



MASTER EN INGENIERIA DE TELECOMUNICACIONES Y BIG DATA

TRABAJO FIN DE MASTER ANALISIS DE ONDAS CEREBRALES MEDIANTE INTELIGENCIA ARTIFICIAL PARA LA CLUSTERIZACION DE RESPUESTAS

Autor: Pablo Mena Gómez de Merodio

Director: David Contreras Bárcena y Mario Castro Ponce

Madrid

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título
“Análisis de ondas cerebrales mediante inteligencia artificial para la clusterización de
respuestas”

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el

curso académico 2018/19 es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido

tomada de otros documentos está debidamente referenciada.

Fdo.: Pablo Mena Gómez de Merodio

Fecha://

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: David Contreras Bárcena

Fecha://

Agradecimientos

En este proyecto tengo que dar las gracias a muchas personas. A mis padres, que se estaban preocupando por que acabase el proyecto antes de haberlo empezado siquiera. Habéis estado ahí desde el principio y sé que os habéis tenido que morder la lengua mil veces, siento todos los disgustos que os habéis llevado por el camino y espero poder compensároslo.

A mi hermana, que siempre estaba ahí cuando necesitaba contarle mis penas y nunca me ha dado un mal consejo (bueno, puede que alguno). Sin ti nunca habría llegado hasta aquí o al menos no habría sido ni la mitad de divertido.

A Ana, que sabe lo que me pasa antes que yo mismo y siempre apuesta por mí, incluso cuando los dos sabemos que no es buena idea. Lo más valioso que me llevo de estos años no son los conocimientos ni las experiencias, ni siquiera los amigos. Lo mejor, eres tú. Eres la persona más cabezota que conozco y sé que nunca me darás la razón, pero tengo muchísima suerte de tenerte en mi vida y espero que nunca dejes de estar a mi lado.

También tengo que darle las gracias a mi director David. No creo que nunca leas esto, pero para mí, tu clase fue la que me hizo cogerle el gusto a todo este mundo de la programación y es por ello que te lo agradezco y te culpo a partes iguales.

A Beltrán, por ser mi mejor y mi peor influencia. Espero poder ayudarte a lo largo de mi vida la mitad de lo que me has ayudado tu en estos años. A Jorge, que pasó más tiempo conmigo del que debería pasar nadie en toda una vida. Muchas gracias por aguantarme, pero todavía me debes unas cervezas.

Y finalmente a María, Manu y Álvaro, que han conseguido que se cumpla mi sueño de que me llamen por mi nombre en un bar.



COMILLAS
UNIVERSIDAD PONTIFICIA

ICAI

MASTER EN INGENIERIA DE
TELECOMUNICACIONES Y BIG DATA

TRABAJO FIN DE MASTER

ANALISIS DE ONDAS CEREBRALES MEDIANTE
INTELIGENCIA ARTIFICIAL PARA LA
CLUSTERIZACION DE RESPUESTAS

Autor: Pablo Mena Gómez de Merodio

Director: David Contreras Bárcena y Mario Castro Ponce

Madrid

ANALISIS DE ONDAS CEREBRALES MEDIANTE INTELIGENCIA ARTIFICIAL PARA LA CLUSTERIZACION DE RESPUESTAS

Autor: Mena Gómez de Merodio, Pablo.

Director: Dr. Contreras Bárcena, David.

Entidad Colaboradora: ICAI – Universidad Pontificia Comillas

RESUMEN DEL PROYECTO

En este proyecto se ha desarrollado un estudio en el que se ha analizado el comportamiento de las ondas cerebrales frente a la visualización de imágenes. El objetivo del trabajo consiste en la identificación de patrones y en el desarrollo de herramientas capaces de identificar si un individuo reconoce la ubicación presentada en la imagen.

Palabras clave: Big Data, Deep learning, EEG, CNN, Identificación de imágenes

1. Introducción

En la actualidad, la gran mayoría de los programas para interpretar ondas cerebrales están centrados en el campo de los sistemas BCI (Brain-Computer Interface) y en el reconocimiento de señales generadas de forma voluntaria, como el impulso eléctrico necesario para mover un brazo o hablar. Sin embargo, el reconocimiento de dichos impulsos eléctricos al reaccionar de forma inconsciente se encuentra mucho menos explotado [1], lo que se deba, probablemente, a que se trate de un campo con una aplicación práctica menos inmediata. Este proyecto, en cambio, espera desarrollar un modelo capaz de detectar si una persona reconoce una imagen a raíz de las respuestas inconscientes del cerebro. Para ello, se realizó un experimento en el cual se recopilaron los datos relativos a las ondas cerebrales de un grupo de sujetos. Durante el experimento se les presentaron tres imágenes. La primera imagen presentaba un entorno conocido para los sujetos, la segunda uno desconocido y la tercera resultaba familiar únicamente a un pequeño porcentaje de los individuos entrevistados. La meta de este proyecto consistía en desarrollar un programa capaz de identificar a estos sujetos específicamente.

2. Definición del proyecto

Los puntos clave para el funcionamiento del proyecto son los siguientes:

1. Realizar un análisis estadístico en profundidad de los datos mediante el uso del lenguaje de programación Python para la identificación de características y patrones clave en el comportamiento de los datos.
2. Implementar técnicas de Data Augmentation para incrementar la limitada cantidad de datos de la que se dispone inicialmente.
3. Desarrollar un estudio de las variables con el fin de detectar cuales de ellas resultan más relevantes para el programa y reducir así la dimensionalidad de los datos
4. Programar diversos modelos de deep y machine learning mediante el uso de distintas librerías para clasificar los datos introducidos por el usuario. Los modelos utilizaran como datos de entrenamiento tanto los registros aportados por la universidad, como aquellos generados mediante Data Augmentation.
5. Definir y pulir aquel modelo que ofrezca los mejores resultados para que sea sencillo de usar e implementar en un entorno real.

3. Descripción del sistema

Este proyecto utiliza como punto de partida los datos aportados por el departamento de psicología de la universidad de Comillas. Sin embargo, la información disponible es muy limitada, por lo que fue necesario obtener nuevas fuentes de datos para nutrir al modelo de clasificación. Es por ello, que una vez que se analizaron los datos iniciales, se procedió a la implementación de técnicas de Data Augmentation especializadas en el campo de los electroencefalogramas [2]. Una vez se tuvo un volumen de datos aceptable, se procedió a analizar los resultados de distintos algoritmos buscando reducir la dimensionalidad de los datos y la solución que mejor se adaptase al problema presentado. Finalmente, se llegó a la conclusión de que el mejor enfoque posible sería utilizar una red convolucional que utilizase imágenes generadas a raíz de las distintas bandas de frecuencia presentes en las ondas EEG. Dichas imágenes se generan a partir de los valores medios de las distintas bandas de frecuencia en una franja de tiempo limitada. A continuación, estos valores se plasman sobre la disposición de los electrodos en unos ejes de coordenadas, generando tantas imágenes como franjas de tiempo se empleen. En las siguientes ilustraciones se pueden ver tanto el esquema de la conversión dato-imagen, como ejemplos de las imágenes generadas.

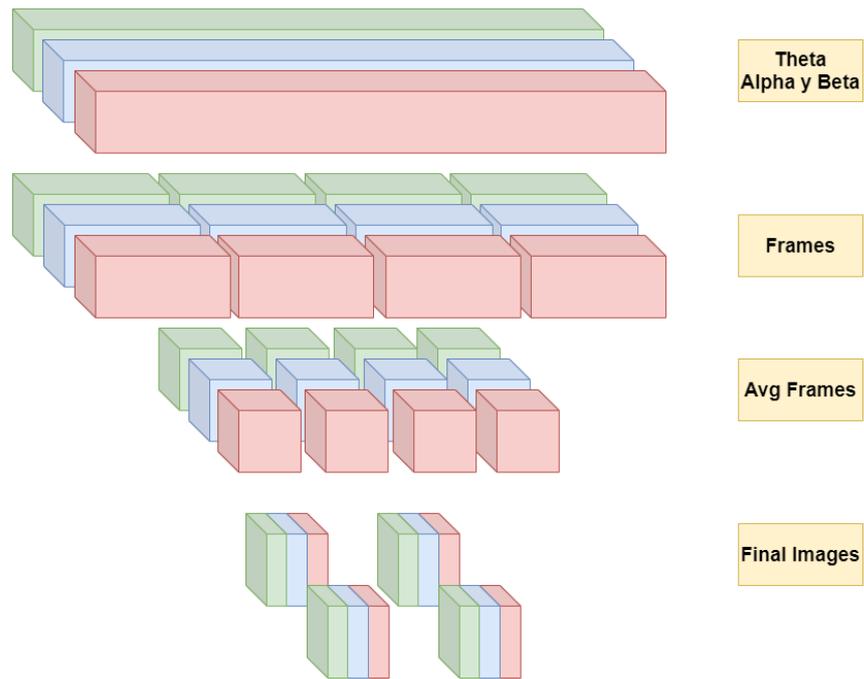


Figura 1. Esquema del funcionamiento de conversión de datos a imágenes

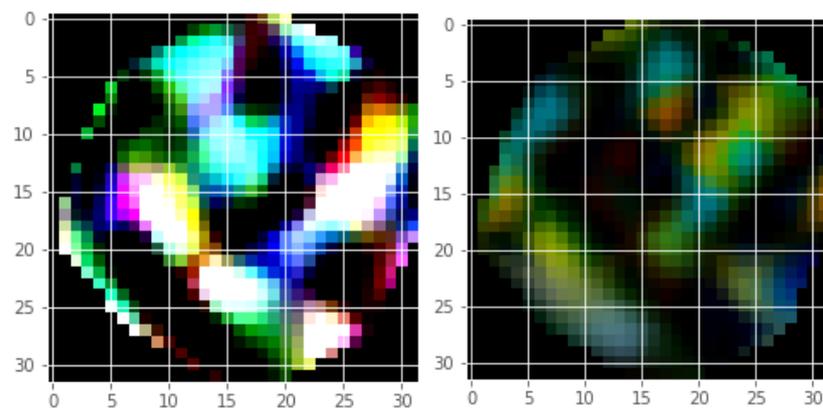


Figura 2. Ejemplos de imágenes generadas

Al aplicar esta técnica el volumen de datos se incrementó considerablemente, lo que permitió la implementación de la CNN. Sin embargo, como contrapartida a este enfoque, los datos de salida del modelo no dan una respuesta única sobre la clasificación de la señal, sino que se devuelven tantas respuestas como número de *frames*, por lo que todavía es necesaria cierta supervisión humana. También es necesario mencionar el extenso estudio que se llevó a cabo y en el que se probaron un mayor número de técnicas (OLS, Multivariate Regression, CCA, RDA) [3]. La razón de que se trate en profundidad el desarrollo y funcionamiento de la CNN se debe a que, por desgracia, fue el único método que generó resultados satisfactorios.

4. Resultados

Como resultado final del proyecto, se han generado métricas y herramientas que permiten reducir la dimensionalidad del conjunto de datos, lo que implica una reducción significativa en los costes del equipo de medición. Por otro lado, el modelo desarrollado cuenta con una tasa de acierto en el conjunto de entrenamiento superior al 70%, lo cual es un gran éxito teniendo en cuenta el punto de partida del proyecto. Se debe tener en cuenta el hecho de que la salida del modelo está compuesta por tantas respuestas como imágenes reciba, por lo que queda pendiente desarrollar un sistema más sofisticado capaz perfeccionar el formato de salida. En la actualidad, el programa devuelve una lista de candidatos que considera que tienen una alta probabilidad de ser positivos y representa la densidad de las respuestas para ayudar a un sujeto externo en la toma de decisiones.

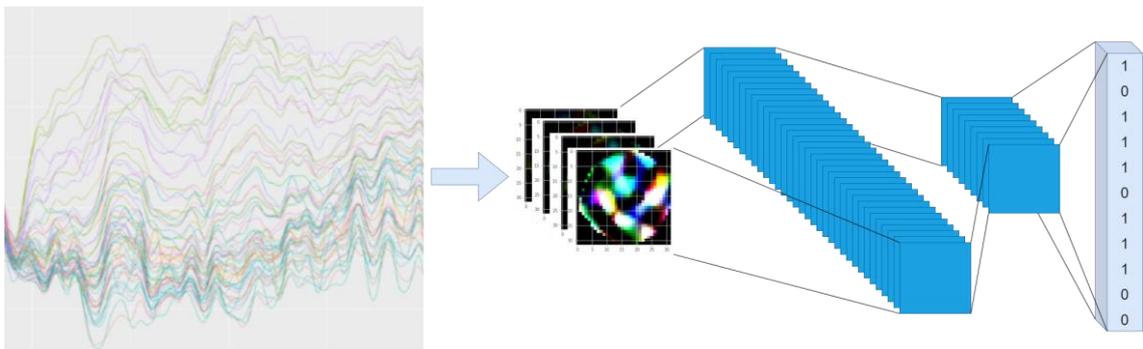


Figura 3. Diagrama del funcionamiento de la CNN

5. Conclusiones

Como conclusión, se ha logrado cumplir con todos los objetivos establecidos en el proyecto. Es decir, se ha profundizado en el conocimiento del campo y se han desarrollado análisis para simplificar el proceso de extracción de datos gracias a la reducción de la dimensionalidad. Además, se ha desarrollado una CNN capaz de estimar si un individuo ha reconocido una imagen en base a un EEG y se ha preparado una infraestructura que facilite la incorporación de nuevos datos para mejorar el sistema existente.

6. Referencias

- [1] E. P. Torres, «EEG-Based BCI Emotion Recognition: A Survey,» 2020.
- [2] Y. Jeon, C. S. Nam, Y.-J. Kim y M. C. Whang, «Brainwave Classification Using Covariance-Based Data Augmentation,» *IEEE Access*, 2020.
- [3] J. Ramsay, *Functional data analysis in matlab and R*, Springer, 2009.

ANALISIS DE ONDAS CEREBRALES MEDIANTE INTELIGENCIA ARTIFICIAL PARA LA CLUSTERIZACION DE RESPUESTAS

Author: Mena Gómez de Merodio, Pablo.

Director: Dr. Contreras Bárcena, David.

Colaborating Entity: ICAI – Universidad Pontificia Comillas

ABSTRACT

In this project, it has been developed a study on the behaviour of brain waves when reacting to different images. The main objective of this analysis is to identify patterns and develop tools that are capable of determine if a test subject recognize or not the location shown in the image.

Keywords: Big Data, Deep learning, EEG, CNN, Image recognition

1. Introduction

Nowadays, almost every computer program that work with EEG waves are focused on the field of the BCI systems (Brain-Computer Interface) and the identification of voluntary reactions. An example of this might be the capacity to determine if someone wants to move the left or the right hand. On the other hand, the analysis of unconscious reactions is far less exploited [1]. This fact may be caused due to the lack of an immediate practical application. Nevertheless, in this project it will be developed a model capable of identify if a person recognizes an image based on his brain waves. For this purpose, the faculty of psychology of Comillas university created an experiment in which the EEG data of a group of people was recorded while showing them three different images. The first one showed a familiar location, the second one was from a unknown location and the third one was recognized just by a small percentage of the test subjects. The final goal of this project is to develop a program that determines which of the original subjects already knew the third location

2. Objectives

The main objectives established for this project are presented below.

1. Perform a Deep statistical study with Python to identify the main characteristics and patterns in the data.
2. Implement Data Augmentation technics to increase the small amount of data provided initially.
3. Develop some analysis over the features of the data in order to determine which of them are more valuable for the future of the project. By doing this the dimensionality of the data will be reduced too.
4. Create a huge variety of Deep and Machine Learning models using different libraries to classify the input data. Those models will use as training data the reports provided by the university and those generated in the Data Augmentation phase.
5. Improve and refine that model that return the best results in order to make it easy to use and implement in the real world.

3. System Description

This project uses as starting point the reports provided by the faculty of psychology of the University of Comillas. Nevertheless, the original data was not enough to train a Deep Learning model, due to this it was necessary to search for new information sources in order to feed the classification model. This is the reason why, once that the statistical analysis was done, a Data Augmentation algorithm specialized on EEG waves was implemented [2]. When the size of the dataset was big enough, different dimension reduction algorithms where implemented in order to improve the quality of the data. Finally, the conclusion that was reached was that the best approach was to use a Convolutional Neural Network that uses images as inputs. These images would be created using the different frequency bands of the waves. Each band and signal are fragmented, and the average value of every wave is calculated. The next step consists on depict these values over the disposition of the electrodes on a 2-D axis. This way, there are generated as much images as fragments of the original waves are created. The next illustrations show the process and an example of the images.

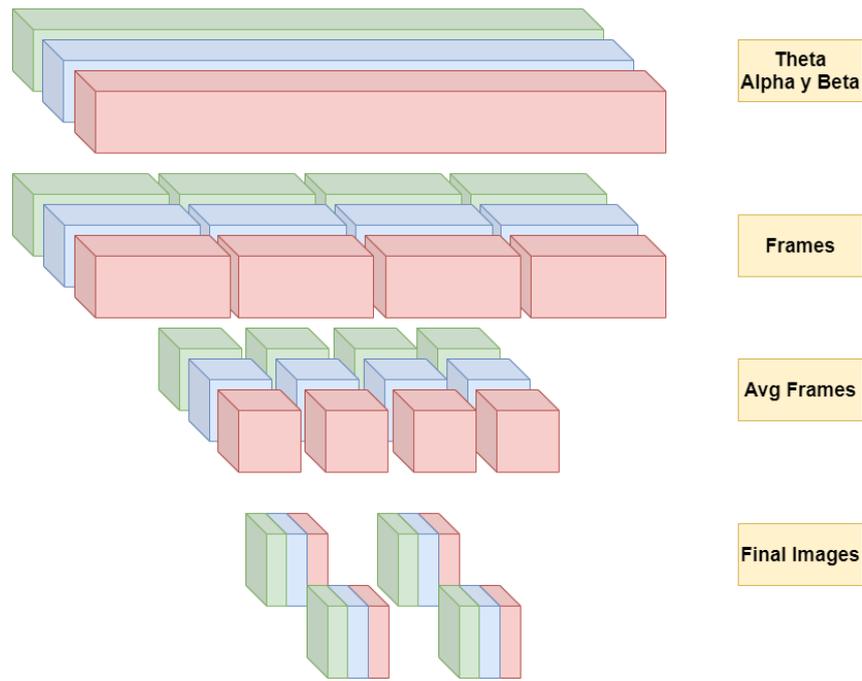


Figura 4. Diagram of how the image creation works

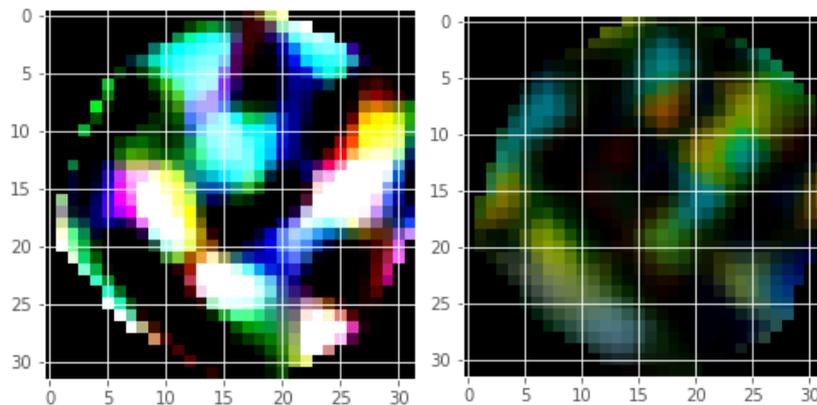


Figura 5. Image examples

As a side effect of applying this technique, the size of the data increased widely, which allowed us to implement a CNN. However, as an offsetting, the output of the model has the same dimension as the input, which means that if a signal is framed in three different images, the output will be three predictions. This spells that there is still a need of some human supervision to interpret the output. It is also necessary to mention that many other algorithms and techniques were implemented during this study. The most relevant of them are OLS, Multivariate Regression, CCA and RDA [3]. The reason why the CNN is getting more attention is that it was the only algorithm that returned satisfactory results

4. Results

At the end of this project, it has been generated metrics and tools that reduce the dimensionality of the data, which implies a reduction on the cost of the devices used to measure and record the signals. Also, the developed model has a test accuracy rate higher than 70%, which is a huge success taking into consideration the starting point of the project. On the other hand, it must be considered the fact that the output of the model is composed by a list of answers, all of them related with just one input signal, so it is still needed to create a more refined program capable of giving back just one answer. Currently, it has been developed a secondary program that filters the input candidates and returns a list of the most probably suspects. It also returns the density of the model output to help the user to make a decision

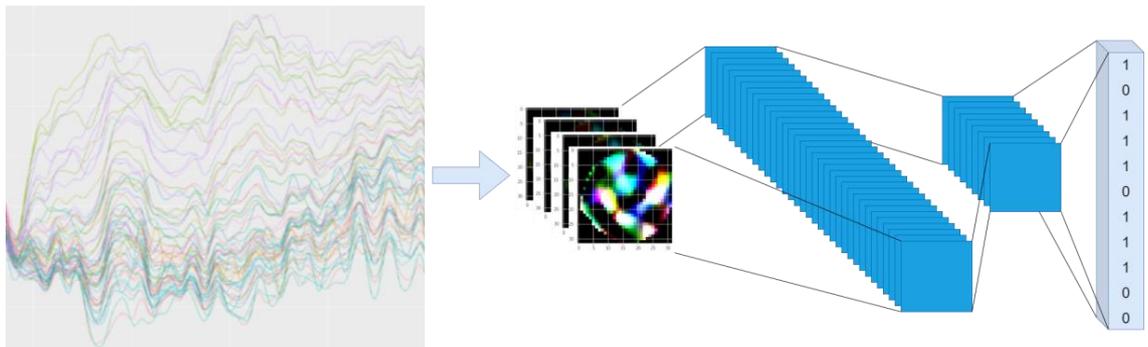


Figura 6. Diagram of the CNN

5. Conclusions

As a conclusion, all the initial objectives were reached. The study deepens on the knowledge of the field and it has been developed tools that simplifies the process of capture the EEG waves thanks to the dimensionality reduction. Also, a CNN was trained to classify if a subject recognizes an image by reading his brain wave activity. Above of that, an infrastructure was created to simplify the process of adding and processing new data.

6. Referencias

- [1] E. P. Torres, «EEG-Based BCI Emotion Recognition: A Survey,» 2020.
- [2] Y. Jeon, C. S. Nam, Y.-J. Kim y M. C. Whang, «Brainwave Classification Using Covariance-Based Data Augmentation,» *IEEE Access*, 2020.

[3] J. Ramsay, Functional data analysis in matlab and R, Springer, 2009.

Índice de la memoria

Capítulo 1. Introducción	7
1.1 Motivación del proyecto.....	8
1.2 Descripción de las tecnologías	10
Capítulo 2. Estado de la Cuestión	13
Capítulo 3. Definición del Trabajo	23
3.1 Justificación.....	23
3.2 Objetivos	23
3.2.1 Análisis de los datos	24
3.2.2 Data Augmentation.....	24
3.2.3 Desarrollo de un modelo de machine learning para la clasificación de ondas cerebrales	25
3.2.4 Revisión de los resultados para la reducción de costes	25
3.3 Metodología.....	26
3.4 Planificación y Estimación Económica	27
3.4.1 Planificación.....	27
3.4.2 Estimación económica.....	27
Capítulo 4. Sistema Desarrollado	29
4.1 Estudio previo de las variables principales	31
4.1.1 Estudio de los datos.....	33
4.1.2 Conclusiones del estudio	44
4.2 Reducción de la dimensionalidad.....	45
4.2.1 Principal component analysis	45
4.3 Data Augmentation.....	52
4.3.1 Transformada Rápida de Fourier (FFT).....	54
4.3.2 Selección de las frecuencias relevantes.....	55
4.3.3 Normalización de la señal.....	55
4.3.4 Síntesis de datos	56
4.3.5 Resultados obtenidos.....	58
4.4 Aplicación de algoritmos.....	61

4.4.1 Canonical Correlation Analysis	61
4.4.2 Convolutional Neural Network.....	69
Capítulo 5. Análisis de Resultados.....	78
5.1 Resultados de la reducción de la dimensionalidad	78
5.2 Resultados del modelo.....	79
5.3 Resultados del sistema global.....	83
Capítulo 6. Conclusiones y Trabajos Futuros.....	85
Capítulo 7. Bibliografía.....	87

Índice de figuras

Figura 1. Esquema del funcionamiento de conversión de datos a imágenes.....	10
Figura 2. Ejemplos de imágenes generadas.....	10
Figura 3. Diagrama del funcionamiento de la CNN.....	11
Figura 4. Diagram of how the image creation works	15
Figura 5. Image examples.....	15
Figura 6. Diagram of the CNN	16
Figura 7. Ejemplo de un encefalograma.....	9
Figura 8. Resumen de las técnicas y los campos en los que se ha usado Deep Learning en el mundo de la neurología	14
Figura 9. Ejemplo del proceso de análisis de EEG para la identificación de movimientos	15
Figura 10. Diagrama del sistema	29
Figura 11. Diagrama del flujo de datos y la conexión entre los módulos implementados..	30
Figura 12. Gráfico de la disposición de los sensores en un EEG	32
Figura 13. Ejemplo de un encefalograma.....	33
Figura 14. Conjunto de matrices de correlación.....	34
Figura 15. Patrones detectados en las matrices de correlación.....	35
Figura 16. Densidad de las señales	36
Figura 17. Resultado del PCA	37
Figura 18. Representación de la primera componente principal	38
Figura 19. Representación de la segunda componente principal	38
Figura 20. Aportación de cada señal a las componentes principales.....	39
Figura 21. Representación de las señales sobre las 2 primeras componentes principales ..	40
Figura 22. Respuesta en frecuencia del EEG y bandas de frecuencia.....	41
Figura 23. Respuesta en tiempo y frecuencia según el tipo de ondas	43
Figura 24. Representación gráfica del proceso de síntesis de datos.....	58
Figura 25. Ejemplo de la respuesta en frecuencia original de las ondas Theta	59

Figura 26. Ejemplo de la respuesta en frecuencia de los datos generados para las ondas Theta	59
Figura 27. Ejemplo de la respuesta temporal original de las ondas Theta	60
Figura 28. Ejemplo de la respuesta temporal de los datos generados para las ondas Theta	60
Figura 29. Imagen extraída del libro Functional data analysis in matlab and R de James Ramsay	62
Figura 30. Ejemplo de CCA sobre ondas Theta	64
Figura 31. Ejemplo de CCA sobre ondas Alpha	64
Figura 32. Ejemplo de CCA sobre ondas Beta	65
Figura 33. K-means sobre CCA de ondas Theta	66
Figura 34. K-means sobre CCA de ondas Alpha.....	67
Figura 35. K-means sobre CCA de ondas Beta	67
Figura 36. Ejemplo de CCA donde no se cumple la condición.....	69
Figura 37. Demostración gráfica del proceso de creación de imágenes.....	73
Figura 38. Diagrama del funcionamiento de la CNN	76

Índice de tablas

Tabla 1. Tabla extraída del artículo EEG-Based BCI Emotion Recognition: A Survey.....	19
Tabla 2. Planificación del proyecto	27
Tabla 3. Coste económico de los recursos empleados.....	28
Tabla 4. Coste económico de la mano de obra	28
Tabla 5. Tabla de dimensionalidad después del análisis PCA	51
Tabla 6. Muestra descriptiva de algunos de los modelos generados	79
Tabla 7. Predicciones del modelo sobre la tercera imagen	81
Tabla 8. Predicciones del modelo usando un sujeto de prueba	82



Capítulo 1. INTRODUCCIÓN

De acuerdo con el estudio llevado a cabo por el Massachusetts Institute of Technology (MIT) [1] un ser humano medio es capaz de procesar imágenes completas en tan solo 13 milésimas de segundo. Estas reacciones son involuntarias y activan conexiones neuronales establecidas por el subconsciente. Dichas conexiones se ven reflejadas en la forma en la que se comportan las ondas cerebrales encargadas de transportar los impulsos eléctricos del cerebro. La forma, la frecuencia y la amplitud del impulso eléctrico necesario para mover el brazo derecho no es comparable con el que se genera al hablar o andar, por ejemplo.

Este hecho se traduce en que, si se contase con el conocimiento y la tecnología adecuada, se podrían establecer herramientas que permitiesen identificar que pretende hacer un sujeto únicamente registrando su capacidad cerebral. De esta forma, se podría ayudar a miles de personas con dificultades de movimiento o comunicación y sería un gran adelanto en el sector de la interfaz hombre-maquina.

Actualmente, la profesora Lucía Halty Burrutieta del departamento de psicología de la Universidad Pontificia de Comillas, se encuentra realizando un experimento en el cual estudia el comportamiento de las ondas cerebrales al mostrar imágenes que resulten familiares o desconocidas para los sujetos de experimentación. A través de este estudio, se pretende desarrollar un programa capaz de identificar patrones en las ondas cerebrales que faciliten su clasificación. De esta forma, se espera poder averiguar si el sujeto de experimentación ha estado en una ubicación concreta.

En particular, el proyecto pretende ayudar a las fuerzas del orden a descubrir si un sospechoso ha estado en la escena de un crimen. Durante el experimento, la profesora Burrutieta mostró, de forma individual, tres imágenes a una población de sujetos entre los cuales se encontraba un pequeño porcentaje de convictos. La primera foto representaba un entorno conocido para los sujetos, como podía ser su propia habitación. La segunda imagen contenía una localización desconocida y la última, la escena en la que se cometió el crimen.

Mientras se les enseñaba las imágenes, se iba capturando el flujo de sus ondas cerebrales. De esta forma, se obtuvieron tres registros por cada participante. En el caso de los convictos, se deberían reconocer como familiares dos de las tres imágenes presentadas, mientras que el resto de la población, únicamente reaccionarían ante la primera fotografía.

Aprovechando la gran disponibilidad de recursos de la universidad y la diversidad de técnicas de análisis de series temporales, se espera poder desarrollar un modelo capaz de identificar si un sujeto reconoce o no una imagen.

1.1 MOTIVACIÓN DEL PROYECTO

Cada año se registran 180.000 casos nuevos de afasia. Un trastorno de comunicación que impide a quienes lo sufren comunicarse con claridad. Esta enfermedad convierte en imposibles tareas sencillas que se realizan a diario. Si se lograra desarrollar una tecnología capaz de traducir de forma precisa las ondas cerebrales en las palabras que se quieren pronunciar, la vida de miles de personas se facilitaría muchísimo. Por desgracia, aún se está lejos de alcanzar ese objetivo, pero con este proyecto se espera profundizar un poco más en el complejo mundo que es la mente humana.

Otro ejemplo de la implementación de esta tecnología en la vida de las personas se ve reflejada en la creación de prótesis inteligentes capaces de moverse según la voluntad de los heridos. En el proyecto DeTOP, financiado por fondos europeos, se ha logrado que personas sin manos hayan sido capaces de controlar, con movimientos sencillos, prótesis robóticas. Sin embargo, es necesario mencionar que, a diferencia del estudio desarrollado en este proyecto, los sensores se encontraban conectados a los nervios del brazo, no al cerebro propiamente dicho.

Como se ha podido comprobar en los párrafos anteriores, las aplicaciones de esta tecnología son capaces de mejorar la calidad de vida de las personas más necesitadas, pero aun así los trabajos desarrollados en este campo aún son escasos y queda un largo camino

por recorrer. La razón de que estos avances no se hayan implementado del todo en la vida diaria se debe principalmente a la complejidad. A pesar de los nuevos descubrimientos, aun se sabe muy poco del cerebro humano y su funcionamiento. De hecho, basta con observar un encefalograma como los usados en este proyecto para comprender la dificultad de la misión.

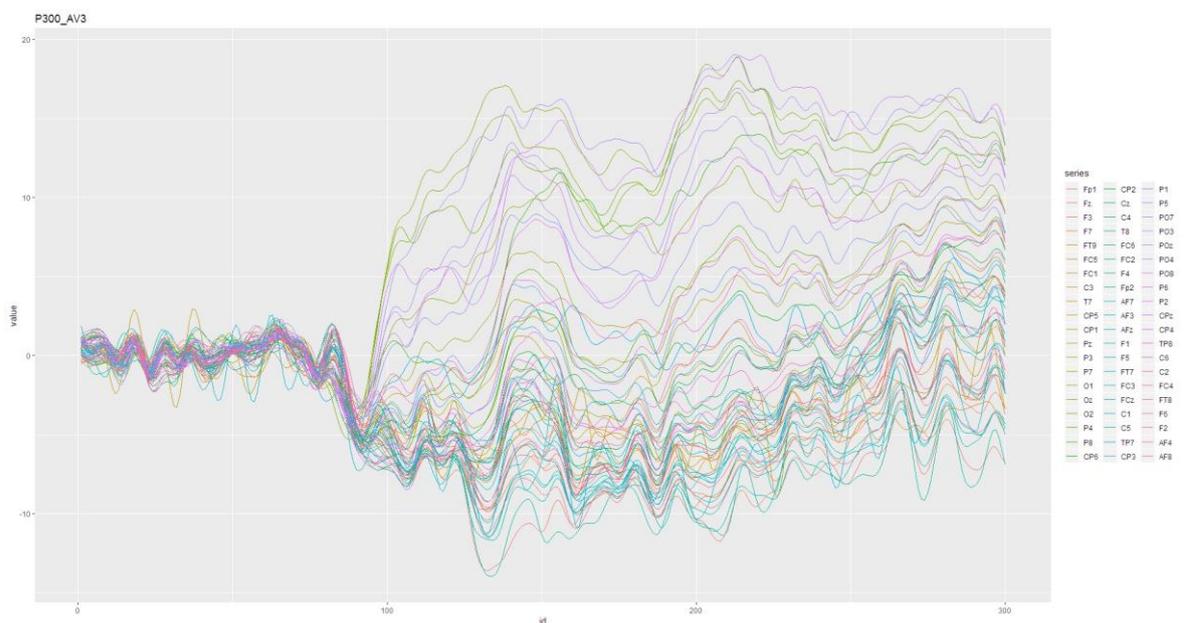


Figura 7. Ejemplo de un encefalograma

Es por ello, que todo el trabajo generado alrededor de este campo es valioso, ya que ayuda a profundizar en el conocimiento de la mente humana. Además, el objetivo final del proyecto consiste en poder desarrollar una aplicación que pueda ayudar en investigaciones policiales. La capacidad para identificar si un sospechoso reconoce o no una ubicación puede ser usada para exculpar a acusados y para facilitar la labor policial.

1.2 DESCRIPCIÓN DE LAS TECNOLOGÍAS

Con el fin de implementar todas las técnicas y algoritmos posibles a lo largo de este proyecto, se han utilizados las siguientes herramientas y tecnologías:

- **Big Data**

Conjunto de datos de gran tamaño, complejidad y velocidad de crecimiento que no pueden ser gestionados mediante los medios habituales debido a su gran volumen. También es la base en la que sustenta la tecnología del machine learning

- **Machine Learning**

Rama de la inteligencia artificial que utiliza grandes cantidades de datos para detectar patrones, realizar predicciones y tomar decisiones sin necesidad de que estas sean programadas directamente por un humano. Este concepto también implica que los sistemas se mejoran de forma automática mediante la práctica y el procesado de nuevos datos

- **Registro de datos**

Conjunto de datos obtenidos por la profesora Lucía Halty Burrutieta a lo largo de sus experimentos y que contienen registros de ondas cerebrales

- **Jupyter notebook**

Plataforma *open-source* que ofrece soporte interactivo para el análisis de datos en cualquier lenguaje de programación. Permite realizar visualizaciones de los datos y facilita el análisis de resultados

- **RStudio**

Entorno de desarrollo integrado para el lenguaje de programación R dedicado a la computación estadística y que facilita la programación y el análisis de resultados

- **Data augmentation**

Técnica empleada en entornos Big Data con la cual se generan registros artificiales de datos a raíz de datos reales ligeramente modificados. Esta técnica es especialmente útil en proyectos donde la cantidad de información existente es reducida.

Capítulo 2. ESTADO DE LA CUESTIÓN

Fue en 1924 cuando Hans Berger inventó el electroencefalograma [2] y demostró la existencia de corriente eléctricas que fluían en el cerebro humano. Un electroencefalograma es una prueba que detecta la actividad eléctrica del cerebro mediante pequeños discos metálicos (electrodos). Desde su descubrimiento, múltiples científicos han realizado diversos avances dentro del campo de la neurología que han permitido explorar y desarrollar nuevas técnicas sin las cuales el mundo de la medicina tal y como lo conocemos hoy en día no existiría. El electroencefalograma es capaz de determinar cambios en la actividad cerebral que pueden ser útiles para diagnosticar trastornos cerebrales como la epilepsia u otros trastornos convulsivos. Un electroencefalograma también puede utilizarse para confirmar la muerte cerebral en una persona que se encuentra en un coma persistente o para ayudar a encontrar el nivel adecuado de anestesia para una persona que se encuentra en un coma inducido por medicamentos.

Sin embargo y a pesar del paso de los años y del refinamiento de la técnica, la interpretación de un encefalograma sigue siendo un proceso muy complejo. Es necesario un arduo entrenamiento y una larga formación médica para ser capaz de interpretar correctamente las señales percibidas por los electrodos e incluso en estos casos no se puede asegurar con absoluta certeza que la interpretación realizada concuerde con la realidad. Es cierto, que en los últimos años se ha vivido un crecimiento en el mundo de la medicina como nunca antes se había visto. Estos avances han sido posibles gracias a las nuevas tecnologías y al análisis de datos mediante técnicas de Deep y Machine Learning, con las cuales se está empezando a desarrollar herramientas capaces de interpretar resultados sin que los profesionales que los manejan necesiten haber adquirido ese extenso conocimiento previo.

El Deep Learning y el Machine Learning han permitido grandes avances en multitud de campos. Las redes convolucionales han permitido que los ordenadores sean capaces de identificar objetos en imágenes y extraer conclusiones a raíz de las mismas de formas que en las que un ser humano jamás lo lograría. Este reconocimiento de imágenes ya se ha

implementado para la detección de fracturas a raíz de radiografías o en la identificación de tumores pulmonares en escáneres. Sin embargo, la capacidad del Deep Learning no se limita al reconocimiento de imágenes, también se han logrado grandes avances en el análisis de secuencias temporales mediante el uso de DNNs (Deep Neural Networks) [3]. Estas secuencias temporales hacen referencia al reconocimiento de lenguaje en grabaciones principalmente, pero no es difícil imaginar cómo se podrían adaptar a otros contextos, como la interpretación de ondas eléctricas similares al electroencefalograma. De hecho, en un estudio realizado por Alexander Craik en 2019 [4] se mostraron cuales habían sido las principales técnicas de Deep Learning utilizadas en el campo de la neurología y en que campos se habían usado.

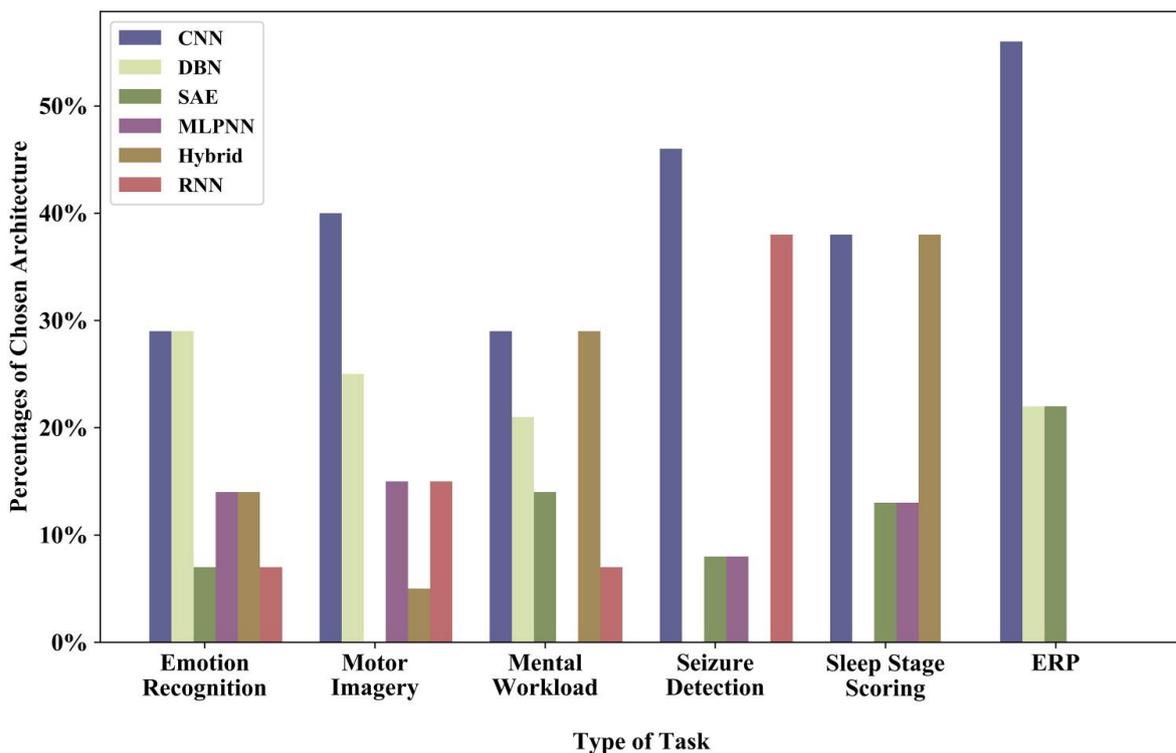


Figura 8. Resumen de las técnicas y los campos en los que se ha usado Deep Learning en el mundo de la neurología

Como se puede ver, los campos investigados son muy variados, pero en todos los casos la técnica más empleada son las redes convolucionales o CNN. Dentro del sector del análisis de los electrocardiogramas hay dos pasos principales y claramente diferenciados. El primero de ellos consiste en la extracción de *features* que pretende obtener aquellos valores o campos que contienen la información relevante dentro de la señal y prescindir del ruido o de las componentes menos útiles. Esta fase del proyecto se suele dividir en la extracción según tres factores diferenciados.

1. Información espacial: ¿Qué canales aportan más información?
2. Información espectral: ¿Qué bandas de frecuencia almacenan la energía?
3. Información temporal: ¿Cómo varía la señal con el tiempo?

El segundo paso mencionado anteriormente consiste en la clasificación de las señales a partir de las *features* obtenidas. Esta sección es similar a cualquier otro problema de clasificación y, por tanto, se pueden aplicar una gran variedad de técnicas [5].

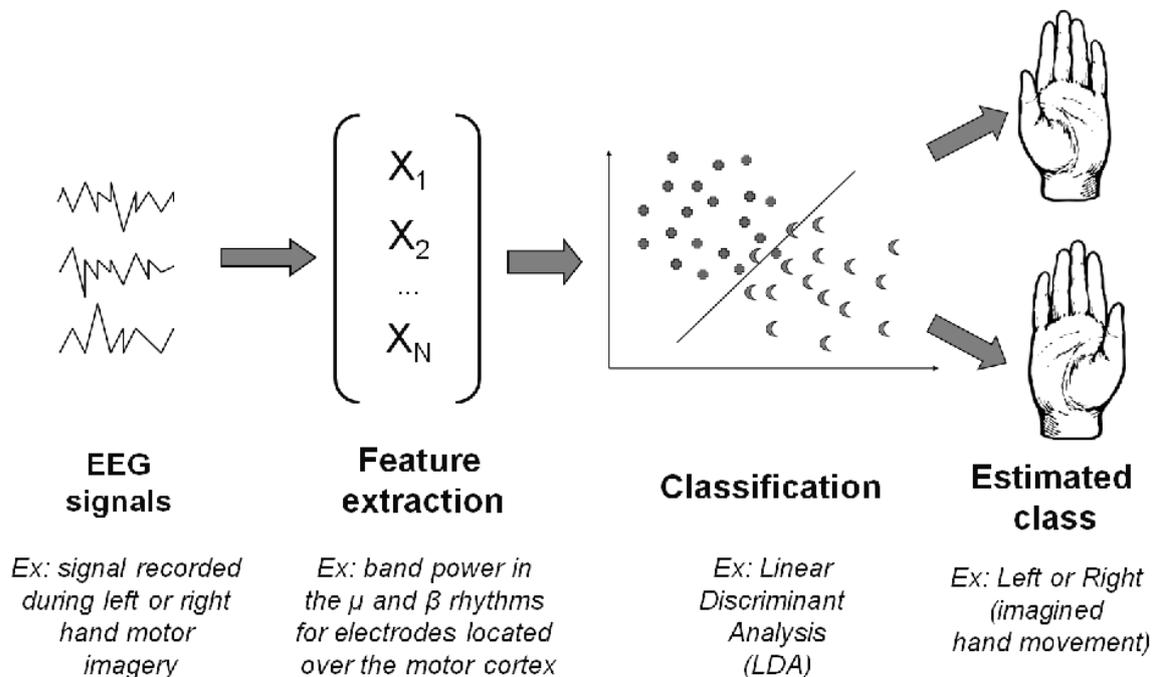


Figura 9. Ejemplo del proceso de análisis de EEG para la identificación de movimientos

Entre todas ellas destacan de forma significativa el CCA (Canonical Correlation Analysis) y LDA (Linear Discriminant Analysis). CCA destaca por su capacidad para extraer relaciones entre varios sets de datos. Esta cualidad facilita la extracción de patrones comunes entre diversas ondas cerebrales, ya sean de un mismo sujeto o de un conjunto de personas. Su funcionamiento se basa en encontrar la combinación lineal de dos sets de datos que genere la mayor correlación con los datasets originales. Mediante la aplicación de este algoritmo, no solo se puede observar la correlación entre varias ondas cerebrales de un grupo de individuos, sino que además se puede estudiar la evolución temporal de los estímulos cerebrales, posibilitando la identificación de una emoción ante un estímulo concreto [6].

LDA por otra parte, se basa en la utilización de hiperplanos para la separación de los resultados, lo cual tiene un funcionamiento similar al de otras técnicas de Machine Learning menos focalizadas en el análisis de ondas cerebrales como la regresión lineal. Se puede observar un ejemplo del funcionamiento de esta técnica en la 15Figura 9.

Como ya se ha mencionado anteriormente, el análisis de los encefalogramas ha sido aplicado a multitud de aspectos dentro del mundo de la medicina. En junio de 2020 la universidad de Chengdu en China publicó un artículo llamado Epilepsy EEG Signal Classification Algorithm Based on Improved RBF [7] en el cual se hablaba de cómo se habían implementado técnicas de Machine Learning para la identificación de pacientes con epilepsia. Este artículo presentaba un enfoque distinto al usado habitualmente en este campo. A diferencia de como se hizo en otros estudios previos donde se trabajaba con variables lineales, el profesor Dongmei Zhou demostró que la combinación de parámetros lineales y no lineales mejoraba la calidad de los resultados. Por otro lado, otros estudios dentro del ámbito de la detección temprana de epilepsia han probado enfoques aún más innovadores [8], aplicando técnicas como Bag of Words para la extracción de features no lineales y demostrando su buen funcionamiento en entornos con elevado nivel de ruido.

Otro ejemplo de la implantación del estudio de las ondas cerebrales en un proyecto Big Data es el que se puede ver en los estudios de BCI (Brain-Computer Interface), en los cuales se espera poder controlar un ordenador o un dispositivo electrónico a través del

pensamiento. A este concepto, que tanto se ha explotado en el cine, todavía le queda un largo camino por recorrer. Sin embargo, ya se están desarrollando iniciativas que se enfocan en alcanzar dicho objetivo. Lo que se pretende conseguir no se centra en generar un sistema que se limite a hacer más rápida, cómoda y eficiente la forma en la que los humanos se comunican con las máquinas, sino a mejorar la calidad de vida de aquellas personas que, por enfermedades o por accidentes, sean incapaces de comunicarse o simplemente cuenten con alguna limitación. En la introducción de este proyecto se habló sobre la afasia y los grandes avances que se están llevando a cabo en el mundo de las prótesis inteligentes. Esta motivación está generando que el número de proyectos de BCI se dispare. En su artículo, Xiang Zhang [9] hace un resumen de cómo ha avanzado este campo en los últimos años, se centra tanto en las técnicas más empleadas en el momento de publicación, como en las limitaciones de la tecnología y las barreras que deben superarse. A día de hoy, los principales problemas a los que se enfrenta son tres, el ruido, la escalabilidad y la complejidad.

Los electroencefalogramas perciben los pensamientos como impulsos eléctricos, dichos impulsos son involuntarios y los genera la mente humana de forma instintiva como respuesta frente a los estímulos que recibe. De hecho, todas las acciones del cuerpo humano generan impulsos eléctricos, desde mover un brazo a parpadear e incluso el latir del corazón crea corrientes eléctricas. En un entorno controlado y seguro se puede limitar el efecto de dichos estímulos externos, ya que las distracciones para el sujeto de experimentación se limitan y toda su atención está centrada en el proyecto. Sin embargo, si se repite el proceso en un entorno real el cerebro se verá afectado por multitud de estímulos, tanto visuales como olfativos o sonoros. Estos hechos se traducen en que las señales percibidas por el electroencefalograma se verán “contaminadas” por nuevas señales y será necesario diferenciar los impulsos que se desean estudiar del ruido.

El segundo problema radica en la escalabilidad del sistema. En apartados anteriores se ha hablado de cómo ha afectado la complejidad del experimento a la hora de obtener datos. Esto se debe a que el dispositivo de medición debe calibrarse de forma individual para cada usuario, lo que implica un elevado tiempo de preparación. Además, si en un futuro estos

dispositivos se produjesen de forma industrial, serían intransferibles de forma directa, lo que resulta negativo y reduce el interés de los inversores.

Por otra parte, la complejidad del problema planteado es enorme, no únicamente por la dificultad técnica. También se debe tener en cuenta que es un campo en el que se necesita un elevado conocimiento de campos muy distintos entre sí como son la neurología, el procesamiento de señales, Machine Learning, física y ciencia cognitiva. Para motivar a los expertos y a aquellas personas interesadas en el mundo del Machine Learning, se han presentado diversas competiciones en las que ha presentado un problema de BMI junto con un conjunto de datos y se ha ofrecido premios a los ganadores. Los resultados de estas competiciones son muy impresionantes y demuestran el potencial de esta tecnología. De hecho, existen proyectos donde se han conseguido desarrollar sistemas de comunicación básicos para personas con dificultades para comunicarse.

En los párrafos anteriores, se ha hablado de proyectos donde se realizan clasificaciones sobre las ondas cerebrales en entornos donde el flujo de los impulsos era anómalo o el usuario presentaba un deseo activo por realizar una acción concreta. Ambos casos difieren del proyecto presentado en este informe en un aspecto esencial. En este caso de uso, se espera clasificar señales en función de reacciones involuntarias. Sin embargo, no se trata de un campo inexplorado, ya que se han realizado algunos avances dentro del sector del reconocimiento de emociones a través de EEG.

Varios artículos afirman que los estados emocionales se encuentran relacionados con la actividad eléctrica del cerebro. Por tanto, es posible discernir el estado de una persona siempre y cuando se pueda estudiar dichos impulsos. Partiendo de esta base, se han realizado varios proyectos [6] donde se ha podido identificar las reacciones de los sujetos de experimentación frente a distintas imágenes. Estos experimentos han permitido realizar descubrimientos sobre la relación de los impulsos eléctricos con las emociones. En su artículo [10], Edgar P Torres habla de dichos descubrimientos y hace hincapié en las diferentes bandas de frecuencia que usan las emociones.

Band	State Association	Potential Localization	Stimuli
Gamma rhythm (above 30 HZ)	Positive valence. These waves are correlated with positive spiritual feelings. Arousal increases with high-intensity visual stimuli.	Different sensory and non-sensory cortical networks.	These waves appear stimulated by the attention, multi-sensory information, memory, and consciousness.
Beta (13 to 30 Hz)	They are related to visual self-induced positive and negative emotions. These waves are associated with alertness and problem-solving.	Motor cortex.	They are stimulated by motor activity, motor imagination, or tactile stimulation. Beta power increases during the tension of scalp muscles, which are also involved in frowning and smiling.
Alpha (8 to 13 Hz)	They are linked to relaxed and wakeful states, feelings of conscious awareness, and learning.	Parietal and occipital regions. Asymmetries reported: rightward-lateralization of frontal alpha power during positive emotions, compared to negative or withdrawal-related emotions, originates from leftward-lateralization of prefrontal structures.	These waves are believed to appear during relaxation periods with eyes shut while remaining still awake. They represent the visual cortex in a repose state. These waves slow down when falling asleep and accelerate when opening the eyes, moving, or even when thinking about the intention to move.
Theta (4 to 7 Hz)	They appear in relaxation states, and in those cases, they allow better concentration. These waves also correlate with anxious feelings.	The front central head region is associated with the hippocampal theta waves.	Theta oscillations are involved in memory encoding and retrieval. Additionally, individuals that experience higher emotional arousal in a reward situation reveal an increase of theta waves in their EEG [17]. Theta coma waves appear in patients with brain damage.
Delta (0 to 4 Hz)	They are present in deep NREM 3 sleep stage. Since adolescence, their presence during sleep declines with advancing age.	Frontal, temporal, and occipital regions.	Deep sleep. These waves also have been found in continuous attention tasks [18].

Tabla 1. Tabla extraída del artículo EEG-Based BCI Emotion Recognition: A Survey

Al igual que en el resto de los proyectos, los sistemas de reconocimiento de emociones cuanta con las fases de extracción de features y de clasificación de las señales. Dentro de la extracción, el método más utilizado es Hjorth Features, donde se usa indicadores estadísticos que miden la pendiente de las señales entre otros muchos parámetros. Este aspecto permite extraer información relevante como por ejemplo el tiempo que tarda en reaccionar el cerebro ante una imagen o la intensidad de los cambios, lo que puede ayudar a identificar momentos clave en el experimento. Otros algoritmos que se han probado en esta fase son los algoritmos genéticos, que persiguen emular el comportamiento de una población que se reproduce y muta. Este tipo de algoritmos han demostrado ser muy útiles en entornos con problemas de difícil solución, como por ejemplo el diseño de un puente para optimizar su peso o la planificación de carreteras.

Sin duda, el artículo que guarda un mayor parecido con el desarrollado en este estudio es el desarrollado por el profesor Patrick Suppes de la universidad de Stanford. En su artículo *Brain wave recognition of words* [11], el profesor Suppes intentó clasificar los patrones generados por las ondas cerebrales al procesar una palabra. Este experimento es similar al

presentado en este documento, en el sentido de que se pretende identificar una reacción inconsciente del cerebro. Es por ello, que las pautas seguidas y las conclusiones extraídas pueden ser extrapoladas al caso de uso del reconocimiento de imágenes.

En el experimento se midieron las respuestas de 7 individuos de distinta edad y nacionalidad al presentarles palabras en una pantalla. Cada sujeto repitió el experimento unas 100 veces con distintas palabras, lo que aseguró una cantidad de datos suficiente para poder implementar técnicas de análisis de datos. Por otro lado, el experimento difería ligeramente entre los individuos. En algunos casos los participantes simplemente debían mirar la pantalla, mientras que otros debían pensar en la palabra que aparecía en la pantalla, otro grupo en cambio tuvo que decir en voz alta la palabra identificada.

A partir de los datos extraídos, se calcularon las medias de las señales obtenidas para cada palabra para obtener una referencia. A continuación, se calculó la respuesta en frecuencia de las señales a través de la transformada de Fourier y se aplicaron filtros a las señales. En su artículo, el profesor Suppes señala que dichos filtros fueron seleccionados de forma individual para cada individuo, por lo que no se puede considerar un método generalizable. Una vez filtrados los datos, se devolvió la señal al espacio temporal y se extrajeron las conclusiones mediante la técnica de mínimos cuadrados, lo cual es llamativo, ya que al tener tal cantidad de datos lo lógico habría sido aplicar técnicas más avanzadas y complejas. Sin embargo, es necesario mencionar que el artículo es del año 1998 y por aquel entonces las tecnologías del machine learning todavía no habían explotado.

Las conclusiones finales presentadas en el artículo se condensan en el hecho de que los resultados obtenidos varían en gran medida en función del sujeto. Suppes indica que se obtuvieron resultados donde la tasa de acierto alcanzó el 97%. Sin embargo, para otros sujetos este porcentaje no llegaba al 40%, lo cual es comprensible teniendo en cuenta que los métodos aplicados no fueron los mismos para todos los individuos (Experimentos diferenciados, filtros personalizados, etc).

Todas las técnicas mencionadas en los párrafos anteriores cuentan con un gran potencial y podrían ser implementadas en el caso de uso de este proyecto. Sin embargo, todos los métodos implican la disponibilidad de una capacidad de computación considerable y de una ingente cantidad de datos. Mientras que el primer problema podría solventarse gracias a los recursos de la universidad, el segundo presenta un reto insalvable, ya que no ha sido posible obtener más información debido a la complejidad del proceso de extracción. Pese a ello, todas las técnicas usadas en los artículos citados han sido considerados y probados en un mayor o menor grado, adquiriendo conocimiento y experiencia en cada prueba.

Capítulo 3. DEFINICIÓN DEL TRABAJO

3.1 JUSTIFICACIÓN

Como ya se ha mencionado previamente, el objetivo de este proyecto consiste en realizar un análisis de las ondas cerebrales de distintos sujetos con el fin de ser capaces de desarrollar un modelo de clasificación capaz de identificar si estas personas reconocen una ubicación o no.

También se ha expresado el deseo de implementar este proyecto como una herramienta de ayuda para las fuerzas policiales en el desarrollo de investigaciones. Se podría considerar que el proyecto pretende desarrollar una variante del famoso polígrafo. Sin embargo, se han escrito artículos que ponen en duda su eficacia y que demuestran que pueden fallar en determinados escenarios [12]. Esta herramienta no se basa en medidas como la frecuencia cardiaca, la respiración o la dilatación de las pupilas. Aspectos que pueden ser entrenados y controlados, sino en el comportamiento del cerebro y las reacciones inconscientes de la mente humana.

Este enfoque no ha sido empleado hasta ahora en ningún país del mundo, por lo que sería una gran innovación dentro del sector y un avance enorme. Sin embargo, hay que ser conscientes de la complejidad del problema y las implicaciones éticas y legales de implementar un modelo capaz de inculpar a una persona. Estos factores dificultan tanto su desarrollo como su uso, pero, aun así, el mero hecho de profundizar en la investigación del cerebro humano justifica el esfuerzo de desarrollar el proyecto.

3.2 OBJETIVOS

El objetivo de este proyecto es el análisis de ondas cerebrales con el fin de desarrollar una herramienta sencilla y portátil que ofrezca resultados sólidos. Estos resultados consisten

en poder clasificar, con un elevado porcentaje de acierto, si el usuario ha reconocido una imagen o no. Además, se espera que el conocimiento adquirido a lo largo del desarrollo del proyecto sirva para simplificar y abaratar los costes del proceso de extracción de datos que se está llevando a cabo hoy en día

De esta forma, los objetivos de este proyecto quedan marcados de la siguiente manera:

3.2.1 ANÁLISIS DE LOS DATOS

Para poder explotar al máximo los recursos de los que se dispone, es necesario en primer lugar familiarizarse con la fuente principal de datos sobre la que se basa el proyecto.

Es la primera vez que se ha tratado con datos de este tipo y es necesario emplear un tiempo para conocer su comportamiento, detectar patrones e identificar formas de aproximarse al problema. Es más, este primer análisis puede ayudar a conocer que variables son más relevantes y aportan más información, lo que está directamente relacionado con el objetivo de abaratar los costes. Esto se debe a que cuantas menos ondas tengan que ser capturadas menor será el coste de los sensores.

3.2.2 DATA AUGMENTATION

Debido a las dificultades técnicas y logísticas que implican la obtención de los registros, la cantidad de datos disponibles es muy limitada. Para poder conseguir resultados satisfactorios en un proyecto de machine learning es necesario contar con un volumen de datos considerable, por lo que es necesario incrementar de forma drástica el número de datos disponibles. Para ello, se realizará un estudio en el que se analizaran las distintas técnicas de Data Augmentation disponibles y las modificaciones necesarias que requiere el trabajar con un tipo de dato tan particular.

3.2.3 DESARROLLO DE UN MODELO DE MACHINE LEARNING PARA LA CLASIFICACIÓN DE ONDAS CEREBRALES

En primer lugar, se realizarán pruebas que implementen las técnicas de clusterización que se han visto y trabajado a lo largo del curso y que podrían considerarse como técnicas clásicas. Esta comparativa permitirá hacerse una idea de que enfoque es más práctico para el caso de uso en cuestión y reducirá la dimensionalidad de los datos.

A continuación, se procederá al estudio de técnicas más novedosas y que se utilizan dentro del mundo de análisis de los encefalogramas. Esta fase será de una elevada complejidad, ya que implicará un estudio intensivo de las técnicas, así como de su implementación en código. Una vez desarrolladas y testeadas, se generarán modelos de clusterización para comparar que enfoque ha generado mejores resultados de cara a una futura implementación en el mundo real.

3.2.4 REVISIÓN DE LOS RESULTADOS PARA LA REDUCCIÓN DE COSTES

Como ya se mencionó en secciones anteriores, actualmente los costes de recopilar información son muy elevados. El dispositivo de medición es muy caro y requiere de una limpieza y calibración entre cada uso, lo que aumenta de forma drástica la duración del experimento.

Mediante el estudio de los resultados obtenidos en el apartado 3.2.3, se espera identificar patrones que demuestren qué campos contienen información útil y cuales son prescindibles. Así como el nivel de precisión necesaria de los sensores. Estos datos y la comparativa entre las técnicas ejecutadas será de ayuda, no solo para el proyecto en sí, sino también para proyectos futuros que surgirán a raíz del mismo.

3.3 METODOLOGÍA

Los primeros meses del proyecto se utilizaron para familiarizarse con el tipo de datos con los que se iba a trabajar. La neurología es un campo muy complejo y conocer los fundamentos del funcionamiento del cerebro humano es crítico para poder entender el proyecto y tener una visión global del conjunto. Además, conocer los tipos de ondas facilitará la comprensión de los datos.

Teniendo en cuenta que la cantidad de datos con los que se cuenta es limitada, el trabajo y la programación se realizó, en gran medida, usando R. Con esta herramienta se realizó un primer análisis básico de las variables y su comportamiento. Los valores a extraer consistieron en las componentes principales, la matriz de correlación y la distribución de los datos entre otros. A raíz de estos resultados se pudieron identificar patrones clave que fueron críticos para las siguientes fases de trabajo

El siguiente paso consistió en aplicar las técnicas más conocidas de clasificación para medir su eficiencia y obtener una imagen genérica del punto de partida. Este proceso no tenía como objetivo obtener resultados definitivos, sino recopilar información para usar más adelante y saber qué pasos se debían seguir. Como era de esperar, los resultados se encontraban muy limitados por el número de registros disponibles, por lo que el siguiente paso lógico consistía en aplicar técnicas de data augmentation.

En esta fase se realizó una investigación sobre los trabajos ya generados en este campo en los últimos años. Después de una valoración inicial, se decidió implementar las técnicas desarrolladas por W. Yang y W. Nam en su informe *Brainwave Classification Using Covariance-Based Data Augmentation* [13]. Esta parte del proceso implicó una gran cantidad de experimentación y análisis matemático tanto de las variables originales como de las artificiales.

Una vez que se tuvo un volumen de datos algo mayor, se repitieron las pruebas iniciales y se realizó una comparativa entre los resultados obtenidos durante la primera fase

y los generados con los nuevos datos. Con las nuevas conclusiones extraídas, se procedió a implementar nuevas técnicas más complejas y mejor adaptadas al caso de uso en cuestión.

Una vez que se desarrollaron los pasos anteriores, se procedió a la comparativa entre los modelos generados para medir los resultados y poder decidir de forma empírica que técnicas son más útiles y pueden aportar un mayor potencial.

3.4 PLANIFICACIÓN Y ESTIMACIÓN ECONÓMICA

3.4.1 PLANIFICACIÓN

La planificación del proyecto se estableció según se representa en la siguiente tabla. A lo largo del desarrollo del sistema se fue ajustando el calendario mediante reuniones periódicas con el director del proyecto. Dichas reuniones servían para realizar correcciones y establecer unos objetivos de tiempo coherentes con la dificultad de las metas propuestas.

	OCTUBRE	NOVIEMBRE	DICIEMBRE	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JUNIO
Familiarización con los datos y el caso de uso									
Análisis inicial con técnicas estandar									
Estudio de los proyectos de Data Augmentation con EGG									
Implementación del Data Augmentation									
Análisis inicial con los nuevos datos									
Implementación de técnicas adaptadas									
Comparativa de resultados									

Tabla 2. Planificación del proyecto

3.4.2 ESTIMACIÓN ECONÓMICA

A la hora de calcular el coste del proyecto, se debe tener en cuenta todos los elementos implicados que han sido utilizados durante el desarrollo del programa. En la siguiente tabla se puede ver cuáles han sido los principales recursos materiales invertidos en la fase de desarrollo.

Recursos utilizados	€/Ud	Uds	Total
Dell Inspiron 13 7000 Series	761	1	761
Monitor HP	139	1	139
Receptor de señales EGG	5679	1	5679
Pycharm premium	199	1	199
		Total	6778

Tabla 3. Coste económico de los recursos empleados

Modulos del proyecto	Horas	Eur/Hora	Total
Análisis inicial	50	7	350
Comparativa de técnicas de Da	75	5	375
Implementación de Data Augm	90	8	720
Análisis avanzado	90	8	720
		Total	2165

Tabla 4. Coste económico de la mano de obra

Teniendo en cuenta la mano de obra y los recursos utilizados (electricidad, emplazamiento, dietas, etc), podemos suponer que la estimación económica global asciende a unos 9.500€.

Capítulo 4. SISTEMA DESARROLLADO

Como ya se ha explicado anteriormente, el sistema desarrollado cuenta con dos funcionalidades diferenciadas, por un lado, se encuentra la reducción de la dimensionalidad de los datos y por otra parte el modelo de clasificación en sí mismo.

A pesar de ser dos elementos diferenciados, se encuentran relacionados, ya que la reducción de la dimensionalidad es un apartado crítico para la optimización del modelo.

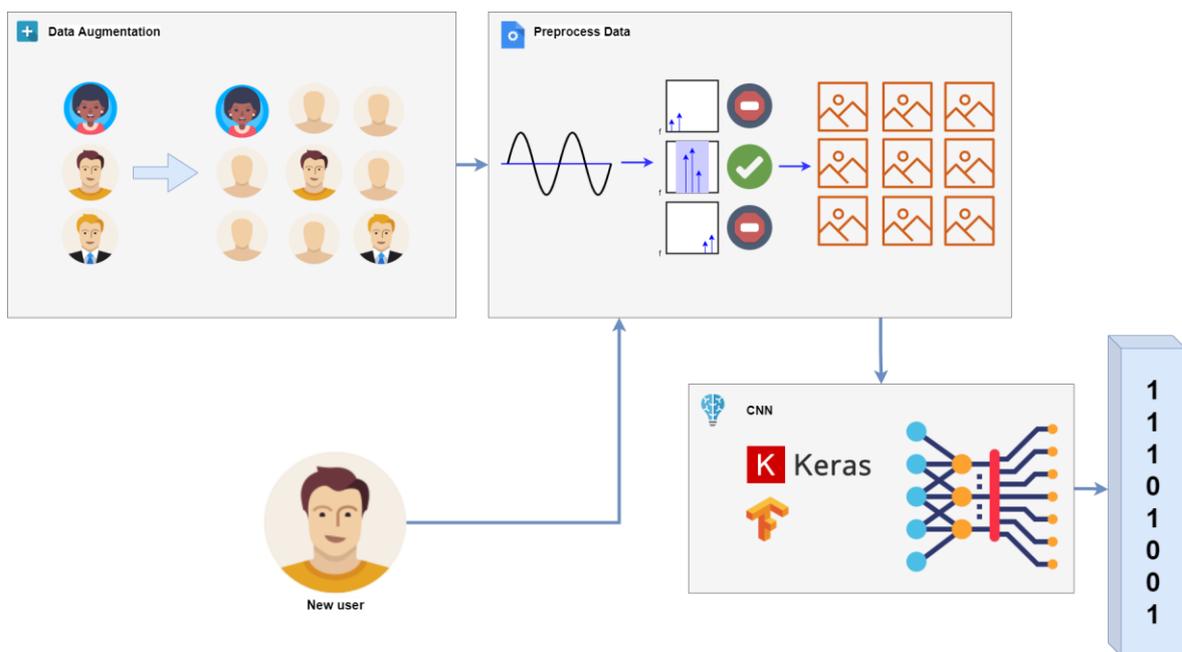


Figura 10. Diagrama del sistema

El sistema en su conjunto está compuesto por distintos módulos. Algunos de ellos se limitan al análisis de los datos, sin extraer ninguna conclusión que se implemente de forma práctica en el desarrollo del modelo. Sin embargo, una parte muy importante de este trabajo reside en el estudio y la investigación, desde distintas perspectivas, de los EEG. Por tanto, no es de extrañar que no todos los análisis sean igual de provechosos.

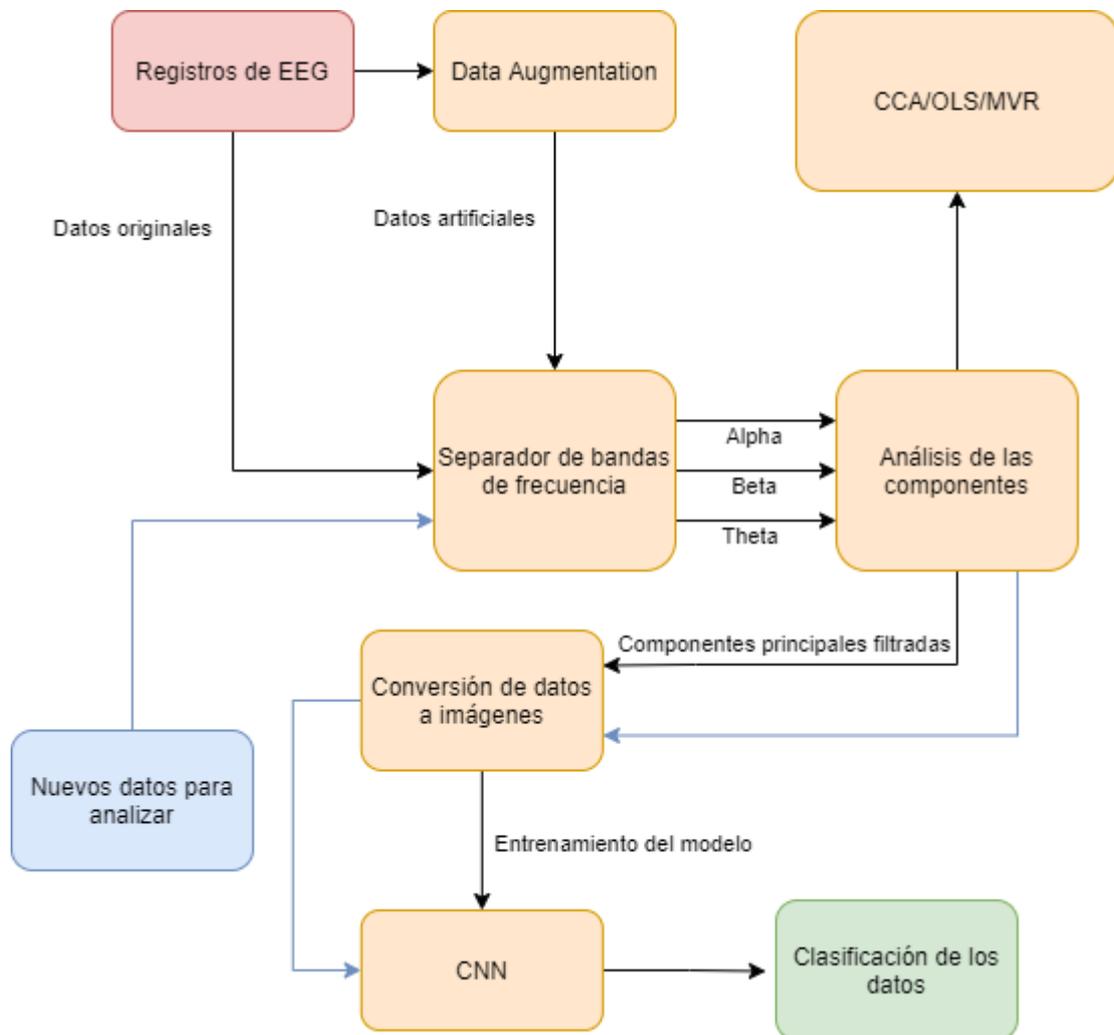


Figura 11. Diagrama del flujo de datos y la conexión entre los módulos implementados

El recuadro rojo representa el punto de partida del proyecto, los datos que fueron ofrecidos por el departamento de psicología de la universidad. El azul indica el input de la parte práctica del proyecto, los registros neuronales que se desean clasificar. Los recuadros naranjas representan los módulos más importantes por los que pasan los datos y el verde el output del modelo que decide si los usuarios han reconocido o no la imagen.

4.1 ESTUDIO PREVIO DE LAS VARIABLES PRINCIPALES

Este proyecto se basa en el análisis de los datos mediante algoritmos especializados de machine learning y, como se ha mencionado previamente, es necesario analizar los datos de los que se dispone, así como los resultados que se espera obtener, para poder seleccionar el algoritmo que mejor se adapte al modelo en cuestión. Para ello, se realizó un estudio estadístico de los datos disponibles con el fin de identificar detalles en los datos que puedan indicar el mejor camino a seguir.

Los datos de los que se dispone y sobre los que se basa el estudio son los aportados por la profesora Lucia Halty Barrutieta. Como ya se ha mencionado, los datos no son muy extensos, pero cada registro contiene multitud de variables asociadas a los distintos tipos de ondas cerebrales. Los datos están almacenados en ficheros CSV de forma que para cada sujeto existen tres archivos distintos, los dos primeros son los resultados de la imagen conocida y de la desconocida y el tercer archivo corresponde a la imagen de la escena del crimen.

Las distintas variables de cada dataset se pueden agrupar en función de la ubicación de los sensores del EEG. A continuación, se detallan las ubicaciones específicas de cada dispositivo. Para evitar un tamaño excesivo se ha decidido indicar aquellos que son considerados como más descriptivos por los expertos.

Área cerebral	Hemisferio izquierdo	Línea Media	Hemisferio derecho
Frontopolar	FP1		FP2
Frontal	F3	FZ	F2
Fronto-temporal	F7, C3	CZ	F8, C4
Temporal medio y parietal	T3, P3	PZ	T4, P4

Temporal posterior y occipital	T5 O1		T6, O2
--------------------------------	-------	--	--------

En la siguiente imagen se puede apreciar cómo se colocarían de forma gráfica. Es necesario destacar que en la imagen aparecen 32 sensores, lo que suele ser habitual en entornos médicos. Sin embargo, para los experimentos se usaron 64 electrodos distintos con la esperanza de captar información adicional. La lista completa de los sensores se puede ver en la Figura 7.

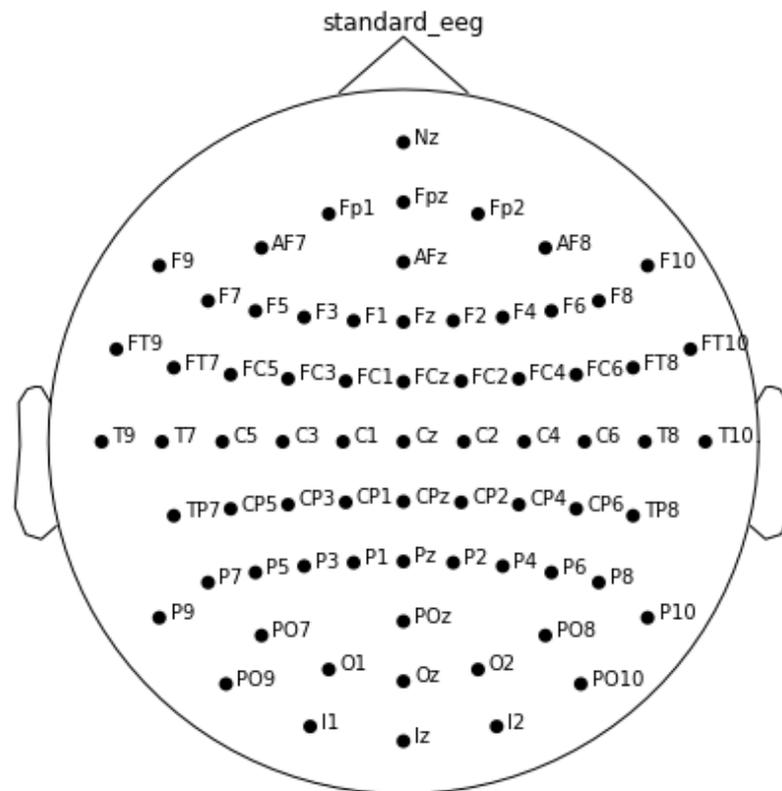


Figura 12. Gráfico de la disposición de los sensores en un EEG

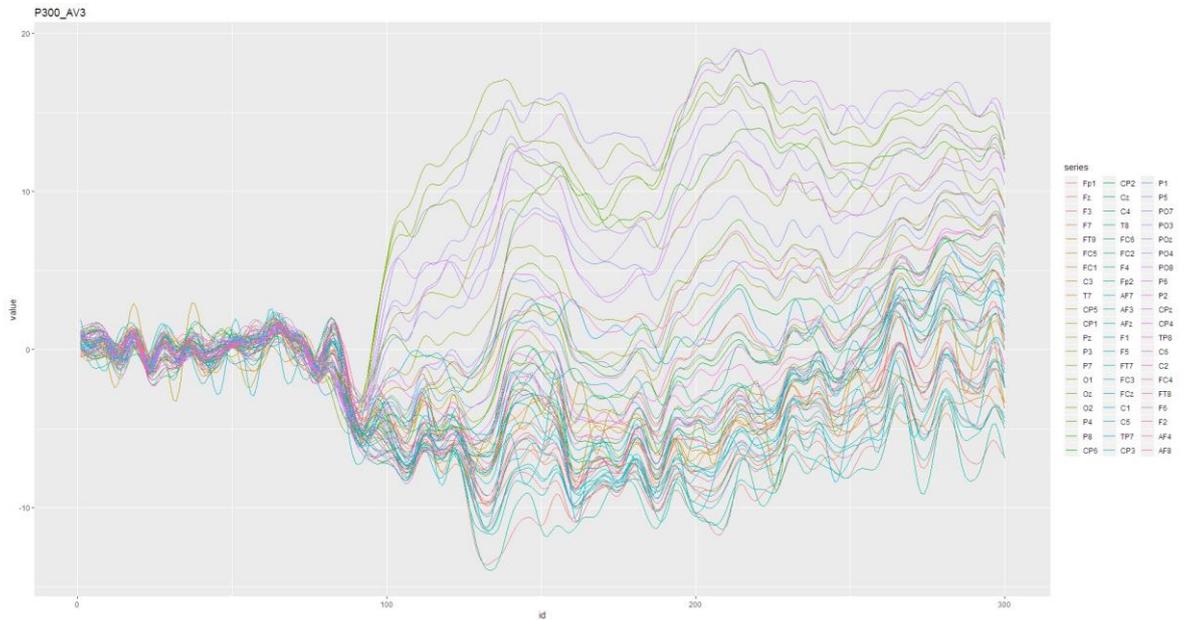


Figura 13. Ejemplo de un encefalograma

4.1.1 ESTUDIO DE LOS DATOS

Este primer estudio se llevó a cabo utilizando el lenguaje de programación R, el cual es un software abierto para computación estadística. El objetivo del análisis era familiarizarse con el contenido de los datos e identificar patrones en el comportamiento de los registros que pudiesen ser de ayuda en el futuro.

Los datos aportados no se encontraban anonimizados, por lo que se disponía de los nombres de los sujetos del experimento, por motivos obvios esta información se modificó, pero para el primer análisis se trabajó con la información de un único sujeto.

La imagen anterior demuestra como las ondas contienen un alto componente de ruido. Además, al ser una serie temporal su tratamiento y comprensión es más compleja. En un principio, se realizaron estudios básicos para entender el comportamiento de las señales. Se puede ver a simple vista el momento en el que el cerebro reacciona ante las imágenes presentadas. Este hecho demuestra que la pendiente de las señales puede contener información relevante, no únicamente para identificar el tiempo de reacción, sino para

detectar momentos críticos en las señales. Otra conclusión importante para el proyecto consiste en que se puede prescindir de la primera parte de la señal, ya que no contiene información relevante.

Teniendo en cuenta que los datos son series temporales, el extraer análisis estadísticos de las variables no parece interesante a priori, aunque más adelante se emplearon los niveles máximos y medios de las señales como variables para el entrenamiento de un modelo.

El siguiente paso consistió en calcular las matrices de correlación de los datasets. Este hecho fue crítico para el desarrollo del proyecto debido a que se descubrieron distintos patrones en las matrices que separaban a unos sujetos de otros.

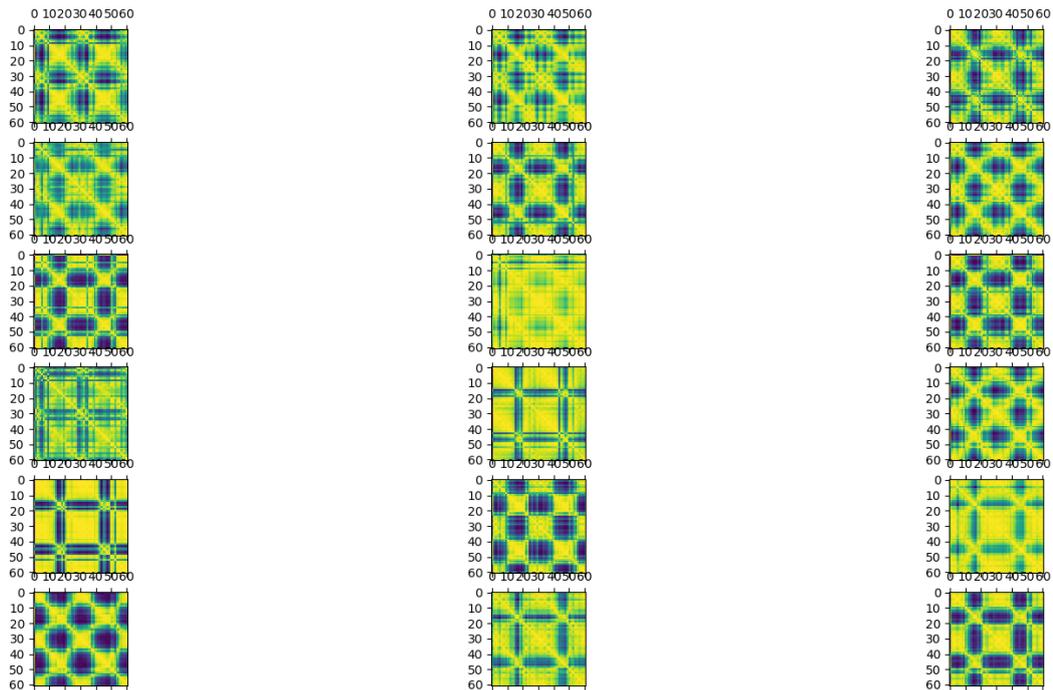


Figura 14. Conjunto de matrices de correlación

Como se puede ver, existen 4 patrones diferenciados en las matrices. En un principio se consideró que este hecho era una simple casualidad. Sin embargo, experimentos posteriores demostraron que la realidad era muy distinta.

El primer grupo contiene las primeras 4 muestras, la quinta y la undécima, siendo el grupo más grande de los detectados. El segundo clúster este compuesto por la cuarta, la sexta, la octava y la decimoséptima. En cuanto al tercer grupo, lo conforman las imágenes pares desde el diez hasta el 16, ambos incluido y el resto de las imágenes pertenecen al cuarto grupo.

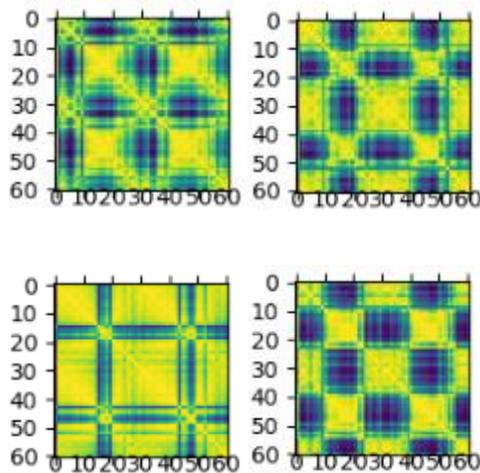


Figura 15. Patrones detectados en las matrices de correlación

Estas clasificaciones fueron clave para el proceso de Data Augmentation debido a que las técnicas aplicadas generaban resultados confusos al utilizarlas sobre la totalidad de los datos, pero al aplicar las distinciones halladas en este apartado las conclusiones fueron considerablemente más satisfactorias.

El siguiente paso consistió en analizar la importancia de las señales para poder realizar un filtrado. Este paso es crítico, ya que la cantidad de señales del dataset original dificulta en gran medida el manejo de los datos y la extracción de conclusiones. En primer lugar, se midió la densidad de las señales para comprobar si a simple vista existían señales

con aspectos similares entre sí. Como se puede apreciar en la siguiente imagen, el comportamiento de las señales se puede clasificar en unos pocos grupos. De hecho, si se comprueban los nombres de las señales y la ubicación de los electrodos en la imagen presentada al principio de la sección 4.1, se puede ver como las señales con los sensores más próximos entre sí tienen una densidad similar.

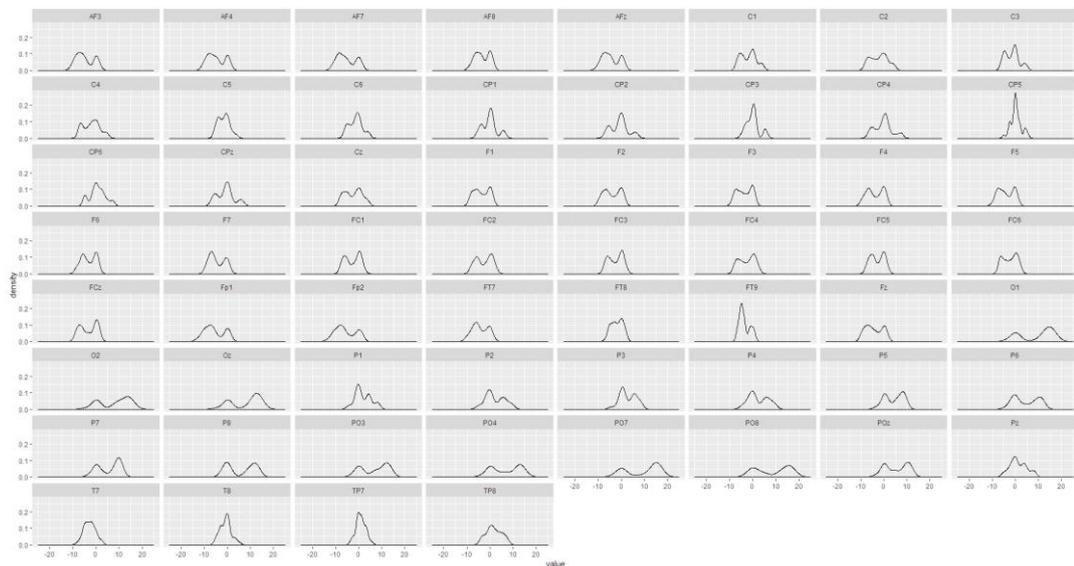


Figura 16. Densidad de las señales

Este hecho es una buena noticia, ya que indica que, efectivamente, la dimensión del conjunto de datos se puede reducir de forma significativa.

Para poder medir de forma efectiva la eficacia de las señales se aplica la técnica de PCA (Principal Component Analysis). Este método es utilizado 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 reducir la dimensionalidad de un conjunto de datos. Teniendo en cuenta la similitud hallada entre las densidades de las señales, es de esperar que la variabilidad del conjunto pueda ser descrita por una pequeña cantidad de señales. Es importante destacar el

hecho de que esta técnica modifica la base de los datos, por lo que las componentes también varían.

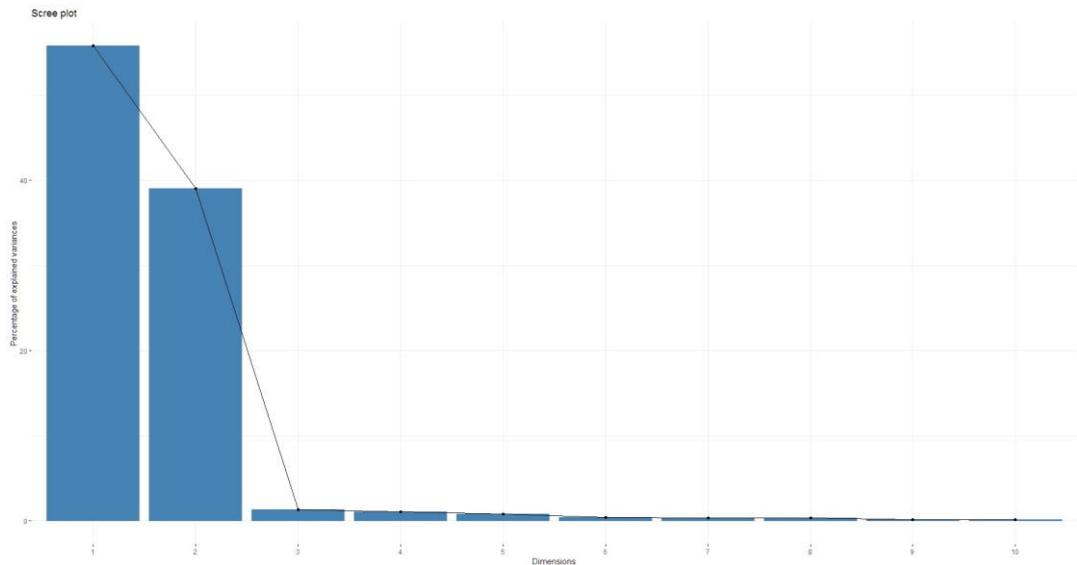


Figura 17. Resultado del PCA

Como se puede ver en la imagen superior, las dos primeras componentes explican en gran medida la variabilidad de los datos. De hecho, el resto de las señales de forma conjunta ni siquiera se acercan a la magnitud de las primeras. Este hecho demuestra que la dimensionalidad del conjunto se puede reducir drásticamente. A continuación, se muestra la representación gráfica de las dos primeras componentes.

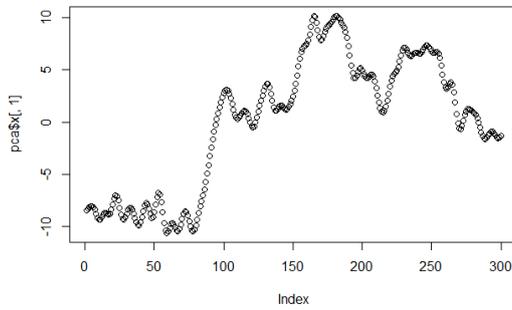


Figura 18. Representación de la primera componente principal

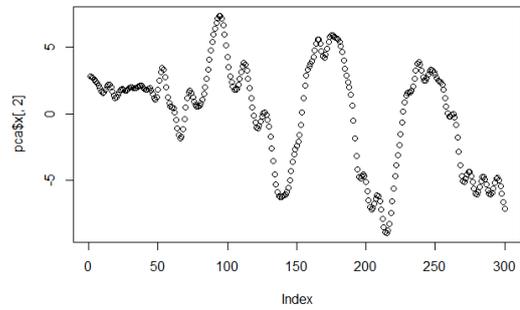


Figura 19. Representación de la segunda componente principal

De forma adicional, también se midió la aportación de cada variable sobre las componentes. Es llamativo el hecho de que las ondas que aportan más información en la primera componente sean también las mismas que son ignoradas en la segunda.

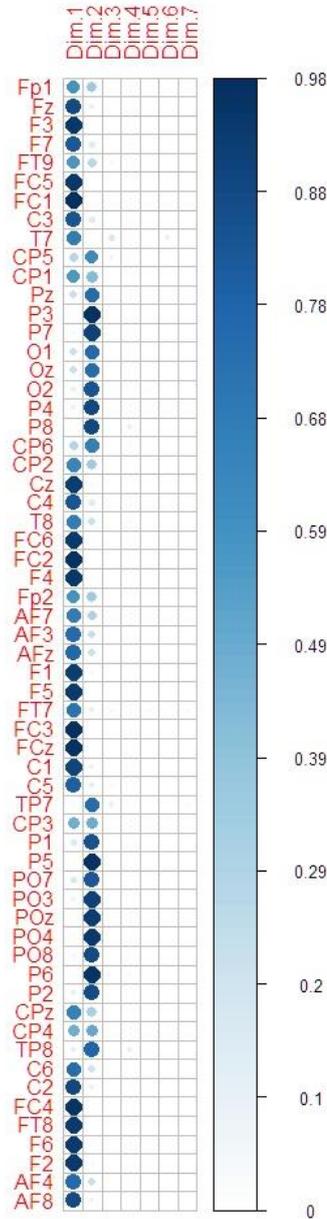


Figura 20. Aportación de cada señal a las componentes principales

Otro aspecto útil de PCA es la representación de las variables en función de las componentes principales. Este método permite identificar agrupaciones de datos sobre los que se puede utilizar técnicas de *clustering* como *kmeans* o incluso redes convolucionales para la detección de imágenes. Este último método requiere de una gran cantidad de datos,

pero en ocasiones se pueden identificar similitudes en las formas a simple vista. Un ejemplo de las representaciones extraídas es la siguiente figura.

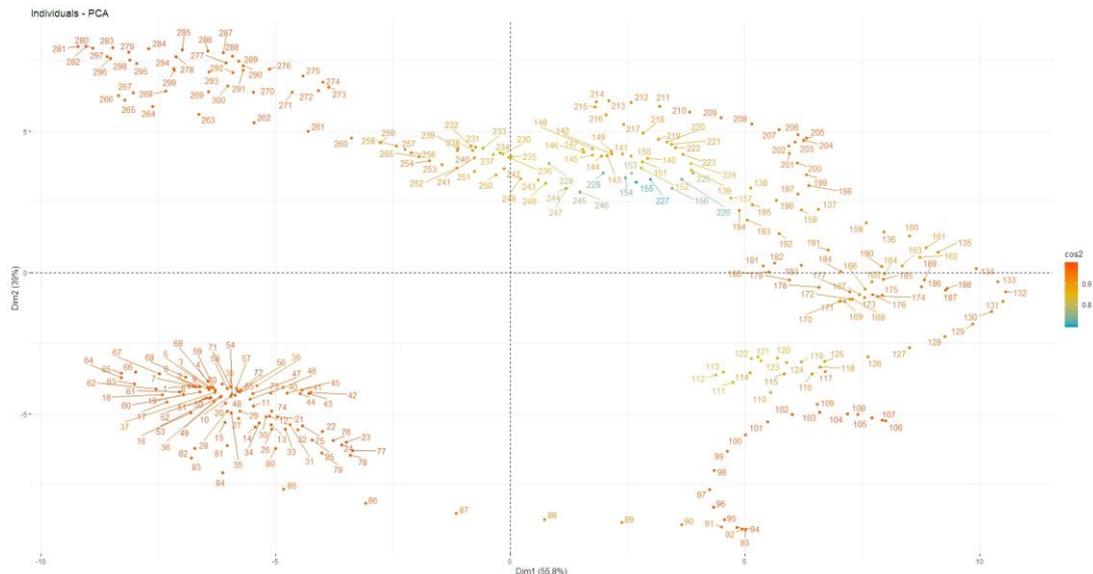


Figura 21. Representación de las señales sobre las 2 primeras componentes principales

Otro aspecto que se consideró relevante para el estudio de los datos es la respuesta en frecuencia de las señales. Las bandas de frecuencia típicas para los adultos son 1-3 Hz para las Delta, 4-7 Hz para las Theta, 8-12 Hz para las Alpha, 12-24 Hz para las Beta y 24-100 Hz para las Gamma [14]. En el caso de los niños estas bandas de frecuencia suelen ser más bajas. Sin embargo, teniendo en cuenta que el estudio se llevó a cabo con personas de mediana edad, se puede considerar estas bandas como correctas.

A la hora de estudiar la frecuencia se utilizaron los datos ya filtrados, es decir, se eliminaron los datos de la cola izquierda de la señal donde no había información relevante. Como se puede apreciar en la siguiente imagen, la intensidad de las señales varía bastante, pero la frecuencia de la señal es bastante baja. Es cierto que existen colar, pero se puede asumir que se debe al ruido generado por impulsos o estímulos externos al experimento.

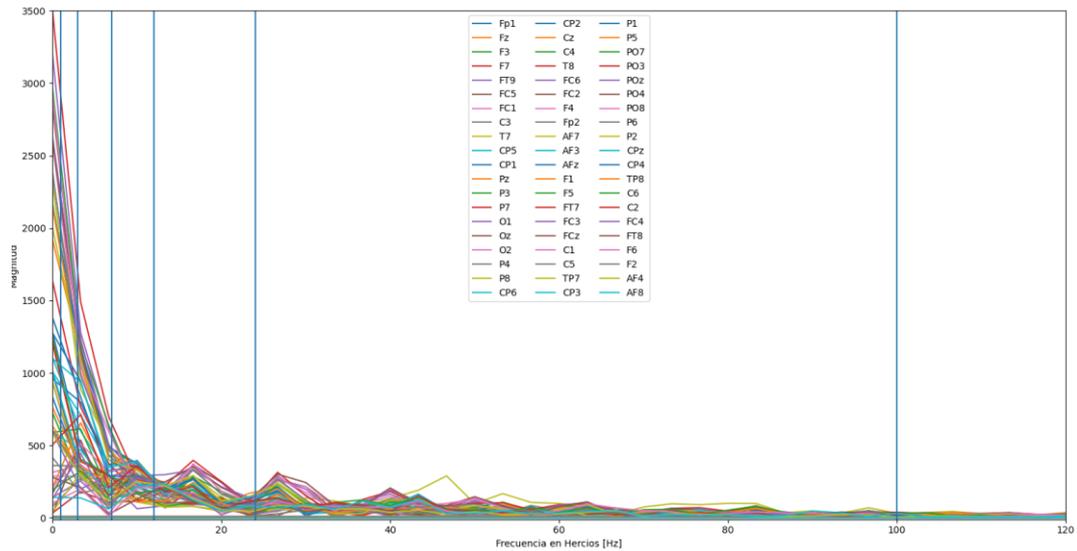
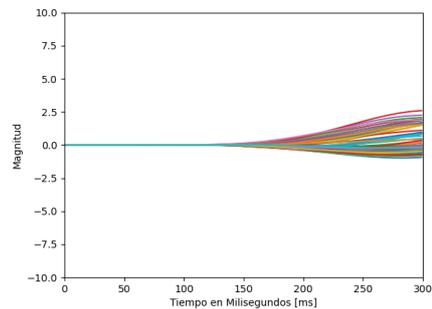
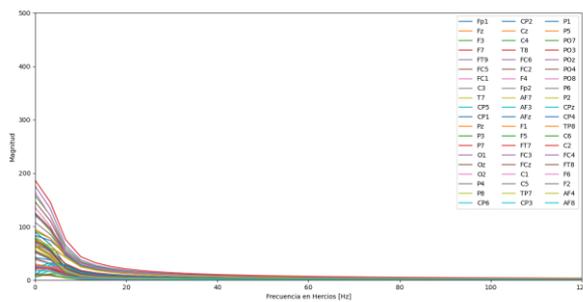
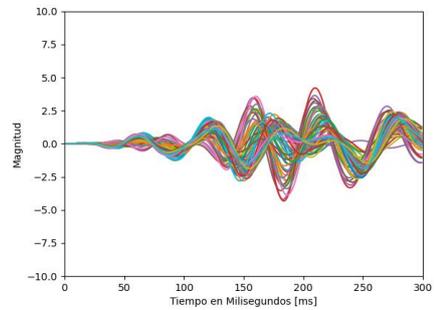
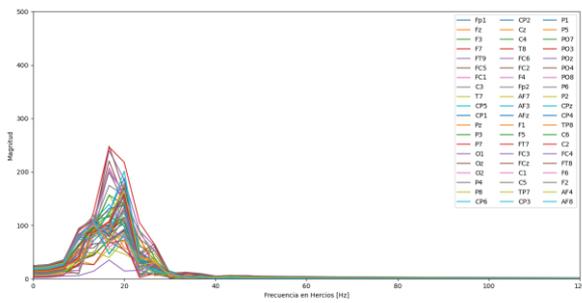
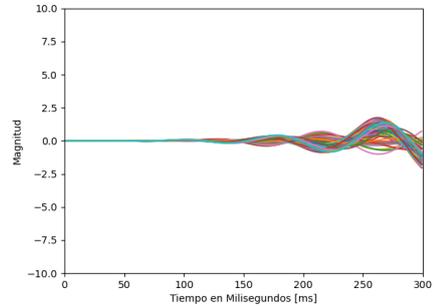
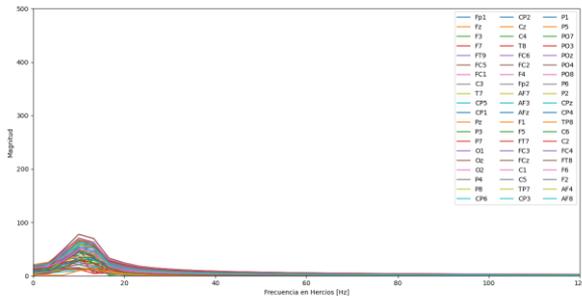
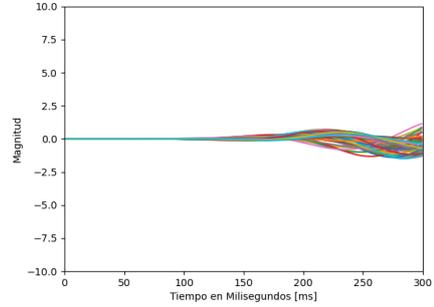
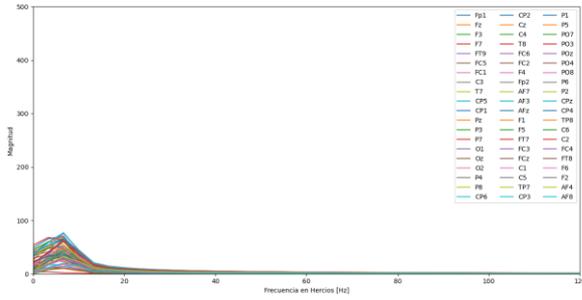


Figura 22. Respuesta en frecuencia del EEG y bandas de frecuencia

En el proyecto del profesor Patrick Suppes [11] se habla de la utilización de filtros paso banda de orden 4 para el preprocesado de los datos, por lo que se decidió seguir el mismo concepto con la esperanza de poder identificar resultados interesantes más adelante. En las siguientes imágenes se puede ver la respuesta en tiempo y en frecuencia de las señales tras haber aplicado filtros sobre las bandas de frecuencia. El orden de aparición de arriba abajo es Delta, Theta, Alpha, Beta y Gamma, la frecuencia se encuentra en la columna de la izquierda y la respuesta temporal a la derecha.





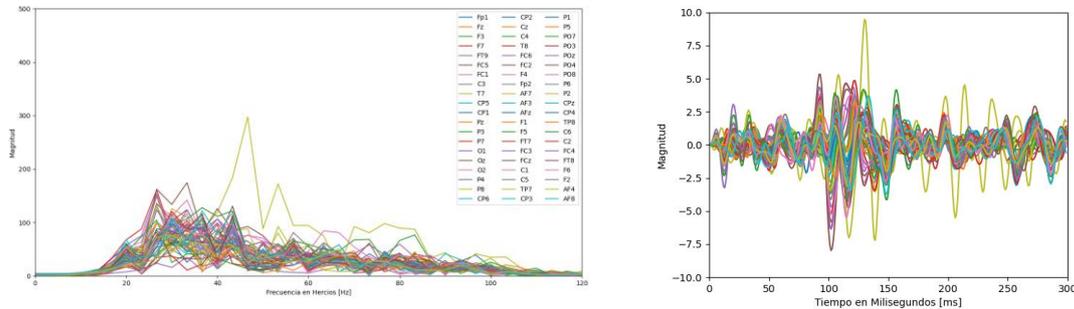


Figura 23. Respuesta en tiempo y frecuencia según el tipo de ondas

Como se puede ver, los resultados se diferencian bastante en función de las bandas de frecuencia. En el caso de las ondas Delta, el filtro ha dejado las señales con más energía del espectro. Sin embargo, al ser un filtro de orden 4 la componente continua ha sido eliminada. Al devolver la señal al marco temporal, se puede ver como no hay respuesta hasta pasados 150 ms aproximadamente. A partir de ese momento las señales se estabilizan rápidamente entorno a distintos niveles. Este hecho implica que este tipo de ondas no tiene mucha información, pero puede ser interesante estudiar el nivel de las señales en función de la imagen presentada.

Las ondas Theta tienen un comportamiento en frecuencia similar a las Delta, con la diferencia de que en este caso los máximos alcanzados son menores. Respecto a la representación en tiempo, se empieza a ver cierta oscilación en las señales, pero los resultados siguen siendo bastante estáticos.

Las Alpha tienen un margen de frecuencias muy similar al de las Theta, lo cual explica que su representación en frecuencia sea muy similar, pero a diferencia de en el caso anterior, ahora la respuesta temporal empieza a adquirir la forma de un conjunto de senoidales ligeramente desfasadas.

Las ondas beta presentan un comportamiento diferente al resto de las analizadas hasta ahora. Por un lado, la amplitud en frecuencia es considerablemente superior al de las ondas Theta o Alpha, prácticamente triplicándolas en algunos casos. Estos picos pueden ser críticos para el análisis de las señales, ya que pueden ser utilizados para identificar cuál de los

sensores genera más información. En cuanto a la respuesta temporal, es más compleja que en los casos anteriores, lo cual indica que se podrá extraer más datos y se podrán realizar más pruebas. Sin embargo, es necesario mencionar que, a diferencia de en los casos anteriores, las variaciones en la señal empiezan alrededor de los 50 ms, lo cual indica que el filtro ha permitido pasar parte de la cola izquierda de la señal, la cual corresponde a los milisegundos anteriores a que el cerebro reaccionase a la imagen presentada.

En cuanto a las ondas Gamma, cuentan con el margen de frecuencias más amplio de todos, por lo que es razonable que esta banda sea también la que más ruido deja pasar, sobre todo teniendo en cuenta que en las ondas Beta ya se comenzaba a entrever parte del ruido de la señal. Al analizar el espectro se puede ver como una de las señales en particular (T7) alcanza un pico de frecuencia alrededor de los 50 Hz. De hecho, al estudiar la respuesta temporal se ve como la misma onda alcanza la máxima amplitud, por lo que puede ser relevante estudiarla en profundidad

4.1.2 CONCLUSIONES DEL ESTUDIO

Al finalizar el análisis de la fuente principal de datos de este proyecto se pueden extraer las siguientes conclusiones:

- La cantidad de sensores empleada en el experimento es excesiva y debe ser filtrado. Esta conclusión se apoya, no únicamente en los datos presentados hasta ahora, sino también en los casos presentados en el estado de la cuestión, donde el número de sensores empleados nunca superó los 30 dispositivos.
- Existen claras diferencias en la forma en la que se relacionan las ondas en función de los sujetos, por lo que seguramente será necesario aplicar distintos filtros y técnicas para cada uno de los grupos identificados.

- Muchas señales se encuentran altamente correlacionadas y, por tanto, pueden ser sustituidas por combinaciones lineales de las demás.
- Al utilizar distintas bandas de frecuencia y aplicar filtros con pendientes pronunciadas la complejidad de las señales se reduce considerablemente, por lo que puede ser óptimo centrarse en los datos post-filtrado.
- Las ondas Gamma contienen un elevado nivel de ruido en comparación con el resto de las señales. Esto no implica que no contengan información, pero su estudio y tratamiento será más complejo.

4.2 REDUCCIÓN DE LA DIMENSIONALIDAD

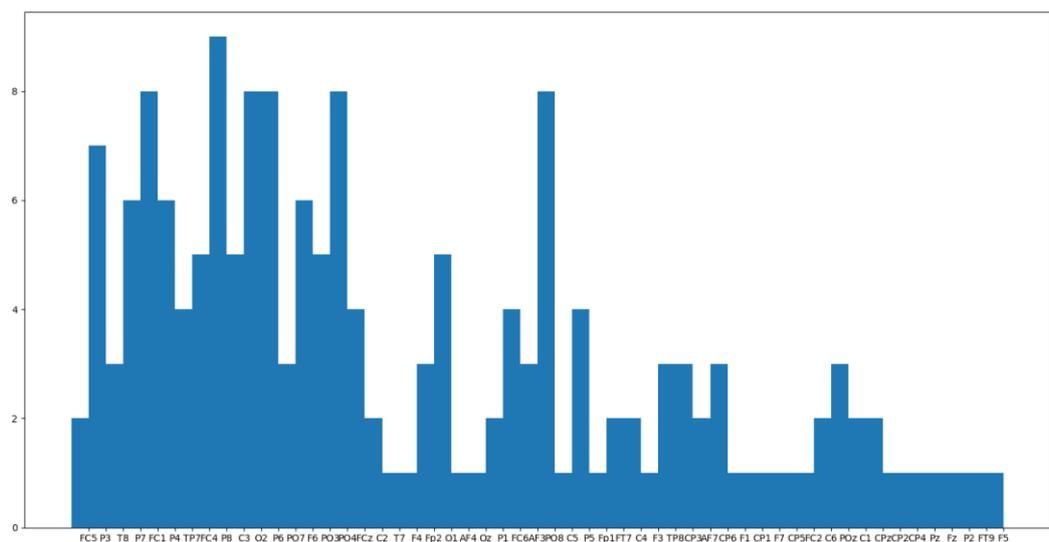
4.2.1 PRINCIPAL COMPONENT ANALYSIS

El paso lógico a la hora de reducir la dimensionalidad de los datos es implementar el análisis de las componentes principales. En el apartado anterior, se demostró como las señales pueden ser representadas en un porcentaje muy elevado utilizando únicamente un par de combinaciones lineales de las señales originales. Sin embargo, es necesario estudiar previamente si la base de cada registro es similar o si los mismos sensores son igual de relevantes para cada sujeto.

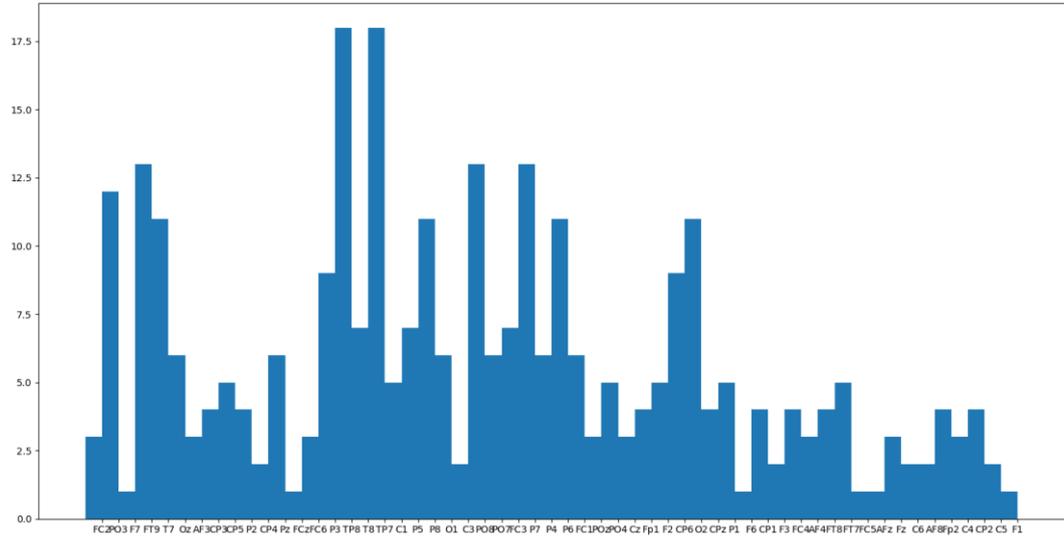
Aprovechando las conclusiones extraídas en el estudio inicial, se decidió que lo mejor sería centrarse en las bandas de frecuencia que generaron mejores resultados. Es decir, las ondas Alpha, Beta y Theta. Es por ello, que se aplicó la reducción de dimensionalidad sobre cada uno de estos casos. Dado que el hecho de que datasets distintos tengan la misma base al aplicar PCA, se decidió estudiar simplemente que sensores describían en mayor medida la información de cada caso. Para ello, se desarrolló un programa capaz de identificar que variables eran más útiles para cada dataset y se generó un histograma que agrupaba los

resultados obtenidos por cada banda de frecuencia. El programa mencionado, devolvía tantas variables como fuesen necesarias hasta que el conjunto de las señales fuese capaz de explicar el 95% de la variabilidad de los datos.

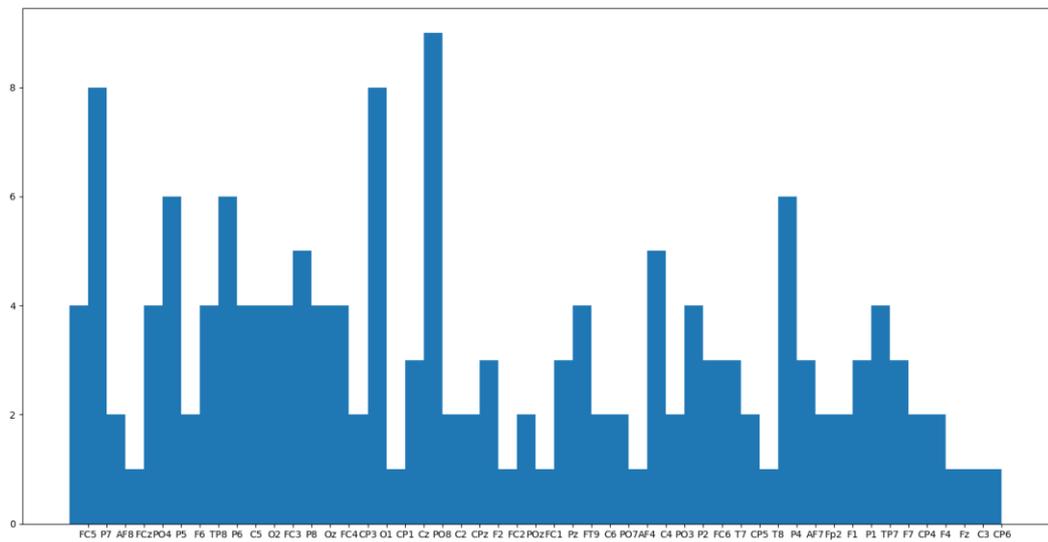
Como se puede ver en las siguientes gráficas, existe una gran variedad entre los sensores más relevantes. Es cierto que existen máximos que indican que hay sensores que suelen ser más explicativos que el resto, pero al analizar las agrupaciones generadas para cada sujeto se vio como estos sensores no aparecían en todos los casos, por lo que no se puede utilizar únicamente los máximos como elementos descriptores del conjunto.



Gráfica 1. Histograma de PCA para ondas alpha



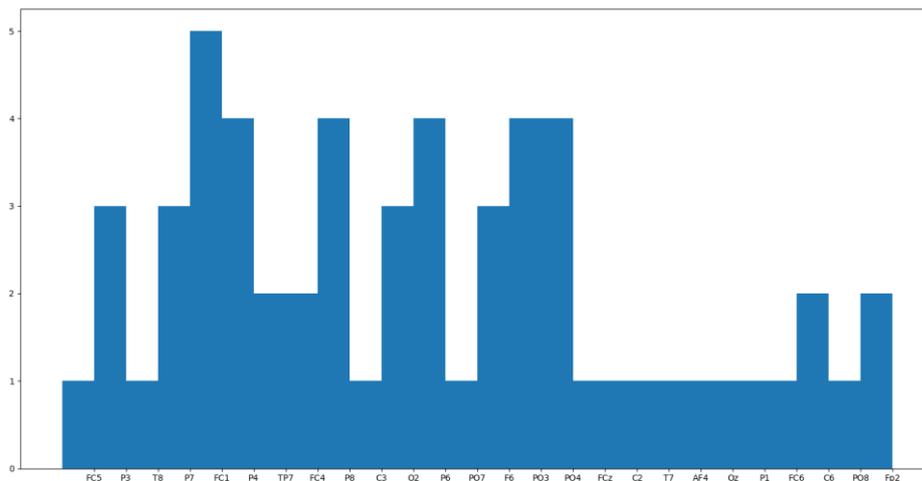
Gráfica 2. Histograma de PCA para ondas beta



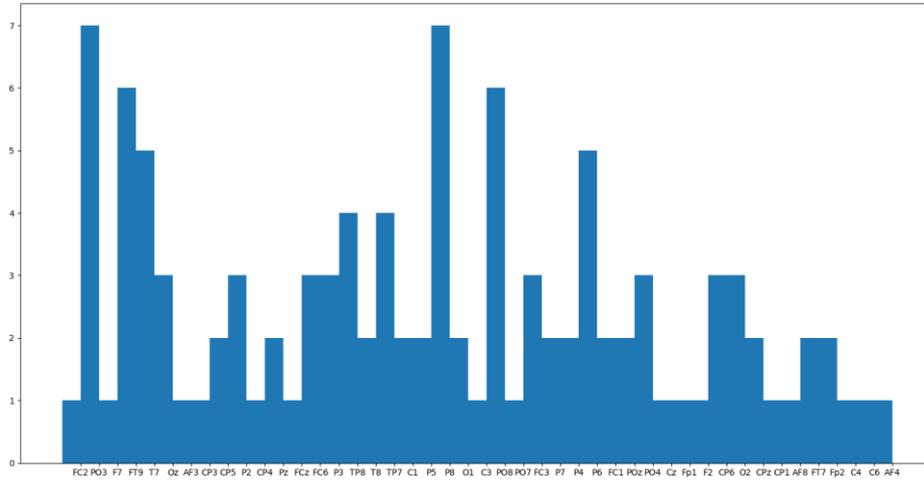
Gráfica 3. Histograma de PCA para ondas theta

Cada uno de los histogramas ha considerado 54, 56 y 50 componentes respectivamente, por lo que no se puede considerar que se haya reducido la dimensionalidad de forma relevante.

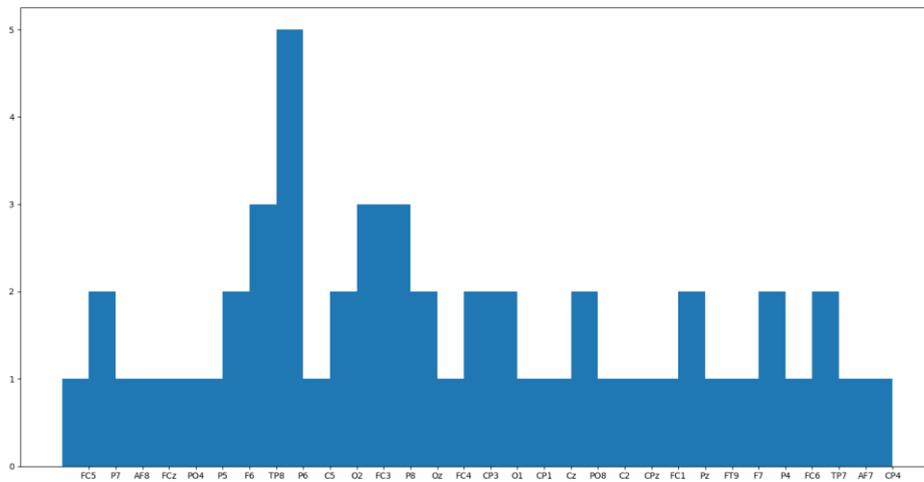
Tras la obtención de estos resultados se decidió probar otro enfoque distinto. Basándose en las conclusiones del apartado anterior, se puede suponer que las señales de los sujetos cuyas matrices de correlación eran similares también tendrán otros aspectos comunes. Al representar los histogramas siguiendo este nuevo enfoque se obtuvieron los siguientes resultados. Para no excederse en el número de imágenes, se muestran únicamente los resultados relativos al primer patrón de matrices.



Gráfica 4. Histograma de PCA para ondas alpha dentro del primer cluster



Gráfica 5. Histograma de PCA para ondas beta dentro del primer cluster



Gráfica 6. Histograma de PCA para ondas theta dentro del primer cluster

Se puede apreciar a simple vista como el número de las componentes seleccionadas se ha reducido considerablemente. Aun así, sigue sin ser posible seleccionar únicamente aquellas variables que han alcanzado los máximos debido a las mismas razones que en el caso anterior.

En un gran número de estudios dentro del campo del BCI se ha hecho hincapié en la realidad de que, en muchos casos, no es viable obtener unos resultados o unos procedimientos generalizables para la población en general, o al menos aún no. También señalan que, a menudo, es necesario aplicar técnicas específicas para cada sujeto, pero en estos casos se suele tener una gran cantidad de datos relativos a cada persona, lo cual no es la situación de este estudio, donde únicamente se cuenta con 3 muestras de cada individuo. Teniendo en cuenta las limitaciones a las que se debe hacer frente, el único enfoque viable es utilizar únicamente aquellas variables que hayan sido identificadas dentro de cada cluster. De esta forma, el conjunto de datos reduce ligeramente su dimensionalidad y adquiere el siguiente aspecto.

		Banda de frecuencia		
		Alpha	Beta	Theta
Patrones de la matriz de correlación	Primer Patrón	FC1, P4, P8, P6, PO3, PO4, P3, P7, O2, F6, TP7, FC4, C6, Fp2, FC5, T8, C3, PO7, FCz, C2, T7, AF4, Oz, P1, FC6, PO8	PO3, P8, FT9, PO8, T7, P6, TP8, TP7, Oz, P2, FC6, P3, FC3, PO4, CP6, O2, CP5, Pz, T8, C1, P5, O1, P7, P4, FC1, POz, CPz, FT7, Fp2, FC2, F7, AF3, CP3, CP4, FCz, C3, PO7, Cz, Fp1, F2, CP1, AF8, C4, C6, AF4	P6, TP8, FC3, P8, P7, F6, O2, Oz, CP3, O1, PO8, Pz, P4, TP7, FC5, AF8, FCz, PO4, P5, C5, FC4, CP1, Cz, C2, CPz, FC1, FT9, F7, FC6, AF7, CP4
	Segundo Patrón	P3, O1, P5, P8, CP3, PO7, PO8, F6, FT7, CP6, FC6, F4, Fp2, P6, FC4, PO3, AF3, C5, Fp1, TP7, C4, PO4, AF7, F1, T8, FC1, C1, FT9, F5	TP8, P7, TP7, O2, T7, F2, Pz, PO3, T8, Fp1, PO8, P1, CP6, CP1, F3, P3, PO7, P4, F6, CP3, Oz, FC3, AF4, FT8, FC4, P5, Cz, P2, Fp2, CP4, Fz, C4, P8, FC2, FT9	O1, PO8, F2, C6, P2, C5, FC5, FC2, P8, AF8, O2, POz, PO7, AF4, C4, PO3, Pz, P5, T7, CPz, T8, C2, FT9, P7, PO4, CP4, Cz, CP6
	Tercer Patrón	O2, C3, PO4, P6, POz, O1, FCz, P8, FC1, PO8, FC2, P4, C1, TP8, P7, T8, C4	O1, O2, P7, PO7, PO8, TP7, FT8, CP6, TP8, FC1, C1, P1, FT7, FT9, C5, AF3, PO4, Fz, P4, C6, FC2, P6, FC3, P5, Oz, CP3, T8, PO3, AF8, C4, Fp2, AF4, CP2	P7, O1, F1, P1, P5, F4, PO4, F7, Cz, P6, TP7, POz, FC5, Fp2, TP8, FC3, FC6, PO3, FC4, PO8, Oz, CP5, C3
	Cuarto Patrón	AF3, CPz, FC5, CP2, P1, CP4, P3, Pz, Fz, CP6, P2, F6, TP8, P5, AF7, C2, P4	TP7, P3, CP2, CP5, CPz, FC3, Fz, CP3, F2, C3, F1, Pz, T8, CP6, FC1, P5, Cz, TP8, T7, P7, P11	P4, P2, T7, P8, F2, Oz, C5, O2, Fz, P1, C4, FC4, FT9, AF7, TP7

Tabla 5. Tabla de dimensionalidad después del análisis PCA

Es cierto que la tabla no ofrece información clara a no ser que se cuente con el conocimiento necesario para interpretar los nombres de los sensores. Sin embargo, si se puede apreciar como el número de variables se ha reducido significativamente. Incluso en aquellos casos donde la reducción parece menor, el número de features ha descendido un tercio. Además, hay que destacar que los casos en los que la reducción de la dimensionalidad no ha sido tan significativa hacen referencia a los grupos con más casos y a la banda de frecuencia beta, la cual es la más compleja de las seleccionadas.

4.3 DATA AUGMENTATION

El gran problema sobre el que gira todo el proyecto es la limitada cantidad de datos disponibles. Como ya se ha explicado en secciones anteriores, recopilar datos provenientes de electroencefalogramas es una tarea muy compleja y sensible que requiere unos cuidados y una calibración especial para cada usuario. Por este motivo, la cantidad final de registros se limita a unas pocas decenas.

Esto provoca que la cantidad de datos conseguida sea muy inferior a la recomendada por diversos estudios y trabajos del campo de *Deep Learning*. En estos estudios se aconseja 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.

$$\text{Mín datos} = 5 * n^{\circ} \text{ sensores} * f$$

Desde una perspectiva más tangible, esto implicaría que usando 32 sensores y muestreando a 250 Hz., que es un valor muy frecuente en este campo, el valor de referencia debería ser de $32 * 250 = 8000$. A partir de ahí se determina que el número de muestras para el conjunto de entrenamiento debería por lo menos alcanzar los 40 000 datos.

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

recopilaban información referente a sus ondas cerebrales. Siguiendo la regla definida en el parámetro anterior, esto implicaría que el conjunto de entrenamiento debería contar con un mínimo de 80.000 datos por cada usuario.

$$\text{Min datos} = 5 * 64 * 250 = 80.000 \text{ datos}$$

Siguiendo esta progresión, en total se debería contar, solo para entrenamiento, con un total de 4 320 000 de datos. Es muy complicado obtener semejante cantidad de muestras debido a las innumerables complicaciones que acarrea el proceso de recogida de datos, donde intervienen factores que provocan, con gran facilidad, que la lectura sea errónea o los valores inválidos. Además, aunque no llegaran a producirse estas situaciones, está demostrado que los experimentos de larga duración de ondas cerebrales tienden a reducir la calidad de los datos [13]

Dado que la cantidad de datos no es suficiente para obtener un modelo fiable, se ha llevado a cabo una búsqueda de metodologías para ampliar la cantidad de datos. Estas son las llamadas técnicas de *data augmentation*. Estas técnicas resultan de vital importancia a la hora de entrenar un modelo de estas características, independientemente del tipo de datos a tratar o la finalidad última del modelo.

Sin embargo, es cierto que estas técnicas varían mucho en función del tipo de dato a tratar. Por ejemplo, de cara a tratar imágenes, es suficiente con hacer pequeñas rotaciones, escaldos, recortes o variaciones de color, ya que en sus primeras etapas de entrenamiento las interpretará como imágenes idénticas, y sólo más adelante comenzará a distinguir las pequeñas diferencias. Este proceso con imágenes resulta sencillo y fácil de comprender. A pesar de ello, los datos de ondas cerebrales son mucho más complejos. Por ello, de cara a aumentar los datos requeridos en este proyecto, el procedimiento es mucho más laborioso, ya que hay que garantizar que todos los datos nuevos obtenidos satisfacen las características de una onda cerebral.

Para lograr unos datos cohesionados y válidos en el contexto estudiado, se han seguido las directrices de [13], artículo en el que se detalla el procedimiento a seguir para

lograr *data augmentation* en el campo de los encefalogramas El proceso descrito consta de los siguientes pasos: FFT (*Fast Fourier Transform*), Selección del rango de frecuencias que aglutina la información relevante, normalización, y síntesis de los datos.

4.3.1 TRANSFORMADA RÁPIDA DE FOURIER (FFT)

Este proceso ya se llevó a cabo con anterioridad y los resultados fueron presentados en el estudio inicial. Sin embargo, en esta sección se pretende profundizar en el concepto y justificar las herramientas utilizadas para la extracción de los datos. Además, al tener que tratar los distintos grupos de datos de forma diferente, se tuvieron que repetir algunos de los procesos previos.

La transformada rápida de Fourier es más conocida por sus siglas, provenientes del nombre inglés: FFT. Este algoritmo calcula la Transformada Discreta de Fourier (Discrete Fourier Transform – DFT) o su inversa. (IDFT) Esta operación se caracteriza por descomponer los valores de una señal en sus valores a diferentes frecuencias, es decir, convierte una señal del dominio del tiempo, al de la frecuencia.

El problema de la DFT reside, principalmente, en su complejidad, lo que se traduce en un gran tiempo de computación. En este contexto 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.

En esta ocasión se va a realizar en Python, empleando las herramientas de las librerías *Spacy* o *Numpy*, que vienen ya preparadas para realizar este tipo de operaciones de forma sencilla.

4.3.2 SELECCIÓN DE LAS FRECUENCIAS RELEVANTES

En su estudio, los profesores Wonseok y Woochul indican la importancia de eliminar aquellas componentes que no aportan información concluyente al estudio, una vez se haya completado la conversión a frecuencia. La nomenclatura que utilizan consiste en caracterizar 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 apartados anteriores, estas son las señales que se consideraron que podían ser más útiles.

La argumentación presentada en el estudio para justificar el filtrado de información se basa en que, en imágenes de ondas cerebrales, frecuencias muy elevadas o reducidas no aportan información al estudio, y tienden a ser iguales independientemente del tipo de onda a considerar. Por ello, de cara a conseguir una clasificación óptima, el rango seleccionado se encuentra entre 8 Hz. y 30 Hz. [15].

Es importante señalar que este proceso debe realizarse sobre el espectro de la señal y no sobre el campo temporal. Esto se debe a que el proceso de síntesis de datos se basa en generar variaciones sobre la señal original. Si dichas variaciones se implementasen directamente sobre la representación temporal, se generarían nuevos picos de frecuencia que no encajarían en las bandas de frecuencia del trabajo.

4.3.3 NORMALIZACIÓN DE LA SEÑAL

Este paso es relativamente sencillo, y tiene como finalidad reducir el efecto general que pueda tener la componente continua de cada una de las ondas, destacando con mayor fuerza las variaciones a lo largo de la misma.

Este procedimiento se ha realizado a partir de la misma librería utilizada para la FFT, ya que contiene herramientas destinadas para ello.

4.3.4 SÍNTESIS DE DATOS

Este es, probablemente, el paso más complicado y específico de este procedimiento. El objetivo final de todo este apartado es lograr un dataset artificial que tenga características similares al original, de forma que la correlación entre distintas componentes se mantenga respecto a aquellas del conjunto de datos original. Para ello, se debe garantizar que la matriz de covarianza de los datos originales (Σ) sea igual a la matriz de covarianza de los datos sintéticos (Σ_C).

Cada uno de los puntos originales del dataset ($Y \in R^{k \times N}$, donde k es el número de características y N el número de puntos) se puede definir de la siguiente manera. Siendo $y^{(i)}$ el dato i comprendido en Y , tenemos que

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

donde u representa la componente media y $v^{(i)}$ es la componente estocástica.

El objetivo es generar un dataset artificial, caracterizado como $Y_C \in R^{k \times n}$, es decir, con igual número de características que el original, pero distinta cantidad de datos. En este nuevo conjunto de datos, cada uno de ellos se representará como

$$y_C^{(i)} = u + v_C^{(i)}$$

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:

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

En ella, 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 se calculan de forma diferente aplicando las siguientes ecuaciones, donde l_{qq} son los componentes de la diagonal principal y l_{pq} los elementos en fuera de 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 (Σ). Con esta ecuación se completaría el proceso total de cálculo de dataset aumentado.

Cabe destacar, que la componente media del dataset se debe calcular como *ensemble average*, es decir, considerando varios sistemas idénticos en un momento determinado.

Con este procedimiento matemático finalizaría la creación del nuevo dataset. El proceso total, se resume de manera más gráfica en Figura 24, obtenida directamente del trabajo de Wonseok y Woochul [13].

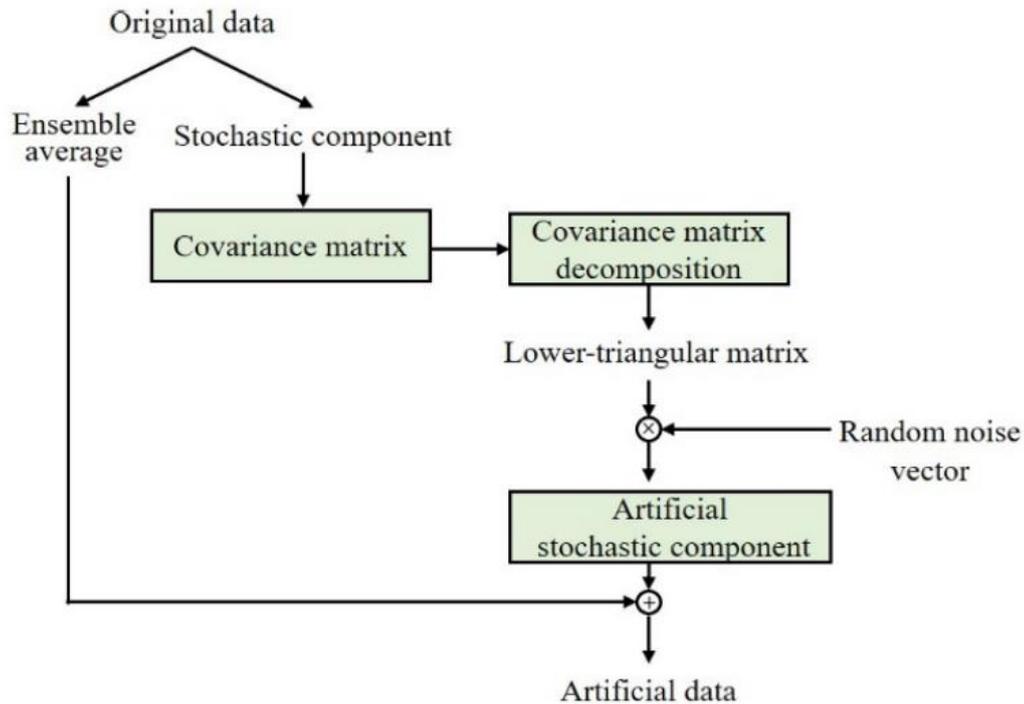


Figura 24. Representación gráfica del proceso de síntesis de datos.

4.3.5 RESULTADOS OBTENIDOS

Una vez implementados todos los pasos del proceso, se obtuvieron las siguientes señales. Como se puede ver, el programa ha funcionado correctamente y ha generado nuevos datos sin modificar la matriz de covarianza de los mismos.

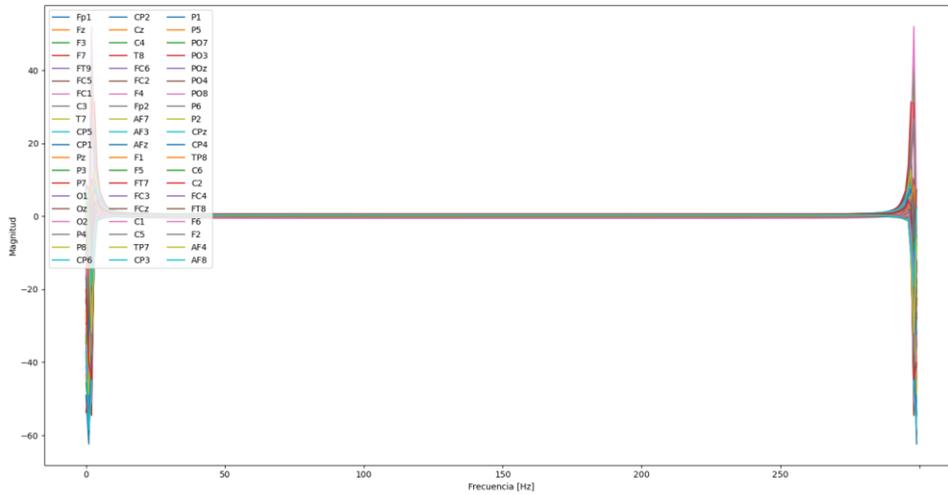


Figura 25. Ejemplo de la respuesta en frecuencia original de las ondas Theta

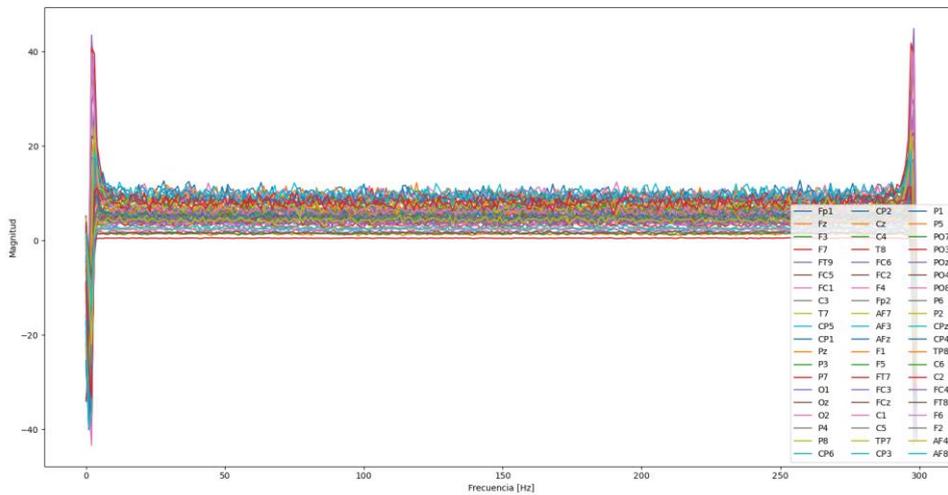


Figura 26. Ejemplo de la respuesta en frecuencia de los datos generados para las ondas Theta

Se puede ver claramente como se ha introducido ruido en la señal, para confirmar que la señal no se ha distorsionado en exceso, se aplicó la transformada inversa con el fin de representar la respuesta temporal.

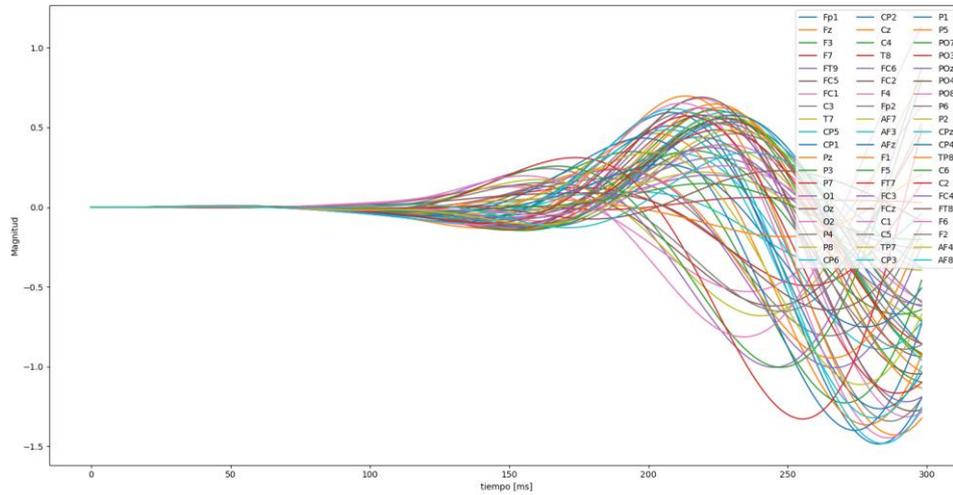


Figura 27. Ejemplo de la respuesta temporal original de las ondas Theta

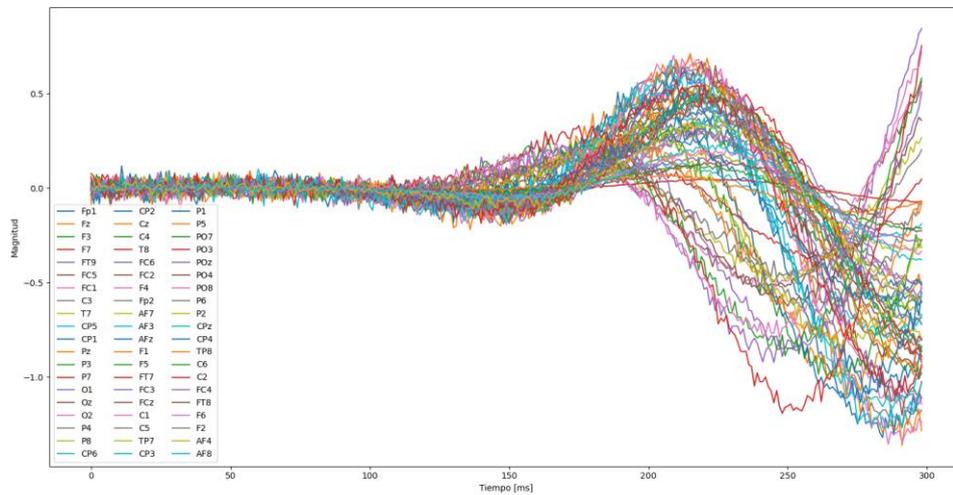


Figura 28. Ejemplo de la respuesta temporal de los datos generados para las ondas Theta

Se puede ver cómo tanto la forma como la magnitud de la señal se han mantenido constante, por lo que se puede considerar que los datos generados son válidos y se puede proceder a incorporarlos a la base de datos original.

4.4 APLICACIÓN DE ALGORITMOS

Una vez que los datos han sido limpiados y se han generado nuevos registros para aumentar el volumen del dataset, se puede comenzar la implementación de las distintas técnicas de machine learning para analizar los datos y generar modelos capaces de clasificar las señales. Como ya se mencionó en apartados anteriores, los datos han sido divididos en función de las bandas de frecuencia, por lo que en todos los casos presentados a continuación se han aplicado las técnicas sobre cada grupo y se han comparado los resultados obtenidos. Todo ello con el fin de adquirir conocimiento sobre el comportamiento de las señales que pueda aplicarse en proyectos futuros.

4.4.1 CANONICAL CORRELATION ANALYSIS

Canonical Correlation Analysis o PCA, 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 [16].

Cuando se está trabajando con un conjunto de datos, la variación de los parámetros se suele expresar a través de la matriz de covarianza o de la matriz de correlación. Sin embargo, 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. En el libro de James Ramsay se utiliza el ejemplo de mediciones atmosféricas en distintos puntos de Canadá para identificar similitudes entre los distintos emplazamientos geográficos y localizar qué ubicaciones pueden usarse para generalizar las predicciones.

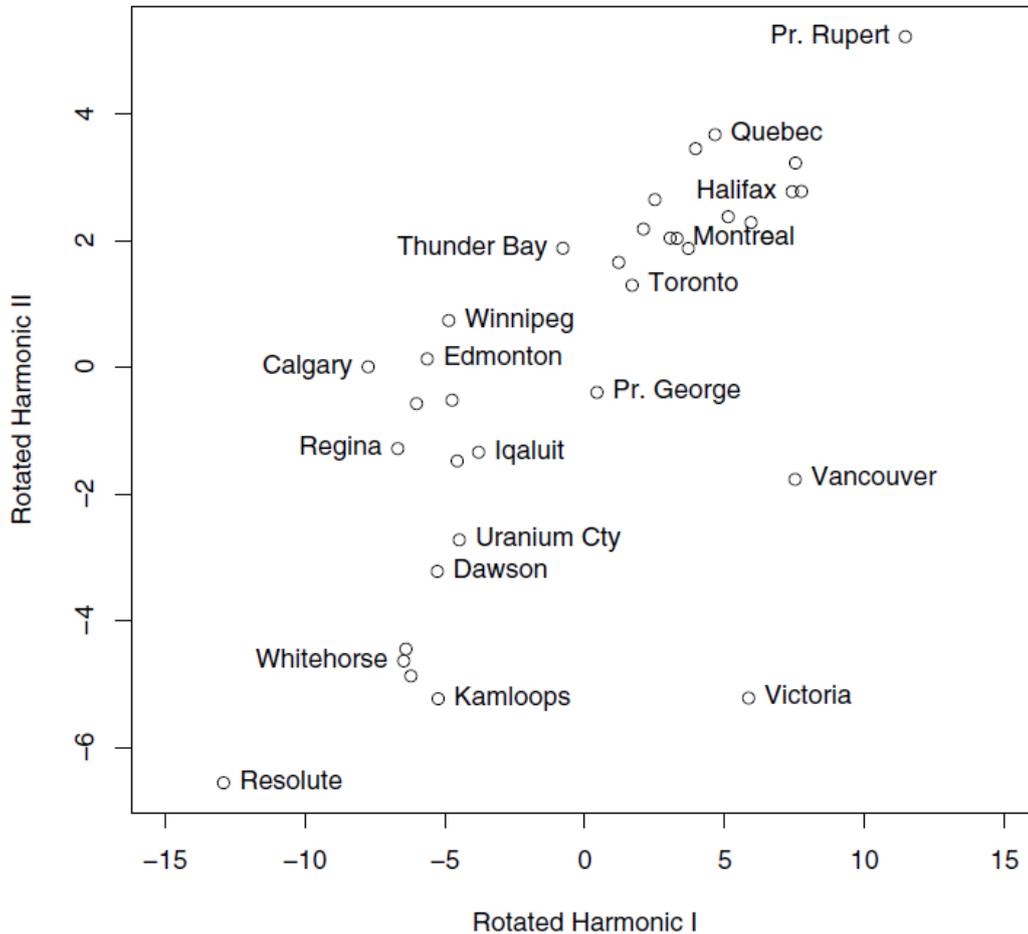


Figura 29. Imagen extraída del libro *Functional data analysis in matlab and R* de James Ramsay

Como se puede ver, las ubicaciones han sido localizadas en función de las dos primeras componentes, de forma similar a como se haría al aplicar PCA sobre un único set de datos. 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:

$$U_i = a_1Y_1 + a_2Y_2 + \dots + a_mY_m$$

$$V_i = b_1X_1 + b_2X_2 + \dots + b_nX_n$$

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.

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. Sin embargo, al realizar las pruebas iniciales 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.

Tras aplicar el algoritmo, se obtuvieron los *scores* de cada componente y se procedió a su representación gráfica. 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 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).

Es importante señalar que, a pesar de representa únicamente un caso, se ha buscado un ejemplo representativo y todas las conclusiones presentadas a continuación surgen del análisis comparativo de todos los casos disponibles.

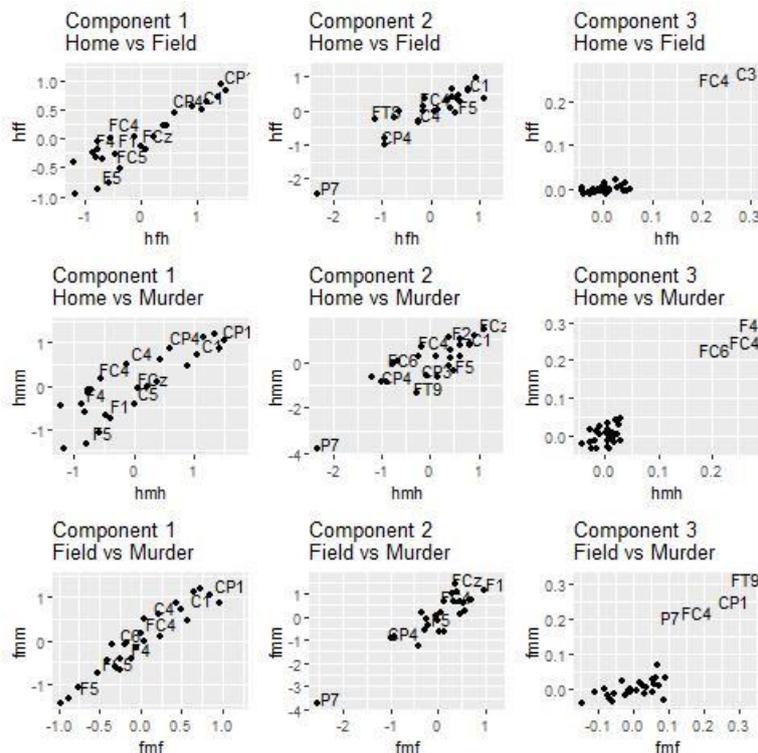


Figura 30. Ejemplo de CCA sobre ondas Theta

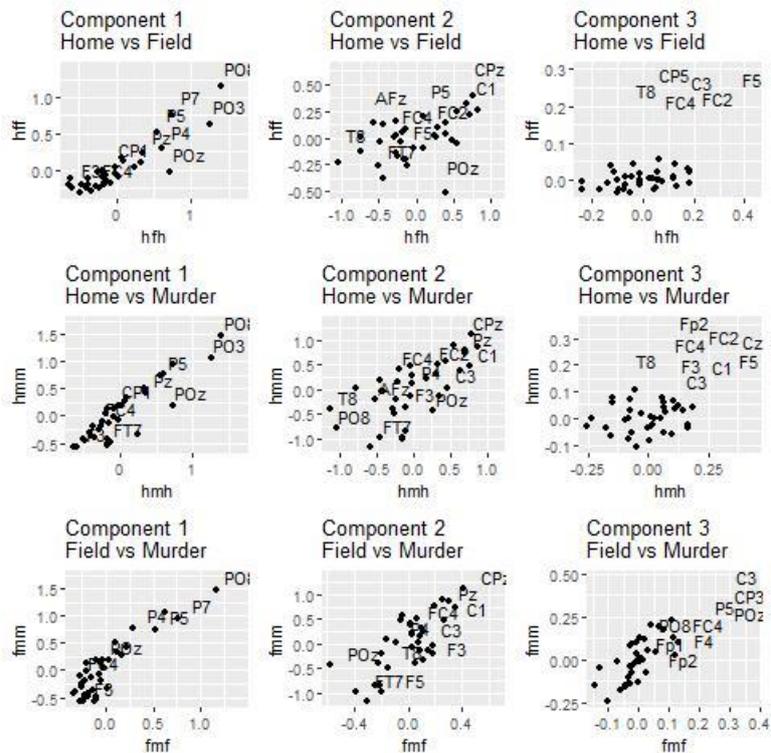


Figura 31. Ejemplo de CCA sobre ondas Alpha

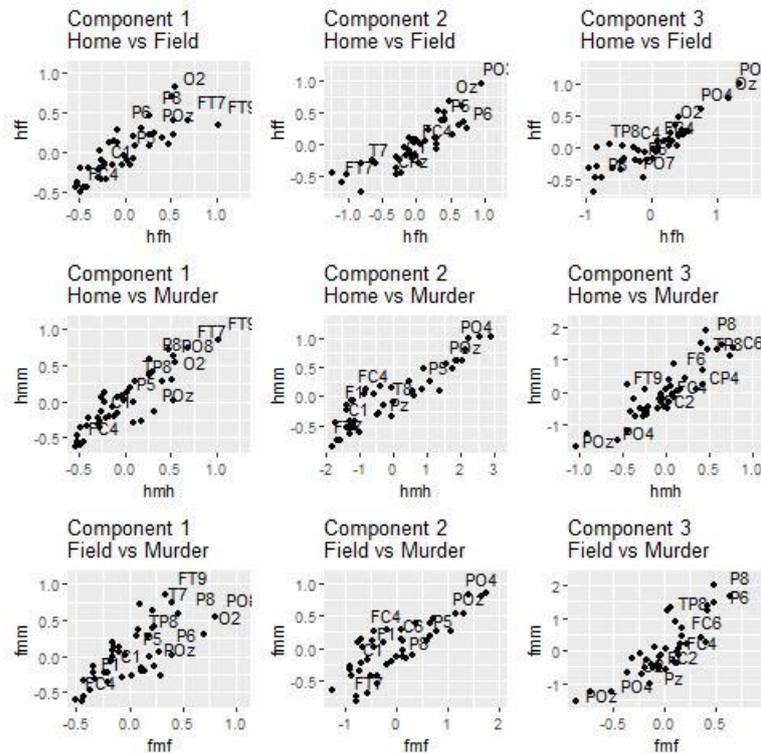


Figura 32. Ejemplo de CCA sobre ondas Beta

A primera 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 como 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.

A continuación, se clusterizaron los resultados para poder obtener medidas empíricas que apoyasen las conclusiones extraídas. Para ello se optó por emplear el algoritmo *kmeans*.

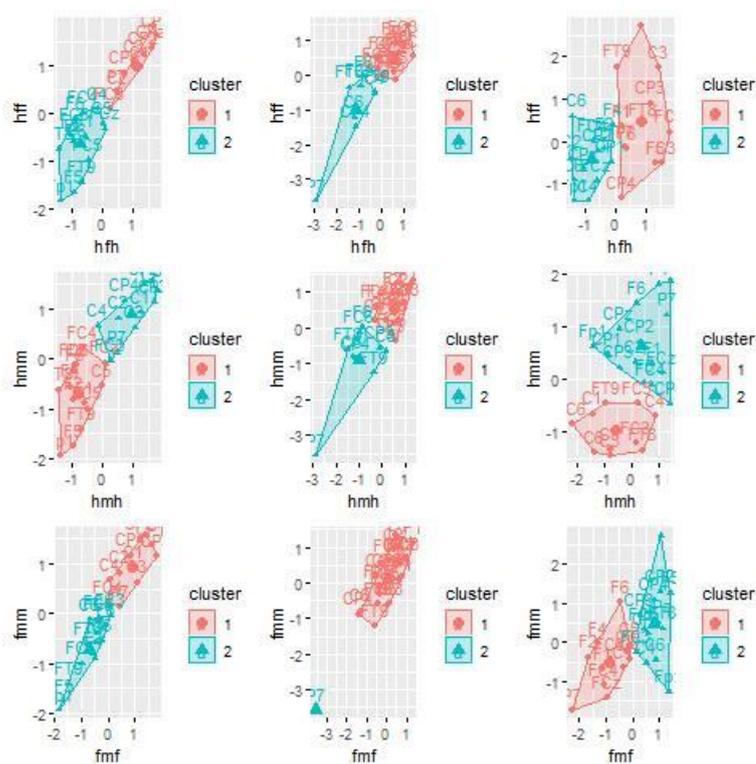


Figura 33. *K-means* sobre CCA de ondas Theta

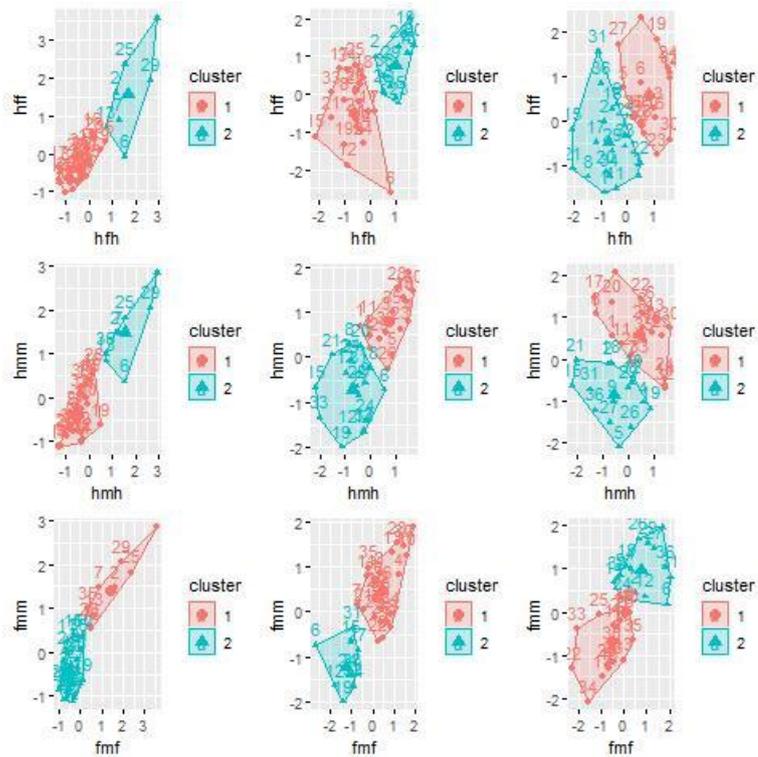


Figura 34. K-means sobre CCA de ondas Alpha

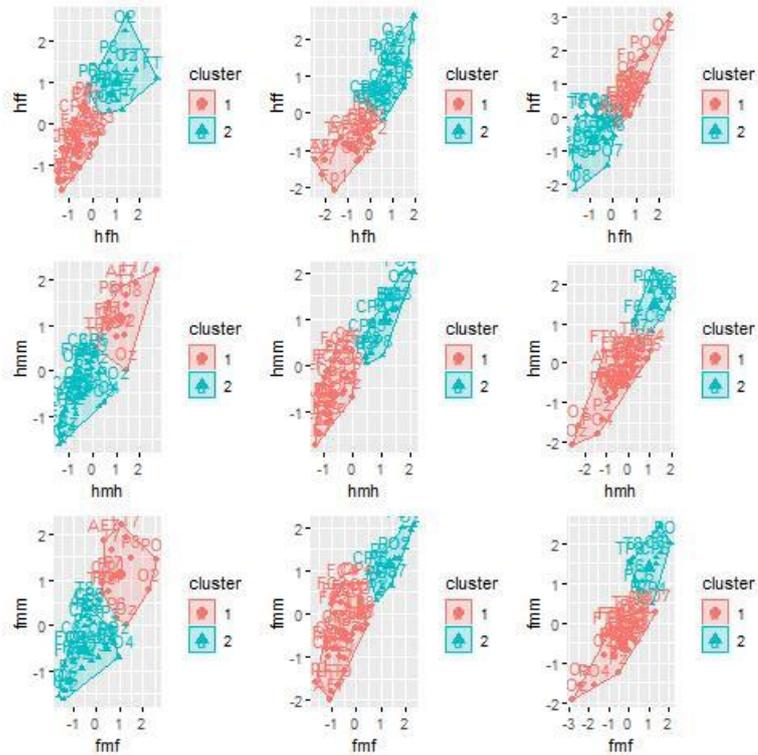


Figura 35. K-means sobre CCA de ondas Beta

Se puede apreciar como las imágenes han variado con respecto a los resultados representados inicialmente. Este hecho se debe a que al implementar *kmeans*, se aplica una normalización sobre el conjunto de los datos en el que las variaciones de las componentes con un rango mayor son consideradas más relevantes que las de rango menor.

A raíz de los resultados obtenidos se identificó un problema crítico. Al igual que como ocurría en el análisis de las componentes principales, las bases empleadas no coinciden entre los distintos datasets de datos, por lo tanto, las conclusiones no son generalizables entre unos casos y otros. Como mucho, es posible realizar una estimación sobre el resultado de la tercera imagen en base a patrones identificados en el resto de las combinaciones. Por ejemplo, la similitud entre la primera y la segunda imagen en la tercera componente de la Figura 30 podría indicar que ambas reacciones corresponden a un evento conocido-desconocido, lo cual descartaría a dicho sujeto como sospechoso. Sin embargo, este comportamiento no se encuentra presente en todos los casos, por lo que no se puede confirmar su veracidad.

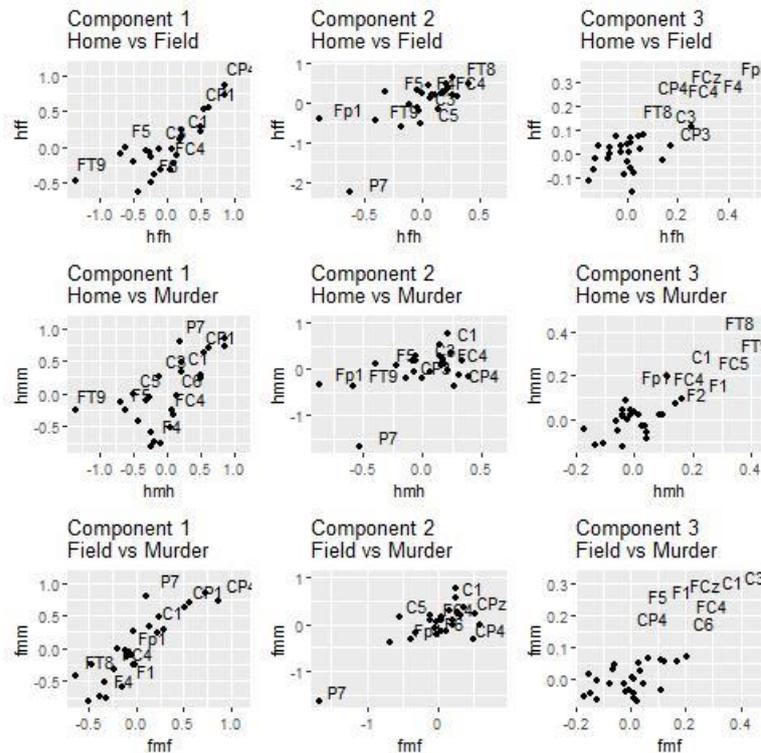


Figura 36. Ejemplo de CCA donde no se cumple la condición

Por todas estas razones, se decidió que este enfoque no resultaba absolutamente obvio en este caso en particular. Sin embargo, 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.

4.4.2 CONVOLUTIONAL NEURAL NETWORK

A lo largo del proyecto, se ha comprobado que uno de los principales problemas reside en el manejo de los datos. La arquitectura que sigue la información obliga a que cada dataset sea tenido en cuenta en su conjunto de forma global o lo que es lo mismo, los resultados surgen a raíz de la relación de todas las señales entre sí y, por tanto, deben analizarse en su conjunto.

A día de hoy, no existen técnicas capaces de comparar dataframes de la misma forma en la que se comparan los registros de un dataset clásico. Es por ello por lo que fue necesario buscar un nuevo enfoque capaz de afrontar el problema de forma satisfactoria. Inicialmente se planteó la posibilidad de implementar *one-hot encoding* para simplificar la estructura del conjunto y poder aplicar técnicas clásicas. Sin embargo, esta aproximación hacía crecer el número de variables del conjunto de forma abrupta y resultaba contraproducente. Sin embargo, el siguiente paso consistió en concebir cada registro, no como un conjunto de datos, sino como una matriz de valores superpuestos (Theta, Beta, Alpha) similar a una imagen RGB.

Convirtiendo los dataframes a imágenes es posible implementar de forma sencilla redes convolucionales, las cuales han demostrado su eficacia en multitud de entornos, tal y como se expresó en secciones anteriores.

Las redes neuronales convolucionales son un tipo de redes neuronales de Deep learning y resultan cruciales a la hora de llevar a cabo distintos procesos de reconocimiento de imágenes y visión artificial.

Estas redes parten de un input, elemento que se va a analizar y que en este caso concreto se trataría de una imagen y lo van convolucionando a través de las distintas capas de la red hasta obtener un resultado. Estas capas se caracterizan por ser 2D, lo que lo convierte en el tipo de red ideal para clasificar imágenes, las cuales también son bidimensionales. Además, este algoritmo requiere muy bajo procesamiento en comparación con otras estructuras destinadas a obtener resultados similares.

Las CNNs están inspiradas en procesos biológicos, concretamente en modelos de visión de gatos y monos [17]. Tratando de aportar una equivalencia con la fisionomía de los mamíferos, ambos siguen un procedimiento por el que las neuronas, como entes independientes, responden a estímulos visuales de su campo receptivo. Estos campos de recepción se van superponiendo a lo largo de las distintas regiones del cerebro hasta completar el total de la imagen. Este procedimiento es análogo al que ocurre con las redes.

Su 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.

Se distinguen distintos tipos de capas a lo largo de una CNN. La clasificación principal incluye la primera y última capa y las neuronas escondidas (hidden layers). Dentro de las hidden layers se encuentran los siguientes tipos:

- Convolution: permiten extraer características automáticamente. Para ello se llevan a cabo las convoluciones, que son operaciones matriciales. A efectos prácticos, esto representa un filtrado de las imágenes.
- Polling: van reduciendo la dimensionalidad de la imagen hasta llegar a un vector de características. De esta forma, se reconocen los rasgos fundamentales permitiendo separarlos de la coordenada en la que se hallen (así se llegaría a identificar como iguales mismas imágenes rotadas o modificadas). Esto reduce el número final de parámetros y la computación necesaria, controlando también la posibilidad de sobreaprendizaje.
- Fully connected: se encuentra en la parte final, y es la responsable de obtener el resultado final a partir de los valores de las distintas neuronas intermedias. Además, durante la fase de entrenamiento se responsabiliza de ajustar los pesos durante cada iteración. La neurona más habitual de este tipo es el perceptrón multi capa.
- Dropout: Este tipo de capas están pensadas para evitar el sobreaprendizaje del modelo y se basan en prohibir temporalmente el uso de algunas neuronas de forma estadística, forzando al algoritmo a investigar nuevos caminos.
- Flatten: Se encuentra justo antes de las fully connected, son las encargadas de convertir la información en una única dimensión, de forma que puedan ser presentadas de forma interpretable.

4.4.2.1 Creación de las imágenes

Las redes convolucionales requieren de la ingesta de una gran cantidad de datos, por lo que los registros artificiales generados en secciones anteriores son vitales para esta parte del proyecto. Sin embargo, el número de imágenes necesarias sigue siendo mucho mayor que la cantidad de datos generados, por lo que es necesario aumentar la cantidad de información de otras maneras.

Según lo expresado al principio de la sección, cada conjunto de ondas Alpha, Beta y Theta son las componentes de una imagen de tres dimensiones, pero al realizarse modificaciones sobre las imágenes en función del tiempo, se puede considerar que se trata de un video en lugar de una fotografía. Cada uno de estos videos este compuesto por *frames* de las imágenes y dichos *frames* están asociados a una etiqueta, por lo que podemos asumir, que se cuenta con un gran número de imágenes asociadas a cada *label*. Sin embargo, si se empleasen todas las imágenes obtenidas mediante este método, la cantidad de datos se dispararía y habría una gran cantidad de capturas sin apenas diferencias, lo que podría degenerar en un sobreaprendizaje del modelo. Para evitar este fenómeno se decidió filtrar de forma coherente el número de imágenes.

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 fuesen posibles sin correr el riesgo de crear registros repetidos, se decidió que la duración adecuada de cada frame debía ser de 10 milisegundos.

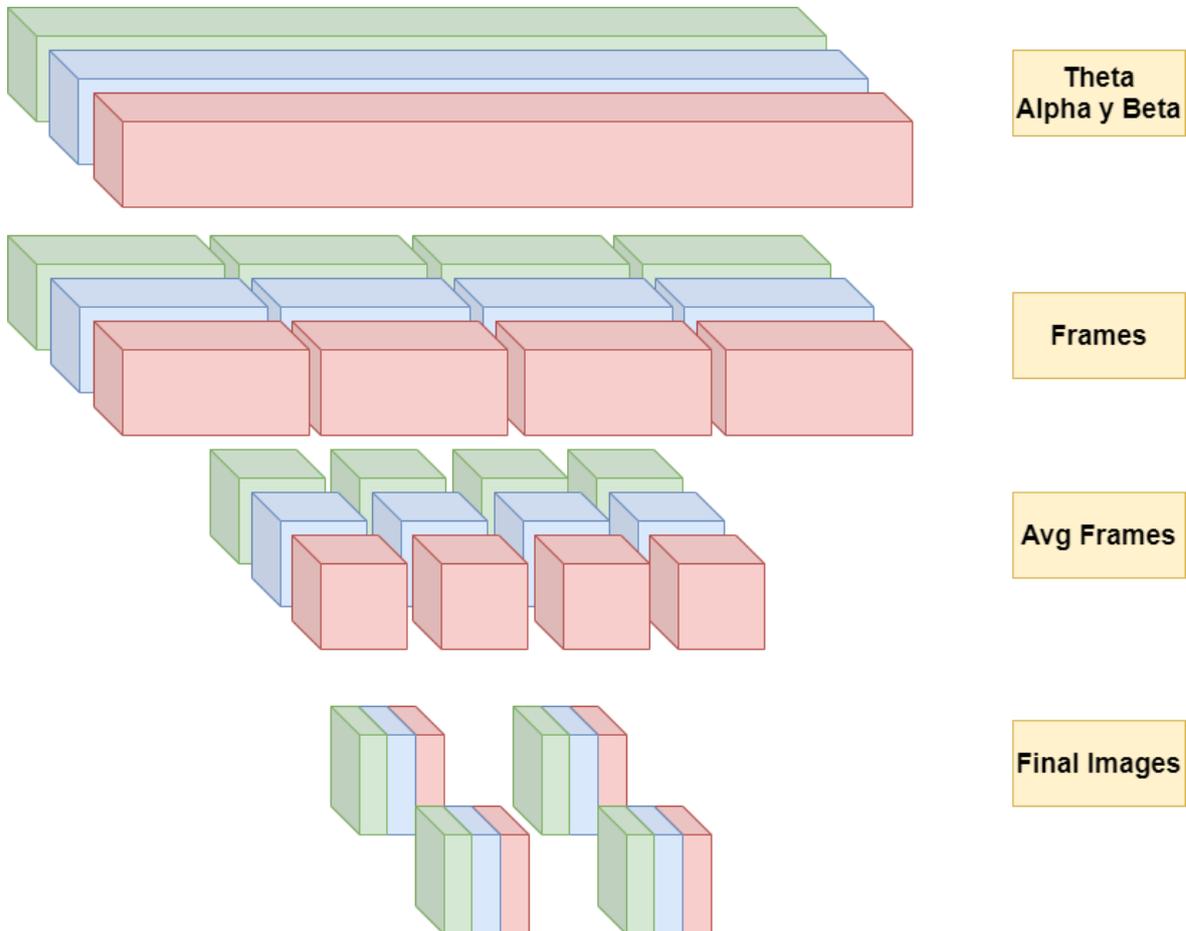
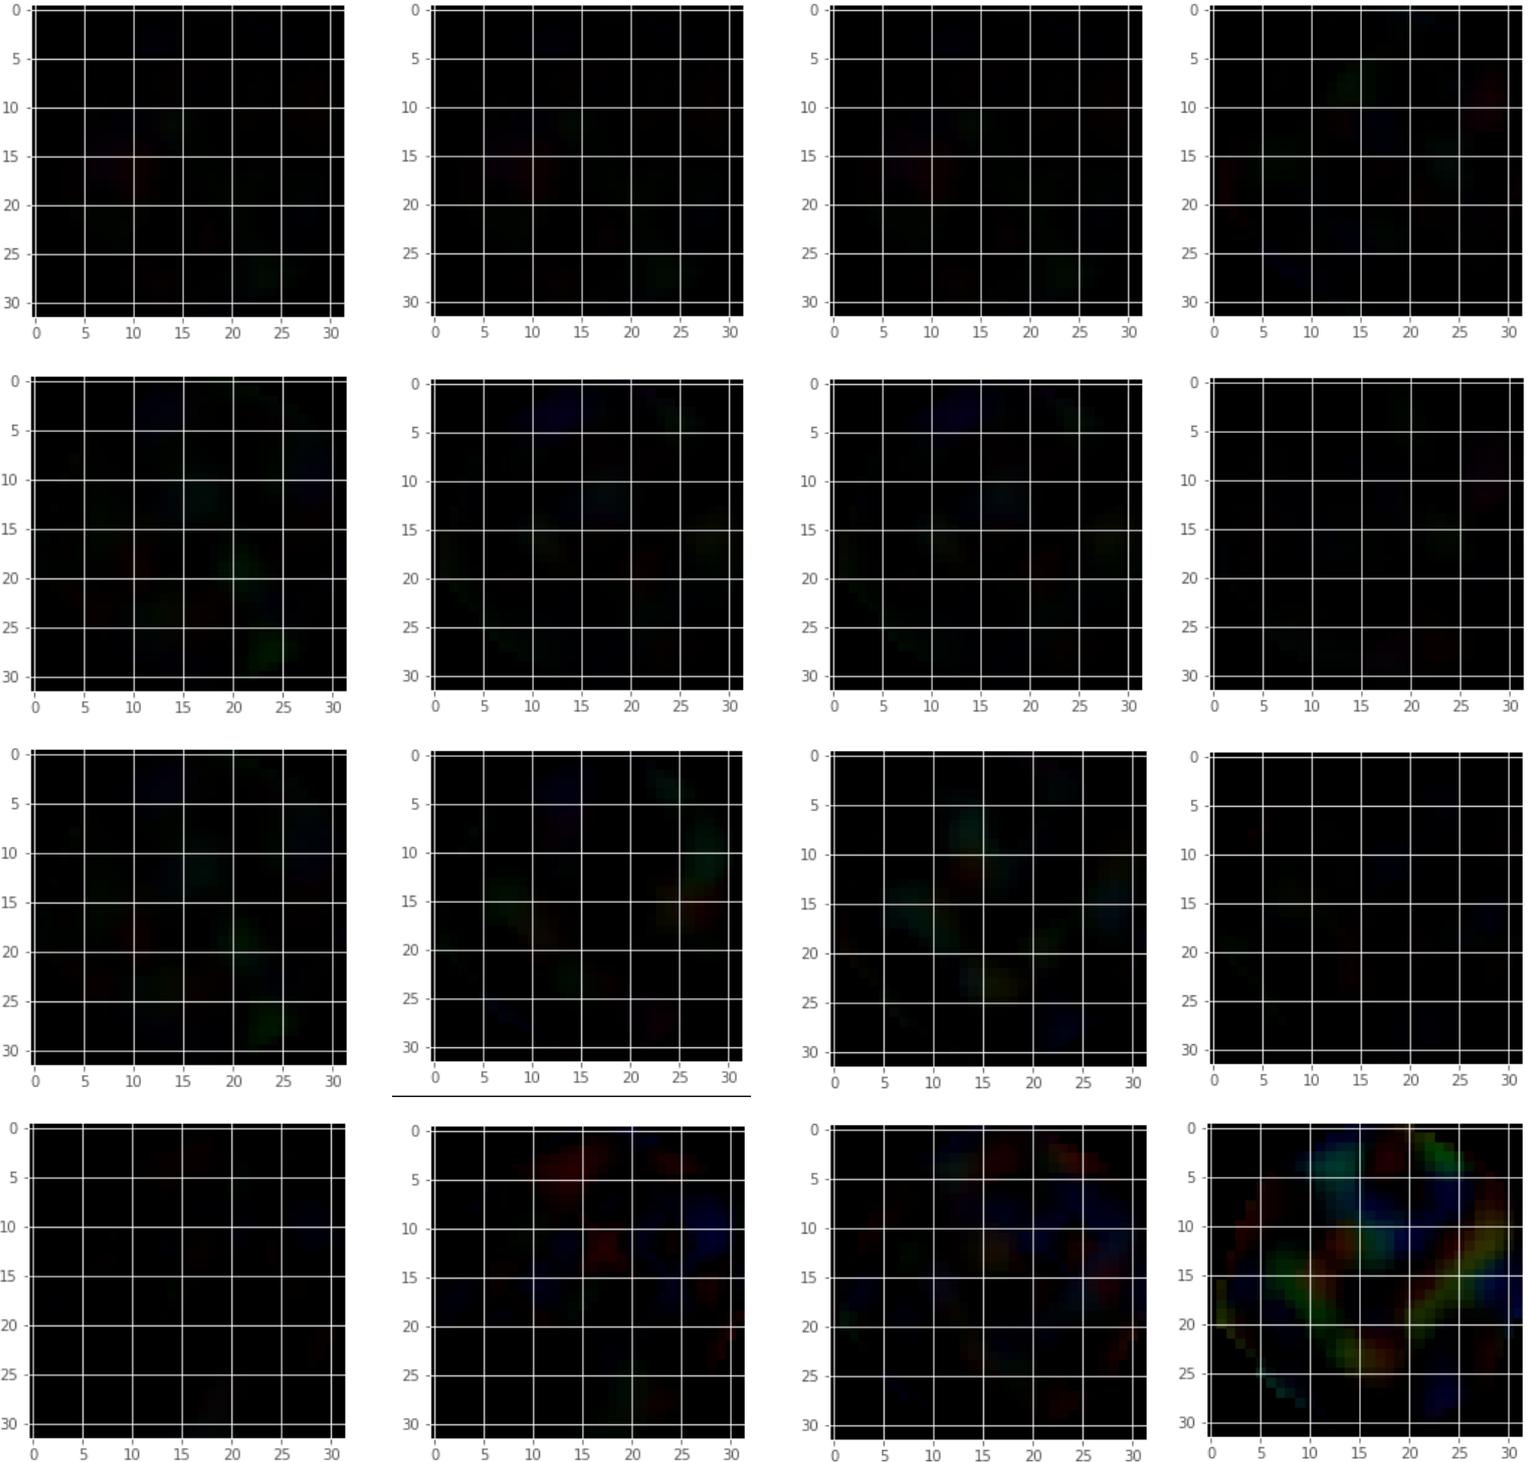
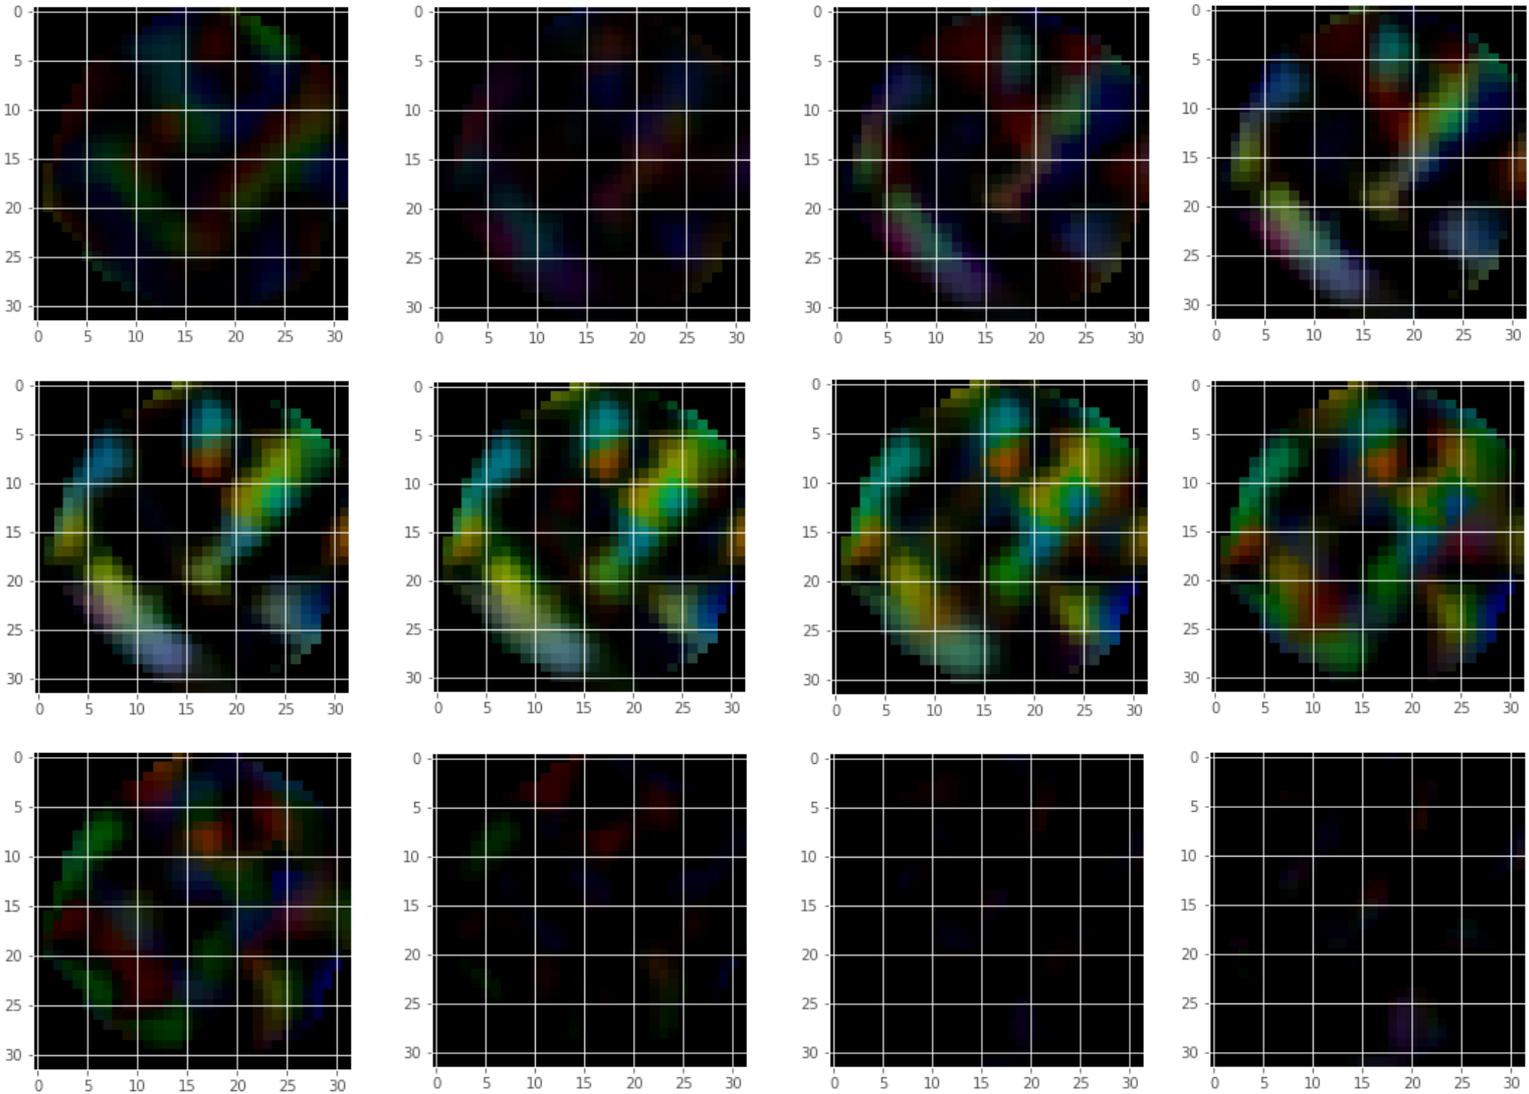


Figura 37. Demostración gráfica del proceso de creación de imágenes

Ahora bien, estas imágenes pueden ser muy confusas y complejas. Además, no se tienen en cuenta la proximidad de los electrodos entre sí a la hora de calcular la aportación de cada medida, por lo que se pierde una parte de la información muy relevante. Para solventar ambos problemas, se optó por representar las medias obtenidas sobre un esquema en dos dimensiones del aparato de medición. De esta forma, la representación será más eficiente y se evitará la aparición de falsos patrones. A continuación, se muestra un ejemplo de la secuencia de imágenes extraídas para un sujeto al reconocer la imagen que se le presenta.





En esta representación se han incluido los primeros segundos del proceso. Es decir, la cola inicial previa a que el cerebro identificase la imagen. Esto se ha hecho simplemente para demostrar que, efectivamente, esta franja de tiempo no es relevante y se puede trabajar únicamente con la señal a partir del décimo frame aproximadamente. Aun así, es llamativo como parece ser que las últimas imágenes tampoco contienen contenido relevante.

Como contrapartida a esta aproximación, la salida del modelo no será todo lo eficiente que podría ser si se usasen imágenes únicas. Esto se debe a que, al entrenar el modelo con imágenes relativas a distintas franjas temporales, el modelo mapea los resultados

con imágenes individuales en lugar de con el conjunto de datos. Este hecho se traduce en que, al introducir nuevos datos, no analizará todo el grupo de ondas, si no que el modelo realizará un estudio individual para cada fotograma y devolverá un grupo de respuestas en lugar de una única label. Para solventar este problema, se optó por implementar una especie de función de activación en la cual se considera que la salida ha dado positivo si la mayoría de los outputs dan positivo.

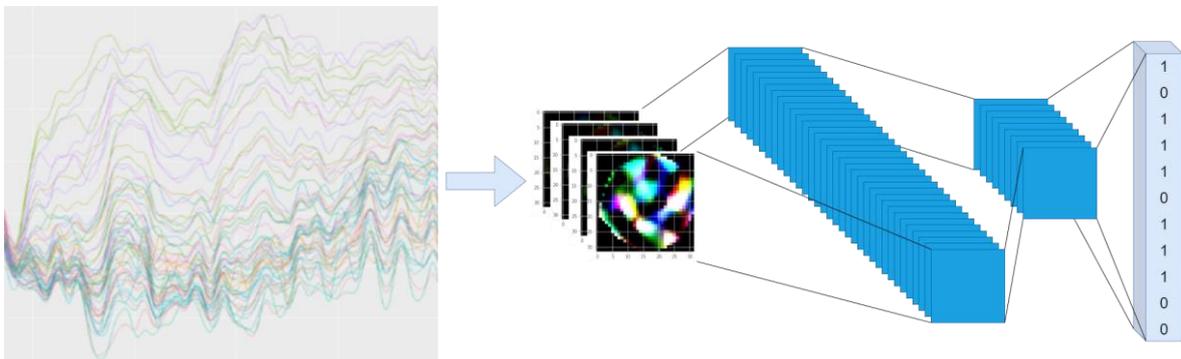


Figura 38. Diagrama del funcionamiento de la CNN

4.4.2.2 Arquitectura de la red

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*.

La estructura es la siguiente:

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

Obviamente, inmediatamente después de cada capa convolucional y *dense layer* se introdujeron funciones de activación. Respecto al número de epochs, el tamaño del batch y la tasa de aprendizaje, se realizaron distintas pruebas variando los valores y esta fue la combinación que ofreció los mejores resultados.

Epochs	500
Learning Rate	0.00075
Batch Size	120

Capítulo 5. ANÁLISIS DE RESULTADOS

De cara a evaluar el éxito del proyecto, existen dos métricas. Por un lado, se encuentra la capacidad para reducir el número de electrodos necesarios durante la realización del experimento y la obtención de los datos. Y la segunda, consiste en la precisión del modelo desarrollado. Obviamente, existen elementos adicionales que pueden utilizarse para medir la eficiencia, como el tiempo de computación y la complejidad de los algoritmos. Sin embargo, los dos pilares principales, cuyos resultados deben analizarse en profundidad, son los originalmente mencionados.

5.1 RESULTADOS DE LA REDUCCIÓN DE LA DIMENSIONALIDAD

A lo largo de este informe se ha mencionado, en multitud de ocasiones, que se puede explicar prácticamente por completo el comportamiento de las señales utilizando únicamente una pareja de componentes. Sin embargo, dichas componentes varían de un sujeto a otro, por lo que las conclusiones que sirven para un individuo perfectamente podrían no servir para otro.

Mediante el Principal Component Analysis se consiguió reducir hasta en un 60% el número de componentes para las ondas Alpha, pero para la implementación del modelo es necesario combinar los tres tipos de ondas, por lo que se deben tener en cuenta todas las señales. Como consecuencia de esto, la reducción en el número de componentes no es tan drástica como podría parecer en un principio.

Pese a ello, existen otros métodos para reducir el número de componentes, como por ejemplo modificar el enfoque del modelo y adaptarlo personalmente a un único individuo. De esta forma únicamente sería necesario emplear unos pocos sensores, pero para lograr este objetivo sería necesario tener un gran número de datos de cada uno de los sujetos.

5.2 RESULTADOS DEL MODELO

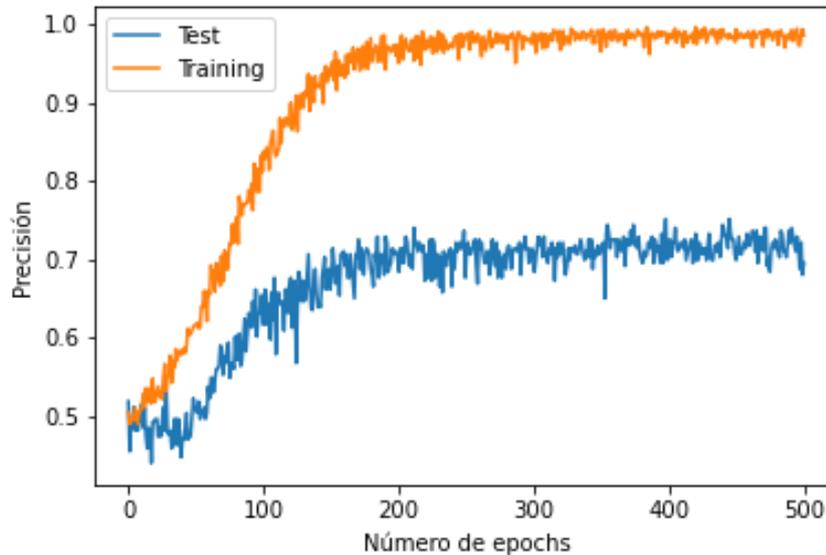
Durante la búsqueda de las características óptimas para la red convolucional, se realizaron multitud de pruebas y mediciones para determinar las mejores condiciones para el modelo. A lo largo de dicha experimentación quedo patente que la cantidad y calidad de los datos limitaban los resultados del programa hasta cierto punto. Este hecho se puede ver reflejado en la siguiente tabla, donde se presenta una pequeña muestra de los modelos entrenados y su rendimiento en los conjuntos de test y de entrenamiento.

	Epochs	Learning Rate	Batch Size	Accuracy in Training	Accuracy in Test
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

Tabla 6. Muestra descriptiva de algunos de los modelos generados

Como se puede apreciar, los resultados no cambian en exceso entre un modelo y otro. En todos los casos se presenta un claro sobreaprendizaje que se aprecia en la diferencia entre la *accuracy* en el entrenamiento y en el test. Por desgracia, pese a los múltiples intentos y a la variación en los atributos del modelo, este efecto no se pudo evitar. Aún así, la calidad en el conjunto de test es excelente teniendo en cuenta la situación de partida del proyecto.

Como se puede ver en la siguiente gráfica, la precisión del modelo se estanca rápidamente y no presenta prácticamente variaciones a partir de la iteración 150 aproximadamente. Sin embargo, el hecho de que no existan oscilaciones bruscas indica que este hecho se debe a las limitaciones de los datos y no a un fallo del modelo.



Gráfica 7. Evolución de los resultados de training y test a lo largo del entrenamiento

Es necesario recordar, que una de las metas que se pretendía alcanzar al inicio de este proyecto consistía en ser capaz de identificar cuáles de los sujetos reconocían la tercera imagen que se les presentaba. Al generar predicciones con el modelo, utilizando como parámetros de entrada las señales registradas al enseñar esta tercera imagen, se obtuvo una lista de listas que contenía los resultados del modelo para cada frame. Cada lista corresponde a uno de los sujetos y para establecer si los individuos reconocen las imágenes se contaron los positivos hallados en cada lista. Si el número de positivos resulta mayor que el de negativos, se concluye que es posible que la imagen haya sido identificada, cuanto mayor sea el número de positivos mayor será la probabilidad de acierto.

Tras la primera iteración, los sujetos identificados y el número de positivos son los siguientes. También se han incluido la secuencia de resultados, ya que no es igual de relevante un positivo en los primeros frames que en aquellos que se encuentran más avanzados.

Identificador de individuos	Número de positivos	Lista de resultados
14	9	[1 0 1 0 1 0 0 0 1 1 1 1 0 0 1 1 0 0 0]
0	9	[1 1 0 0 1 1 1 0 0 0 0 0 0 1 1 1 1 0 0]
5	10	[1 0 0 0 0 1 0 1 1 1 1 0 1 1 1 0 0 0 1]
3	11	[0 1 0 0 1 1 1 1 1 1 1 0 0 0 0 1 1 1 0]
15	13	[1 1 1 0 1 0 0 1 1 1 0 1 1 1 1 1 0 0 1]
12	13	[1 1 0 0 1 1 1 1 1 1 1 1 1 0 0 1 0 0 1]

Tabla 7. Predicciones del modelo sobre la tercera imagen

Como se puede ver, los individuos 15 y 12 son los que tienen una mayor probabilidad de haber reconocido la imagen. Sin embargo, tampoco se puede descartar que los sujetos 3 y 5 no sean positivos. Interpretar estos resultados es aún más complejo debido a que no se dispone de las respuestas finales, por lo que se decidió reentrenar el modelo con las mismas características, pero excluyendo a uno de los sujetos. De esta forma, cuando se realicen predicciones sobre sus datos, se podrán comparar los resultados con los del resto de individuos.

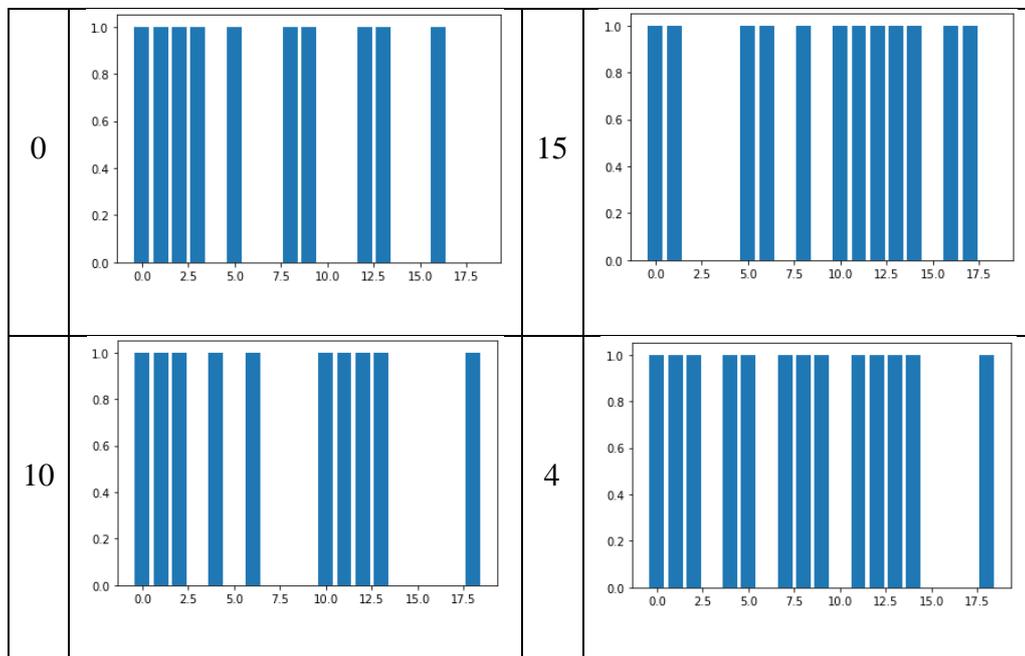
Tras el nuevo entrenamiento, las estadísticas obtenidas son bastante similares a las del modelo anterior, pero los resultados de las predicciones han variado. Se debe tener en cuenta que, a diferencia de en el evento anterior, en esta ocasión se han introducido de forma adicional los registros del sujeto excluido en la fase de entrenamiento, por lo que se debería añadir su identificador a la lista de candidatos.

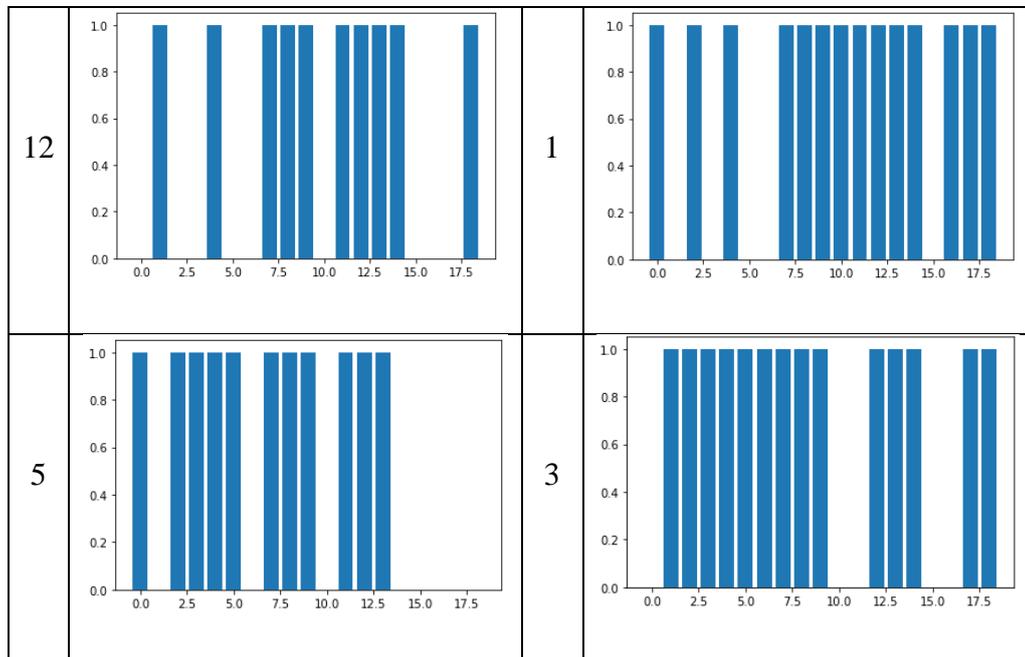
Como se puede ver en la siguiente tabla, se ha descartado como candidato uno de los identificados por el antiguo modelo, pero se han mantenido al resto. Además, ha nominado a otros dos individuos, uno de ellos es el sujeto de referencia (alcanzando la máxima puntuación), mientras que el otro es posible que se trate de un error del programa.

Identificador de individuos	Número de positivos	Lista de resultados
0	10	[1 1 1 1 0 1 0 0 1 1 0 0 1 1 0 0 1 0 0]
10	10	[1 1 1 0 1 0 1 0 0 0 1 1 1 1 0 0 0 0 1]
12	10	[0 1 0 0 1 0 0 1 1 1 0 1 1 1 1 0 0 0 1]
5	11	[1 0 1 1 1 1 0 1 1 1 0 1 1 1 0 0 0 0 0]
15	12	[1 1 0 0 0 1 1 0 1 0 1 1 1 1 1 0 1 1 0]
4	13	[1 1 1 0 1 1 0 1 1 1 0 1 1 1 1 0 0 0 1]
1 (Usuario añadido)	14	[1 0 1 0 1 0 0 1 1 1 1 1 1 1 1 0 1 1 1]
3	14	[0 1 1 1 1 1 1 1 1 1 0 0 1 1 1 0 0 1 1]

Tabla 8. Predicciones del modelo usando un sujeto de prueba

Como ya se ha mencionado anteriormente, la distribución de los resultados también es relevante, ya que los resultados más cercanos a la posición 0 tienen más posibilidades de corresponder a frames donde la actividad cerebral todavía no ha despegado. Es por ello, que puede resultar útil comparar la distribución de los positivos y de los negativos.





En base a estas imágenes, se podría decir que los resultados 0, 5 y 3 deberían ser revisados, pero no se puede considerar que un análisis tan superficial sea concluyente. Sin embargo, si se analiza la distribución del nuevo sujeto, el cual sabemos que ha reconocido la imagen, se aprecia claramente como los positivos se agrupan en la zona de la derecha del gráfico.

5.3 RESULTADOS DEL SISTEMA GLOBAL

No se debe olvidar, que el fin del estudio llevado a cabo por la profesora Barrutieta consistía en desarrollar una herramienta que pudiese ser de ayuda en investigaciones policiales, durante el interrogatorio de sospechosos más concretamente. El modelo todavía cuenta con limitaciones y sufre un claro sobreaprendizaje que debería corregirse tan pronto como se dispusiese de un mayor número de datos. Sin embargo, de cara a emplearse como herramienta en el mundo real, dicho sobreaprendizaje podría ser de utilidad.

El modelo ha demostrado una gran capacidad para aprender de los datos ingeridos. Es por ello, que, aprovechando la reducida cantidad de tiempo necesaria para reentrenar el modelo, se podría desarrollar un protocolo en el cual se midiesen las respuestas de los sospechosos ante una serie de imágenes de referencia y con los registros obtenidos se reentrenaría el modelo. De esta forma, se podría generar un algoritmo relativamente personalizado para cada individuo.

Esta teoría no deja de ser precisamente eso, una teoría. Sin embargo, analizando los resultados obtenidos, se puede asumir que cuenta con una base relativamente sólida. Obviamente esta idea debería ser probada, pero al tener un único registro de cada tipo para cada sujeto, resulta imposible llevar a cabo el experimento.

En cualquier caso, se puede considerar que el trabajo realizado a lo largo de este estudio ofrece una herramienta de ayuda para las fuerzas del orden. Aunque sus resultados no puedan considerarse absolutamente irrefutables, se puede emplear como una guía o un elemento de ayuda.

Capítulo 6. CONCLUSIONES Y TRABAJOS FUTUROS

En este proyecto se ha analizado el complejo mundo del análisis de electroencefalogramas a través de técnicas de machine learning. La situación inicial no era excesivamente prometedora debido a la limitada cantidad de datos disponibles y al complejo formato en el que se encontraban los registros inicialmente. Sin embargo, los resultados presentados en la sección anterior demuestran que los objetivos presentados al principio del informe han sido alcanzados satisfactoriamente.

Gracias a las técnicas de PCA y CCA se ha logrado identificar grupos de variables cuyo comportamiento es claramente más relevante para el conjunto de los datos que el del resto de las señales. Además, se ha desarrollado un modelo funcional capaz de predecir con un porcentaje de acierto elevado si un sujeto reconoce una imagen o no. Sin embargo, durante el desarrollo de este proyecto y su correspondiente investigación, se han descubierto nuevas técnicas y enfoques que podrían ser útiles para trabajos futuros.

En primer lugar, existe una librería de Python especializada en el análisis y tratamiento de EEG llamada MNE. Sus herramientas de visualización y las técnicas definidas pueden ser una gran ayuda para futuros desarrollos. El motivo de que no haya sido implementada en este trabajo se debe a que el formato de los datos de entrada debe consistir en una combinación de datos puros con anotaciones. Dichas anotaciones deben indicar los distintos eventos y sus correspondientes marcas temporales y por desgracia, no se dispuso de esta información.

Por otro lado, en multitud de estudios se habla de la dificultad intrínseca de generalizar los resultados de un estudio de EEG para varios individuos. En la mayoría de los casos, se suele generar un modelo relativamente personalizado para cada sujeto. Para ello, sería necesario disponer de más datos sobre cada uno de los entrevistados, por lo que se recomienda que, en futuros experimentos, en lugar de mostrar únicamente tres imágenes, se muestren un conjunto más amplio y se etiqueten las respuestas debidamente. De esta forma, la precisión de los modelos se incrementará notablemente y el aumento en el volumen de

datos servirá de ayuda en el futuro. Además, mejorará los resultados obtenidos mediante Data Augmentation y se podrá reducir la dimensionalidad de los datos y el número de electrodos empleados durante el experimento, como se mencionó en el capítulo 5. Siguiendo esta misma idea, una vez que se disponga de una cantidad suficiente de datos, sería recomendable desarrollar una red GAN como sustituto para el actual sistema de generación de datos artificiales.

Teniendo en cuenta los buenos resultados obtenidos mediante la CNN, el siguiente paso a considerar en este proyecto consistiría implementar una red recurrente con el objetivo de explotar la secuencialidad de los datos.

Capítulo 7. BIBLIOGRAFÍA

- [1] 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>.
- [2] L. Palacios, «Breve historia de la electroencefalografía».
- [3] H. F. G. W. J. Ismail Fawaz, «Deep learning for time series classification: a review,» 2019.
- [4] A. Craik, «Deep learning for electroencephalogram (EEG) classification tasks: a review,» 2019.
- [5] F. Lotte, «A Tutorial on EEG Signal Processing Techniques for Mental State Recognition in,» de *Guide to Brain-Computer Music*, 2014.
- [6] W. Zheng, «Multichannel EEG-Based Emotion Recognition via Group Sparse Canonical Correlation Analysis,» *IEEE Transactions on Cognitive and Developmental Systems*, 2017.
- [7] X. L. Dongmei Zhou¹, «Epilepsy EEG Signal Classification Algorithm Based on Improved RBF,» *Front. Neurosc*, 23 June 2020.
- [8] JesusMartinez-del-Rincon, «Non-linear classifiers applied to EEG analysis for epilepsy seizure detection,» *Expert Systems with Applications*, vol. 86, pp. 99-112, 2017.
- [9] X. Zhang, «A Survey on Deep Learning based Brain Computer Interface: Recent Advances and New Frontiers,» 2019.

- [10] E. P. Torres, «EEG-Based BCI Emotion Recognition: A Survey,» 2020.
- [11] P. Suppes, «Brain wave recognition of words,» *Proceedings of the National Academy of Sciences*, vol. 94, 1998.
- [12] W. G. Iacono, “Effective Policing: Understanding How Polygraph Tests Work and Are Used,” *Criminal Justice and Behavior*, vol. 35, pp. 1295-1308, 2008.
- [13] Y. Jeon, C. S. Nam, Y.-J. Kim y M. C. Whang, «Brainwave Classification Using Covariance-Based Data Augmentation,» *IEEE Access*, 2020.
- [14] Marco Weiergräber, «Sampling rate, signal bandwidth and related pitfalls in EEG analysis,» *Journal of Neuroscience Methods*, vol. 268, pp. 53-55, 2016.
- [15] C. S. N. Y.-J. K. y. M. C. W. Y. Jeon, «Event-related (De)synchronization (ERD/ERS) during motor imagery tasks: Implications for brain-computer interfaces,» *Int. J. Ind. Ergonom*, vol. 41, n° 5, pp. 428-436, Sep 2011.
- [16] J. Ramsay, *Functional data analysis in matlab and R*, Springer, 2009.
- [17] D. H. Hubel y T. N. Wiesel, «Receptive Fields, Binocular Interaction and Functional Architecture in the Cat's Visual Cortex,» *Journal of Physiology*, vol. 160, pp. 106-154, 1962.
- [18] M. A. Shipp, «Diffuse large B-cell lymphoma outcome prediction by gene-expression profiling and supervised machine learning,» *Nature*, 2002.
- [19] C. J. Jolliffe IT, «Principal component analysis: a review and recent developments».
- [20] A. Blum, «Foundations of Machine Learning and Data Science,» 2015.

ANEXO I - ODS

El 25 de septiembre de 2015, los líderes mundiales establecieron una serie de objetivos a cumplir con el fin de mejorar la situación global y alcanzar un futuro donde la pobreza y las desigualdades no existiesen, además de asegurar el bienestar del planeta para las generaciones venideras.

Se establecieron 17 objetivos o ODS, los cuales deben ser una guía para todos los planes y proyectos futuros.



En este proyecto se ha profundizado en el ODS número 16 (Paz, justicia e instituciones solidas), ya que uno de los objetivos a desarrollar consistía en construir una herramienta que facilitase el trabajo de las fuerzas del orden y que sirviese para probar la culpabilidad o inocencia de los individuos. Sin embargo, a lo largo de este estudio también se ha profundizado mucho en el comportamiento de las ondas cerebrales y en las características más relevantes de un EEG. A lo largo de dicho trabajo se han extraído conclusiones que facilitarían las mediciones de ondas cerebrales en contexto médicos. Por lo tanto, también se puede concluir que este proyecto colabora a mejorar la salud y el bienestar de la población.

ANEXO A

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA I.C.A.I.

PROYECTOS FIN DE MÁSTER
CURSO: 2º MIT + MBD

Ficha de proyecto fin de máster
(RELLENAR CON LETRAS DE IMPRENTA EN ORDENADOR)

Titulación y optatividad: Master en Ingeniería de Telecomunicaciones y Master en Big Data

Alumno 1º Apellido: Mena
 2º Apellido: Gómez de Merodio
 Nombre: Pablo

Teléfono de contacto: : 630505912
e-mail: pablomena.mena95@gmail.com

Título del Proyecto Fin de Máster: Análisis de ondas cerebrales mediante inteligencia artificial para la clusterización de respuestas

Director (nombre y dos apellidos): David Contreras Bárcena y Mario Castro Ponce
Teléfono de contacto:
e-mail: davidcb@comillas.edu
e-mail: marioc@comillas.edu

Breve descripción del proyecto (5 o 6 líneas)

Aprovechando los recursos proporcionados por el departamento de psicología de la universidad, el objetivo del proyecto consiste en aplicar técnicas de inteligencia artificial centradas en clustering. La finalidad es identificar patrones en las ondas cerebrales y servir como herramienta durante el desarrollo de estudios psicológicos futuros.