



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Industrial

Desarrollo de un modelo basado en inteligencia artificial
para estimar la recuperación neurológica del estado de
coma tras paro cardíaco.

Trabajo Fin de Grado

Grado en Ingeniería Biomédica

AUTOR/A: Ors Quixal, Rafael Teodoro

Tutor/a: Millet Roig, José

Cotutor/a: Castells Ramón, Francisco Sales

CURSO ACADÉMICO: 2022/2023

Agradecimientos

Gracias a mi familia, amigos y docentes por todo el apoyo dado y por los ánimos a siempre hacer más.

*"Somos como enanos colocados a hombros de gigantes."
- Juan de Salisbury -*

Resumen

Este proyecto surge como respuesta a un reto internacional "The George B. Moody Physio-Net Challenge", lanzado por el Computing in Cardiology (CinC), en el cual participa el grupo BioITACA.

El reto consiste en el desarrollo de un algoritmo que permita la ayuda al diagnóstico de pacientes en coma tras un paro cardíaco y su clasificación en la correspondiente categoría de rendimiento cerebral (CPC: Cerebral Performance Category).

Para afrontar el reto y después de explorar el estado del arte en la bibliografía científica, se procedió a desarrollar un nuevo modelo basado en inteligencia artificial en el cual se propone el uso de nuevos parámetros más allá de los empleados en el estado del arte del procesamiento de señales de electroencefalografía, basados en el dominio tiempo-frecuencia, añadiendo la dimensión espacial. Con el fin de lograr este objetivo, se comenzó a desarrollar modelos simples en un ordenador personal, con el fin de evaluar la capacidad de dichos modelos para clasificar según la categoría CPC. Tanto los modelos como los resultados obtenidos, fueron presentados a la primera fase del reto.

Vistos los buenos resultados obtenidos, posteriormente se decidió ampliar la complejidad del modelo propuesto, añadiendo los parámetros mencionados anteriormente y ampliando la arquitectura del modelo. Esto nos llevó a la necesidad de disponer de una plataforma de cómputo más potente. Para ello, fue necesario poner en marcha un servidor de computación montado sobre un multiprocesador basado en GPUs que el grupo de investigación aún no tenía en funcionamiento.

Por otra parte, debido a las restricciones que impone la normativa de participación en el reto, este trabajo no puede presentar los modelos y los resultados ahí presentados. Por lo que para el mismo, se han desarrollado otros modelos más simples que únicamente permiten diferenciar entre los pacientes que pertenecen a las categorías CPC 1 y 2, frente a las categorías 3,4 y 5, siendo su principal diferencia, la capacidad cognitiva para poder vivir con cierto grado de independencia. El modelo aquí presentado, consiste en una fase convolucional tridimensional cuyo objetivo es comprimir la información espacio-temporal y otra fase basada en redes neuronales densas que puedan analizar la información comprimida en un vector para dar un resultado según la clasificación anterior. Se trata de un modelo de arquitectura simple con buenos resultados clasificando segmentos de señal, lo cual permite su uso, no solo en dichos fragmentos, si no para evaluar la evolución de la clasificación de la señal en el tiempo.

Con los resultados obtenidos en los primeros modelos y presentados en la primera fase del reto, se logró superar el primer corte y pasar así a la segunda fase, en la cual se nos ha invitado a presentar los resultados del trabajo desarrollado en una ponencia que se presentará en el CinC celebrado en Atlanta el próximo mes de octubre.

Palabras Clave: Categorías de rendimiento cerebral CPC; EEG; electroencefalografía; Conv3D; Convolucionales; Redes neuronales densas; Aprendizaje automático; Inteligencia artificial; Coma; Explicabilidad. TFG

Resum

Aquest projecte sorgeix com a resposta a un repte internacional "The George B. Moody PhysioNet Challenge", proposat per Computing in Cardiology (CinC), en el qual participa el grup BioITACA.

El repte consisteix en desenvolupar un algorisme que permeti l'ajuda en el diagnòstic de pacients en coma després d'un atac cardíac i la seva classificació en la corresponent categoria de rendiment cerebral (CPC: Cerebral Performance Category).

Per afrontar el repte i després d'explorar l'estat de l'art en la bibliografia científica, es va procedir a desenvolupar un nou model basat en intel·ligència artificial en el qual es proposa l'ús de nous paràmetres més enllà dels emprats en l'estat de l'art del processament de senyals d'electroencefalografia, basats en el domini temps-freqüència, afegint la dimensió espacial. Per aconseguir aquest objectiu, es van començar a desenvolupar models simples en un ordinador personal per avaluar la capacitat d'aquests models per classificar segons la categoria CPC. Tant els models com els resultats obtinguts es van presentar a la primera fase del repte.

Vists els bons resultats obtinguts, posteriorment es va decidir ampliar la complexitat del model proposat, afegint els paràmetres esmentats anteriorment i ampliant l'arquitectura del model. Això ens va portar a la necessitat de disposar d'una plataforma de còmput més potent. Per això, va ser necessari posar en marxa un servidor de computació muntat sobre un multiprocessador basat en GPUs que el grup de recerca encara no tenia en funcionament.

D'altra banda, a causa de les restriccions que imposa la normativa de participació en el repte, aquest treball no pot presentar els models i els resultats presentats en aquest. Per això, s'han desenvolupat altres models més simples que únicament permeten diferenciar entre els pacients que pertanyen a les categories CPC 1 i 2, enfront de les categories 3, 4 i 5, sent la seva principal diferència, la capacitat cognitiva per poder viure amb cert grau d'independència. El model aquí presentat consisteix en una fase convolucional tridimensional amb l'objectiu de comprimir la informació espai-temporal i una altra fase basada en xarxes neuronals densament connectades que puguin analitzar la informació comprimida en un vector per donar un resultat segons la classificació anterior. Es tracta d'un model d'arquitectura simple amb bons resultats classificant segments de senyal, el que permet el seu ús, no només en aquests fragments, sinó per avaluar l'evolució de la classificació de la senyal en el temps.

Amb els resultats obtinguts en els primers models i presentats a la primera fase del repte, es va aconseguir superar el primer tall i passar així a la segonafase, en la qual se'ns ha convidat a presentar els resultats del treball desenvolupat en una ponència que es presentarà al CinC celebrat a Atlanta el pròxim mes d'octubre.

Paraules clau: Categories de rendiment cerebral CPC; EEG; electroencefalografia; Conv3D; Convolucionals; Xarxes neuronals denses; Aprenentatge automàtic; Intel·ligència artificial; Coma; Explicabilitat.

Abstract

This project emerged as a response to the international challenge "The George B. Moody PhysioNet Challenge" proposed by Computing in Cardiology (CinC), in which the BioITACA group participates.

The challenge involves developing an algorithm that aids in the diagnosis of patients in coma after cardiac arrest and classifying them into the appropriate category of cerebral performance (CPC).

To tackle the challenge, extensive research was conducted on the state-of-the-art literature, and a new artificial intelligence-based model was developed. This model proposes the use of new parameters beyond those employed in the state-of-the-art processing of electroencephalography signals, incorporating both time-frequency and spatial dimensions. Initially, simple models were developed on a personal computer to evaluate their ability to classify according to the CPC category. The models and the obtained results were submitted for the first phase of the challenge.

Based on the promising results obtained, it was decided to enhance the complexity of the proposed model by incorporating the aforementioned parameters and expanding the model architecture. This necessitated the deployment of a more powerful computing platform. To fulfill this requirement, a server with a multiprocessor based on GPUs was set up, which the research group did not previously have in operation.

However, due to participation rules, this work cannot present the models and results from the challenge. Therefore, simpler models were developed specifically for this purpose, which only differentiate between patients belonging to CPC categories 1 and 2 versus categories 3, 4, and 5, with the main distinction being the cognitive ability to live with a certain degree of independence. The model presented here consists of a three-dimensional convolutional phase that compresses the spatiotemporal information and a dense neural network phase that analyzes the compressed information in a vector to provide a result based on the aforementioned classification. It is a simple architecture model with good results in segmenting signal segments, allowing not only the evaluation of such segments but also tracking the evolution of signal classification over time.

The results obtained from the initial models presented in the first phase of the challenge surpassed the first cutoff, advancing to the second phase. As part of the second phase, we have been invited to present the results of this work in a conference to be held at CinC in Atlanta next October.

Keywords: Cerebral Performance Category (CPC); EEG; electroencephalography; Conv3D; Convolutional; Dense neural networks; Machine learning; Artificial intelligence; Coma; Explainability.

Índice general

Resumen	I
Resum	V
Abstract	VII
Índice general	IX
I Memoria	1
1 Introducción	3
1.1 Contextualización.	3
1.2 La señal de electroencefalografía no invasiva (EEG).	4
1.3 La señal de EEG del paciente en coma.	5
1.4 Análisis de EEG de pacientes en coma basado en inteligencia artificial: Un enfoque actual.	9
1.5 Aspectos a tener en cuenta en el entrenamiento y validación de sistemas de aprendizaje automático.	10
1.6 La ética en la Inteligencia Artificial.	12
2 Propuesta, Justificación y Objetivos	15
2.1 Propuesta y justificación del proyecto.	15
2.2 Objetivos.	16
3 Materiales y Métodos	17
3.1 Materiales.	17
3.2 Métodos.	19
3.3 Complejidad computacional.	30

4 Resultados	35
4.1 Métricas	35
4.2 Complejidad computacional	36
4.3 Resultados del CinC	36
4.4 Explicabilidad	37
5 Conclusiones y Líneas de futuro	41
5.1 Conclusiones	41
5.2 Futuras líneas de trabajo	42
6 Bibliografía	43
II Presupuesto	45

Parte I

Memoria

Capítulo 1

Introducción

En este capítulo se realiza una breve descripción del problema, las señales de EEG como base para el diagnóstico, así como las diferentes propuestas actuales planteadas en la bibliografía para solucionarlo, continuando con una introducción a su funcionamiento. Y finalizando con el marco ético de estas.

1.1 Contextualización

Las cardiopatías están reconocido por la Organización Mundial de la Salud (OMS) como la primera causa de muerte a nivel mundial, con una tasa de supervivencia entre el 1 y 10% en función de la localización geográfica. En algunos casos, un paro puede dar lugar a una cuadro aún más grave conocido como muerte súbita. La muerte súbita se refiere a un fallecimiento repentino e inesperado que ocurre de manera instantánea, sin previo aviso.

Aunque el tratamiento de la muerte súbita depende de la causa subyacente, en situaciones de paro cardíaco repentino, la reanimación cardiopulmonar (RCP) inmediata y el uso de un desfibrilador externo automático (DEA) son vitales para intentar restaurar el ritmo cardíaco normal.

Pese a ello, de entre los pacientes que inicialmente sobreviven a la resucitación, el daño cerebral severo suele ser la causa más común de defunción, encontrándose la mayoría de los pacientes que son llevados posteriormente a la unidad de cuidados intensivos (UCI), en estado comatoso.

Los supervivientes al paro que ingresan en este estado, permanecerán al menos tres días en la UCI, pudiendo tomar a partir del tercer día la decisión de mantener artificialmente con vida al paciente, o desconectarlo del soporte vital. Este tiempo de espera permite la recuperación parcial del paciente, para su evaluación según una serie de ensayos tipificados, como es el de la escala de coma de Glasgow (GCS), un conjunto de pruebas que permite estimar el nivel de conciencia de una persona utilizando parámetros tales como la respuesta verbal, ocular y motora, con el fin de mejorar la toma de decisiones en una situación en la que una prognosis equivocada puede suponer, por una parte, la retirada del soporte vital a una persona que podría recuperar la consciencia en breve, y por otra, la inversión de una gran cantidad de recursos, y dedicar una cama de la UCI, con lo que ello conlleva, a una persona que no va a lograr despertar del coma. Cabe destacar, que en la literatura se han reportado casos, en los que a pesar de indicarse que el paciente no iba a conseguir salir del coma, este lo consigue, en ocasiones, incluso con

una recuperación completa de sus capacidades cognitivas, lo que complica aún más la toma de decisiones.

Con el propósito de reducir la subjetividad y estandarizar la toma de este tipo de decisiones, existen escalas de clasificación del rendimiento cerebral como la "Cerebral Performance Category" (CPC), que evalúa el estado neurológico del paciente con una clasificación en cinco estados:

- **CPC 1:** Buen rendimiento cerebral, se encuentra consciente, alerta y es capaz de trabajar y llevar una vida normal, aunque puede presentar déficit menores a nivel psicológico o neurológico.
- **CPC 2:** Discapacidad moderada, es consciente con suficiente capacidad para trabajar en entornos específicos y para realizar actividades diarias de forma independiente, pudiendo presentar déficit más graves como pérdida permanente de la memoria o cambios de la personalidad.
- **CPC 3:** Discapacidad severa, consciente pero con dependencia para la realización de tareas diarias. Incluyendo un gran conjunto de disfunciones neurológicas como por ejemplo demencia o severas afectaciones de la memoria.
- **CPC 4:** Inconsciente, ya sea en coma o en estado vegetativo, no presenta indicios cognitivos ni respuesta a estímulos ambientales.
- **CPC 5:** Muerte cerebral, pérdida de funcionalidad en todo el encéfalo. Aunque pueden permanecer reflejos medulares.

En la actualidad, la clasificación de pacientes en coma en estas categorías se realiza a partir de escalas como la GCS junto al análisis por parte de profesionales de señales de electroencefalografía no invasiva (EEG) registrada en el paciente mediante electrodos fijados al cuero cabelludo.

1.2 La señal de electroencefalografía no invasiva (EEG)

La electroencefalografía no invasiva consiste en un conjunto de señales adquiridas de la actividad bioeléctrica del cráneo, a partir de la cual, se obtiene parte de la del encéfalo. Esta señal, está relacionada con los potenciales post-sinápticos y se asocia a la actividad neuronal.

La señal es originada en el interior del cráneo y observada en el exterior, por lo que se pierde parte de la información perteneciente al contenido de mayor frecuencia de esta debido a la impedancia del denso cráneo. Además, puede verse afectada por la interferencia de la actividad bioeléctrica cercana, como son las señales mioeléctricas generadas por los músculos de la cabeza, así como las electrooculares propias del movimiento ocular. Además de otros agentes externos como el ruido de red eléctrica cuando no se consigue aislar bien el sistema.

La señal de interés tiene unos valores típicos de amplitud entre 20 y 100 μV en sujetos sanos, además de agruparse típicamente en cinco bandas de frecuencias δ (0.5-4) Hz, θ (4-7) Hz, α (8-13) Hz, β (13-30) Hz, γ (30+) Hz. Cada una de ellas asociadas a estados o actividades concretas.

En entornos clínicos y de investigación, esta señal es adquirida mediante electrodos, típicamente con ayuda de un gel entre la superficie metálica del electrodo y el cuero cabelludo, que favorece la conducción al hidratar y penetrar la piel, permitiendo también la captación de señal en zonas con alta densidad capilar. Es importante destacar que con el objetivo de que las señales

puedan ser comparadas entre estudios, la distribución topológica de los electrodos se encuentra estandarizada, siendo el estándar 10-20 internacional uno de los más empleados.

Esto permite una representación del conjunto de señales con nombres comunes asociados a cada canal (posiciones de los electrodos), representándose en una gráfica de amplitud en función del tiempo en la que los canales son mostrados bien en diferentes ejes separados verticalmente, o centrados todos en el mismo eje.

Debido a la complejidad de esta señal y su difícil interpretación, la cual requiere de un extenso entrenamiento y cierta experiencia, se están desarrollando cada vez más enfoques basados en inteligencia artificial que intentan poder interpretar la señal más allá de los parámetros que puede captar el ojo humano entrenado.

1.3 La señal de EEG del paciente en coma

Adicionalmente, en pacientes en coma, es habitual que la señal de EEG muestre determinados patrones. En base a esto, se han propuesto en la literatura clasificadores basados únicamente en estos tipos de patrones y el tiempo transcurrido desde el paro cardíaco hasta la hora de registro de la señal. En base a los resultados aportados por estos sistemas, hasta el momento no existe consenso en la comunidad científica sobre la calidad de éstos. Pese a ello, cabe destacar que aun no habiéndose sido reconocidos estos clasificadores como un sistema en si, sí que pueden ser incorporados como parte de otro sistema con el fin de obtener una mayor fiabilidad en conjunto.

A continuación se muestran un conjunto representativo de los patrones habituales de EEG en pacientes en coma en un conjunto reducido de señales EEG según el montaje estándar 10-10:

Supresión: En este estado, la amplitud permanece por debajo de los $10 \mu V$.

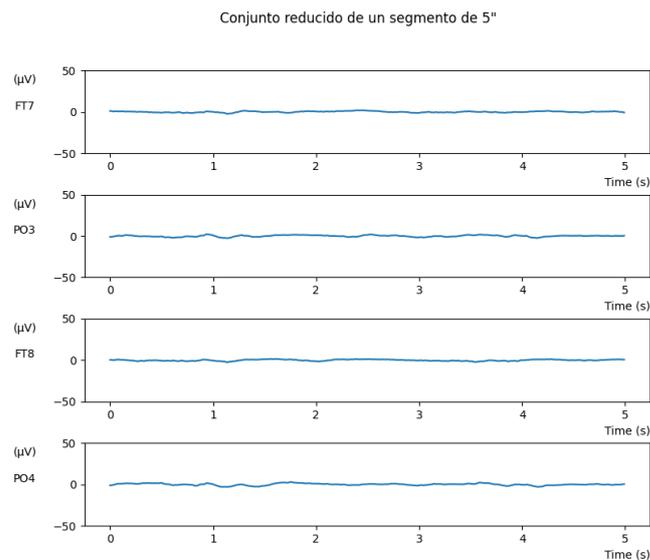


Figura 1.1: Ventana de 5" de un registro perteneciente a la CPC 5 mostrando un estado de supresión de actividad.

Bajo Voltaje: En este estado la amplitud se mantiene por debajo de $20 \mu V$.

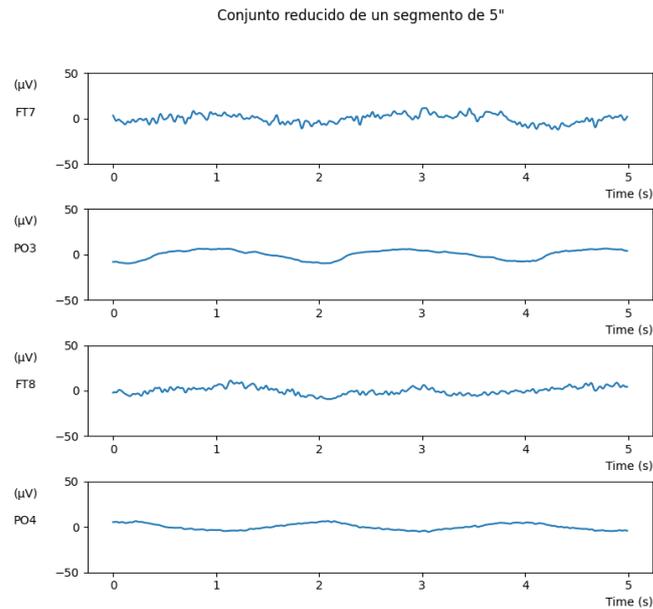


Figura 1.2: Ventana de 5" de un registro perteneciente a la CPC 5 mostrando un estado de baja amplitud de señal.

Supresión y ráfagas: Más de un 50% del registro se encuentra en supresión de actividad, mientras que el resto muestra ráfagas de actividad

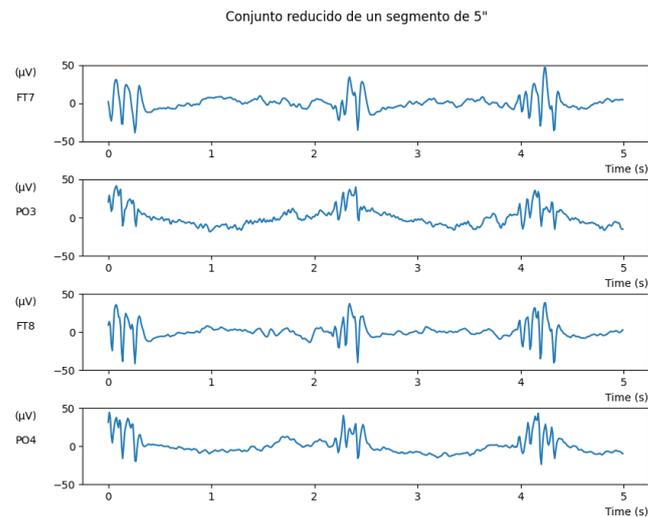


Figura 1.3: Ventana de 5" de un registro perteneciente a la CPC 5 mostrando un estado de supresión y ráfagas de actividad.

Estado epiléptico: Compuesto por descargas epileptiformes o actividad delta-theta en un cuadro clínico de ictus.

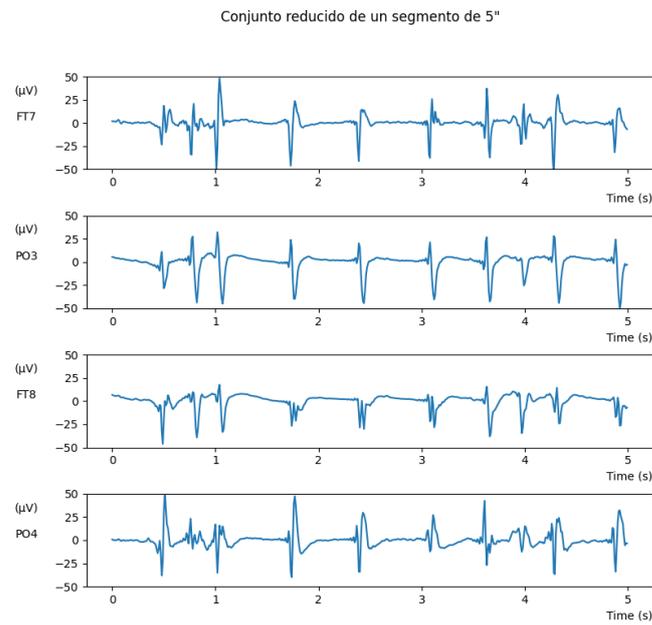


Figura 1.4: Ventana de 5" de un registro perteneciente a la CPC 5 mostrando descargas de morfología epileptiforme.

Estado epiléptico mioclónico: Se caracteriza por ser un subtipo de estado epiléptico en el cual se producen contracciones musculares repetitivas.

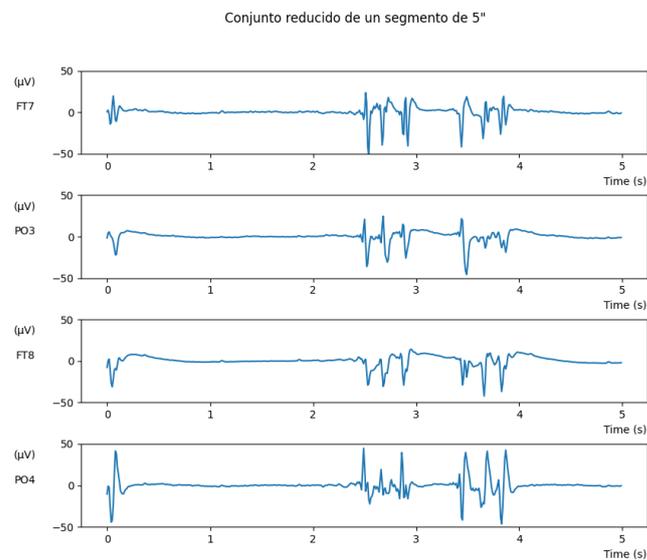


Figura 1.5: Ventana de 5" de un registro perteneciente a la CPC 5 mostrando un estado epiléptico mioclónico

Descargas periódicas: Se compone de descargas epileptiformes de morfología similar y de recurrencia regular.

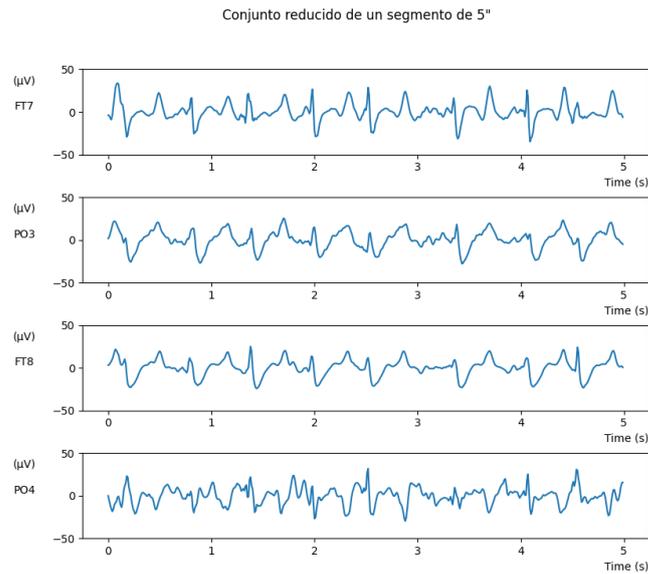


Figura 1.6: Ventana de 5" de un registro perteneciente a la CPC 5 mostrando una serie de descargas periódicas.

Voltaje normal continuo: Consiste en una señal continua y de amplitud superior a $20 \mu V$, con hasta un 10% de tolerancia a supresión o reducción de la actividad.

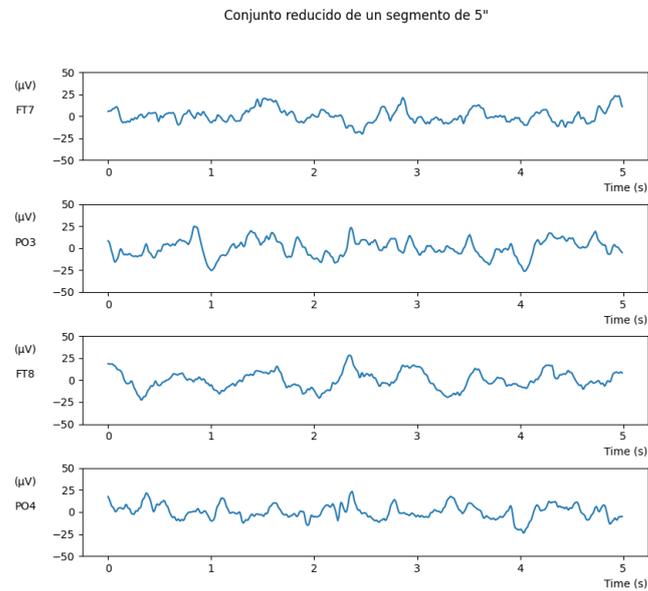


Figura 1.7: Ventana de 5" de un registro perteneciente a la CPC 1 mostrando un estado normal de actividad

1.4 Análisis de EEG de pacientes en coma basado en inteligencia artificial: Un enfoque actual

Actualmente en el campo de la inteligencia artificial aplicada al análisis sobre las señales EEG adquiridas de pacientes en coma, se encuentra muy extendido el uso de redes neuronales convolucionales. Dado los excelentes resultados obtenidos en la extracción automática de parámetros en imágenes (señales bidimensionales), y su posterior adopción para el análisis de señales vectoriales. Originalmente, se trabajaba sólo con redes neuronales convolucionales bidimensionales (RNC 2D), debido a su uso extendido en imágenes, pero posteriormente se desarrollaron las redes neuronales convolucionales de una sola dimensión (RNC 1D) con el fin de extraer de forma más eficiente los parámetros de las señales vectoriales.

Las RNC no son más que un conjunto de métodos estadísticos y algebraicos, que componen un sistema recursivo en el cual se produce la convolución entre dos espacios, siendo uno de estos el espacio de entrenamiento, y el otro, el espacio de aprendizaje, el cual recibe el nombre de núcleo. Realmente, en la práctica no se trabaja con dos espacios individuales, sino con conjuntos de espacios, pero para simplificar la explicación se reducirá a un conjunto de entrenamiento, y un kernel bidimensional.

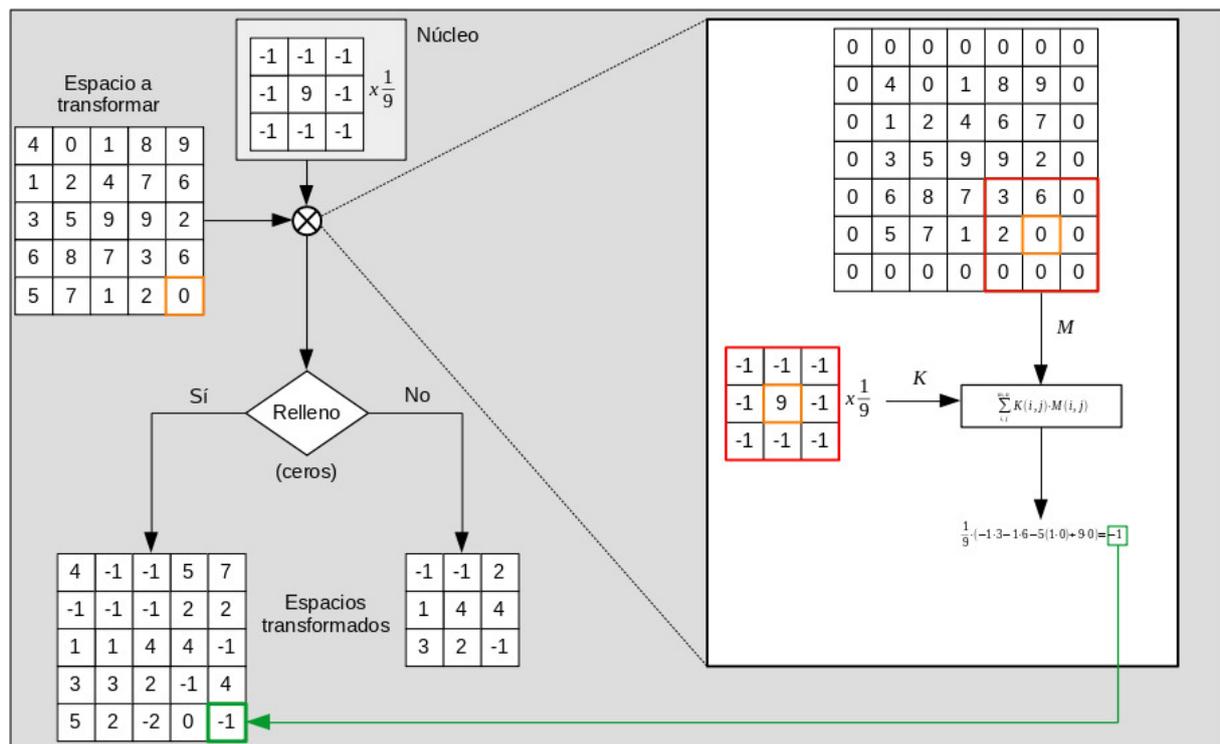


Figura 1.8: Convolución de un núcleo sobre un subespacio del espacio a transformar tras la aplicación del relleno a ceros.

Como se puede ver en el ejemplo de la figura anterior, la convolución de un núcleo sobre un espacio, no es más que la transformación de la posición coincidente con el centro del núcleo (siempre que este sea de dimensiones impares) al resultado de la suma del producto de los valores en las posiciones vecinas dentro del espacio acotado por el núcleo. Realizándose esta operación con el núcleo centrado en todas las posiciones del espacio, a no ser que se indique algún vector de

desplazamiento a aplicar sobre las posiciones en las que se centra el núcleo para la convolución, lo que provoca una reducción las dimensiones del espacio de salida conforme con el de entrada. Dicha reducción también se da en el caso de no usar relleno en los bordes, forzando a que el núcleo sólo pueda ser centrado en las posiciones en las cuales todo su dominio se encuentre envuelto por el del espacio a transformar. Para evitar este efecto, se usan diferentes formas de relleno, como por ejemplo el uso de valores nulos, como se muestra en el ejemplo, valores promedio, dónde se asigna el valor medio del espacio a transformar en la región definida por el núcleo, o valores a modo de espejo, donde se repiten los de dentro del dominio fuera de este. Debe tenerse en cuenta que hay más estrategias de relleno, y que su elección afecta al resultado, pudiendo perderse información relativa al rango de frecuencias más alto en estas regiones.

En los estudios que aparecen en la bibliografía científica utilizando estos sistemas sobre señales EEG de pacientes en coma, se encuentran dos enfoques diferentes. Por un lado, se desarrollan modelos de arquitecturas complejas, que combinan capas RNC 2D para capturar las dimensiones espacio-temporales, junto con capas "Bidirectional Long-Short-Term Memory" (Bi-LSTM) que ayudan a obtener información sobre la variación de los datos de entrada entre los distintos pasos del entrenamiento [14]. Y por otro lado, se proponen el uso de modelos con arquitectura más simple, en la cual se emplea el uso consecutivo de capas RNC 1D sobre canales individuales con el fin de poder extraer características canal a canal de forma independiente [0][4].

Las principales ventajas del uso de capas RNC 1D son, por una parte su menor coste computacional, uso menor de memoria tanto en entrenamiento como en el almacenamiento del modelo, y el hecho de poder implementarse canal a canal, permitiendo su uso en el resto de canales en el caso de que alguno presentase un gran número de artefactos, o por situaciones de patología anatómica, no se hubiese podido colocar el electrodo, o no existiese actividad en la zona por causas anteriores al coma (cirugía, hipoxia, malformación, etc). Mientras que si se usan capas RNC 2D, se aumentan las dimensiones de obtención de información a varios canales, por lo que no sólo se tiene información aislada de cada canal, si no su relación con el resto de canales próximos en el vector de señales.

Como se puede deducir, las ventajas y desventajas entre el uso de ambas técnicas son complementarias: si se usan RNC 1D, no se tiene resolución espacial, mientras que si se usan RNC 2D, no se puede usar en canales individuales, ocupando esta última además más espacio en memoria y teniendo un coste computacional más elevado.

1.5 Aspectos a tener en cuenta en el entrenamiento y validación de sistemas de aprendizaje automático

Si bien se ha visto cómo funcionan las convoluciones, no se ha profundizado en cómo estos núcleos intentan adaptarse al entorno de trabajo actualizando sus pesos de forma iterativa, siendo esta la base del funcionamiento de los modelos anteriormente descritos, así como del presentado en este trabajo.

Como se menciona en el punto anterior, estos modelos son sistemas recursivos basados en la actualización de los pesos o probabilidades de diferentes espacios con el fin de clasificar una entrada al sistema en una o varias salidas. Este proceso precisa de un segundo espacio asociado a cada espacio de entrada con el fin de poder entrenar los pesos del sistema al compararlo

con el producido por el sistema. Este segundo espacio puede o bien ser un nuevo conjunto con características concretas, una etiqueta o un vector categórico (vector binario donde una configuración representa una sola clase) de estas etiquetas.

Esta actualización de los pesos consta de tres fases, una en la que se propaga la información desde el inicio del sistema hasta el final, tal y como se ha visto en el apartado anterior, mediante la convolución de los núcleos sobre el espacio de entrada. Esto produce el conjunto solución a la salida del sistema, el cual es comparado con el conjunto esperado según la métrica de error (o función de pérdidas) elegida. En la segunda fase, esta diferencia es usada para actualizar el gradiente del sistema según una técnica llamada descenso por gradiente, con la cual se busca un mínimo local del espacio de soluciones. El resultado de este es propagado por el sistema en la tercera fase, desde la salida hacia la entrada, modificando los pesos (valores) de cada núcleo a su paso. Esta modificación puede ser ponderada según un ratio de aprendizaje, que reduce el efecto de la corrección con el fin de suavizar las correcciones a lo largo de cada iteración. Adicionalmente, también se puede mejorar el uso del ratio de aprendizaje valiéndose de optimizadores como SGD o Adam[3], que varían este ratio de forma adaptativa en función de la magnitud de los gradientes estimados.

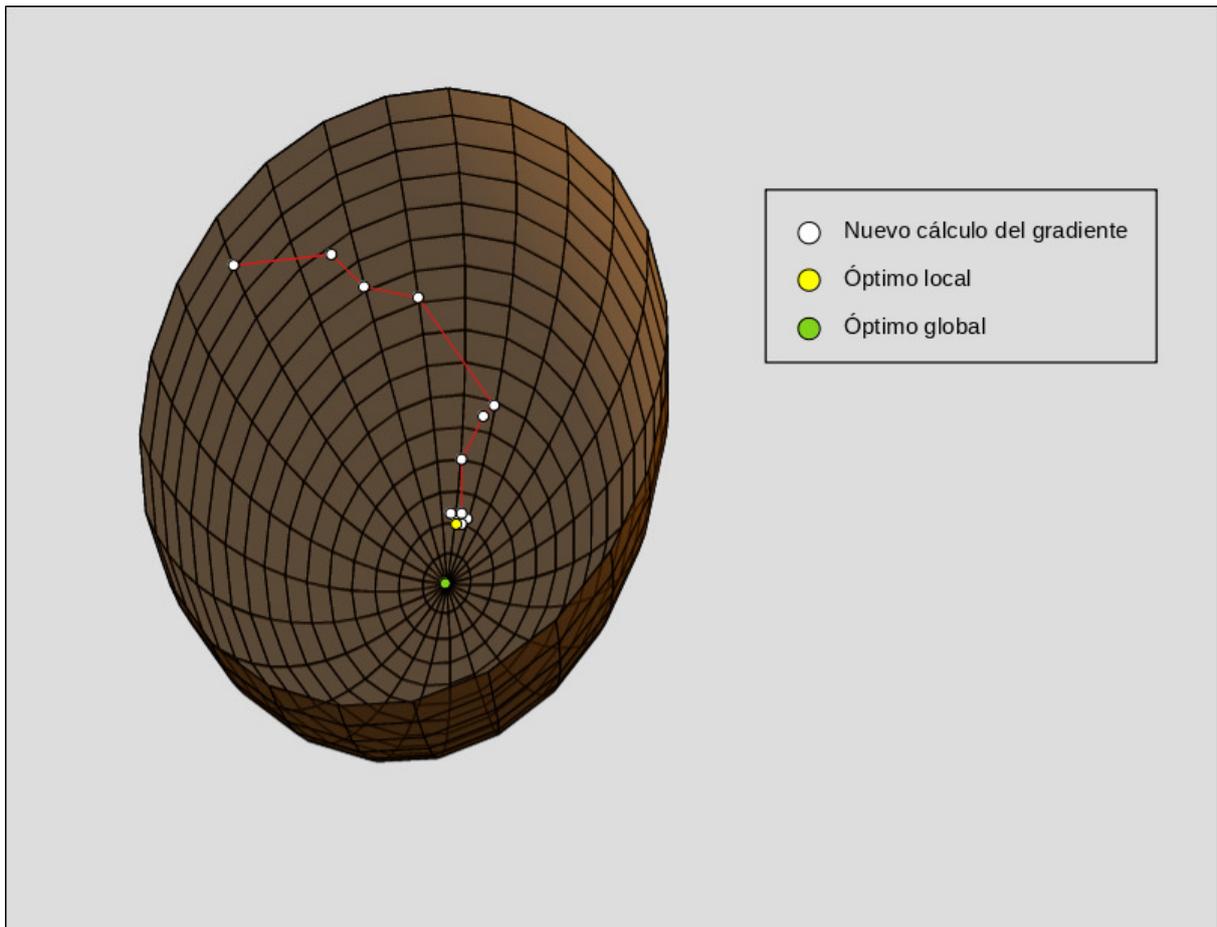


Figura 1.9: Descenso por el gradiente en el espacio de soluciones extendido(*).

(*) Se ha utilizado el concepto de espacio de soluciones extendido en este caso para denotar que no es habitual trabajar con el sistema perfectamente modelado, es por ello que en la representación

sólo se encuentra un mínimo local pese a verse un claro camino entre el mínimo local y global sin ninguna variación en la pendiente que impida al algoritmo de descenso por gradiente llegar a la solución.

Todo este proceso de actualización se realiza de forma iterativa buscando minimizar el resultado de la función de pérdidas empleada. Con el fin de hacerlo de forma óptima, el conjunto de datos con el que se pretende entrenar el sistema es dividido en diferentes épocas, cada una de ellas con una cantidad de datos de entrada preestablecida denominada tamaño de lote.

Adicionalmente, es común el uso de una herramienta de vigilancia que pueda detectar si el aprendizaje no mejora (o incluso empeora) en un intervalo de épocas determinado. Permitiendo esta detener el entrenamiento y recuperar el mínimo local alcanzado dentro del periodo vigilado.

Por otra parte, en el ámbito clínico tiene especial relevancia la explicabilidad de los sistemas basados en IA, con el fin de evitar modelos de caja negra. Es por ello que existen técnicas para representar el subconjunto del espacio de entrada que está generando el espacio de soluciones, así como todas las "activaciones" de las capas internas del sistema y qué núcleos están involucrados en la generación de tal solución. Estas técnicas se basan en la variación de parámetros de entrada con el fin de generar cambios en la salida y a la vez, ver qué conjuntos de núcleos se están activando.

Por último, cabe destacar que todo este proceso se ha descrito en el ámbito de los sistemas convolucionales, sin embargo, las mismas herramientas son usadas también en otros modelos como los basados en redes neuronales, donde en lugar de un núcleo convolucional, el problema es más sencillo, tratándose de resolver un sistema del tipo $Ax+b = y$, donde y es la salida del sistema, A la entrada, x un el conjunto de valores del núcleo, y b un factor de sesgo.

1.6 La ética en la Inteligencia Artificial

Cuando se están desarrollando o utilizando aplicaciones que utilizan técnicas de Inteligencia Artificial (IA), hay que tener en cuenta las connotaciones éticas que conlleva el uso de la misma. Este problema se vuelve especialmente delicado cuando la IA se utiliza en aplicaciones con datos altamente sensibles, como son en particular los que se manejan en el área de la salud.

Efectivamente, vivimos en un mundo que cada vez es más consciente de los peligros que puede ocasionar la utilización de técnicas de IA [11]. De hecho, cada vez más organismos públicos y privados son conscientes de este problema y han comenzado a tomar medidas para paliar en la medida de lo posible los efectos negativos que una mala utilización de estas herramientas puede ocasionar.

En esta línea, la UPV ha promovido diferentes iniciativas:

- Las primeras de ellas, van dirigidas a la concienciación tanto del alumnado como de profesionales y resto de la sociedad. En esa línea podemos destacar la conferencia que se realizó en Octubre de 2020 Reflexiones en torno a la ética y la inteligencia artificial con Adela Cortina y Vicente Botti"
- Por otra parte se está promoviendo la participación activa en diferentes proyectos que traten sobre esta problemática. En este sentido la Unión Europea (UE), ha seleccionado a la

UPV como centro de excelencia por la investigación y aplicación de la IA, después de que Bruselas haya escogido al proyecto Tailor, impulsado por la red internacional Claire (a la que pertenece la UPV), como iniciativa clave para el futuro de la Inteligencia Artificial en la UE. En el proyecto, participan tanto universidades como centros tecnológicos y empresas en el campo de la IA. Y entre estas empresas, se encuentra el Instituto VRAIN de la UPV. De España, participan también el Instituto de Investigación en Inteligencia Artificial (IIIA) del Consejo Superior de Investigaciones Científicas (CSIC), la Universitat Pompeu Fabra y la Universidad de Málaga.

Además, la Generalitat Valenciana también está impulsando medidas en este campo:

- La Conselleria de Innovación refleja en sus presupuestos 2023 su apuesta por la Inteligencia Artificial con una inversión de 9 millones en programas pioneros.
- El pleno del Consell ha aprobado el mes de Junio de 2023 la creación del Observatorio de la Inteligencia Artificial de la Comunitat Valenciana, que servirá para planificar, estudiar y analizar el impacto del uso de la IA en el entorno y la realidad socioeconómica de la provincia.

En lo referente a este marco, el proyecto se adherirá a estas recomendaciones como se puede observar en los objetivos del mismo, así como en el apartado de conclusiones.

Propuesta, Justificación y Objetivos

En este capítulo se plantea y justifica el modelo a emplear, se enumeran los objetivos planteados así como las tareas a desarrollar

2.1 Propuesta y justificación del proyecto

Como se ha visto en el capítulo anterior, existe un gran problema (tanto ético como tecnológico) a la hora de diagnosticar las posibilidades de supervivencia de una persona en coma tras un paro cardíaco, por lo que la comunidad científica está intentando colaborar mediante el desarrollo de sistemas de ayuda, capaces de clasificar de una manera mucho más precisa el estado del paciente en una de las categorías CPC y por tanto determinar sus posibilidades de supervivencia a partir de la información de la evolución del mismo.

En este contexto se enmarca el reto "The George B. Moody PhysioNet Challenge", que este año ha buscado incentivar la investigación en herramientas que pudiesen guiar el diagnóstico de este tipo de casos clínicos con el fin de reducir el número de pronosis equivocadas, salvando vidas y ahorrando grandes costos a los sistemas de salud. Para ello, se han propuesto dos fases en las que grupos de investigación pertenecientes a instituciones públicas y/o privadas de todo el mundo presentasen sus resultados, tanto con las puntuaciones logradas en la tabla de la plataforma del reto, como con un resumen en la primera fase del reto, a modo de filtro y como artículo de congreso para su presentación en el Computing in Cardiology, CinC'23 que se celebrará el próximo octubre en Atlanta, Estados Unidos de América.

Con motivo de la publicación del reto, el grupo de investigación BioITACA, perteneciente al instituto ITACA (Applications of Advanced Information and Communication Technologies) de la Universitat Politècnica de València. Con experiencia en el sector de la tecnología biomédica y ayuda al diagnóstico. Propuso al alumnado la participación en dicho reto. Por mi parte como estaba trabajando con el grupo de investigación OGMIOS del instituto VRAIN (Valencian Research Institute for Artificial Intelligence) de desarrollo de aplicaciones web, tratamiento de datos e investigación en el estado del arte de inteligencia artificial aplicada a la genómica. Por otra parte, había adquirido experiencia en el uso de técnicas de análisis en señales de EEG a partir de una colaboración con el grupo de enfermedades neurodegenerativas, en el que se evaluaba el efecto de determinadas enfermedades en la dinámica de transición entre microestados

(discretización de la distribución de energía a lo largo de los canales en los picos de la potencia de campo global). A partir de los conocimientos adquiridos en el desarrollo de estas actividades, consideré idónea la oportunidad que brindaba este reto, y por ello solicité participar en el mismo. Siendo seleccionado tal fin, por medio de un contrato de prácticas.

En cuanto a la normativa del "The George B. Moody PhysioNet Challenge", esta obliga explícitamente, hasta pasada la conferencia, a la no publicación del contenido de los modelos y resultados en él presentados. Al aceptar el reto, aceptamos esta limitación, por lo que, con el fin de no complicar el proceso de selección de tribunal y ahorrar trámites administrativos en cuanto a temas de confidencialidad, se decidió presentar como trabajo de fin de grado otro modelo alternativo y modificar el problema de clasificación. Si bien se continúa planteando en la línea de desarrollar un sistema de ayuda a la decisión, proporcionando una clasificación a partir de las señales de EEG, se han agrupado las clases según si ofrecen un pronóstico favorable o desfavorable, siguiendo las directrices de lo que en el reto se considera como tal. Evidentemente se trata de un problema de clasificación más sencillo, aunque con la dificultad adicional de lograr un modelo escalable y reutilizable.

2.2 Objetivos

El objetivo principal del proyecto consiste en desarrollar un modelo que permita clasificar a los pacientes en dos categorías: los pacientes en coma que van a poder recuperarse, por tanto con un diagnóstico favorable (que correspondería a las categorías de CPC 1 y 2) o en caso contrario, con pronóstico desfavorable (correspondiente a las categorías de CPC 3, 4 y 5).

Otros objetivos secundarios son: soportar explicabilidad gráfica, escalabilidad y coste computacional reducido.

Para la consecución de dichos objetivos se establecieron las siguientes tareas:

- Estudio de la bibliografía científica relacionada con esta temática.
- Puesta en marcha y ajuste de una plataforma de cómputo científico basada en un multi-procesador de GPU's, capaz de entrenar el modelo propuesto en tiempos razonables.
- Desarrollo, depuración y ajuste de un modelo alternativo al presentado en el reto, que contemple las siguiente características:
 - Sencillez: Lograr el resultado con la arquitectura más sencilla posible.
 - Explicabilidad: Ofrecer una mayor explicabilidad frente a los modelos mencionados.
 - Complejidad computacional: Se pretende ofrecer una complejidad computacional razonable
 - Escalabilidad: Entrenar un modelo como unidad básica para la exportación y uso en otros modelos que trabajen con problemas similares.
 - Humano: En la línea del uso ético de la IA, se favorecerá a la clase que, en expensas de un mayor coste para el sistema sanitario, salve más vidas.

Capítulo 3

Materiales y Métodos

A lo largo de este capítulo se exponen los materiales empleados en la realización del proyecto así como la metodología seguida para la consecución de los objetivos expuestos en el capítulo anterior.

3.1 Materiales

3.1.1 Base de datos

La base de datos utilizada en el proyecto es la aportada por "The George B. Moody PhysioNet Challenge 2023", proveniente de siete hospitales distribuidos entre Europa y Estados Unidos de América, miembros del 'International Cardiac Arrest REsearch consortium' (I-CARE). Se trata de segmentos de cinco minutos de señales de EEG tomadas de pacientes en coma tras sufrir un paro cardíaco. Esos cinco minutos son los de mayor calidad presentes en cada registro de una hora, habiéndose intentado registrar la señal desde la entrada en la UCI hasta su salida. El uso de esta base de datos era requisito obligatorio para la participación del reto a partir del cual surge el proyecto.

Las señales ya se encuentran preprocesadas, con un filtrado paso banda entre 0.5 y 30 Hz, además de haber sido remuestreadas a 100 Hz. Presentan la configuración de electrodos en el estándar 10-20 internacional, y se ponen a disposición ya como señales diferenciales según el eje longitudinal. Resultando en un total de 18 canales.

A continuación se muestra un esquemático del contenido de la base de datos aportada:

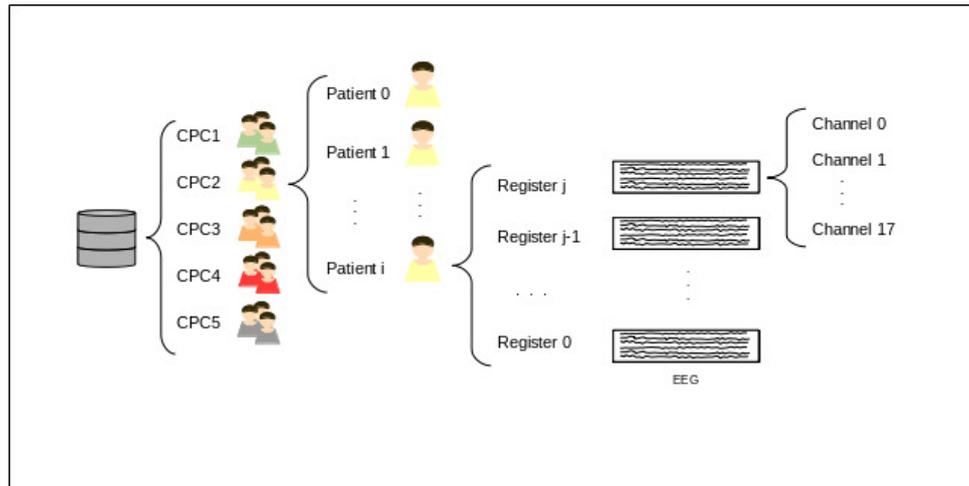


Figura 3.1: Representación de la estructuración de la BBDD.

3.1.2 Hardware

Para la realización de este proyecto se ha dispuesto del uso de dos máquinas

- **Ordenador personal:**
 - **Modelo:** HP Spectre x360 Convertible
 - **CPU:** Intel i7-6500U (4) @ 3.100 GHz
 - **GPU:** Intel HD Graphics 520
 - **RAM:** 8 GB
 - **Memoria:** 240 GB
- **Servidor de computación basado en GPUs:**
 - **CPU:** Intel i7-5820K (12) @ 3.600 GHz
 - **GPU:** (3x) NVIDIA GeForce GTX 1060 3GB
 - **RAM:** 48 GB
 - **Memoria:** 1 TB

3.1.3 Software

El sistema operativo del ordenador personal es:

- Debian GNU/Linux 10 (buster) x86_64

Y el del servidor es:

- Debian GNU/Linux 11 (bullseye) x86_64

Adicionalmente, se dispuso del siguiente software para el desarrollo del proyecto:

- **Entorno gráfico:** Xfce v4.18 + Awesome v4.3
- **Multiplexor de terminales:** Tmux v3.1c
- **Aplicaciones de conectividad remota:** OpenSSH v7.9, OpenSSL v1.1.1, Authenticator v6.2305.3477
- **Sistema de control de versiones:** Git v2.20.1
- **Entorno de desarrollo:** Visual Studio Code v1.79.2, nano v3.2
- **Lenguajes de programación:** Python 3.9.2, Bash v5.0.3
- **Herramientas de dibujo:** LibreOffice 6.1.5.2

3.2 Métodos

3.2.1 Organización de los datos

Con motivo de poder realizar un balance a nivel de población y distribuir los datos de forma óptima, se analizó la base de datos aportada por el reto. Para ello se usaron los lenguajes de programación Python y Bash, con el fin de obtener el número de pacientes perteneciente a cada clase, así como la distribución de éstos agrupando según rango de edades, sexo y otros parámetros proporcionados.

Tras realizar el balance de la distribución de los datos según las anteriores agrupaciones, se distribuyeron los datos en 9 conjuntos de entrenamiento y validación con el fin de que se representase toda la población en las validaciones del modelo. A su vez, estos nueve conjuntos tienen asociado su subconjunto de datos, también representativo, pero con menor número de pacientes, con el fin de realizar una exploración rápida del espacio de soluciones con volúmenes de datos pequeños pero representativos.

3.2.2 Visualización y obtención de los parámetros clásicos

Antes de decidir cómo proceder con los datos, se representaron las señales de varios pacientes de cada categoría en el dominio del tiempo y de la frecuencia con el fin de poder determinar si se encontraban diferencias significativas entre cada clase, y se podían determinar qué parámetros podrían aumentar la distancia entre clases y disminuir dentro de cada clase. Una vez representados y analizados visualmente estos conjuntos de datos se aplicaron técnicas analíticas para identificar qué parámetros pueden discernir bien entre los diferentes tipos de señal, para ello se observaron características morfológicas de señal, tanto en el dominio del tiempo como en el de la frecuencia, así como parámetros representativos de energía, entropía y dinámica de las señales. También se realizaron este tipo de análisis según las bandas de frecuencia características de este tipo de señales, y se extrajeron indicadores de uso clínico.

3.2.3 Propuesta y desarrollo de una nueva técnica de procesamiento de señales EEG

Mientras se trabajaba con información en las dimensiones espacio, tiempo, se investigó a fondo en la literatura y al no encontrarse nada relacionado, comenzó a desarrollarse una nueva técnica de procesado de señales EEG en las que se tienen en cuenta las dimensiones espacial, temporal y frecuencial. Inicialmente el algoritmo realizaba la transformada de Fourier en ventanas de tres segundos y posteriormente calculaba el campo de potencia global de la concatenación de los espacios en el dominio de la frecuencia, con el fin de generar microestados [6](elementos discretos que abarcan un periodo de tiempo en el que la distribución de energía en cada canal varía muy poco), basados en la distribución de la energía en este dominio a lo largo de los 18 canales, pero esta parte del algoritmo ha sido modificada para obtener mejores resultados. Inicialmente se buscaba extraer la mayor cantidad de microestados posibles de cada clase, para luego reducir el número de estos a cinco con el fin de obtener un conjunto mucho más generalista con el fin de poder clasificar pacientes a nivel individual. Esto se debe a que al aumentar el número de microestados, estos se hacen más específicos, perdiendo similitud con la población a la que pertenece. Después de obtener los microestados en el dominio de la frecuencia se calculaba la clase de pertenencia según la correlación cruzada entre los centros de los grupos, siguiendo la hipótesis de que cada conjunto pertenece a la población a la que más se parece. A continuación se va a ilustrar el proceso de obtención de los microestados en el dominio del tiempo, dado que el algoritmo empleado era el mismo, pero de esta forma no se revela la estrategia seguida para la concatenación de los dominios en frecuencia. La representación se realiza con cuatro señales con el fin de facilitar el seguimiento del algoritmo.

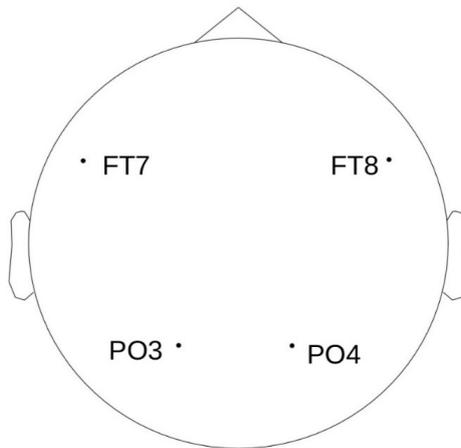


Figura 3.2: Posiciones de los canales empleados según el estándar 10-10.

A partir de estas derivaciones se calcula la GFP como el producto de la media y la desviación típica de los valores de amplitud de cada canal en cada muestra.

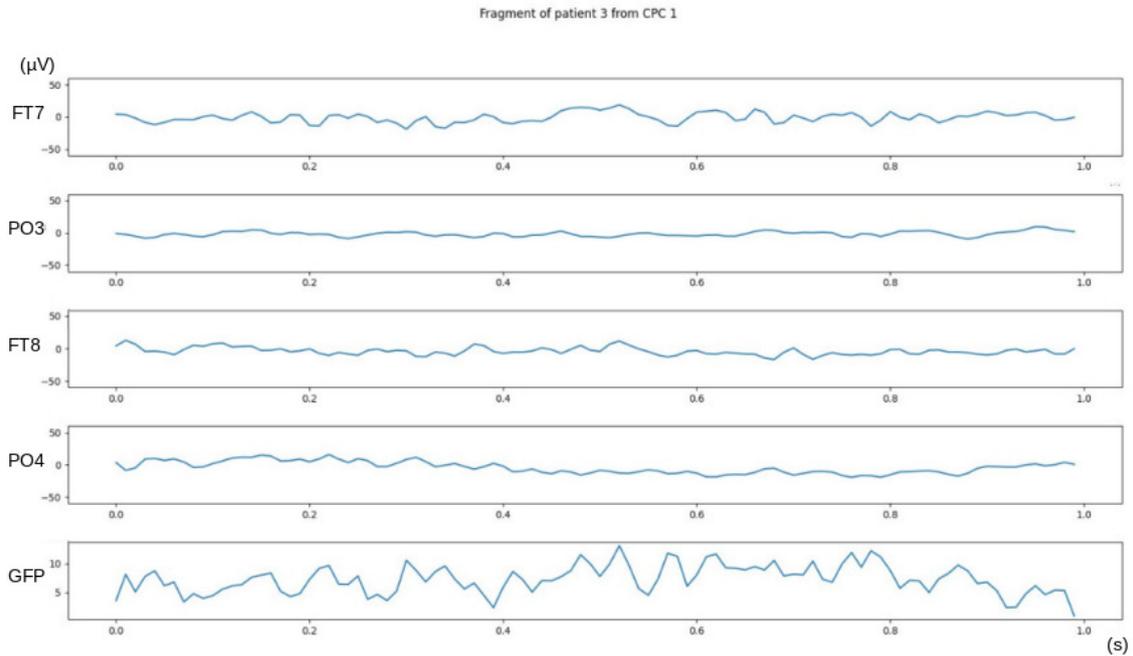


Figura 3.3: Cálculo de la GFP a partir de las 4 señales.

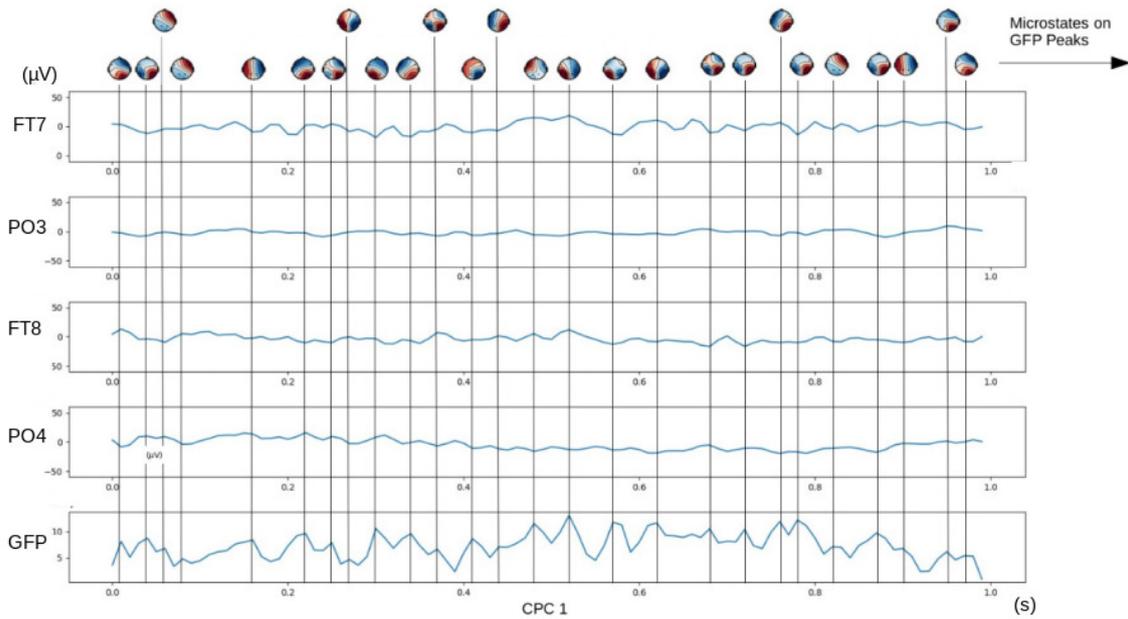


Figura 3.4: Microestados asociados a la topología en cada pico de la GFP.

Los microestados se obtienen en los picos de la GFP por ser dónde hay mayor ratio señal ruido y muestran la distribución de potencial por la superficie craneal. Permiten discretizar un sistema continuo y dinámico, asumiendo que los valores no cambian en el tiempo, si no que se mantienen constantes unos milisegundos para luego cambiar de nuevo.

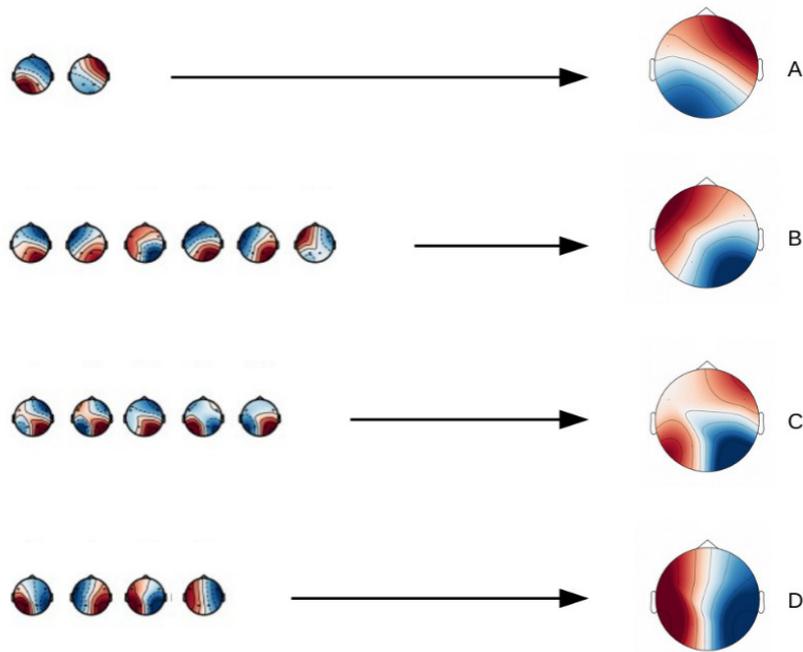


Figura 3.5: Generalización de los microestados.

Los microestados con este método pueden ser usados para calcular la dinámica de la señal en función de estos, realizar una segmentación de la señal o, como en nuestro caso, comparar lo parecidos que son los conjuntos entre sí con fin de clasificarlos.

Esta técnica fue presentada a la fase inicial del reto, y fue con la que se consiguió ser seleccionado para presentar el resto del trabajo durante la siguiente fase en el congreso de CinC.

3.2.4 *Puesta en marcha del servidor basado en GPUs*

Con el fin de afrontar con éxito esta segunda fase y agilizar los tiempos de entrenamiento del modelo, poder trabajar con volúmenes más grandes de datos, y poder realizar ajustes más eficientes al modelo, fue necesario realizar una transición desde un ordenador personal a un sistema de mayores prestaciones, al cual se pudiese acceder en remoto. Para ello, se configuró una máquina del laboratorio, la cual inicialmente trabajaba únicamente como un ordenador de computación para uso local y con sistema operativo Windows 8.1.



Figura 3.6: Vista superior de la máquina configurada.

Para ello, se decidió instalar Debian 11, por ser el sistema operativo gratuito más usado en servidores, dada su alta estabilidad y largos periodos de soporte por parte del equipo de desarrollo. Además de reducir el desgaste de memoria y el consumo de energía y recursos (RAM y almacenamiento), en comparación con los sistemas que utilizan Windows.

Otra ventaja del uso de sistemas basados en GNU/Linux es la disponibilidad de una gran cantidad de librerías gratuitas, estables y seguras, que permiten la utilización del sistema de una forma más ágil que en máquinas con software privativo. Adicionalmente, se puede configurar completamente el sistema, lo cual es muy deseable en equipos de computación de altas prestaciones para un mejor uso de los recursos.

Una vez instalado el sistema operativo, se instaló y configuró un multiplexor de terminales para permitir la ejecución persistente de procesos aún después de que el usuario que lanzase el proceso se desconectase del servidor. En cuanto al sistema de usuarios, dado el reducido número de usuarios que pueden conectarse a la vez, se estableció un único usuario en el sistema, sin privilegios de administrador, permitiendo la existencia de varias sesiones simultáneas para el mismo usuario desde diferentes conexiones.

La seguridad de acceso queda garantizada, teniendo en cuenta que para poder acceder se precisa disponer de un usuario en la UPV, y validar el inicio de sesión de VPN a través de la aplicación Authenticator de Microsoft en el caso de intentar acceder desde fuera de la red de la universidad.

Por último, para que esta máquina pueda ser utilizada de forma sencilla por el resto de personal que compone el grupo de investigación, se creó un mensaje de inicio con los comandos necesarios para ejecutar correctamente los procesos por parte del usuario, además de haberse redactado un manual de usuario con las instrucciones de uso del sistema y ejemplos de estas.

3.2.5 Reestructuración de los canales

Con el fin de poder trabajar con las señales respetando su topología original, se crearon diferentes plantillas para representar la información en el espacio, escogiendo la de dimensiones más pequeñas por restricciones de las especificaciones de la máquina. A partir de esta, las señales fueron reorganizadas desde su espacio matricial original a un tensor de dimensiones 4x5x500, siendo 4x5 las dimensiones espaciales de la plantilla y 500 la ventana de 5 segundos elegida por razones que se verán más adelante.

∅	∅	∅	Fp1	∅	Fp2	∅	∅	∅
∅	F7	∅	∅	∅	∅	∅	F8	∅
∅	∅	F3	∅	Fz	∅	F4	∅	∅
∅	∅	∅	∅	∅	∅	∅	∅	∅
T3	∅	C3	∅	Cz	∅	C4	∅	T4
∅	∅	∅	∅	∅	∅	∅	∅	∅
∅	∅	P3	∅	Pz	∅	P4	∅	∅
∅	T5	∅	∅	∅	∅	∅	T6	∅
∅	∅	∅	O1	∅	O2	∅	∅	∅

Figura 3.7: Plantilla que mejor representa la topología de los electrodos, pero conlleva un gran coste de almacenamiento.

∅	Fp1	∅	Fp2	∅
F7	F3	Fz	F4	F8
T3	C3	Cz	C4	T4
T5	P3	Pz	P4	T6
∅	O1	∅	O2	∅

Figura 3.8: Plantilla de calidad y coste intermedio.

AF7	AF3	∅	AF4	AF8
FT7	FC3	Fcz	FC4	FT8
TP7	CP3	Cpz	CP4	TP8
PO7	PO3	∅	PO4	PO8

Figura 3.9: Plantilla de menor fidelidad y menor coste.

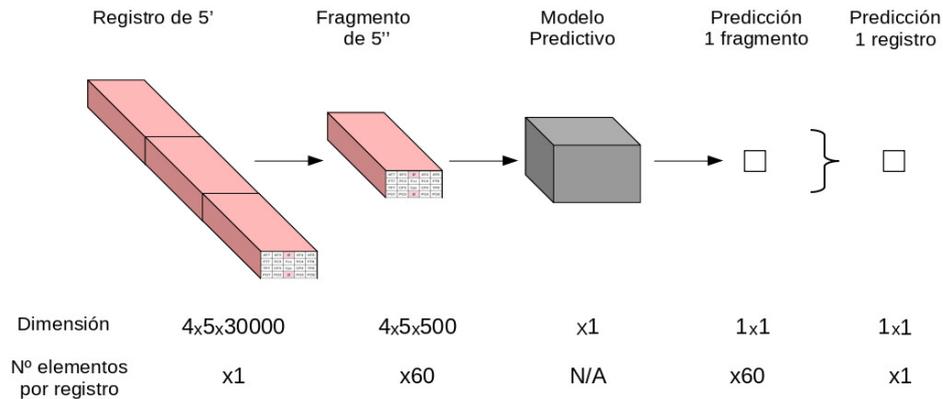


Figura 3.11: Estrategia "divide y vencerás" seguida para la fragmentación y clasificación de los registros.

3.2.6 Diseño de la arquitectura del modelo

Una vez con el servidor configurado y desplegado, y los datos reestructurados, se diseñaron modelos de acorde a los objetivos establecidos. Teniendo en cuenta, que como condicionante del diseño, el tamaño máximo soportado por el sistema mientras ofrece una interfaz gráfica al usuario es de 2,9 GB en la primera GPU, siendo esta la única destinada por el entorno empleado a almacenar la información asociada a los pesos y gradientes del sistema. Para reducir la problemática del limitado espacio, se ajustaron ciertos parámetros del uso de las GPUs, activando la bandera 'TF_FORCE_GPU_ALLOW_GROWTH', y seleccionando 'cuda_malloc_async' como 'TF_GPU_ALLOCATOR'. Además, se redujo la precisión de los valores de los registros a 'float16' y se configuró la política de precisión mixta de keras para que sólo trabajase con 'bfloat16' el cual utiliza tres bits de más en el exponente y 3 menos en las fracciones que el IEEE half-precision float16, pero no enlentece las operaciones en la GPU, cosa que ocurre con la media precisión float16 para GPU con cuda y capacidad de computo inferior a 7, trabajando las GPUs del servidor con una capacidad de 6.1).

En los modelos originales, se emplearon una fase de capas convolucionales tridimensionales con el fin de disminuir el tamaño del tensor de entrada en la dimensión temporal, y sustituir los valores de cada canal, en un inicio de amplitud de tensión, a la relación de esta con la de los canales contiguos. Tras esta transformación del tensor, este es reorganizado en un vector que sirve de entrada a la segunda fase, un conjunto de cuatro capas neuronales densamente conectadas que comprimen la información hasta dar un valor comprendido entre 0 y 1, significando 0 un diagnóstico favorable y 1 desfavorable.

De forma iterativa, se fueron ejecutando los diseños varias veces sobre los diferentes conjuntos reducidos de entrenamiento y validación con el fin de obtener estadísticas de su habilidad para clasificar correctamente, e ir realizando modificaciones sobre los modelos que mejor rendimiento mostrasen para explorar las regiones contiguas del espacio de soluciones.

Siguiendo las figuras 3.12 y 3.13, primero se establece un umbral en el promedio por métrica en función del mejor valor encontrado en cada una de estas, todo lo que mejore ese umbral es coloreado de verde claro; segundo se realiza lo mismo en la desviación típica; y tercero se colorean de verde oscuro aquellas celdas verde claro que coincidan en el promedio y la desviación típica. El mejor modelo o modelos que tengan más celdas de color verde oscuro pasan a la siguiente ronda de estudio de viabilidad en la cual los modelos a probar estarán basados en variaciones de su arquitectura no exploradas con anterioridad.

AVERAGE								
Model	Loss	Accuracy	Precision	Recall	AUC	Binary Crossentropy	False Positives	
0	1,15	0,658	0,692	0,703	0,712	1,242	363	
1	1,121	0,652	0,688	0,713	0,698	1,197	387	
2	1,728	0,647	0,691	0,67	0,693	1,881	348	
4	1,435	0,656	0,695	0,694	0,705	1,53	356	
5	1,483	0,674	0,721	0,682	0,723	1,687	305	
6	1,155	0,623	0,643	0,813	0,627	1,224	563	
7	1,555	0,65	0,695	0,678	0,694	1,669	349	
8	1,444	0,666	0,696	0,722	0,717	1,649	368	
10	1,312	0,679	0,699	0,752	0,726	1,5	376	
11	1,238	0,649	0,698	0,656	0,697	1,293	327	
12	0,764	0,591	0,622	0,832	0,573	0,775	649	
13	1,267	0,675	0,711	0,707	0,731	1,351	332	
14	0,859	0,607	0,628	0,864	0,593	0,891	653	
15	1,228	0,628	0,664	0,711	0,658	1,318	433	
16	1,49	0,63	0,669	0,73	0,657	1,574	451	
17	1,005	0,6	0,626	0,82	0,593	1,049	618	
18	0,844	0,597	0,631	0,862	0,58	0,857	671	
19	1,413	0,651	0,689	0,715	0,69	1,532	391	

Figura 3.12: Promedio de las métricas usadas sobre los diferentes modelos.

STD DV								
Model	Loss	Accuracy	Precision	Recall	AUC	Binary Crossentropy	False Positives	
0	0,189	0,014	0,021	0,069	0,016	0,218	64	
1	0,157	0,027	0,04	0,105	0,054	0,188	152	
2	0,166	0,011	0,016	0,057	0,008	0,185	51	
4	0,085	0,012	0,022	0,082	0,009	0,116	74	
5	0,144	0,009	0,015	0,031	0,01	0,155	32	
6	0,414	0,05	0,069	0,153	0,102	0,474	280	
7	0,137	0,02	0,028	0,106	0,015	0,177	94	
8	0,107	0,017	0,029	0,068	0,018	0,15	78	
10	0,152	0,016	0,03	0,037	0,015	0,142	72	
11	0,218	0,008	0,012	0,035	0,009	0,236	33	
12	0,131	0,038	0,081	0,21	0,087	0,147	316	
13	0,142	0,009	0,015	0,037	0,013	0,166	38	
14	0,257	0,058	0,087	0,172	0,115	0,301	316	
15	0,358	0,026	0,045	0,116	0,055	0,417	176	
16	0,497	0,042	0,066	0,161	0,089	0,54	263	
17	0,429	0,041	0,07	0,19	0,095	0,476	302	
18	0,273	0,066	0,124	0,24	0,139	0,296	411	
19	0,277	0,031	0,048	0,106	0,063	0,323	180	

Figura 3.13: Desviación típica de las métricas usadas sobre los diferentes modelos.

Una vez alcanzada una arquitectura cuyas variaciones no generasen mejoras en la predicción, esta fue seleccionada para pasar a la siguiente fase del diseño. Cabe destacar que, ramas de exploración de la arquitectura óptima, fueron cortadas debido a falta de memoria en la GPU principal, por lo que no se puede asegurar que esta sea el mínimo global de una región del espacio de soluciones acotada, cercana y centrada en esta solución.

En lo referente a las métricas empleadas, se ha usado la precisión para optimizar la clasificación de la clase 0 (pronóstico favorable) y la recuperación ('recall' en inglés) para la clase 1. Esto es debido a que, como se ha indicado con anterioridad, se favorece el poder salvarle la vida a más personas frente a ahorrar más dinero al sistema de salud. En esta línea también se ha usado el número de falsos positivos, aunque en este caso se trata del número para ambas clases. Las pérdidas, AUC y la exactitud (accuracy) se han usado por ser las métricas estándar que permiten estimar la bonanza del modelo, y la entropía cruzada binaria por ser la función de pérdidas empleada.

3.2.7 Ajuste de los hiperparámetros

Ya escogida la arquitectura, se sometió a un ajuste de hiperparámetros automático en el cual se iban explorando varias combinaciones de valores para cada hiperparámetro buscando el mínimo local en el espacio de soluciones. Una vez se llegó a dicho mínimo la arquitectura final del modelo quedó ajustada según:

- **Modelo secuencial**
 - **Neuronal convolucional tridimensional**
 - **Nº de filtros:** 96 filtros
 - **Tamaño del kernel** (3,3,15)
 - **Desplazamiento** (1,1,5)
 - **Relleno** Misma dimensión
 - **Función de activación** Unidad lineal rectificada
 - **1ª Neuronal densamente conexa**
 - **Nº de neuronas:** 256 neuronas
 - **Función de activación** Unidad lineal rectificada
 - **2ª Neuronal densamente conexa**
 - **Nº de neuronas:** 64 neuronas
 - **Función de activación** Unidad lineal rectificada
 - **3ª Neuronal densamente conexa**
 - **Nº de neuronas:** 16 neuronas
 - **Función de activación** Unidad lineal rectificada
 - **4ª Neuronal densamente conexa**
 - **Nº de neuronas:** 1 neurona
 - **Función de activación** Sigmoides

■ Entrenamiento

- **Longitud de segmento:** 500 muestras
- **Número de épocas:** 100 épocas truncadas a 24 por vigilancia
- **Tamaño de lote:** 100 segmentos
- **Optimizador**
 - **Tipo:** Adam
 - **Ratio de aprendizaje:** 0,0005
- **Función de pérdidas:** Entropía binaria cruzada
- **Vigilancia**
 - **Época inicial:** 10
 - **Paciencia:** 10 épocas
 - **Recuperación mejor valor:** Sí

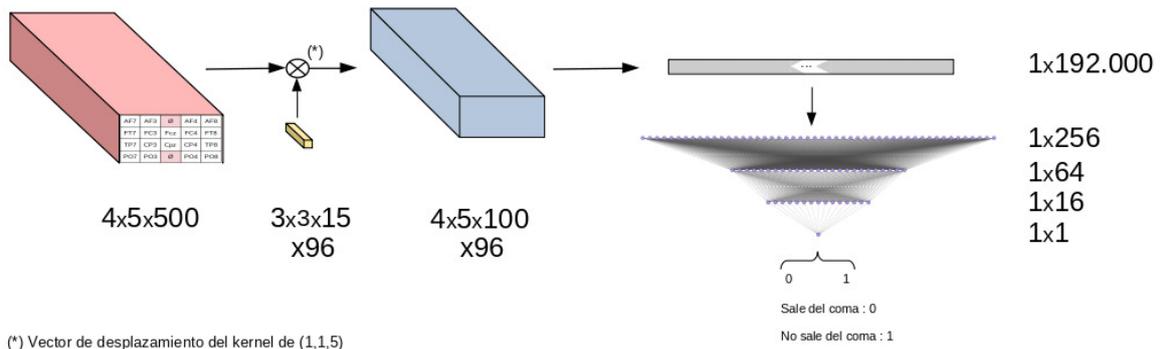


Figura 3.14: Arquitectura del modelo diseñado.

3.2.8 Balance de clases

En cuanto al número de clases, aunque distribuidas de forma que se preserve la representación entre los subconjuntos, existen grandes desigualdades entre el número de pacientes pertenecientes a estas. Por lo que se realizó un ajuste del número de registros que entraban a entrenamiento en función de la clase, este consiste en aceptar horas más lejanas en el tiempo al último registro en las clases CPC 3 y 4, frente al resto de clases. Pese a que alejarse de la última hora registrada hace que la señal sea menos específica de su clase, al ser ambas clases pertenecientes al grupo de un diagnóstico desfavorable, los beneficios de alejarse en el tiempo superan a los perjuicios de homogeneización de la señal.

3.2.9 Desarrollo de la explicabilidad

Con el fin de crear un sistema visual que pueda indicarle al profesional sanitario a qué relaciones entre canales e indirectamente, a qué estado de cada uno de estos le "presta atención" el modelo, de forma que se elimine el modelo de caja negra que a menudo causa desconfianza por parte del cuerpo de profesionales sanitarios. Se ha implementado un conjunto de herramientas gráficas que representan, a través de un mapa de calor vectorial, qué segmentos de muestras en el tiempo y qué canales están produciendo la respuesta del sistema.

Para poder obtener estos mapas de calor, y que sean representativos del resultado del sistema, se han de almacenar los mapas de activación de cada capa, de forma que sea trazable desde la salida hacia la entrada a qué neuronas se les ha dado más prioridad, hasta alcanzar la primera capa de red neuronal densa, la cual evalúa las relaciones entre canales. Sabiendo a que "presta atención" esta capa se pueden obtener las relaciones relevantes para la predicción, y deshaciendo la convolución, teniendo en cuenta los filtros activados, se pueden ver las señales de EEG originales, y que regiones de estas han sido destacadas para la clasificación. A continuación se muestra un esquema del proceso de representación, este contiene un número menor de neuronas y filtros con el fin de reducir la complejidad del mismo.

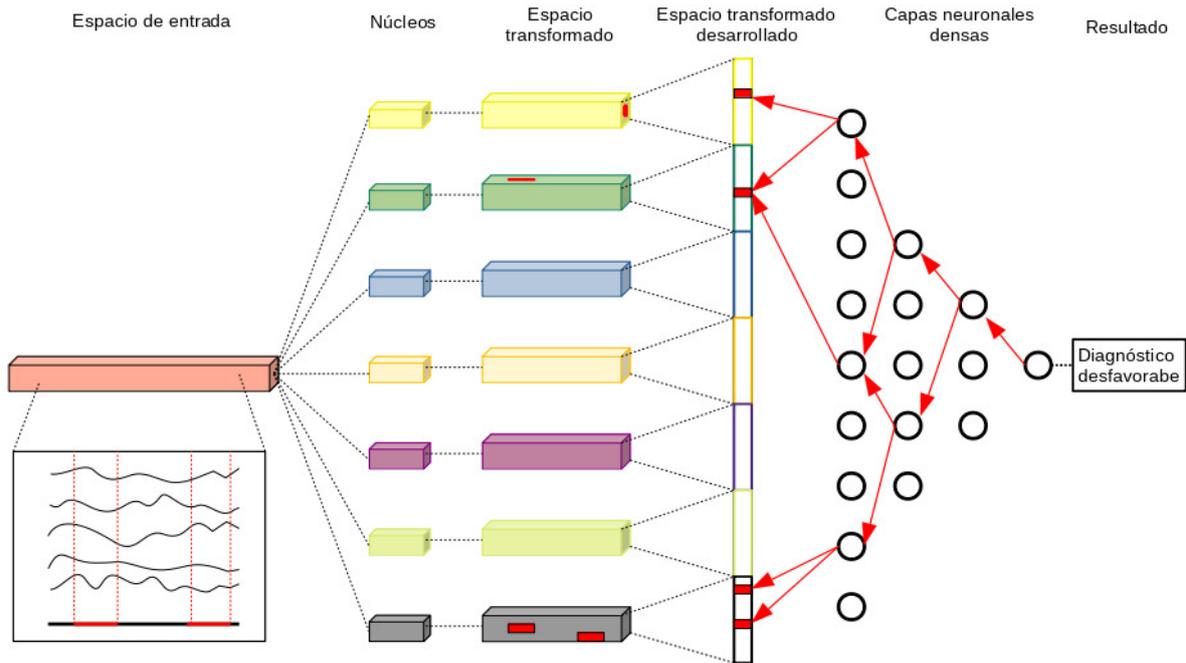


Figura 3.15: Esquema del proceso de extracción de la "atención" del modelo.

3.3 Complejidad computacional

Como se ha visto anteriormente, las RNC 1D presentan una complejidad computacional menor que las RNC 2D, siendo estas últimas uno menor que las RNC 3D. Sin embargo, estas redes se emplean como elementos de arquitecturas, comúnmente heterogéneas, por lo que en cuanto a lo que respecta a la complejidad de un modelo, se ha de hablar de la complejidad global.

Durante el estudio de la bibliografía científica en el ámbito del proyecto, se han visto diferentes niveles de complejidad computacional, aquí se expondrán los de menor complejidad y se compararán con el modelo presentado.

Complejidad del modelo propuesto

- **Complejidad de la capa convolucional:**

$$\begin{aligned}
 V &= X \times Y \times S \\
 K &= K_x \times K_y \times K_s \\
 D &= \frac{1}{D_x} \times \frac{1}{D_y} \times \frac{1}{D_s} \\
 &\mathcal{O}(N \times V \times K \times D)
 \end{aligned}$$

Ecuación 3.1: Términos de complejidad de la capa convolucional 3D

Donde:

- N es el número de núcleos.
- K es el tamaño del kernel siendo las coordenadas x, y las dimensiones de la plantilla y s la del número de muestras del segmento.
- V es el volumen del tensor de entrada, donde X y Y son las dimensiones espaciales de la plantilla y S la longitud de muestras volumen de entrada.
- D es el coeficiente de reducción por desplazamiento del kernel, aplicado en cada dimensión del tensor de entrada.

- **Complejidad de la capa plana:**

$$\mathcal{O}(1)$$

Ecuación 3.2: Términos de complejidad de la capa plana

- **Complejidad de las capas densas:**

$$\mathcal{O}(E \times S)$$

Ecuación 3.3: Términos de complejidad de la capa densa

Donde:

- E es el número de neuronas de entrada.
- S es el número de neuronas de salida.

Al encontrarse las capas de forma secuencial, la complejidad total es la suma de la complejidad de cada capa. Resultando:

$$\mathcal{O}(N \times V \times K \times D + 1 + E_0 \times S_0 + E_1 \times S_1 + E_2 \times S_2 + E_3 \times S_3 + E_4 \times S_4)$$

Que tras simplificar queda:

$$\mathcal{O}(N \times V \times K \times D + (V \times D) \times S_0 + S_0 \times S_1 + S_1 \times S_2 + S_2 \times S_3 + S_3)$$

Y dando valor a los parámetros que no dependen del entrenamiento:

$$\mathcal{O}(96 \times V \times (4 \times 5 \times 15) \times 0,2 + (4 \times 5 \times 15) \times 0,2 \times 256 + 256 \times 64 + 64 \times 16 + 16 \times 1)$$

Lo que equivale a:

$$\mathcal{O}(5760 \times V + 32784)$$

Calculando el valor numérico con las especificaciones del entrenamiento:

$$\mathcal{O}(5760 \times 500 + 32784) \approx 3 \times 10^6 \text{ parámetros a entrenar}$$

Teniendo en cuenta el número de épocas y el tamaño de lote, resultaría en una complejidad de:

$$\mathcal{O}(L \times E \times (5760 \times V + 32784))$$

Y dándole valores numéricos según lo empleando en el entrenamiento y considerando el peor caso posible:

$$\mathcal{O}(100 \times 100 \times (5760 \times V + 32784)) \approx 28 \times 10^9 \text{ parámetros a entrenar}$$

Complejidad del modelo con RNC 2D

- **Complejidad de la capa convolucional:**

$$\mathcal{O}(N \times K \times A)$$

Ecuación 3.4: Términos de complejidad de la capa convolucional 2D

Donde:

- N es el número de núcleos.
- K es el tamaño del núcleo.
- A es la dimensión de la matriz de entrada.

▪ **Complejidad de la capa Bi-LSTM:**

$$\mathcal{O}(U \times L)$$

Ecuación 3.5: Términos de complejidad de la capa Bi-LSTM

Donde:

- U es el número de unidades en la capa Bi-LSTM.
- L es la longitud de la secuencia de entrada.

▪ **Complejidad del predictor poblacional**

$$\mathcal{O}(3) \approx \mathcal{O}(1)$$

Ecuación 3.6: Términos de complejidad del predictor poblacional

Nuevamente las capas se encuentran de forma secuencial, por lo que la complejidad total resulta:

$$\mathcal{O}(C(N \times K \times A) + B(U \times L) + 1)$$

Donde:

- C es el número de capas convolucionales 2D.
- B es el número de capas Bi-LSTM.

Sustituyendo con los parámetros específicos aportados del modelo dado:

$$\mathcal{O}(61(N \times K \times (18 \times 1000))) + B(1024 \times 30) + 1)$$

$$\mathcal{O}(1098000(N \times K) + B(30721))$$

Teniendo en cuenta que la red analiza registros completos de hasta 72 horas con 30 ejecuciones por hora, incluso considerando despreciable el coste de la capa Bi-LSTM de grano fino por solo considerar 6 de las 72 horas, y empleando ya los parámetros de tamaño de lote y número de épocas con los nombres de variable anteriormente empleados:

$$\mathcal{O}(L \times E \times 1098000 \times N \times K + 72 \times 30 \times 30721)$$

$$\mathcal{O}(1098000 \times L \times E \times N \times K + 66357360)$$

$$\approx \mathcal{O}(1 \times 10^6 \times L \times E \times N \times K + 6 \times 10^7)$$

Y dados los tamaños usuales de las épocas, lotes y número de filtros por capa:

$$\approx \mathcal{O}(L \times E \times N \times K \times 10^6) > 10^9$$

Complejidad del modelo con RNC 1D

- **Complejidad de la capa convolucional:**

$$\mathcal{O}(N \times V \times K \times D)$$

Ecuación 3.7: Términos de complejidad de la capa convolucional 1D

Donde:

- N es el número de núcleos.
- K es la longitud del núcleo.
- V es el la longitud del vector de entrada
- D es el coeficiente de reducción por desplazamiento del núcleo

- **Complejidad del mapeo de características:**

$$\mathcal{O}(n), n \text{ cte.}$$

Ecuación 3.8: Términos de complejidad del extractor de características

En este modelo las capas también se encuentran de forma secuencial, por lo que la complejidad de una iteración resulta:

$$\begin{aligned} & \mathcal{O}(3(2^5(2 + 2 \times (2 + 2 \times (2 + 2 \times (4)))) + 1024 + 512 + 256 + 128) + 2) \\ & \approx \mathcal{O}(3(1472 + 1024 + 512 + 256 + 128) + 2) = 10178 \approx 10^4 \text{ parámetros a entrenar por iteración} \end{aligned}$$

Ahora bien, si se tienen en cuenta los tamaños de lote y las épocas necesarias para entrenarlo:

$$\approx \mathcal{O}(L \times E \times 10178) \approx \mathcal{O}(E \times 2000 \times 10178) \approx E \times 20356000 \approx 10^7 \text{ parámetros a entrenar por época}$$

Capítulo 4

Resultados

En este capítulo se muestran y discuten los resultados obtenidos tras seguir los pasos descritos en la metodología.

4.1 Métricas

Una vez desarrollado el modelo expuesto en la metodología, se obtuvieron los siguientes resultados en el procedimiento de validación:

Valores promedio			
Validación	Exactitud	Precisión	Recuperación
Global	0,82 ±0,02	0,95 ±0,01	0,87 ±0,01
Paciente	0,95 ±0,01	-	-
Diag. Favorable	-	0,96 ±0,01	-
Diag. Desfavorable	-	-	0,98 ±0,01

Figura 4.1: Resultados del promedio calculado sobre las métricas relevantes a cada nivel.

Como se puede observar en la figura 4.1, los valores promedio oscilan en torno a un 1,11 % del total y tienen una alta precisión para los diagnósticos favorables, así como una alta recuperación para los desfavorables, significando esto que se ha minimizado, tal y como se había planteado, el número de pacientes que van a ser erróneamente etiquetados con un pronóstico desfavorable. Esto claramente indica que se ha optimizado el modelo para favorecer el punto de vista más humano, en el cual se valora más salvar una vida humana que un gasto extra en recursos.

Se puede comprobar también cómo la estrategia "divide y vencerás" ha mejorado los resultados del modelo, aumentando la exactitud final del modelo de 0,82 a 0,95 por el hecho de pasar a tener en cuenta el registro total del paciente y no sólo segmentos de este. Viéndose esto en la comparación entre la exactitud global (la clasificación de todas las etiquetas de registros) y la del paciente (etiqueta de paciente).

4.2 Complejidad computacional

La complejidad computacional es un parámetro relevante a la hora de considerar un modelo, y cómo se ha visto en el capítulo anterior, el modelo propuesto, aunque es más costoso que el basado en convolucionales 1D en cuanto a una iteración se refiere, resulta más rentable al final de entrenamiento, al requerir de menos iteraciones. Consiguiendo un coste computacional menor.

O(n)	N.º Parámetros por iteración	N.º Parámetros por época
Conv. 1D	$\approx 10^4$	$\approx 10^7$
Conv. 3D	$\approx 10^6$	$\approx 10^7$

Figura 4.2: Ordenes de magnitud de la cantidad de parámetros a entrenar.

4.3 Resultados del CinC

A continuación, se mostrarán los resultados presentados al reto, véase que si bien puede discernir correctamente entre las clases pertenecientes a un diagnóstico desfavorable, tiene dificultades para diferenciar entre las del diagnóstico favorable.

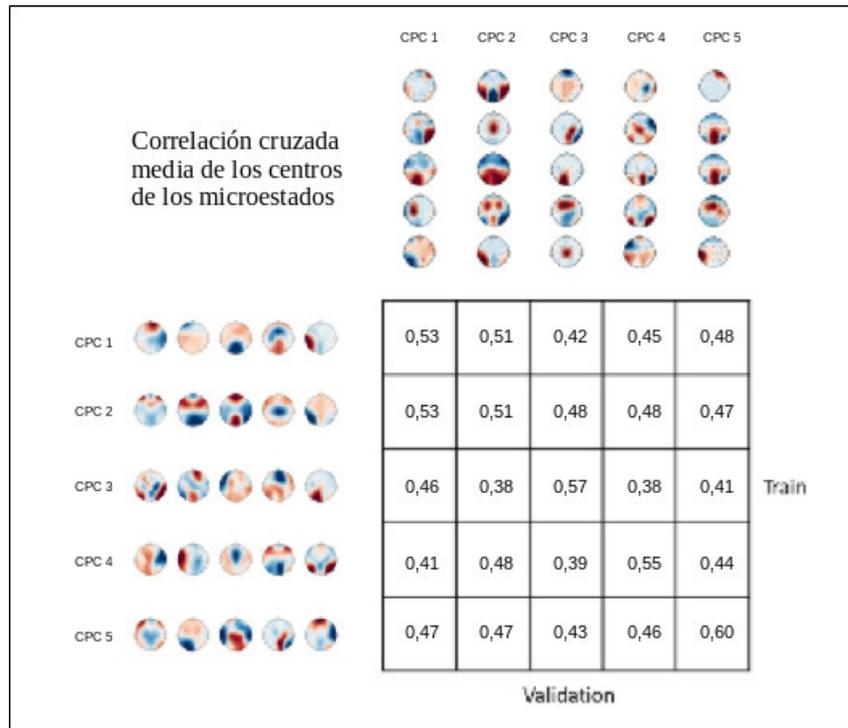


Figura 4.3: Resultados entregados en el reto.

Gracias a estos resultados mostrados en la siguiente página y la técnica propuesta descrita en el capítulo anterior, el grupo se clasificó para la participación en el congreso.

También se pudo realizar una comparación de la efectividad de clasificación entre la técnica establecida (dominio temporal) y la propuesta (dominio frecuencia), obteniéndose mejores valores en el dominio de frecuencia que el tiempo:

Segmentación con 5 microestados basados en el dominio del tiempo.

	cpc1	cpc2	cpc3	cpc4	cpc5
cpc1	0,78	0,74	0,51	0,68	0,55
cpc2	0,65	0,67	0,45	0,61	0,51
cpc3	0,66	0,68	0,48	0,56	0,46
cpc4	0,58	0,57	0,45	0,59	0,45
cpc5	0,34	0,34	0,4	0,37	0,43

Figura 4.4: Resultados de clasificación según correlación de microestados obtenidos del dominio temporal.

Segmentación con 5 microestados basados en el dominio del tiempo.

	CPC 1	CPC 2	CPC 3	CPC 4	CPC 5
CPC 1	0.78	0,74	0,51	0,68	0,55
CPC 2	0,65	0,67	0,45	0,61	0,51
CPC 3	0,66	0,68	0,48	0,56	0,46
CPC 4	0,58	0,57	0,45	0,59	0,45
CPC 5	0,34	0,34	0,4	0,37	0,43

Figura 4.5: Resultados de clasificación según correlación de microestados obtenidos del dominio frecuencial.

4.4 Explicabilidad

En lo referente a la explicabilidad, es de gran importancia si aspiramos a que el modelo pueda ser incorporado en el uso clínico.

El modelo presentado consta de un total de 96 núcleos encargados de extraer relaciones entre canales. Cada uno de esos núcleos presenta un conjunto de activación, y no siempre funcionan de forma aislada. La primera capa de redes neuronales tras la vectorización del tensor se encarga de establecer relaciones entre la activación de uno o varios núcleos, como se puede ver en la Figura 3.15 del capítulo anterior. A continuación se presenta el mapa de activación de uno de los canales tras la convolución, el cual representa que relaciones entre la señal original sus canales vecinos es relevante para la clasificación.

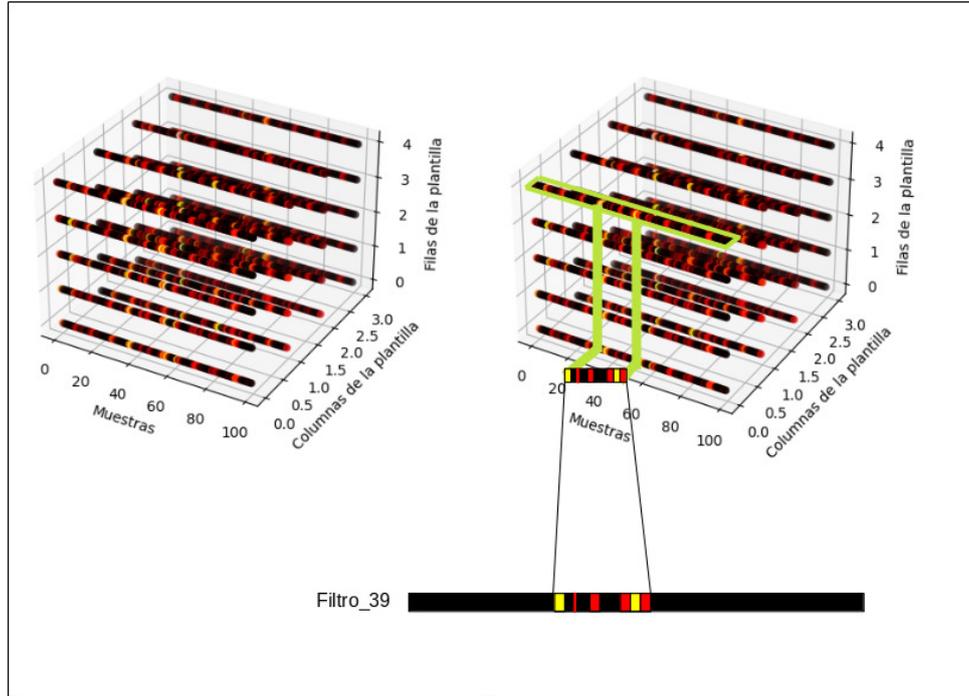


Figura 4.6: Proyección y extracción gráfica del vector de calor.

De todo el vector de activación del canal AF7 tras la convolución se ha decidido representar sólo el segmento con mayor magnitud de activación con el fin de simplificar su explicación. Este a continuación es comparado con las señales originales de sus canales vecinos a partir de los cuales se ha extraído la información de relación.

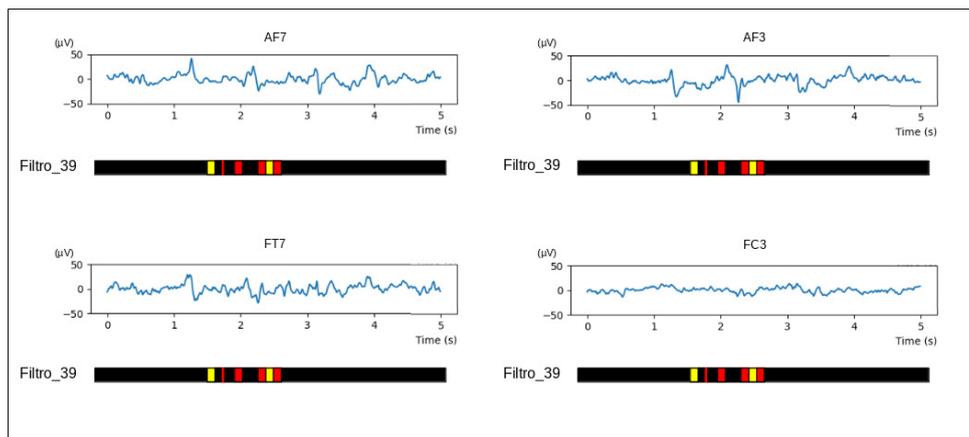


Figura 4.7: Evaluación de correspondencia sobre la señal.

Como se puede ver, al tratarse de información relacional, esta no es posible ser interpretada de forma individual señal a señal. Es por eso, que se propone su representación frente al conjunto de señales de origen, como se muestra a continuación:

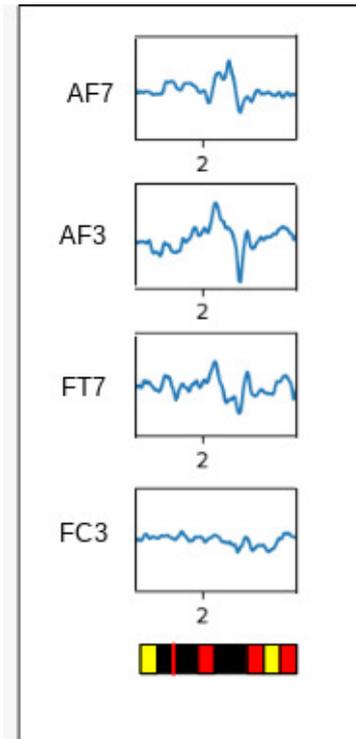


Figura 4.8: Segmento de las señales en las que se encuentra la activación.

Ahora si que se puede visualizar correctamente que las activaciones de mayor magnitud corresponden a instantes de tiempo en los que las cuatro señales se encuentran en un valor cercano a cero, y activaciones de menor magnitud que muestran correlación con instantes en los que tres de cuatro señales se encuentran distantes del cero, y una se encuentra cercana a este.

Conclusiones y Líneas de futuro

A continuación se presentan las conclusiones del trabajo realizado y las posibles vías de futuro que quedan abiertas tras éste.

5.1 Conclusiones

Se ha propuesto un modelo basado en redes neuronales convolucionales y densas capaz de discriminar entre pacientes en coma con un pronóstico favorable o desfavorable con una exactitud de 0,95 favoreciendo a la clase de pronóstico favorable, con una precisión de 0,96 sin descompensar la clase de pronóstico desfavorable, en la cual se obtiene una métrica de recuperación de 0,98 todo ello a partir de señales de EEG.

Mediante la explicabilidad se ha conseguido discernir qué relaciones entre canales producen la clasificación en el modelo. Si bien en un principio se pensaba que también podrían discernirse patrones morfológicos desde las señales de entrada, que pudiesen relacionarse con la clasificación, se ha visto que este modelo no puede proporcionar dicha información debido a su comportamiento. Sin embargo, sí que permite extraer un tipo de información poco explorado en este ámbito, la información relacional entre las señales de entrada.

Se ha conseguido igualar en orden de magnitud el coste de complejidad computacional del modelo al empleado en el menos costoso de los vistos en la literatura científica que empleasen RNC 1D, siendo éste de 10^7 parámetros a entrenar

Se trata de un sistema escalable, dado su bajo coste computacional y diseño paralelizable, algo de vital importancia dada la trayectoria que está llevando el conjunto de servicios informáticos en el entorno clínico y alineado con los objetivos de desarrollo sostenible.

Por último, como ya se ha mencionado anteriormente, el presente proyecto surge como respuesta a un reto planteado por "The George B. Moody PhysioNet Challenge" a la comunidad científica internacional.

Recientemente, se han publicado los resultados de la primera fase del reto, habiendo sido seleccionados para pasar a la siguiente fase. Adicionalmente, se nos ha remitido por correo electrónico el resultado de la revisión de nuestro trabajo, invitándonos a participar en el congreso de CinC

que se celebrará el próximo mes de octubre en Atlanta, Estados Unidos de América. Dónde se presentará el trabajo realizado para el reto, junto a los nuevos resultados que se espera obtener.

5.2 Futuras líneas de trabajo

De entre las futuras líneas de actuación que abre el trabajo actual, se pueden destacar dos vertientes:

Se busca continuar con el desarrollo del modelo, de forma que se pueda desplegar como componente de uno más complejo.

Dada la nueva base de datos aportada por el reto para la siguiente fase, se ha incrementado la cantidad de información disponible, tanto en tiempo de registro como en la variedad de estos, disponiendo ahora de otro tipo de registros de señal bioeléctrica. Facilitando esto la exploración de nuevas herramientas que puedan aportar un mayor rendimiento.

Así mismo, se pretende realizar un detallado estudio comparativo entre la técnica presentada y otras técnicas evaluadas con una exactitud similar.

Por otra parte, a partir del propio proyecto/reto se ha desarrollado una nueva técnica de procesamiento de señales EEG, cuyos buenos resultados alientan a seguir investigando en su desarrollo, de cara a optimizarla. Además, esta técnica aun en su versión inicial ya ha dado como fruto una publicación y se espera que tras su perfeccionamiento pueda generar nuevas publicaciones más allá del ámbito de estudio original.

Capítulo 6

Bibliografía

- [0] Huang, S., Tang, J., Dai, J., Wang, Y. (4 2019). Signal Status Recognition Based on 1DCNN and Its Feature Extraction Mechanism Analysis. *Sensors*, 19, 2018. doi:10.3390/s19092018
- [1] Khazanova, D., Douglas, V. C., Amorim, E. (6 2021). A matter of timing: EEG monitoring for neurological prognostication after cardiac arrest in the era of targeted temperature management. *Minerva Anestesiologica*, 87, 704–713. doi:10.23736/S0375-9393.21.14793-5
- [2] Khosla, A., Khandnor, P., Chand, T. (4 2020). A comparative analysis of signal processing and classification methods for different applications based on EEG signals. *Biocybernetics and Biomedical Engineering*, 40, 649–690. doi:10.1016/j.bbe.2020.02.002
- [3] Kingma, D. P. (2014, 22 diciembre). Adam: A Method for Stochastic Optimization. arXiv.org. <https://arxiv.org/abs/1412.6980>
- [4] Li, B., Cao, J. (2023). Classification of coma/brain-death EEG dataset based on one-dimensional convolutional neural network. *Cognitive Neurodynamics*. <https://doi.org/10.1007/s11571-023-09942-2>
- [5] Liu, T., Yang, D. (5 2021). A three-branch 3D convolutional neural network for EEG-based different hand movement stages classification. *Scientific Reports*, 11, 10758. doi:10.1038/s41598-021-89414-x
- [6] Mishra, A., Englitz, B., Cohen, M. X. (3 2020). EEG microstates as a continuous phenomenon. *NeuroImage*, 208, 116454. doi:10.1016/j.neuroimage.2019.116454
- [7] Pham, S. D. T., Keijzer, H. M., Ruijter, B. J., Seeber, A. A., Scholten, E., Drost, G., . . . Tjepkema-Cloostermans, M. C. (8 2022). Outcome Prediction of Postanoxic Coma: A Comparison of Automated Electroencephalography Analysis Methods. *Neurocritical Care*, 37, 248–258. doi:10.1007/s12028-022-01449-8
- [8] Sandroni, C., Cavallaro, F., Callaway, C. W., D’Arrigo, S., Sanna, T., Kuiper, M. A., . . . Nolan, J. P. (10 2013). Predictors of poor neurological outcome in adult comatose survivors of

cardiac arrest: A systematic review and meta-analysis. Part 2: Patients treated with therapeutic hypothermia. *Resuscitation*, 84, 1324–1338. doi:10.1016/j.resuscitation.2013.06.020

[9] Su, Y., Zhang, Z., Li, X., Zhang, B., Ma, H. (8 2022). The multiscale 3D convolutional network for emotion recognition based on electroencephalogram. *Frontiers in Neuroscience*, 16. doi:10.3389/fnins.2022.872311

[10] Tjepkema-Cloostermans, M. C., da Silva Lourenço, C., Ruijter, B. J., Tromp, S. C., Drost, G., Kornips, F. H. M., . . . van Putten, M. J. A. M. (10 2019). Outcome Prediction in Postanoxic Coma With Deep Learning*. *Critical Care Medicine*, Vol. 47, pp. 1424–1432. doi:10.1097/CCM.0000000000003854 CCC50068.2020.9189502

[11] Unesco. (1 2021). Recomendación sobre la ética de la inteligencia artificial. [https://Unesdoc.Unesco.Org/Ark:/48223/Pf0000381137_spa](https://unesdoc.unesco.org/ark:/48223/pf0000381137_spa), 40, 4606–4617. doi:10.1002/hbm.24724

[12] Xu, Z., Wang, J., Wang, R., Zhang, Z., Yang, S. (7 2020). Deep Convolutional Neural Network for Detection of Disorders of Consciousness. 7084–7089. doi:10.23919/

[13] Zhang, Y., Cai, H., Nie, L., Xu, P., Zhao, S., Guan, C. (12 2021). An end-to-end 3D convolutional neural network for decoding attentive mental state. *Neural Networks*, 144, 129–137. doi:10.1016/j.neunet.2021.08.019

[14] Zheng, W.-L., Amorim, E., Jing, J., Ge, W., Hong, S., Wu, O., . . . Westover, M. B. (12 2021). Predicting neurological outcome in comatose patients after cardiac arrest with multiscale deep neural networks. *Resuscitation*, 169, 86–94. doi:10.1016/j.resuscitation.2021.10.034

Parte II

Presupuesto

A continuación se procede al desglose de presupuestos necesarios para llevar a cabo este proyecto.

Código	Denominación de la mano de obra	Precio (€/h)	Horas (h)	Total (€)
MO.O1	Catedrático tutor	7,6	20	152
MO.O2	Becario	1,91	330	630
Total mano de obra				782

Figura 6.1

Código	Denominación de la maquinaria	Precio (€/h)	Horas (h)	Total (€)
MO.O1	HP Spectre x360 Convertible	0,09	330	29,7
Total maquinaria				29,7

Figura 6.2

Presupuesto parcial nº1 DESPLIEGUE DEL SERVIDOR					
N.º	Ud	Descripción	Medición (h)	Precio (€/h)	Importe (€)
01.01	H	Instalación del sistema operativo y drivers			
Total			6	7	42
01.02	H	Configuración y despliegue de funcionalidades			
Total			10	15	150
Total presupuesto parcial nº1 DESPLIEGUE DEL SERVIDOR					192

Figura 6.3

Presupuesto parcial nº2 DESARROLLO DE LA METODOLOGÍA					
N.º	Ud	Descripción	Medición (h)	Precio (€/h)	Importe (€)
02.01	H	Análisis y procesado de los datos			
Total			8	10	80
02.02	H	Desarrollo y obtención de resultados			
Total			200	12	2400
Total presupuesto parcial nº2 DESARROLLO DE LA METODOLOGÍA					2480

Figura 6.4

Presupuesto parcial nº3 REDACCIÓN DE MEMORIA					
03.01	H	Redacción de la memoria del trabajo			
Total			84	10	840
Total presupuesto parcial nº3 REDACCIÓN DE MEMORIA					840

Figura 6.5

Presupuesto parcial n.º4 AYUDA PRESTADA EN LABORATORIO					
04.01	H	Atención técnica a colaboradores			
Total			2	20	40
Total presupuesto parcial nº4 AYUDA PRESTADA EN LABORATORIO					40

Figura 6.6

Capítulo	Importe (€)
DESPLIEGUE DEL SERVIDOR	192
DESARROLLO DE LA METODOLOGÍA	2480
REDACCIÓN DE MEMORIA	840
AYUDA PRESTADA EN LABORATORIO	40
Presupuesto de ejecución material	3552
13 % gastos generales	461,76
6% beneficio industrial	213,12
Suma	4226,88
21% IVA	887,6448
Presupuesto de ejecución por contrata	5114,5248

Figura 6.7