

# Análisis de ondas cerebrales mediante inteligencia artificial para la clusterización de respuestas

Pablo Mena Gómez de Merodio

Autor

David Contreras Bárcena

Director

**Abstract**— En la actualidad, existe un gran número de estudios relacionados con la interpretación de las ondas cerebrales mediante técnicas de Deep Learning. La gran mayoría de estos trabajos están centrados en desarrollar prototipo de BCI (Brain-Computer Interface) cuya finalidad es desarrollar un sistema de comunicación entre los usuarios y las máquinas a través de los impulsos cerebrales generados de forma voluntaria por los individuos. Sin embargo, el campo del análisis de las respuestas involuntarias del cerebro se encuentra considerablemente menos explotado. En este estudio se espera profundizar en este campo, en concreto en los impulsos relacionados con la identificación de localizaciones. Para obtener los datos de los EEG (Electroencefalograma) se contó con la ayuda de la profesora Lucia Halty Barrutieta, quien realizó un experimento en el cual se les mostró a un grupo de individuos tres imágenes de forma individual. La primera imagen presentaba una localización conocida para todos los individuos, la segunda una ubicación desconocida y la tercera solo fue reconocida por un pequeño porcentaje del grupo de estudio. El objetivo final del proyecto consiste en ser capaz de discernir cuáles de los participantes del experimento reconocieron la última imagen. Con esta idea en mente, se aplicaron técnicas especializadas de Data Augmentation y distintos algoritmos de clasificación para profundizar en el conocimiento del campo. Finalmente, se optó por realizar una conversión de los datos a imágenes para entrenar una red convolucional (CNN) la cual ha generado unos resultados en el conjunto de test del 80% a la hora de identificar si un individuo reconoce una imagen.

**Keywords** — EEG, Data Augmentation, CNN, LDA, BCI, Clusterización

## I. INTRODUCCIÓN

En 1924 el neurólogo alemán Hans Berger inventó el electroencefalograma [1] y demostró la existencia de corrientes eléctricas en el cerebro humano. Desde entonces han surgido multitud de estudios basados en su trabajo y con la explosión de las tecnologías Big Data que se ha visto en la última década, han surgido un gran número de trabajos que utilizan esta herramienta para realizar avances tanto dentro del mundo de la medicina como fuera del mismo

El primer proyecto de BCI (Brain-Computer Interface) fue desarrollado en 1970 por la Universidad de California y desde entonces este campo de investigación ha tenido como objetivo final desarrollar un sistema de comunicación hombre maquina completamente libre de manipulaciones físicas, interpretando los pensamientos del individuo para lograr la respuesta deseada.

Desgraciadamente, este hito aún se encuentra muy lejos de ser una realidad, debido principalmente a la complejidad

intrínseca de obtener datos, la dificultad para generalizar resultados entre distintos individuos y, sobre todo, al desconocimiento que todavía existe sobre el funcionamiento de la mente humana.

Actualmente estas tecnologías se encuentran en auge y se van realizando avances en este campo de la ciencia, como por ejemplo los estudios realizados por la universidad de Chegdu en China en los cuales han sido capaces de identificar signos tempranos de epilepsia a través del estudio de las ondas EEG [2]. Otro caso en el que se ha llevado a cabo la implementación de esta tecnología es la creación de prótesis inteligentes capaces de moverse según lo deseen los usuarios. En este campo se encuentra el proyecto DeTOP, financiado con fondos europeos, que ha logrado controlar prótesis robóticas mediante sensores invasivos conectados directamente a los nervios de los usuarios. Todos estos avances y la continua investigación que se realiza sobre este campo harán que pronto elementos diseñados a partir de estos principios formen parte de nuestra vida.

El potencial de las tecnologías BCI es enorme, pero como ya se ha mencionado, el camino que queda por recorrer es todavía muy extenso. Debido a esto, todos los descubrimientos que sean identificados, por pequeños que sean, pueden ser de utilidad para trabajos futuros. En este sentido se puede contemplar el trabajo del profesor Patrick Suppes de la universidad de Stanford y su aplicación en este proyecto. En 1998 el profesor Suppes presentó su artículo *Brain wave recognition of words* [3], en el cual esperaba ser capaz de clasificar ondas cerebrales en función de las palabras que se les presentaban a los sujetos. Su proyecto guarda grandes similitudes con el tratado en este artículo, pero, por desgracia, el profesor Suppes alcanzó resultados muy poco generalizables entre distintos individuos. Aun así, sus conclusiones y métodos han sido de gran ayuda en este estudio, ya que se puede considerar que, en este proyecto, el análisis de los datos es tan relevante como los propios resultados.

Este trabajo surge a partir de un experimento psicológico en el cual se enfrenta a una serie de sujetos a distintas fotografías que representan entornos conocidos y desconocidos para ellos mientras se registraba su respuesta cerebral. En primer lugar, se les mostraba a los individuos un entorno conocido para ellos como puede ser su propia habitación. A continuación, se les mostraba una imagen de un descampado en el que ninguno de los participantes había estado y finalmente, una imagen con una ubicación que tan solo un pequeño porcentaje de ellos reconocía.

El propósito final del experimento consistía en desarrollar una herramienta de ayuda para las fuerzas del orden que les

permitiese detectar si un sospechoso reconocía la escena del crimen. Partiendo de esta información, se ha tratado de identificar patrones en las ondas cerebrales para determinar si el lugar resulta conocido o no para los sujetos del experimento, o lo que es lo mismo, identificar cuáles de los participantes reconocieron la última imagen.

Uno de los grandes problemas que presenta el trabajo en este campo es el formato de los datos. Este estudio se inicia con una serie de ficheros de extensión CSV que contenían las respuestas cerebrales obtenidas de cada una de las imágenes. En cada uno de estos archivos se podía encontrar información de 64 sensores captados a una frecuencia de 1000 Hz durante 300 ms. Esto significa que por cada individuo se contaba con 3 *dataframes* distintos, lo que complica considerablemente tanto la comparación de los datos como la aplicación de algoritmos de clasificación.

Otro obstáculo al que se tuvo que hacer frente fue a la limitada cantidad de información inicial. Los dispositivos de medición de electroencefalogramas requieren de una calibración delicada y muy sensible, por lo que recopilar datos es una tarea lenta y laboriosa. Debido a ello, únicamente se dispuso de la información de 18 sujetos de experimentación. Por otra parte, hay estudios que demuestran que los experimentos de larga duración de ondas cerebrales tienden a reducir la calidad de los datos [4].

Desde cualquier punto de vista, esta cantidad de recursos es insuficiente para cualquier proyecto Big Data, por lo que fue necesario implementar técnicas de Data Augmentation para incrementar el volumen de los datos sin afectar a la calidad de estos.

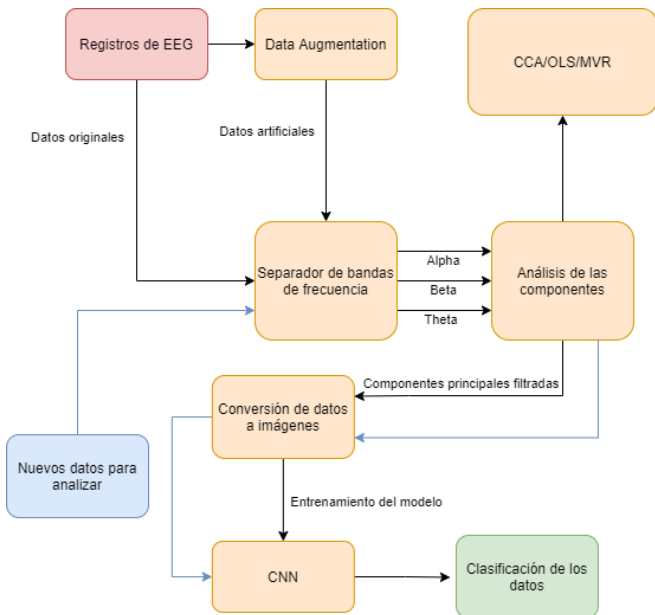


Figura 1. Esquema del sistema IoT desarrollado

Teniendo en cuenta todos los factores presentados en los párrafos anteriores, el objetivo del proyecto consiste en profundizar en el estudio del campo de las tecnologías BCI, así como desarrollar un modelo de Deep Learning capaz de clasificar si un individuo ha reconocido la localización presentada en cada imagen. Con esta idea en mente se han desarrollado un conjunto de módulos conectados entre sí que

se retroalimentan generando valor. La arquitectura de dicho sistema se puede ver en la Figura 1.

### A. Sistema de medición

El dispositivo utilizado para medir las respuestas cerebrales frente a los distintos estímulos es similar a un casco con distintos electrodos. Cada uno de estos sensores recopila información relativa a un tipo de onda y, por tanto, tanto la distribución de los sensores, como las distintas señales están relacionadas entre sí. En la Figura 2 se puede ver un esquema de la disposición de los electrodos sobre la cabeza de un sujeto.




Figura 2. Diagrama de la disposición de los sensores

### B. Datos iniciales

El formato de los datos en un proyecto Big data siempre resulta muy importante. La disposición de la información puede facilitar o dificultar en gran medida el análisis, siendo un factor determinante. La complejidad del estudio puede aumentar considerablemente si los datos no se encuentran correctamente almacenados y este estudio es un claro ejemplo de esta situación.

Una característica que facilita la tarea es poder disponer de todos los datos a través de una única fuente. Sin embargo, como se ha comentado anteriormente, en este caso se disponía de una base de datos tridimensional por cada individuo. Estas bases de datos contenían, respectivamente, la siguiente información:

1. Tiempo
2. Tipo de onda
3. Fase del experimento

Debido a esta estructura los enfoques tradicionales no resultan efectivos, ya que no se puede considerar un único set de datos sin el resto del conjunto y no se puede unificar la información en un único dataframe mediante técnicas de one-hot encoding ya que implicaría un incremento en la dimensionalidad de los datos que resultaría contraproducente a largo plazo.

Otro aspecto importante sobre las ondas EEG que debe ser mencionado es su clasificación. En función de las bandas de frecuencia en las que se muevan las señales son clasificadas de la siguiente forma:

1. Delta [1-3 Hz]
2. Theta [4-7 Hz]

3. Alpha [8-12 Hz]
4. Beta [12-24 Hz]
5. Gamma [24-100 Hz]

Diversos estudios neurológicos y psicológicos coinciden en que las bandas de frecuencias relacionadas con las respuestas involuntarias son las Theta, Alpha y Beta, por lo que el estudio se ha centrado en gran medida en este tipo de ondas.

## II. PREPROCESADO DE LOS DATOS

### A. Visualización de la señal

El primer paso durante el procesado de los datos consistió en visualizar la información con el fin de detectar información relevante a simple vista. En la Figura 3 se puede apreciar la complejidad de las ondas EEG, pero también se ve claramente que existe un margen de tiempo previo a la reacción del cerebro. Este hecho concuerda con la investigación del MIT que afirma que un ser humano medio es capaz de procesar una imagen en 13 ms [5], pero se requiere un tiempo adicional para que la imagen llegue al cerebro.

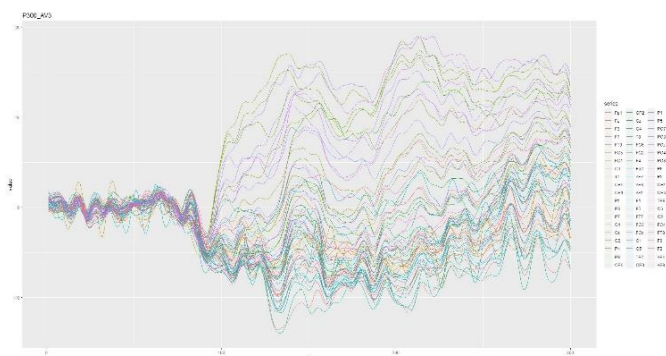


Figura 3. Ejemplo de EEG

A raíz de este hecho se puede asumir que la primera parte de la señal debe ser eliminada y filtrada, ya que no aporta información relevante y puede generar fallos en futuros modelos.

### B. Detección de patrones

El siguiente paso lógico consiste en analizar las señales y estudiar similitudes y diferencias en su comportamiento en función de los sujetos.

Una primera aproximación consistió en extraer las matrices de correlación y estudiar si existían semejanzas en el comportamiento de las ondas, lo que permitiría tratar al conjunto de los datos de forma similar. Este estudio preliminar concluyó que la relación entre las ondas no varía entre una fase del experimento y otra. Sin embargo, sí existen claras diferencias entre los sujetos.

Esto quiere decir que la forma en la que se relacionan las ondas cerebrales de un sujeto A es independiente de la imagen que se le esté mostrando, pero sí difieren de las ondas de un sujeto B. A pesar de estas diferencias, se detectaron patrones similares entre los distintos individuos, de donde se puede deducir que el comportamiento de las ondas cerebrales puede ser clasificado en subgrupos en función de cada persona. En la muestra inicial se detectaron 4 grupos claramente

diferenciados. Los patrones seguidos se pueden observar en la Figura 4.




Figura 4. Patrones detectados

Estas clasificaciones fueron clave para el proceso de Data Augmentation y para el entrenamiento del modelo debido a que las técnicas aplicadas previamente de forma conjunta sobre el total de los datos generaban resultados confusos, pero al aplicar las distinciones halladas en este apartado las conclusiones fueron considerablemente más determinantes.

Dado que, como ya se ha mencionado, no todas las bandas de frecuencia son igual de relevantes, en este apartado también se llevó a cabo el filtrado en frecuencia que dejó como resultantes las ondas Theta, Alpha y Beta.

### C. Reducción de la dimensionalidad

Por otro lado, en la mayoría de los proyectos BCI se suele tomar mediciones usando entre 20 y 30 sensores. En este proyecto en cambio, se usaron la totalidad de los electrodos, 64, por lo que el número de variables es considerablemente más elevado.

Este enfoque se debió a que, a diferencia de otros proyectos, este subcampo de estudio dentro del BCI es todavía relativamente desconocido. Por ello, no se dispone de información sobre qué sensores aportan información más valiosa y por tanto se ha decidido no obviar ningún sensor sin más.

Sin embargo, de cara al tratamiento de la información, la dimensionalidad del conjunto es excesiva y por ello se debe reducir el número de variables. Para ello, se aplicó la técnica del PCA (Principal Component Analysis) sobre el conjunto de datos.

PCA se utiliza para describir un conjunto de datos en términos de nuevas componentes no correlacionadas entre sí. Dichas componentes se ordenan por la cantidad de varianza original que describen, por lo que la técnica es útil para llevar a cabo el objetivo propuesto: reducir la dimensionalidad de un conjunto de datos. Durante el estudio inicial se realizaron pruebas que demostraron que un porcentaje muy elevado del conjunto se podría representar utilizando únicamente 2 componentes, como se puede ver en la siguiente imagen.




Figura 5. Ejemplo del PCA obtenido

No obstante, dichas componentes no son constantes a lo largo de las distintas fases del experimento y además varían en función del sujeto, por lo que esta reducción en el número de variables no se puede realizar de forma tan drástica. Esta conclusión se ve apoyada por un gran número de estudios dentro del campo del BCI. En [6], [7], [8] se hace hincapié en esta realidad del sector, según la cual, al menos actualmente, no es viable obtener resultados o procedimientos generalizables a toda la población.

En cualquier caso, el análisis sirvió para detectar aquellas componentes que no aportaban información en ninguno de los casos de manera significativa. De esta forma se procedió a considerar inservibles dichas señales y eliminarlas del conjunto de datos a estudiar.

Como resultado de este análisis, el número de variables se redujo en un 20%, lo cual, a pesar de no suponer una reducción significativa, facilita en cierta medida los futuros procesamientos.

### III. DATA AUGMENTATION

Es una convención en el mundo de los proyectos de Deep Learning relacionados con los EEG que el número de ejemplos para el conjunto de entrenamiento sea, como mínimo, cinco veces superior al resultado del producto del número de sensores por la frecuencia. En este proyecto los datos engloban 54 registros, obtenidos a partir de los 18 sujetos que participaron en el experimento. Estos sujetos estaban expuestos a 64 sensores que tomaban datos a una frecuencia de 1 KHz, lo que significa que se debería contar con un total de 4 320 000 datos únicamente para el entrenamiento del modelo.

Tras la reducción de la dimensionalidad explicada en el apartado anterior, la cantidad de sensores empleados disminuye, pero el número total de datos necesario sigue siendo superior a los que se poseen. Por ello es necesario generar datos artificiales que sirvan de apoyo.

Las técnicas de Data Augmentation suelen emplearse en imágenes o señales de audio. En este caso se pretende aplicar las técnicas sobre ondas cerebrales, que por su naturaleza son mucho más sensibles y que, por tanto, requieren de un tratamiento especializado.

Para garantizar que la generación de nuevos datos se realiza de manera correcta, se ha emulado el trabajo de Wonseok Yang de la universidad de Chung-Ang en el cual genera señales EEG artificiales basándose en la similitud entre

matrices de covarianza [4]. El flujo de trabajo se puede apreciar en la Figura 6.

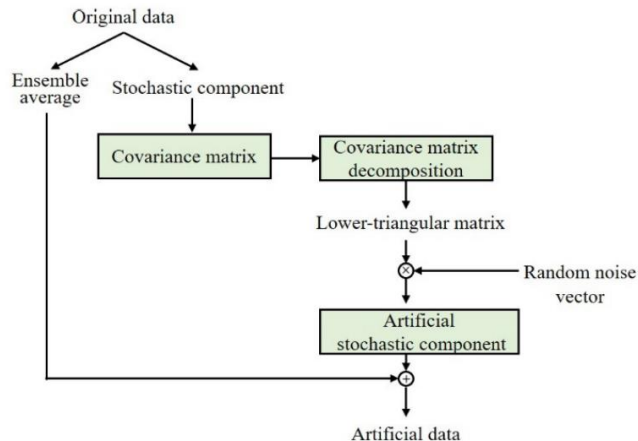


Figura 6. Diagrama de los pasos seguido para el Data Augmentation

#### A. FFT

El primer paso consiste en obtener la respuesta en frecuencia de la señal. Esto se debe principalmente a que las señales generadas son similares a las originales, pero con una ligera distorsión. Si se aplicase el proceso sobre la componente temporal, estas variaciones introducidas se eliminarían a la hora de realizar el filtrado en frecuencia necesario para obtener las señales Theta, Alpha y Beta.

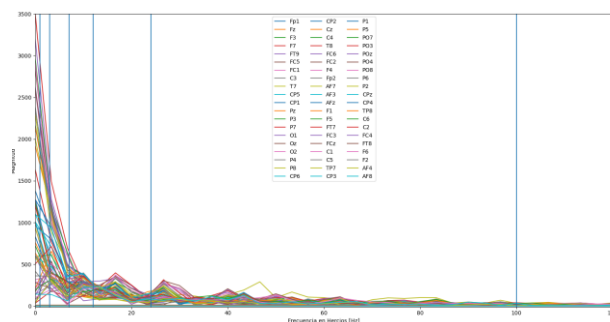


Figura 7. Espectro en frecuencia y bandas de frecuencia

Para obtener la señal en frecuencia se ha utilizado la FFT, es decir, la transformada rápida de Fourier (“Fast Fourier Transform”), Este algoritmo calcula la Transformada Discreta de Fourier (Discrete Fourier Transform – DFT) o su inversa. (IDFT). El problema fundamental a la hora de aplicar la DFT reside, en su complejidad, lo que se traduce en un gran tiempo de computación. Para solucionar este problema surge la FFT, que factoriza la matriz de la DFT convirtiéndola en una matriz de dispersión. De esta forma los resultados son, en muchos casos, más eficientes que realizando el propio procedimiento de DFT.

#### B. Selección de las frecuencias

En su estudio [4], los profesores Wonseok y Wochul indican la importancia de eliminar aquellas componentes que no aportan información concluyente al estudio, es por ello, que una vez se ha completado la conversión a frecuencia, el artículo dividen las señales en tres rangos: frecuencias bajas (0-8 Hz.), frecuencias intermedias (8-30 Hz.) y frecuencias elevadas (30-50 Hz.). A pesar de usar otros nombres, dichas bandas de frecuencia son similares a las de las ondas Theta,



Alpha y Beta, lo cual es positivo, ya que, como se mencionó en anteriormente, estas son las señales que se consideraron que podían ser más útiles.

### C. Síntesis de los datos

Como ya se mencionó en secciones anteriores, en este apartado se aplicaron inicialmente las técnicas sobre todo el conjunto de los datos. Sin embargo, al comparar los datos originales con los artificiales las diferencias resultaban drásticas. Es por ello por lo que se optó por seguir la aproximación descrita en la sección II: aplicar las técnicas de manera conjunta a los datos que perteneciesen a un mismo grupo independientemente de los demás. Los pasos explicados en esta sección fueron, por tanto, repetidos para los 4 casos identificados.

En primer lugar, se calculó la media del dataset para cada muestra y se descompusieron los datos según la siguiente ecuación, donde  $u$  es la media y  $v$  la diferencia con respecto a los valores originales, o lo que es lo mismo, la componente estocástica.

De esta forma, el dato  $y^{(i)}$  se encuentra compuesto por la suma de la media  $u$ , común a todos los datos y la componente estocástica  $v^{(i)}$ , característica de cada uno de los datos del conjunto.

$$y^{(i)} = u + v^{(i)}$$

Al recopilar todos los valores de  $v$  del dataset, se obtuvo un nuevo conjunto de datos cuya matriz de covarianza debe mantenerse constante a pesar de los cambios que se apliquen sobre el conjunto.

En el dataset artificial los datos se pueden representar de forma parecida a la original,

$$y_c^{(i)} = u + v_c^{(i)}$$

donde  $u$  continúa representando la componente media en su valor original y  $v_c^{(i)}$  es la componente estocástica generada de manera artificial.

El cálculo de esta componente estocástica se obtiene siguiendo la siguiente ecuación:

$$v_c^{(i)} = L * z^{(i)}$$

Donde  $z$  es el vector de ruido aleatorio, que deberá ser diferente para cada una de las componentes y  $L$  es una matriz triangular inferior que se obtiene a partir de la covarianza de los elementos del dataset original. Los valores de esta matriz  $L$  se calculan de forma diferente aplicando las siguientes ecuaciones, donde  $l_{qq}$  son los componentes de la diagonal principal y  $l_{pq}$  los elementos externos a la diagonal.

$$l_{qq} = \pm \sqrt{c_{qq} - \sum_{m=1}^{q-1} l_{qm}^2}$$

$$l_{pq} = \frac{1}{l_{qq}} (c_{pq} - \sum_{m=1}^{q-1} l_{pm} l_{qm})$$

Los elementos  $c_{qq}$  y  $c_{pq}$  son, respectivamente, los elementos de la diagonal, y de fuera de la diagonal de la matriz covarianza obtenida a partir del conjunto de datos originales ( $\Sigma$ ). Con esta ecuación se completaría el proceso total de cálculo del dataset aumentado. Los resultados obtenidos se pueden ver en la Figura 8 y la Figura 9.




Figura 8. Ejemplo de señales originales en la banda Theta




Figura 9. Ejemplo de resultado del Data Augmentation en la banda de frecuencias Theta

Como se puede ver, los datos artificiales y los originales son muy similares tanto en forma como en magnitud y la matriz de covarianza es similar, por lo que se puede concluir que las modificaciones no han alterado el valor intrínseco de los datos.

## IV. APLICACIÓN DE ALGORITMOS

La estructuración de los datos dificulta enormemente la manipulación de los registros, por lo que las técnicas aplicadas deben enfocarse en la comparativa de dataframes y en la detección de patrones entre ellos. Además, al dividir las señales originales en tres bandas de frecuencia, los experimentos deben repetirse para cada tipo de onda.

Con esta idea en mente se implementaron distintas técnicas (OLS, Multivariate Regression, CCA, RDA), pero los resultados obtenidos no resultaron excesivamente satisfactorios. Es por ello, que se ha optado por mostrar únicamente aquellos enfoques que han generado conclusiones dignas de mención o resultados apropiados.

### A. CCA

Canonical Correlation Analysis o CCA, es una técnica estadística aplicada para extraer la relación entre dos pares de variables y es, probablemente, una de las técnicas más aplicadas en el campo del análisis de datos funcionales. Además, los fundamentos estadísticos y los subprocesos necesarios para su desarrollo son similares a los

implementados en otras técnicas más orientadas a modelos como FRA [9].

Cuando se está trabajando con un conjunto de datos, la variación de los parámetros se suele expresar a través de la variación de covarianza o de la matriz de correlación. No obstante, si se desea comparar varios sets de datos distintos, la situación varía ligeramente y es necesario profundizar en el comportamiento y en la relación de variabilidad entre cada parámetro. CCA permite estudiar la relación entre dos conjuntos diferenciados y comparar los resultados utilizando una misma base.

La lógica subyacente se basa en encontrar una combinación lineal de variables de forma que la correlación entre los dos subconjuntos de datos sea máxima. Suponiendo dos subconjuntos X e Y con n y m variables, las ecuaciones canónicas serían las siguientes:

$$U_i = a_1 Y_1 + a_2 Y_2 + \dots + a_m Y_m$$

$$V_i = b_1 X_1 + b_2 X_2 + \dots + b_n X_n$$

A continuación, se realiza la derivada sobre el par U,V y se calcula la correlación entre ambas, obteniendo finalmente los pesos deseados.

En el caso de uso de este proyecto no es coherente realizar comparativas sobre todos los conjuntos de datos entre sí. Sin embargo, esta técnica permite probar una hipótesis. En un principio, la relación entre las señales obtenidas al presentar la primera imagen y la segunda deberían caracterizar la relación entre un evento conocido y desconocido, por lo que, al realizar combinaciones entre los 3 datasets de cada uno de los sujetos del experimento, es posible identificar patrones que permitan la clasificación de los datos.

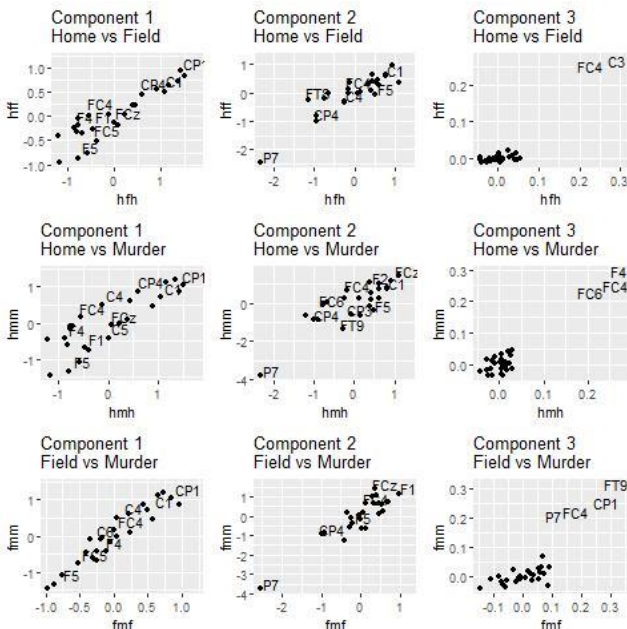


Figura 10. Ejemplo de CCA sobre ondas Theta

Al igual que en PCA, cuanto mayor sea el número de componentes a utilizar mayor será el porcentaje de variabilidad que explica la nueva base. Durante el análisis preliminar se comprobó que con 2 componentes principales se podía explicar prácticamente todo el conjunto.

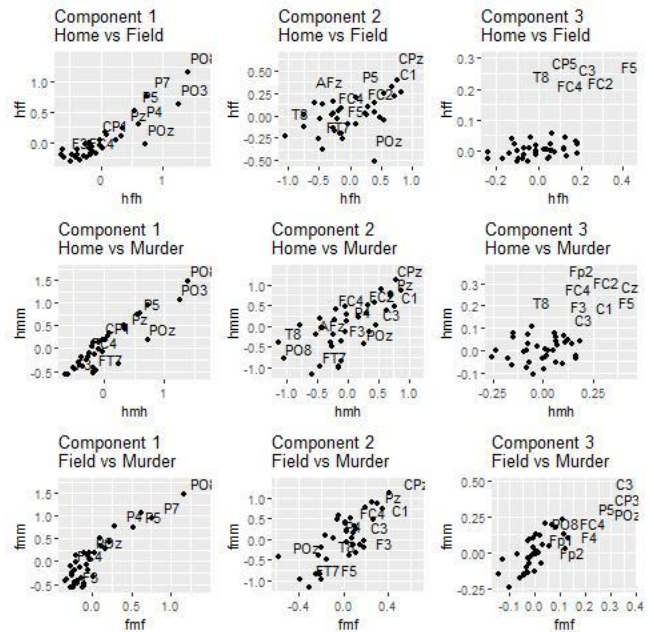


Figura 11. Ejemplo de CCA sobre ondas Alpha

Sin embargo, al realizar pruebas posteriores se comprobó que la representación utilizando únicamente una componente era excesivamente lineal y, por tanto, resultaba complejo poder extraer conclusiones al respecto. Debido a ello, se optó por aumentar el número de componentes a 3 y analizar los resultados.




Figura 12. Ejemplo de CCA sobre ondas Theta

Tras aplicar el algoritmo, se obtuvieron los *scores* de cada componente y se procedió a su representación gráfica que se puede ver en las imágenes anteriores (Figura 10, Figura 11, Figura 12). Con el fin de representar la mayor cantidad de información posible de la forma más eficiente, se optó por un enfoque matricial en el que las columnas representan las componentes y cada fila hace referencia a una combinación de datos.

La primera fila se corresponde con la primera y la segunda imagen (conocido-desconocido), la segunda fila con la primera y la tercera fotografía (conocido-incógnita) y la última con la segunda y la tercera imagen (desconocido-incógnita).

A simple vista se pueden identificar ciertos aspectos llamativos. En primer lugar, la linealidad de los datos parece encontrarse directamente relacionada con la frecuencia e inversamente relacionada con el número de componente. Estas dos conclusiones pueden considerarse ciertas, ya que son coherentes con la investigación inicial.

En las bandas de frecuencia más bajas, las señales eran sencillas, pero contenían mayor variedad, mientras que las frecuencias altas incluían señales senoidales muy similares. En cuanto a la relación con el número de componentes, también es lógico asumir que la relación es sólida. Las primeras componentes explican un porcentaje muy elevado de la variabilidad, por lo que según vaya aumentando el número de componentes utilizadas, las nuevas bases buscarán cubrir valores específicos que se diferencian entre un caso y otro.

Las ondas Theta parecen seguir un comportamiento similar en todas las combinaciones. La primera componente sigue una distribución lineal donde los sensores frontales cuentan con los valores más elevados y los sensores centrales los más bajos. En la segunda componente hay una agrupación clara de los sensores en la esquina superior derecha, con la excepción del electrodo P7, que se encuentra en la esquina opuesta. Finalmente, la tercera componente presenta dos agrupaciones en esquinas opuestas, de forma similar a lo que ocurría en la segunda componente. Sin embargo, en esta ocasión el grupo mayoritario ocupa los valores inferiores y en la tercera fila la dispersión aumenta considerablemente.

Las bandas Alpha y Beta no presentan rasgos claramente distintivos, por lo que, a primera vista, no es posible identificar patrones que faciliten la clasificación.

Dado que los resultados obtenidos no resultaron concluyentes, se optó por implementar el algoritmo de *k-means* sobre los puntos representados.

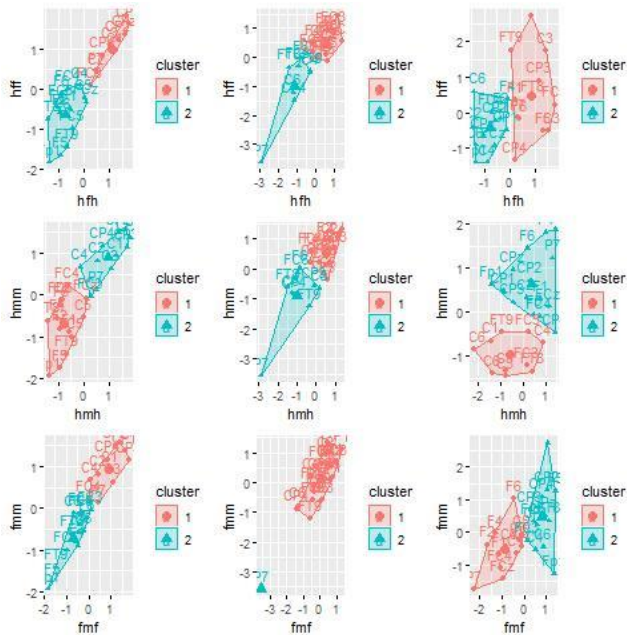


Figura 13. K-means sobre CCA de ondas Theta

*K-means* es una técnica de clusterización no supervisada en la que los individuos son clasificados en función de su proximidad al valor medio de los *clústers*. De esta forma se puede encontrar similitudes entre datos.

En este caso concreto se espera que las señales que se agrupan juntas en la primera o la segunda fase del experimento vuelvan a agruparse de forma similar en la tercera. Es necesario mencionar que los patrones o la información obtenida de un sujeto no puede ser aplicado al resto de casos debido a que las bases utilizadas son distintas.

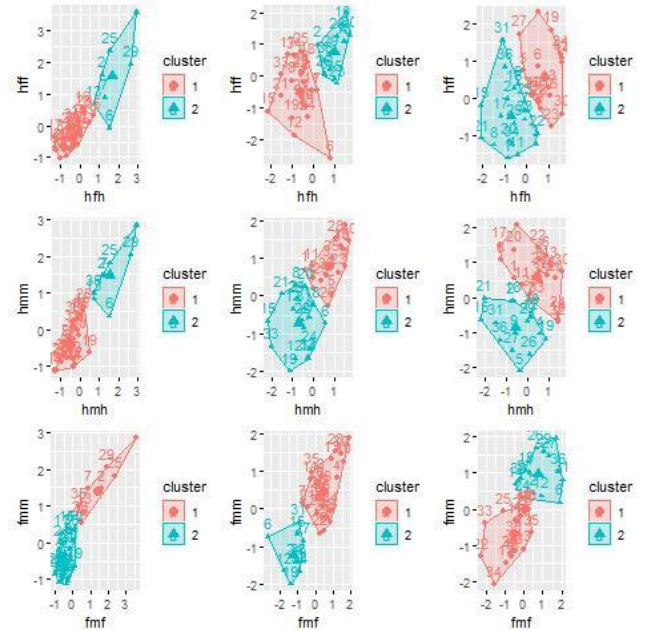


Figura 14. K-means sobre CCA de ondas Alpha

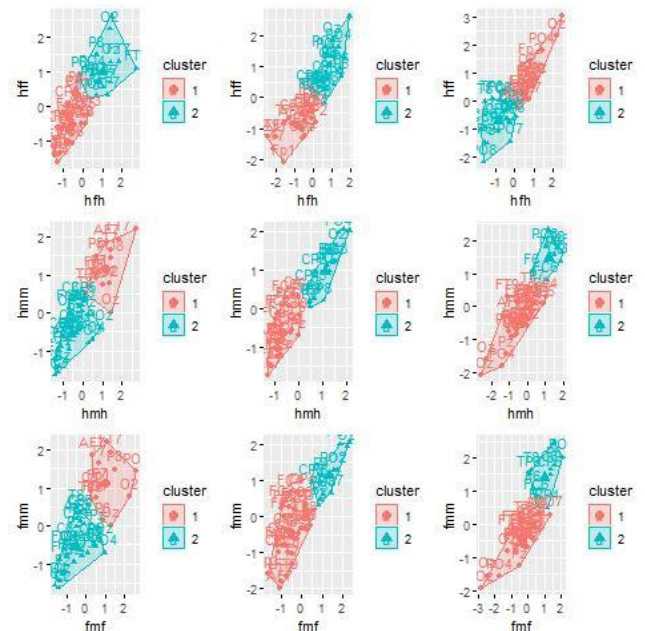


Figura 15. K-means sobre CCA de ondas Beta

Al no poder extrapolar la información entre individuos el potencial de este enfoque se ve muy limitado. Además, en la mayoría de los casos no se obtuvieron los resultados esperados al no repetirse las agrupaciones en las distintas combinaciones.



A pesar de todo, si se obtuviesen más datos referentes a un único sujeto, se podrían extraer conclusiones más sólidas a través de esta misma técnica, por lo que se trata de un enfoque con proyección de futuro.

### B. CNN

Como ya se ha mencionado en reiteradas ocasiones, uno de los principales problemas del proyecto reside en el manejo de los datos. La arquitectura de los datos obliga a tratar cada dataset en su conjunto, es decir, las conclusiones surgen a raíz de la relación de todas las señales entre sí y, por tanto, deben analizarse en su conjunto.

Durante la fase de experimentación se descubrió que dicho problema podría verse solucionado al representar los dataframes como imágenes en lugar de como conjuntos de datos puros.

El concepto es bastante sencillo, al disponer de tres bandas de frecuencia se puede considerar cada una de ellas como una banda de un canal RGB y plasmar los resultados sobre el esquema de la distribución de los electrodos, similar al representado en la Figura 2. De esta forma se pueden tratar los datos de forma conjunta y a la vez tener en cuenta la cercanía entre los electrodos, factor que no se había podido tratar con los enfoques previos.

El único aspecto que queda por tratar es que esta aproximación es válida para un único instante, por lo que se obtendrían 300 imágenes por cada dataset y muchas de estas imágenes resultarían muy similares. Para solventar este problema cada onda fue dividida en grupos de frames de la misma duración y se calculó la media de cada grupo, obteniendo así una versión reducida y simplificada de los datos originales.

Considerando los recursos disponibles y la necesidad de generar tantas imágenes como fuese posible sin correr el riesgo de crear registros repetidos, se decidió que la duración adecuada de cada frame debía ser de 10 milisegundos. El proceso en su conjunto se puede ver en Figura 16.

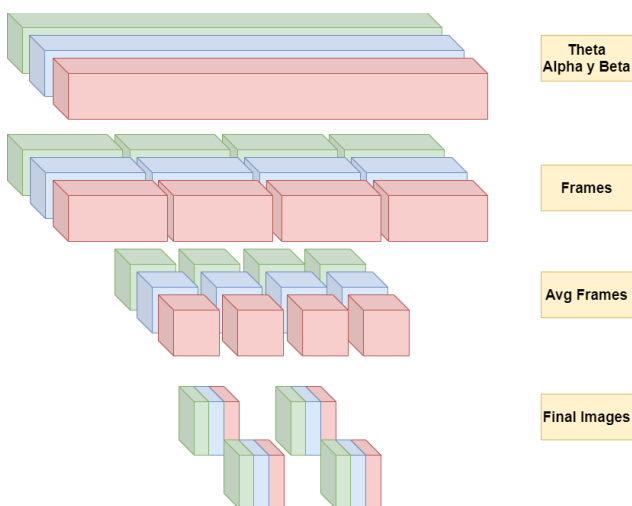


Figura 16. Esquema de la generación de imágenes

El resultado de dicho proceso son imágenes similares a las presentadas a continuación, en la Figura 17.

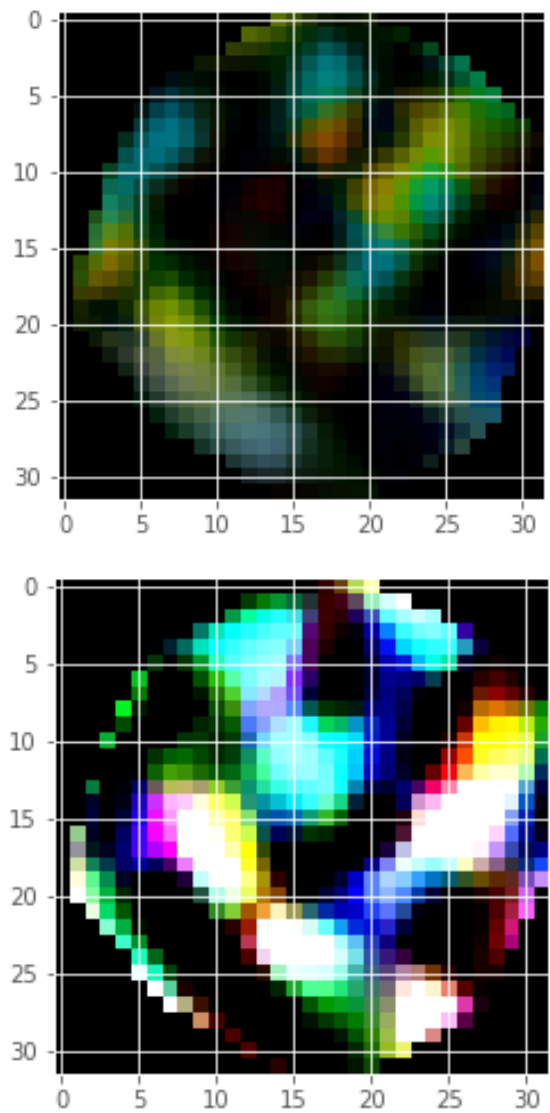


Figura 17. Ejemplos de las imágenes generadas

Después de la conversión, el número de datos aumentó, ya que se generaron varias imágenes por cada uno de los individuos que participaron en el experimento. Aprovechando el aumento en el número de registros y la conversión a imágenes, fue posible implementar una red convolucional.

Las redes convolucionales, o CNN, son redes neuronales cuyo funcionamiento se basa en la extracción de rasgos característicos de las imágenes. Estos rasgos fundamentales vienen determinados por el entrenamiento previo que se le da a la red neuronal, que se obtiene a partir de grandes conjuntos de imágenes. Cada capa aumenta la complejidad de estas características aprendidas hasta llegar a conseguir modelos muy precisos.

Para encontrar la estructura de capas óptima, se realizó una comparativa entre varios modelos en los cuales se fueron realizando combinaciones de distintas *layers*, teniendo siempre en cuenta que, debido al limitado número de datos y al riesgo de sobreaprendizaje, se deben limitar tanto la complejidad del modelo como el número de *dense layers*. El diseño que devolvió los mejores resultados siguió la siguiente estructura:

1. Convolutional layer



2. Convolutional layer
3. Pooling layer
4. Dropout layer
5. Convolutional layer
6. Pooling layer
7. Convolutional layer
8. Pooling layer
9. Dropout layer
10. Flatten layer
11. Dense layer
12. Dropout layer
13. Dense layer

También se realizaron diversas combinaciones alterando los valores de los epochs, la tasa de aprendizaje y otras variables. Como se puede ver en la siguiente tabla (Tabla 1), todos los modelos sufren de un elevado sobreaprendizaje pero, teniendo en cuenta la situación inicial del proyecto se puede concluir que una tasa de acierto en test cercana al 80% es aceptable.

Tabla 1. Resultado de los distintos modelos realizados

	Epochs	Learning Rate	Batch Size	Tr Acc	TsAcc
Modelo 1	250	0.001	100	0.96	0.72
Modelo 2	500	0.0001	75	0.89	0.68
Modelo 3	250	0.001	100	0.96	0.72
Modelo 4	75	0.00075	100	0.77	0.66
Modelo 5	500	0.0015	120	0.97	0.71
Modelo 6	500	0.00075	120	0.93	0.77

La estructura del sistema desarrollado es la representada en la Figura 18




Figura 18. Diagrama de la CNN

Como se puede ver, al generar varias imágenes de un único conjunto de señales, el número de salidas que genera la red es similar al número de frames en los que se ha dividido la señal. Por tanto, para un mismo registro pueden existir resultados tanto positivos como negativos. Para discernir si la valoración global ha sido positiva o negativa, se desarrolló una sencilla función de activación que clasifica las salidas y decide si el sujeto de experimentación reconoce la ubicación que se le presenta.

Finalmente, se puso a prueba el modelo con los resultados reales del experimento. La conclusión fue una tasa de acierto algo superior al 50%, lo cual resultó bastante sorprendente teniendo en cuenta las precisiones obtenidas en la fase de desarrollo.

Tras comentar los resultados con especialistas del departamento, se llegó a la conclusión de que era necesario volver a aplicar las técnicas de forma individual para cada uno de los grupos que se detectaron durante el EDA (*Exploratory Data Analysis*). Esto significa que, en lugar de contar con un único modelo, se debe entrenar un modelo por cada uno de los patrones detectados.

Los cuatro modelos usaron una estructura similar a la de la versión original, pero en esta ocasión el sobreaprendizaje se redujo considerablemente. Los resultados se recogen en la Tabla 2.

Tabla 2. Resultados del modelo al entrenarlo de forma separada según las características del individuo.

	Training Acc	Test Acc
Grupo 1	0.97	0.93
Grupo 2	0.98	0.89
Grupo 3	0.98	0.91
Grupo 4	0.98	0.90

Al aplicar este enfoque es necesario incorporar un nuevo procesamiento de los datos responsable de identificar a qué grupo pertenece cada individuo, ya que es preciso determinar qué modelo se debe utilizar.

Para ello se desarrolló una nueva CNN que identificaba a el grupo identificativo de cada individuo a partir de la matriz de correlación inicial. Empleando esta información, las señales eran pre procesadas y tratadas con el modelo correspondiente.

A continuación, se decidió volver a probar los datos reales con el nuevo sistema y en este caso los resultados fueron considerablemente mejores, pero de nuevo es necesario desglosarlos por grupos.

En el primer grupo, todos los sujetos fueron clasificados correctamente salvo uno. En el segundo, todos los individuos fueron clasificados positivamente, lo cual es, claramente, erróneo. En el tercer grupo solamente se identifica un falso positivo, siendo los demás resultados correctos y en el cuarto y último grupo todos los individuos fueron correctamente clasificados.

## V. CONCLUSIONES Y TRABAJO FUTURO

A lo largo del proyecto se han detectado y descubierto patrones que profundizan en el comportamiento de los impulsos del cerebro. Se han implementado algoritmos de forma más o menos satisfactoria en función del caso de estudio logrando, finalmente, extraer conclusiones determinantes tras generar un modelo adecuado.

Se han generado datos artificiales replicando el trabajo de los profesores Wonseok y Woonchul y se ha demostrado su

utilidad en entornos con una cantidad de información inicial muy limitada.

En cuento a los modelos generados, han demostrado tener una elevada precisión tanto en los conjuntos de entrenamiento como en los de test. Además, durante el proceso de validación únicamente hubo un modelo que no se mantuvo a la altura de los demás.

Como trabajo futuro queda pendiente obtener más datos para poder comprobar que las conclusiones y los modelos entrenados son generalizables. Dichos datos deben consistir en registros de distintos individuos a los que se les recomienda realizar unas 10 pruebas. Esta cantidad de experimentos devolverá una cantidad de datos que resulta suficiente para multiplicar significativamente el número de registros sin resultar excesivo para los entrevistados.

Por otro lado, queda pendiente investigar los motivos tras los cuales los resultados obtenidos con el modelo del segundo grupo no han sido igual de buenos que con los demás. Se sugiere que pueda influir el hecho de que uno de los participantes de ese grupo es superdotado, lo que sin duda afecta a la forma de procesar eventos, llegando a confundir al modelo.

Las redes convolucionales han resultado dar buenos resultados en el proyecto, pero una vez se cuente con un volumen de datos suficientemente grande podrían implementarse redes recurrentes que tienen en cuenta la secuencia temporal de los datos y que pueden aportar un enfoque integral a los datos.

Finalmente, como conclusión del experimento, la herramienta desarrollada aún no puede ser empleada en entornos reales y mucho menos en el entorno de las fuerzas del orden, donde una respuesta errónea puede perjudicar seriamente una investigación o la vida de un individuo. Sin embargo, los avances son prometedores y se han alcanzado grandes logros a pesar de nos disponer de una fuente de datos suficientemente extensa, por lo que se debe seguir profundizando en el campo.

## VI. BIBLIOGRAFÍA

- [1] L. Palacios, «Breve historia de la electroencefalografía».
- [2] X. L. Dongmei Zhou<sup>1</sup>, «Epilepsy EEG Signal Classification Algorithm Based on Improved RBF,» *Front. Neurosc.*, 23 June 2020.
- [3] P. Suppes, «Brain wave recognition of words,» *Proceedings of the National Academy of Sciences*, vol. 94, 1998.
- [4] Y. Jeon, C. S. Nam, Y.-J. Kim y M. C. Whang, «Brainwave Classification Using Covariance-Based Data Augmentation,» *IEEE Access*, 2020.
- [5] A. Trafton, «In the Blink of an Eye,» 28 enero 2021. [En línea]. Available: <https://news.mit.edu/2014/in-the-blink-of-an-eye-0116>.
- [6] A. Craik, Y. He y J. L. Contreras-Vidal, «Deep Learning for electroencefalogram (EEG) classification tasks: a

review,» *Journal of Neural Engineering*, vol. 16, n° 3, 2019.

- [7] W. Zheng, «Multichannel EEG-Based Emotion Recognition via Group Sparse Canonical Correlation Analysis,» *IEEE Transactions on Cognitive and Developmental Systems*, vol. 9, n° 3, pp. 281-290, 2017.
- [8] F. Lotte, «A Tutorial on EEG Signal Processing Techniques for Mental State Recognition in Brain-Computer Interfaces,» 2014.
- [9] J. Ramsay, *Functional data analysis in matlab and R*, Springer, 2009.