- Miembros del jurado:

13:30 - *D. Roberto Hornero*

- *D. Javier Reina*

- *D. Juan Carlos Antony*

Moderador: *D. Roberto Hornero*

13:30 *Descanso*

-

15:00

15:00 **Premio José María Ferrero Corral**

- Miembros del jurado:

18:00 - *Dña. Elisabete Aramendi*

- *Dña. Beatriz Giraldo*

- *Dña. Gema Prats*

Moderador: *Dña. Elisabete Aramendi*

PROGRAMA - VIERNES 26 DE NOVIEMBRE DE 2021

10:00 **Welcome & opening words**
- *By Enrique Javier Gómez, President of SEIB; and*
10:15 *Cristina Bescós, EIT Health Spain Managing Director.*

10:15 **Session to raise patients' voice in innovation**
- *By EUPATI Fellow.*
10:50 *Session followed by questions from the audience.*

10:50 **Roundtable: «How I became an Entrepreneur in Biomedical Engineering»**
- **Engineering»**
11:50 **With:**
- *Francesc Huguet París, Lainomedical*
- *Markus Wilhelms, Mowoot*
- *María González, Tucuvi*

11:50 *Break*
-
12:00

12:00 **Working'Health. Raising Life and Health Science Talent in Europe**
- *By Claire Nassiet*
12:30

12:30 **Acto de clausura**

- *D. Enrique J. Gómez, Presidente CASEIB2021 y presidente SEIB*

14:30

- *D. Sergio Muñoz, Director Innovación de FENIN*

- *Dña. Cristina Bescós, Directora General de EIT Health Spain*

- *Dña. Patricia Sánchez, Secretaria del Comité Científico CASEIB2021*

Entrega de premios

- *D. Roberto Hornero (Premios FENIN-GIB)*

- *Dña. Elisabete Aramendi (Premios JM Ferrero)*

- *Dña. Lilisha Burris (Premios EIT Health)*

ÍNDICE DE SESIONES CIENTÍFICAS

Jueves 25 de Noviembre de 2021, a las 11:45

Premios FENIN para alumnos de Grado en Ingeniería Biomédica

Moderador: D. Roberto Hornero

Implementing an optical tweezers setup as a microrheology technique to study the mechanical properties of the cytoplasm	2
Diseño e implementación de algoritmos de machine learning para la caracterización objetiva del temblor patológico mediante señales cinemáticas y fisiológicas	6
Monitorización longitudinal de la compliancia pulmonar basada en la TIE en pacientes infectados por COVID-19	10
A Virtual Reality Application for Training Medical Students in a Pneumothorax Procedure	14
Reconstrucción en 3D del microambiente inmunológico de tumores de cáncer pancreático	18
Estudio de la arquitectura temporal de la actividad neuronal en la demencia por enfermedad de Alzheimer mediante técnicas de conectividad funcional dinámica	22
Optimización de hidrogeles inyectables y liberación de factores de crecimiento hepático.....	26
Discovering the drivers of aberrant splicing in cancer	30
Análisis de texturas como ayuda al diagnóstico neurooncológico en imágenes de resonancia magnética	34
Análisis de las variables biomecánicas para el estudio del índice de ruptura de la Triple A	38
SleepBCI: a platform for memory enhancement during sleep based on automatic scoring	42
Telerehabilitation of post-stroke motor impairment	46

Premios José María Ferrero Corral

Moderadora: Dña. Elisabete Aramendi

Prediction of short-term survival in glioblastoma patients with total tumor resection from multimodal pre-surgical MRI images using machine learning	51
Evaluación de la robustez de la red neuronal funcional en la enfermedad de Alzheimer	55
Análisis de las alteraciones en la organización jerárquica de la actividad neuronal debidas a la enfermedad de Alzheimer	59
Modelo de deep learning basado en la combinación de redes neuronales convolucionales y recurrentes para clasificar eventos de apnea e hipopnea mediante la señal de oximetría	63
Surgical phase recognition for non-intrusive surgical skills' assessment in educational contexts based in speech and video	67
La importancia dinámica como indicador de comportamiento de hub en la región parietal de la red neuronal por defecto	71
Sub-surface laser engraving application for hexagonal SiPM	75
Methodologies for the quantification and classification of nuclear medicine neuroimaging for clinical decision support	79
La importancia de la aurícula izquierda en la alteración del sustrato auricular tras ablación por catéter de Fibrilación Auricular Paroxística	83
Optimización preoperatoria de la configuración de los electrodos de estimulación con un modelo 3D de médula espinal personalizado al paciente	87
P-Wave detection using latent spaces from autoencoders and domain description classifiers	91
“Time-Warping” ponderado sobre la onda T para reducir el impacto de errores de delineación: implicaciones clínicas	95
Diseño e implementación de un sistema de simulación para el manejo de la fractura de pelvis	99
Cambio de FiO2 como alternativa al gadolinio para estudios de perfusión cerebral por resonancia magnética	103
Análisis de OCTA (angiografía por tomografía de coherencia óptica) mediante redes neuronales convolucionales para el diagnóstico de esclerosis múltiple	107

Desarrollo y validación de los bucles de control para las interfaces hápticas de un simulador de silla de ruedas manual	111
Modificación de un modelo de miocito ventricular humano para representar el papel de los canales SK en insuficiencia cardiaca	115
Análisis del impacto combinado del grupo sanguíneo y los antígenos leucocitarios humanos en la supervivencia del trasplante renal en Andalucía	119
Machine learning algorithms to predict adherence to treatment pathways in secondary prevention of patients with acute coronary syndrome	123
Deep learning-based segmentation of head and neck organs on CT for radiotherapy treatment: lessons learned with clinical data	127
Propuesta de modelos predictivos en salud mental para la personalización de terapias de rehabilitación en pacientes con adicción a la cocaína	131
Visualización de estudios preoperatorios en forma de nube de puntos volumétrica en dispositivos de realidad mixta	135
Evaluación de la calidad en registros electrocardiográficos para diagnósticos automáticos fiables mediante aprendizaje profundo y aumento de datos	139
Design, manufacture and validation of customized surgical guides for total knee replacement	143
Análisis paso a paso de registros de ablación por catéter en fibrilación auricular paroxística	147
Evaluación del riesgo de hipertensión a partir de registros fotopletimográficos utilizando clasificadores de deep learning	151
Diferencias entre patrones de ondas P y ondas de activación local del seno coronario durante ablación por catéter de fibrilación auricular paroxística	155
Reconocimiento automático de posiciones radiográficas en radiología	159
EEG-InceptionGen: una red convolucional de propósito general para la clasificación de señales EEG	163
Procesamiento de TAC de tórax para su uso en simulaciones de tomosíntesis.....	167
Electrophysiological modelling of left ventricle with heterogeneous scar to assess inducibility of reentry circuits	171
Inclusión de compensación de movimiento en un esquema deep learning basado en modelo para la reconstrucción de imágenes de cine cardíaco	175
Reconstrucción de imágenes para tomosíntesis de tórax mediante aprendizaje profundo	179
A simplified methodology to measure gait spatio-temporal parameters using low-cost inertial sensors	183

Wearable technology for predicting the quality of surgical performance and workload in laparoscopic surgery: preliminary results	187
Citometría de microflujo para estudios bacterianos	189
Información a priori obtenida con aprendizaje profundo para su uso en algoritmo de reconstrucción iterativo	193
Método para la caracterización de la señal de presión arterial invasiva continua durante la reanimación cardiopulmonar	197
Interfaz para el estudio del “jitter” neuromuscular	201
An immersive virtual reality training system for paediatric stroke code medical training	205

EEG-InceptionGen: Una Red Convolutiva de Propósito General para la Clasificación de señales EEG

Eduardo Santamaría-Vázquez^{1,2}, Sergio Pérez-Velasco¹, Víctor Martínez-Cagigal^{1,2}, Roberto Hornero^{1,2}

¹ Grupo de Ingeniería Biomédica, Universidad de Valladolid, Valladolid, España

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

Resumen

La electroencefalografía (EEG) es una técnica ampliamente utilizada en campos como la investigación del sistema nervioso central, el diagnóstico clínico y los sistemas brain-computer interface (BCI), que requieren del análisis automático de esta señal para la detección de patrones de interés. Sin embargo, este análisis es de gran complejidad, y habitualmente se necesita una gran inversión en tiempo y esfuerzo para identificar las características más relevantes de estos patrones y diseñar un algoritmo de detección. Con el objetivo de resolver esta limitación, hemos diseñado desarrollado y validado una red neuronal convolutiva multipropósito, llamada EEG-InceptionGen, aplicable a una gran cantidad de tareas de clasificación EEG con un alto rendimiento. El modelo ha sido validado en 3 tareas distintas como el control de un sistema BCI basado en potenciales relacionados con eventos, la detección de la imaginación motora de las manos derecha e izquierda y la detección de episodios epilépticos. En la primera se alcanzó una precisión del 74.27% en una base de datos de 31 sujetos con grave discapacidad. En la segunda tarea, un 87.46% en una base de datos de 105 sujetos. En la tercera, se detectaron correctamente el 96.52% de los episodios epilépticos utilizando una base de datos de 24 sujetos. En todos los casos, los análisis fueron inter-sujeto. Los resultados alcanzados son comparables, o superan, al estado del arte en cada una de estas tareas, poniendo de manifiesto la utilidad del modelo presentado.

1. Introducción

La electroencefalografía (EEG) es una técnica que permite registrar la actividad eléctrica de las neuronas superficiales del córtex mediante la colocación de electrodos sobre el cuero cabelludo [1]. Debido a su excelente resolución temporal y a la utilización de un equipo portátil, no invasivo y de bajo coste, la señal de EEG es utilizada en numerosas aplicaciones. Entre las más importantes se encuentran la investigación del sistema nervioso central, el diagnóstico de patologías como la epilepsia, la monitorización del nivel de consciencia, o la caracterización de las fases sueño [1]. Además, la irrupción en los últimos años de los sistemas brain-computer interface (BCI) ha incrementado en gran medida las aplicaciones del EEG, fomentando su desarrollo. Entre las aplicaciones de los sistemas BCI, se encuentran aplicaciones asistivas para la comunicación y el control de dispositivos orientadas a personas con grave discapacidad, la rehabilitación motora y cognitiva, e incluso el entretenimiento [1]. Cabe destacar que todas estas tareas requieren de la detección (manual o automática) de patrones específicos dentro de la señal EEG asociados a la actividad cerebral concreta que se está estudiando.

Desafortunadamente, el EEG no está exento de limitaciones, entre las que destacan su baja resolución espacial y su gran sensibilidad a artefactos ruidosos [1]. Por estas razones, sumadas a la inherente complejidad de la actividad cerebral, el análisis de la señal de EEG plantea numerosos retos.

La metodología habitual para la detección de patrones en el EEG de forma automática consiste en la extracción, selección y clasificación de características específicamente diseñadas para un problema concreto, destacando aquellas basadas análisis temporal, espectral y no lineal [2]. Sin embargo, el diseño de estas características requiere un nivel alto de conocimiento previo sobre el problema a tratar, siendo altas las probabilidades de seleccionar un conjunto subóptimo que afecte al rendimiento del modelo [2]. En este sentido, los modelos basados en *deep learning* han permitido en los últimos años mejorar la detección de patrones en el EEG por su capacidad para extraer conjuntos de características optimizados a partir de la señal cruda [2].

Debido a las características especiales del EEG, este avance no ha sido tan relevante como en otros campos [2]. La mayoría de los modelos presentados hasta el momento han sido optimizados para tareas concretas, y no son validados de forma más general. Por ejemplo, se han diseñado modelos para detección de episodios epilépticos [3], ritmos sensoriomotores (*sensorimotor rhythms, SMR*) durante tareas de imaginación motora [4], potenciales relacionados con eventos (*event-related potentials, ERP*) [5] o esfuerzo mental [6]. Sin embargo, ninguno de los mencionados ha sido validado en otros escenarios. Esto es debido a las diferentes características intrínsecas de cada análisis (número de canales, frecuencias de interés, longitud de los segmentos, etc). Por otro lado, muchos de los avances presentados en estos modelos podrían ser aplicados en otras ramas del análisis del EEG. En este contexto, el diseño de arquitecturas que se puedan adaptar a diferentes tareas resulta de especial relevancia, acelerando los avances de este campo.

El objetivo de este estudio es doble: (i) diseñar y desarrollar una red convolutiva aplicable en múltiples escenarios de clasificación EEG; y (ii) validar el modelo en 3 tareas diferentes como son el control de un sistema BCI asistivo basado en ERPs, la detección de SMR asociados a la imaginación del movimiento de las manos derecha e izquierda, y la detección de episodios epilépticos en sujetos pediátricos.

2. Métodos

2.1. EEG-InceptionGen

En este estudio, se ha utilizado como base la red convolucional EEG-Inception para el análisis de la señal de EEG. Esta red fue presentada en nuestro anterior trabajo [5], mostrando unos excelentes resultados para una tarea de clasificación de ERPs. Sin embargo, la estructura fija descrita en [5] no permite la aplicación de la red a tareas que requieran parámetros de entrada diferentes a los definidos (i.e., número de canales, longitud de época y número de clases). En este trabajo, se han introducido las modificaciones necesarias para permitir la configuración de estos parámetros a la vez que se mantienen las proporciones internas de la red de forma automática, aumentando la versatilidad del modelo para que pueda aplicarse en otras tareas de clasificación EEG con éxito. El nuevo modelo, varios ejemplos de uso y una descripción detallada de todos los hiperparámetros, pueden encontrarse en este [repositorio](#).

La arquitectura de EEG-InceptionGen (Figura 1) está compuesta por 2 bloques Inception y un módulo de salida. Este modelo permite configurar la longitud de la época, el número de canales EEG y el número de clases de salida. El primer bloque Inception está formado por tres ramas que realizan convoluciones 2D en el eje temporal con diferentes campos receptivos (tamaño del núcleo) en cada una de las ramas, realizando un análisis multiescala que permite extraer características más complejas a partir de la señal cruda del EEG [5]. En EEG-InceptionGen, las escalas en cada una de las ramas son configurables, ya que este hiperparámetro puede variar en función de la tarea a realizar. Posteriormente, se realiza una convolución tipo *depthwise* en el eje espacial, seleccionando los canales EEG más relevantes para cada una de las características temporales extraídas anteriormente [5]. El segundo bloque Inception vuelve a realizar un análisis temporal, utilizando las mismas escalas que el primero, pero teniendo en cuenta toda la información espacial. Por último, el módulo de salida reduce la dimensionalidad del conjunto paulatinamente para evitar el efecto de sobreentrenamiento. El número de capas convolucionales en este bloque varía en función de la longitud de la época a la entrada, aplicando una capa *GlobalAveragePooling2D* al final. Las características resultantes a la salida de este módulo son clasificadas por una capa *softmax*. Adicionalmente, a lo largo de la red se utiliza *average pooling*, activaciones tipo *exponential linear unit* (ELU), *batch normalization*, y *dropout* [5].

2.2. Tarea 1: sistema BCI basado en ERPs

La primera tarea de clasificación utilizada para validar EEG-InceptionGen es el control de un *speller* BCI basado en ERPs. Este sistema utiliza el paradigma *oddball* para permitir al usuario seleccionar un comando entre varias posibilidades mediante la detección automática de ERPs generados en el EEG mediante estimulación visual [5]. La principal aplicación de este sistema es la comunicación y el control de dispositivos para aumentar la calidad de vida de personas con grave discapacidad [5].

Uso	Estudios	Sujetos	Trials	Eventos
Pre-entrenamiento	[7]–[11]	66 sanos	4490	699405
Validación cruzada	[9], [10]	31 discapacidad motora	2333	309410

Tabla 1. Base de datos de la tarea 1. La columna *trials* indica el total de selecciones realizadas por los sujetos. La columna *eventos* es el número total de estimulaciones.

La base de datos utilizada estaba compuesta por 5 subconjuntos diferentes donde se utilizaba un sistema BCI basado en ERPs [7]–[11] (Tabla 1). Todos los subconjuntos fueron adaptados y homogeneizados con el siguiente algoritmo de preprocesado: submuestreo a 128 Hz, filtrado paso-banda entre 0.5 y 45Hz, selección de 8 canales monopares, extracción de épocas de 1s para cada evento de estimulación (128 muestras x 8 canales) y normalización *z-score*.

Para la validación de EEG-Inception en esta tarea, primero se realizó un pre-entrenamiento utilizando registros provenientes de 66 sujetos sanos. Posteriormente, para la evaluación se seleccionó un subconjunto formado por 31 sujetos con grave discapacidad, analizando el rendimiento de la red utilizando el algoritmo de validación cruzada *leave-one-subject-out* (LOSO). Por tanto, se realizaron 31 iteraciones, en las que la red se entrenaba con 30 sujetos y se evaluaba en el restante. Es importante destacar que la clasificación fue inter-sujeto, eliminando la habitual etapa de calibración con el sujeto de test [8].

2.3. Tarea 2: clasificación de imaginación motora

La segunda tarea de validación consistió en una tarea de clasificación de imaginación motora. En esta tarea, los sujetos imaginan el movimiento de la mano derecha o mano izquierda, provocando la aparición de una actividad, denominada SMR, asociada principalmente a la banda de los 12-15 Hz en la zona motora contralateral a la mano imaginada [12]. Los SMR han sido ampliamente estudiados para el control de los sistemas BCI, aplicándose en los últimos años para rehabilitación motora y cognitiva de pacientes con ictus [1].

Los datos utilizados, provenientes de 4 bases de datos públicas diferentes, fueron adaptados y homogeneizados utilizando el siguiente pre-procesado: submuestreo a 128 Hz, filtrado paso-banda entre 0.1 y 45 Hz, selección de 32 canales monopares, extracción de épocas de 3s relativas a los eventos de imaginación motora (384 muestras x 32 canales) y normalización *z-score*.

Para la validación del modelo en esta tarea, primero se realizó un pre-entrenamiento utilizando 3 bases de datos [12]–[14] (Tabla 2). Posteriormente, se evaluó la precisión del modelo en la base de datos Physiobank Motor/Mental Imagery database [15]. De forma análoga a la tarea anterior, se aplicó LOSO como validación cruzada, realizando 105 iteraciones correspondientes al número de sujetos incluidos en esta última base de datos. De esta forma, tampoco se realizó una calibración del modelo utilizando datos del sujeto testeado en cada iteración [4].

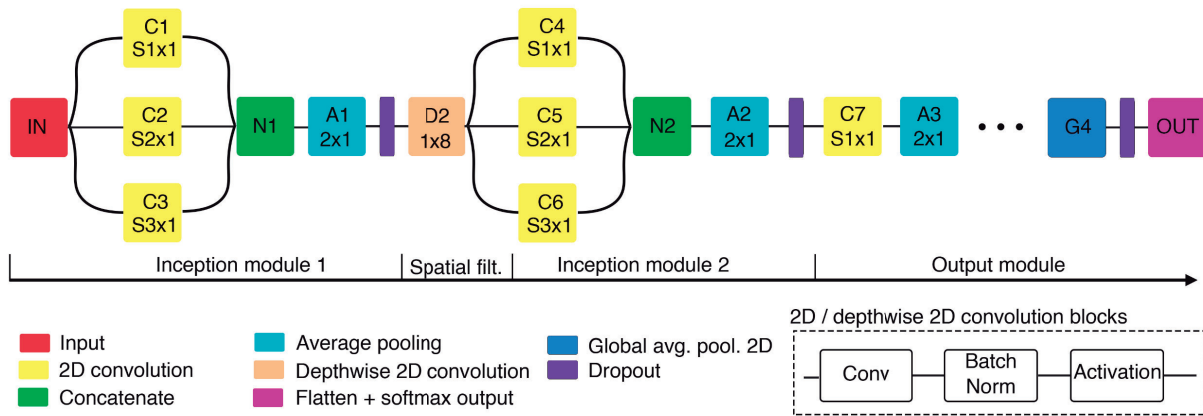


Figura 1. Representación esquemática de EEG-InceptionGen. El número de capas en el módulo de salida se adapta automáticamente en función de los parámetros de entrada para evitar el sobre-entrenamiento. $S1$, $S2$ y $S3$ representan las escalas temporales (campos receptivos) de las convoluciones y son configurables. En este estudio $S1=64$, $S2=32$ y $S3=125$.

Uso	Estudios	Sujetos	Eventos
Pre-entrenamiento	[12]–[14]	158 sanos	171523
Validación cruzada	[17]	105 sanos	4714

Tabla 2. Base de datos de la tarea 2. La columna eventos se refiere al número total de imaginaciones realizadas.

Tarea 3: detección de episodios epilépticos en registros pediátricos

La tercera tarea consistió en la detección automática de crisis epilépticas. Estas crisis consisten en periodos de actividad cerebral anormal, de unas decenas de segundos de duración, caracterizados por la aparición de patrones rítmicos detectables en el EEG y localizados en cualquier punto del córtex [16]. Entre las motivaciones más importantes para la detección de eventos epilépticos de forma automática se encuentra la optimización del proceso de diagnóstico, en el que es habitual que un especialista tenga que analizar registros de varias horas o incluso días de duración [16]. Otra aplicación es la detección en tiempo real del episodio mediante la monitorización EEG, facilitando una rápida intervención de ser necesario [16].

La base de datos utilizada para la validación de EEG-InceptionGen en este problema de clasificación fue CHB-MIT [16]. Esta base de datos contiene registros de 22 sujetos de entre 9 y 42 horas de duración con un total de 198 crisis epilépticas marcadas por especialistas al inicio y final de cada evento [16]. Estos registros continuos fueron preprocesados aplicando: selección de 23 canales bipolares comunes a la mayoría de los registros, submuestreo a 128 Hz y filtrado paso-banda entre 0.1 y 30 Hz. Posteriormente se extrajeron épocas de 5s de duración con solapamiento del 50% (640 muestras x 23 canales). Debido a la desproporción entre las épocas no ictales e ictales (i.e., asociadas a crisis epilépticas), se aplicó un submuestreo a la clase mayoritaria para balancear al 50% el número de ejemplos de cada clase en el entrenamiento del modelo.

El proceso de validación fue similar a las otras tareas, aplicando validación cruzada utilizando el algoritmo LOSO. En este caso, no se pre-entrenó la red previamente.

3. Resultados

Los resultados de los experimentos de validación, correspondientes a las 3 tareas se muestran en la Tabla 3. En los casos de las tareas 1 y 2, la comparación se realiza de forma directa con un modelo de referencia validado anteriormente en cada escenario, mientras que para la tarea 3 se realiza una comparación con la literatura existente.

Los resultados de la tarea 1 corresponden a la precisión, promediada por sujetos, de la decodificación de los comandos utilizando 15 secuencias de estimulación (15 estimaciones por fila y columna de la matriz). El modelo de referencia empleado fue EEG-Inception [5]. Los resultados de la tarea 2 corresponden a la precisión en la clasificación en la tarea de imaginación motora. El modelo de referencia empleado fue EEGNet [4], una red muy utilizada en la actualidad en el campo de los sistemas BCI basados en este paradigma. Al igual que en el caso anterior, se trata de una comparación directa repitiendo el mismo experimento. El modelo fue entrenado utilizando los hiperparámetros recomendados por estudio original [4]. Por último, los resultados de la tarea 3 muestran el porcentaje de episodios epilépticos correctamente detectados (i.e., ictal vs no ictal). En cuanto a los resultados por épocas, lo que equivaldría a una monitorización continua del paciente, EEG-InceptionGen alcanzó una precisión del 74.18%, una sensibilidad del 63.10% y una especificidad del 85.25%. En este caso, no se aplicó un modelo de referencia ya que los estudios revisados no incluían el código utilizado.

4. Discusión y conclusiones

En cuanto a la arquitectura de EEG-InceptionGen, cabe destacar que para cada una de las tareas se han utilizado épocas de señal de diferente longitud y número de canales sin que el rendimiento de la red se haya visto afectado. Esta robustez se debe al empleo de los módulos Inception y a un control efectivo del sobre-entrenamiento. En este sentido, los modelos basados en *deep learning* aplicados al EEG son muy sensibles al sobre-entrenamiento por la baja relación señal a ruido de esta señal [5]. EEG-InceptionGen controla este efecto mediante una adaptación automática

Tarea	Referencia	EEG-InceptionGen
1	73.81 ± 23.03 %	74.27 ± 19.92 %
2	83.08 ± 10.92 %	87.46 ± 09.33 %
3	* 96.00 % [17], 97.5% [3]	96.52 ± 10.37%

Tabla 3. Resultados de los experimentos de validación. En la tarea 3, el asterisco indica que la comparación es con estudios previos en la misma base de datos.

del módulo de salida para homogeneizar el número de características extraídas por la red independientemente de los parámetros de entrada y la introducción de una capa GlobalAveragePooling2D antes de la capa de clasificación. Gracias a estas características, se espera que esta arquitectura pueda alcanzar resultados satisfactorios en cualquier tarea de clasificación EEG supervisada.

Respecto a los resultados de validación, se puede apreciar como EEG-InceptionGen supera a la versión original del modelo en la tarea de clasificación de ERPs [5]. Además, es destacable la adaptación de la red a los otros escenarios de validación. En concreto, en la tarea 2 la mejora en la precisión ha sido del 4.4% respecto a EEGNet [4] en la comparación directa, lo que representa un incremento significativo. Además, Dose *et al.* [17] alcanzaron en una precisión de 80.38% en la misma base de datos, muy por debajo del resultado presentado en este estudio. Por su parte, los resultados de la tarea 3 son comparables a los de la literatura, con un 96.52 % de precisión en la detección de eventos epilépticos. Por ejemplo, Shoeb [16] alcanzó una precisión del 96.00% en la misma base de datos, mientras que en el estudio de Zhou *et al.* se mejoró ligeramente este valor, alcanzando un 97.5% de precisión utilizando transformaciones al dominio frecuencial [3].

En este estudio se ha presentado un nuevo modelo de red convolucional, denominado EEG-InceptionGen, con un diseño multipropósito adaptable a la mayoría de las tareas de clasificación EEG. Además, este modelo ha sido validado en 3 tareas diferentes: control de un sistema BCI basado en ERPs, clasificación de imaginación motora y detección de episodios de epilepsia; alcanzando unos excelentes resultados que se comparan, e incluso superan, a los alcanzados por modelos desarrollados para estos escenarios específicos.

Agradecimientos

Este trabajo ha sido financiado por los proyectos PID2020-115468RB-I00 y RTC2019-007350-1 del 'Ministerio de Ciencia, Innovación y Universidades' y 'Análisis y correlación entre la epigenética y la actividad cerebral para evaluar el riesgo de migraña crónica y episódica en mujeres' ('Cooperation Programme Interreg V-A Spain-Portugal POCTEP 2014–2020') de la Comisión Europea y FEDER, así como por CIBER-BBN a través del 'Instituto de Salud Carlos III'.

Referencias

[1] J. Wolpaw and E. W. Wolpaw, *Brain-computer interfaces: principles and practice*. OUP USA, 2012.

- [2] A. Craik *et al.*, "Deep learning for electroencephalogram (EEG) classification tasks: A review," *J. Neural Eng.*, vol. 16, no. 3, 2019.
- [3] M. Zhou *et al.*, "Epileptic seizure detection based on EEG signals and CNN," *Front. Neuroinform.*, vol. 12, no. December, pp. 1–14, 2018.
- [4] V. J. Lawhern *et al.*, "EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces," *J. Neural Eng.*, vol. 15, no. 056013, pp. 1–17, 2018.
- [5] E. Santamaria-Vazquez *et al.*, "EEG-Inception: A Novel Deep Convolutional Neural Network for Assistive ERP-based Brain-Computer Interfaces," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 28, no. 12, pp. 2773–2782, 2020.
- [6] Z. Jiao, *et al.* "Deep Convolutional Neural Networks for mental load classification based on EEG data," *Pattern Recognit.*, vol. 76, pp. 582–595, 2018.
- [7] V. Martínez-Cagigal *et al.*, "An Asynchronous P300-Based Brain-Computer Interface Web Browser for Severely Disabled People," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 25, no. 8, pp. 1332–1342, 2017.
- [8] V. Martínez-Cagigal *et al.*, "Towards an accessible use of smartphone-based social networks through brain-computer interfaces," *Expert Syst. Appl.*, vol. 120, pp. 155–166, 2019.
- [9] E. Santamaria-Vázquez *et al.*, "Asynchronous Control of ERP-Based BCI Spellers Using Steady-State Visual Evoked Potentials Elicited by Peripheral Stimuli," *IEEE Trans. neural Syst. Rehabil. Eng.*, vol. 27, no. 9, pp. 1883–1892, 2019.
- [10] B. Blankertz *et al.*, "The BCI competition III: Validating alternative approaches to actual BCI problems," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 14, no. 2, pp. 153–159, 2006.
- [11] C. Guger *et al.*, "How many people are able to control a P300-based brain-computer interface (BCI)?," *Neurosci. Lett.*, vol. 462, no. 1, pp. 94–98, 2009.
- [12] J. Meng and B. He, "Exploring Training Effect in 42 Human Subjects Using a Non-invasive Sensorimotor Rhythm Based Online BCI," *Front. Hum. Neurosci.*, vol. 13, Apr. 2019.
- [13] M. H. Lee *et al.*, "EEG dataset and OpenBMI toolbox for three BCI paradigms: An investigation into BCI illiteracy," *Gigascience*, vol. 8, no. 5, pp. 1–16, 2019.
- [14] J. R. Stieger, *et al.*, "Mindfulness Improves Brain-Computer Interface Performance by Increasing Control over Neural Activity in the Alpha Band," *Cereb. Cortex*, vol. 31, no. 1, pp. 426–438, 2021.
- [15] G. Schalk *et al.*, "BCI2000: A general-purpose brain-computer interface (BCI) system," *IEEE Trans. Biomed. Eng.*, vol. 51, no. 6, pp. 1034–1043, 2004.
- [16] A. Shoeb "Application of machine learning to epileptic seizure onset detection and treatment," *Diss. Massachusetts Inst. Technol.*, pp. 157–162, 2009.
- [17] H. Dose *et al.*, "An end-to-end deep learning approach to MI-EEG signal classification for BCIs," *Expert Syst. Appl.*, vol. 114, pp. 532–542, Dec. 2018.

ÍNDICE DE AUTORES

A

Abella M	159, 167, 179, 193
Acosta O	127
Aja-Fernández S	51
Albajar Sigalés A	2
Alberdi Aramendi A	10
Alberola-López C	51, 175
Alcaraz Martínez R	83, 139, 147, 151, 155
Almagro-Pérez C	18
Álvarez González D	63
Álvarez I	42
Añorbe de Frutos A	30
Aramendi Ecenarro E	197
Arroyo Domingo CA	63
Atienza Vicente CM	143

B

Barea R	107
Barrenechea M	10
Barroso FO	6
Bautista-Salineró M	22
Beedle AEM	2
Berdón PM	167
Berruezo Sánchez A	171
Bertomeu-González V	83, 147, 151, 155
Berve PO	197
Blanco-Velasco M	91
Blas JG	167
Boquete L	107
Braxton A	18
Bueno H	123

C

Cabezas E	127
Calle D	103
Calvillo Arbizu J	119
Camara Rey O	171
Cano del Pozo M	22
Cano J	151
Cano M	55
Cano-Manuel JL	179
Canós MA	87
Cañadas M	189
Carmona Sánchez P	205
Carro J	115
Castelli J	127
Castillo-Rabazo J	187
Castro de la Nuez P	119
Cavaliere C	107
Cepeda Chafía S	51

Chen R	10
Chénier F	111
Chil R	75
Cuba Gato MA	183
Cubero L	127
Cussó L	103

D

De Andrés J	87
de Crevoisier R	127
de Luis García R	51
del Campo F	63
Del Cerro CF	159, 179, 193
Desco M	103, 159, 167, 179, 193
Durá JL	87
Durán-Rey D	187

E

Elola Artano A	197
Esparza-Iaizzo M	42

F

Fácil L	151
Ferreira D	95
Ferrer-Bonsoms JA	30

G

Galán A	167, 179
Galán C	34
Gallego-Ferrer G	26
García A	46
García Carmona R	14
García-Blas J	159, 179, 193
García-Martín E	107
García-Sáez G	123, 131
Garnés Camarena O	201
Giménez RC	159
Gómez C	55, 59, 71
Gómez EJ	67, 79, 205
Gómez M	115
Gómez-Cruz C	189
Gómez-Grande A	79
Gómez-Pilar J	55, 59
Gomis P	95
González-Portillo MR	187
Goya Esteban R	22
Gutiérrez R	107
Gutiérrez -de Pablo V	59, 71
Gutiérrez Martín A	6, 99
Gutiérrez Tobal GC	63
Guzmán-García C	67

H			
Hernando ME	123, 131	Moreno-Castán A	103
Hidalgo Torres LA	75	Muñoz-Barrutia A	18, 189
Hornero R	55, 59, 63, 71, 163	Muñoz-Romero S	91
Hornero Sos F	83, 147, 155	N	
Hruban R	18	Navarro González R	51
Huerta Herraiz A	139	Navarro Ruiz E	38
I		Nicolás-Sáenz L	18
Iniesta JM	131	Núñez P	22
Iriarte A	46	O	
Isasa Reinoso I	10	Oropesa I	67
J		Ortiz M	107
Jauregui Garrido B	171	P	
Jiménez García J	63	Palmieri F	95
K		Pardo Picazo MA	38
Kiemen A	18	Pascau J	127
Klinzing JG	42	Pascual-Valdunciel A	6
L		Pérez Valdivia MA	119
Laguna P	95	Pérez-Benito D	75
Laguna S	189	Pérez-Gandía C	131
Larraga García B	99	Pérez-Velasco S	163
López Dorado A	107	Piol A	193
López-Agudelo I	187	Pizarro-Chong A	111
López-Larraz E	42	Plaza de Miguel C	135
Lopo-Martínez V	6	Plaza-Seco C	91
Losada H	143	Poza J	22, 55, 59, 71
Lovas A	10	Pueyo E	95, 115
M		Q	
Malanda Triguero A	201	Quesada Dorador A	83, 147, 155
Manuel-Cano JL	167	Quintana Díaz M	99, 205
Mares-Bou S	26	R	
Margelí C	46	Ràfols P	34
Martí-Bonmatí L	87	Ramírez J	95
Martín González E	175	Reina Tosina J	119
Martínez JP	95	Revilla-Orodea A	175
Martínez Rodrigo A	139	Revilla-Vallejo M	55
Martínez Seijas V	123	Reyes Leiva KM	183
Martínez-Cagigal V	163	Rico-Gómez I	189
Maturana-Candelas A	71	Rieta Ibáñez JJ	83, 139, 147, 151, 155
Mayans B	46	Roa Romero LM	119
Medina López R	119	Roca-Cusachs Soulere P	2
Méndez de Vigo Iriarte I	14	Rodríguez-Fernández J	26
Minguez J	42	Rodríguez-Galván JR	175
Molas C	46	Rodríguez Rodríguez M	99
Möller K	10	Rodríguez Matesanz M	205
Monasterio V	115	Rojo-Álvarez JL	91
Montesano L	42	Romera M	34
Moreno Muñoz G	123	Rubio Bolívar J	99, 205
		Ruiz JE	95

S

Saiz J	87
Sales Bellés C	171
San Martín L	143
San Martín Retegi A	30
Sánchez Anzules R	135
Sánchez-González P	67, 79, 205
Sánchez-Margallo FM	135, 187
Sánchez-Margallo JA	135, 187
Santamaría-Vázquez E	163
Santos Paz JA	14
Sebastián Aguilar R	171
Seiffert AP	79
Serrancolí G	46
Serrano J	127
Serrano Olmedo JJ	183
Sevilla-Ruiz MT	175
Simon A	127
Solanes C	87
Sosenko K	159
Soto Iglesias D	171
Stashuk DW	201

T

Talaminos Barroso A	119
Tapia-Galisteo J	131
Tejo-Otero A	143
Tola-Arribas MA	22, 55
Torner J	46
Trujillo-Muñoz S	26

U

Urgelés D	131
Urrea JF	179
Urteaga Urizarbarrena J	197

V

Valle Morgado C	203
Vaquerizo Villar F	63
Vaquero JJ	75
Verdú C	205
Villarejo-Galende A	79
Vraka A	83, 147, 155

W

Wik L	197
Wirtz D	18
Wood L	18
Wu P	18

Z

Zangróniz R	151
-------------	-----