



UNIVERSIDAD DE VALLADOLID



Escuela Técnica Superior de Ingenieros de Telecomunicación  
*Universidad de Valladolid*

## TRABAJO FIN DE GRADO

GRADO EN INGENIERÍA DE TECNOLOGÍAS DE  
TELECOMUNICACIÓN

INTERPRETACIÓN DE REDES NEURONALES PROFUNDAS  
COMO HERRAMIENTAS PARA DIFERENCIAR SUBTIPOS DE  
TDAH A PARTIR DE PATRONES DE ACTIVIDAD

---

AUTOR: GUILLERMO CHICO DELGADO  
TUTOR: PATRICIA AMADO CABALLERO  
J.P. CASASECA DE LA HIGUERA

20 de septiembre de 2023

TÍTULO: INTERPRETACIÓN DE REDES NEURONALES PROFUNDAS COMO HERRAMIENTAS PARA DIFERENCIAR SUBTIPOS DE TDAH A PARTIR DE PATRONES DE ACTIVIDAD

AUTOR: GUILLERMO CHICO DELGADO

TUTOR: PATRICIA AMADO CABALLERO  
J.P. CASASECA DE LA HIGUERA

DEPARTAMENTO: TSCIT

### **Miembros del Tribunal**

PRESIDENTE: CARLOS ALBEROLA LÓPEZ

SECRETARIO: J.P. CASASECA DE LA HIGUERA

VOCAL: JAVIER AGUIAR PÉREZ

SUPLENTE 1: FEDERICO SIMMROSS WATTENBERG

SUPLENTE 2: RODRIGO DE LUIS GARCÍA

CALIFICACIÓN:

### **Resumen del proyecto**

El Trastorno por Déficit de Atención e Hiperactividad (TDAH) es un trastorno neuropsiquiátrico que afecta a niños y a adultos. El TDAH se divide en tres subtipos: predominantemente inatento, predominantemente hiperactivo y combinado. Tradicionalmente, el diagnóstico tanto del TDAH como de su subtipo se han basado en evaluaciones médicas con un importante componente subjetivo. El correcto diagnóstico del subtipo de TDAH es fundamental para el desarrollo de un tratamiento adecuado y adaptado al paciente. Estudios recientes han revelado que el uso de métodos basados actimetría junto aprendizaje profundo son buenas opciones a la hora de identificar el TDAH, así como diferenciar sus subtipos. Sin embargo, en el caso del TDAH predominantemente hiperactivo, no se ha llevado a cabo ningún estudio de esta índole al tratarse del tipo menos diagnosticado y del que menos información se tiene. Por ello, en el presente trabajo se propone la elaboración de un sistema capaz de caracterizar el TDAH de tipo hiperactivo mediante el análisis de patrones de actividad y técnicas de interpretabilidad. Para ello, a partir de las señales actigráficas de los pacientes, se han creado espectrogramas divididos por el subtipo y se han entrenado redes neuronales convolucionales. Tras ello, se analizan las salidas de dichas redes mediante técnicas como los mapas de oclusión y modelos de mezcla gaussiana.

### **Palabras clave**

TDAH, Actigrafía, Aprendizaje Profundo, CNN, Espectrograma, Mapas de oclusión

### **Abstract**

Attention Deficit Hyperactivity Disorder (ADHD) is a neuropsychiatric disorder that affects

children and adults. ADHD is divided into three subtypes: predominantly inattentive, predominantly hyperactive, and combined. Traditionally, the diagnosis of both ADHD and its subtype have been based on medical evaluations with an important subjective component. The correct diagnosis of the ADHD subtype is essential for the development of a suitable treatment adapted to the patient. Recent studies have revealed that the use of actimetry-based methods together with deep learning are good options when it comes to identifying ADHD, as well as differentiating its subtypes. However, in the case of predominantly hyperactive ADHD, no study of this nature has been carried out as it is the least diagnosed type and about which the least information is available. Therefore, in this work we propose the development of a system capable of characterizing hyperactive ADHD through the analysis of activity patterns and interpretability techniques. For this purpose, based on the actigraphic signals of the patients, spectrograms divided by subtype have been created and convolutional neural networks have been trained. After that, the outputs of these networks are analyzed using techniques such as occlusion maps and gaussian mixture models.

**Keywords**

ADHD, Actigraphy, Deep Learning, CNN, Spectrogram, Occlusion Sensitivity

## AGRADECIMIENTOS

En primer lugar, quiero expresar mi agradecimiento a mis tutores, Juan Pablo Casaseca de la Higuera y Patricia Amado Caballero por ofrecerme la posibilidad de realizar este Trabajo Fin de Grado, así como su ayuda y orientación a lo largo de la realización del mismo.

También me gustaría agradecer al Laboratorio de Procesado de Imagen por haber facilitado los medios necesarios para el desarrollo del trabajo.

Gracias a mi familia por el apoyo durante todos los años de carrera así como a mis amigos y compañeros a lo largo de mis estudios.

# ÍNDICE GENERAL

<b>1. Introducción</b>	<b>1</b>
1.1. Motivación	1
1.2. Objetivos	2
1.3. Fases y Métodos	3
1.4. Medios necesarios empleados para el desarrollo	3
1.5. Estructura del documento	4
<b>2. Antecedentes y estado del arte</b>	<b>5</b>
2.1. Diagnóstico convencional	5
2.2. Métodos objetivos de diagnóstico	6
2.3. Basados en imagen por resonancia magnética (MRI)	6
2.4. Basados en electroencefalograma (EEG)	8
2.5. Basados en otros métodos	10
2.6. Basados en actimetría	12
<b>3. Aprendizaje automático</b>	<b>16</b>
3.1. Inteligencia Artificial, Machine Learning y Deep Learning	16
3.2. Redes neuronales	18
3.2.1. Estructura y funcionamiento	18
3.2.2. Aprendizaje y entrenamiento	20
3.2.3. Modelos de redes neuronales	21
3.2.3.1. Redes neuronales feed-forward	21
3.2.3.2. Redes neuronales recurrentes	22
3.2.3.3. Redes neuronales de base radial	22
3.2.3.4. Redes neuronales convolucionales	24
3.2.3.5. Otros modelos	26
3.3. Interpretabilidad	27
3.3.1. Herramientas de interpretación	27
3.3.2. Modelado mediante mezcla de gaussianas	29
3.3.3. P-valores	29
3.4. Técnicas para la evaluación del rendimiento de un sistema	31
3.4.1. Reconocimiento de Patrones	31
3.4.1.1. Adquisición de datos de entrada	31
3.4.1.2. Extracción de Características	31
3.4.1.3. Clasificación	32
3.4.2. Métricas de evaluación de clasificación	32
3.4.3. Validación cruzada	33

---

<b>4. Métodos</b>	<b>36</b>
4.1. <i>Presentación de los datos de entrada</i>	37
4.1.1. <i>Señales actigráficas</i>	37
4.1.2. <i>Espectrogramas</i>	38
4.2. <i>Clasificación de pacientes</i>	39
4.2.1. <i>Sectorización de pacientes</i>	39
4.2.2. <i>Diseño de la CNN</i>	40
4.2.3. <i>Entrenamiento de la red</i>	41
4.3. <i>Mapas de oclusión</i>	42
4.4. <i>Modelado mediante mezcla de gaussianas</i>	44
<b>5. Resultados y discusión</b>	<b>46</b>
5.1. <i>Presentación de los resultados</i>	46
5.1.1. <i>Comparativa entre Tipo1 y Tipo3</i>	47
5.1.2. <i>Comparativa entre Tipo2 y Tipo3</i>	55
5.2. <i>Discusión de los resultados</i>	61
<b>6. Conclusiones y líneas futuras</b>	<b>64</b>
6.1. <i>Conclusiones</i>	64
6.2. <i>Limitaciones y Líneas Futuras</i>	65

# ÍNDICE DE FIGURAS

3.1. Relación entre Inteligencia Artificial, Machine Learning y Deep Learning . . . . .	17
3.2. Funcionamiento de una neurona artificial . . . . .	18
3.3. Funciones de activación . . . . .	19
3.4. Arquitectura de una red neuronal multicapa . . . . .	20
3.5. Conexiones recurrentes o realimentaciones entre neuronas . . . . .	22
3.6. Estructura de una red neuronal de base radial . . . . .	23
3.7. Funcionamiento de la capa convolucional . . . . .	24
3.8. Operaciones de max pooling y average pooling en la capa de pooling . . . . .	25
3.9. Ejemplo de estructura de una red neuronal convolucional . . . . .	25
3.10. Estructura de un autoencoder . . . . .	26
3.11. Proceso de creación de mapas de oclusión . . . . .	28
3.12. Matriz de confusión . . . . .	33
3.13. Validación cruzada aleatoria o método holdout . . . . .	34
3.14. Validación cruzada de k-fold . . . . .	34
3.15. Validación cruzada de leave-one-out . . . . .	35
3.16. Validación cruzada anidada . . . . .	35
4.1. Flujo de trabajo realizado . . . . .	37
4.2. Ejemplo de uno de los espectrogramas obtenidos de 129x55 píxeles (imagen ampliada) . . . . .	39
4.3. Ejemplo de uno de los espectrogramas obtenidos de 129x55 píxeles (imagen ampliada) . . . . .	40
4.4. Ejemplo de mapa de oclusión . . . . .	44
4.5. Mapa de oclusión y modelado por mezcla de 2 gaussianas . . . . .	45
4.6. Mapa de oclusión y modelado por mezcla de 3 gaussianas . . . . .	45
5.1. Mapas de oclusión medios de Tipo1 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo1 y Tipo3 para actividad nocturna . . . . .	47
5.2. Mapas de oclusión medios de Tipo1 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo1 y Tipo3 para actividad diurna . . . . .	48
5.3. boxplots del peso de la primera gaussiana ( $p_1$ ) (derecha) y de la diferencia de pesos ( $ p_1 - p_2 $ ) entre la primera y segunda gaussiana (izquierda), para actividad diurna y modelado por 2 gaussianas (Tipo1 vs Tipo3) . . . . .	49
5.4. boxplots de $\eta_y$ para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad nocturna y modelado por 2 gaussianas (Tipo1 vs Tipo3) . . . . .	50
5.5. boxplots de $\eta_y$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo1 vs Tipo3) . . . . .	50
5.6. boxplots de $\eta_y$ para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (Tipo1 vs Tipo3) . . . . .	51
5.7. boxplots de $\eta_y$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (Tipo1 vs Tipo3) . . . . .	51

5.8. boxplots de $\sigma_x$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo1 vs Tipo3) . . . . .	52
5.9. boxplots de $\sigma_x$ para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (Tipo1 vs Tipo3) . . . . .	52
5.10. boxplots de $\sigma_x$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (Tipo1 vs Tipo3) . . . . .	53
5.11. boxplots de $\sigma_y$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo1 vs Tipo3) . . . . .	53
5.12. boxplots de $\sigma_y$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (Tipo1 vs Tipo3) . . . . .	54
5.13. boxplots de la divergencia de Kullback-Leibler entre la primera y segunda gaussiana ( $D_{KL}(G_1 \parallel G_2)$ ) (derecha) y entre la segunda y la primera gaussiana ( $D_{KL}(G_2 \parallel G_1)$ ) (izquierda), para actividad diurna y modelado por 2 gaussianas (Tipo1 vs Tipo3) . . . . .	54
5.14. Mapas de oclusión medios de Tipo2 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo2 y Tipo3 para actividad nocturna . . . . .	55
5.15. Mapas de oclusión medios de Tipo2 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo2 y Tipo3 para actividad diurna . . . . .	55
5.16. boxplots del peso de la primera gaussiana ( $p_1$ ) (derecha), de la segunda gaussiana ( $p_2$ ) (centro) y de la tercera gaussiana ( $p_3$ ) (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo2 vs Tipo3) . . . . .	57
5.17. boxplots de diferencia de pesos de las gaussianas entre las gaussianas: entre la primera y la segunda ( $ p_1 - p_2 $ ) (izquierda), entre la primera y la tercera ( $ p_1 - p_3 $ ) (centro) y entre la segunda y la tercera ( $ p_2 - p_3 $ ) (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo2 vs Tipo3) . . . . .	57
5.18. boxplots $\eta_x$ de la segunda gaussiana, para actividad diurna y modelado por 2 gaussianas (Tipo2 vs Tipo3) . . . . .	58
5.19. boxplots de $\eta_y$ para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (Tipo2 vs Tipo3) . . . . .	58
5.20. boxplots de $\eta_y$ para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (Tipo2 vs Tipo3) . . . . .	59
5.21. boxplots de $\eta_y$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (Tipo2 vs Tipo3) . . . . .	59
5.22. boxplots de $\sigma_x$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo2 vs Tipo3) . . . . .	60
5.23. boxplots de $\sigma_x$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (Tipo2 vs Tipo3) . . . . .	60
5.24. boxplots de $\sigma_y$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo2 vs Tipo3) . . . . .	61
5.25. boxplots de $\sigma_y$ para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (Tipo2 vs Tipo3) . . . . .	61

# ÍNDICE DE TABLAS

2.1. Estudios basados en imagen por resonancia magnética (MRI) . . . . .	8
2.2. Estudios basados en electroencefalograma (EEG) . . . . .	10
2.3. Estudios basados en otros métodos . . . . .	12
2.4. Estudios basados en otros métodos . . . . .	14
4.1. Sujetos de estudio de cada grupo . . . . .	40
4.2. Número de espectrogramas disponibles para cada tipo . . . . .	41
4.3. Distribución de los folds balanceados . . . . .	41
4.4. Distribución de los folds no balanceados . . . . .	42
4.5. Media de las precisiones del test de la red entrenada con 10 folds . . . . .	42
4.6. Número de espectrogramas disponibles para cada tipo . . . . .	42
4.7. Número de imágenes y porcentaje con respecto al total en función del tipo y el porcentaje de acierto para Tipo1 vs Tipo3 . . . . .	43
4.8. Número de imágenes y porcentaje con respecto al total en función del tipo y el porcentaje de acierto para Tipo2 vs Tipo3 . . . . .	43
5.1. <i>p</i> -valores obtenidos de los parámetros de estudio con 2 gaussianas para Tipo1 vs Tipo3 . . . . .	48
5.2. <i>p</i> -valores obtenidos de los parámetros de estudio con 3 gaussianas para Tipo1 vs Tipo3 . . . . .	49
5.3. <i>p</i> -valores obtenidos de los parámetros de estudio con 2 gaussianas para Tipo2 vs Tipo3 . . . . .	56
5.4. <i>p</i> -valores obtenidos de los parámetros de estudio con 3 gaussianas para Tipo2 vs Tipo3 . . . . .	56
5.5. Tabla comparativa entre el modelado por 2 y 3 gaussianas . . . . .	62
5.6. Tabla resumen que indica qué tipo obtuvo mayores valores para cada parámetro representado en los boxplots, para la comparativa entre Tipo1 y Tipo3 . . . . .	62
5.7. Tabla resumen que indica qué tipo obtuvo mayores valores para cada parámetro representado en los boxplots, para la comparativa entre Tipo2 y Tipo3 . . . . .	63



## Capítulo 1

# INTRODUCCIÓN

En el presente capítulo, se pretende establecer el contexto de este Trabajo Fin de Grado, el cual presenta una solución para el diagnóstico de subtipos del trastorno por déficit de atención e hiperactividad (TDAH) empleando técnicas de *Deep Learning*. El diagnóstico del TDAH, así como su subtipo, se basan en evaluaciones clínicas, las cuales implican un alto grado de subjetividad ya que incluye la interpretación de síntomas y observación del paciente. El objetivo principal del trabajo es conseguir sistema capaz de detectar los subtipos de TDAH, concretamente el TDAH de tipo hiperactivo. En las siguientes secciones, se presentarán los diferentes subtipos de TDAH y sus métodos de diagnóstico, así como los medios y métodos utilizados en el presente trabajo y la estructura del mismo.

## 1.1 MOTIVACIÓN

---

El trastorno por déficit de atención e hiperactividad (TDAH) es un trastorno neuroconductual común que afecta tanto a niños como a adultos. Se caracteriza por dificultades persistentes en la atención, la hiperactividad y la impulsividad que interfieren con el funcionamiento diario y el desarrollo adecuado. El diagnóstico del TDAH, siguiendo los criterios establecidos en el *Diagnostic And Statistical Manual Of Mental Disorders (DSM-V)*, se basa en una evaluación integral. Esta incluye entrevistas clínicas, recopilación de información y observación del sujeto durante al menos 6 meses en los que se detectan síntomas y si estos mantienen un grado que no concuerda con el nivel de desarrollo y afecta directamente las actividades sociales y académicas [1].

Según [1], se clasifica en tres subtipos principales: el TDAH predominantemente hiperactivo-impulsivo (TDAH-H), el TDAH predominantemente inatento (TDAH-I) y el TDAH combinado (TDAH-C). En el subtipo hiperactivo, la hiperactividad y la impulsividad son más prominentes, mientras que en el subtipo inatento predominan los problemas de atención. El subtipo combinado implica la presencia de síntomas en ambas áreas. El diagnóstico del subtipo de TDAH sigue también los criterios diagnósticos establecidos en el DSM-V. Se diagnosticará TDAH de tipo inatento o hiperactivo en base a si se han observado suficientes síntomas de inatención o hiperactividad/impulsividad respectivamente. En caso de que se observen síntomas de ambos tipos, se diagnosticará con TDAH combinado.

Es importante diagnosticar adecuadamente el tipo de TDAH para poder proporcionar un tratamiento adecuado que se adapte a las necesidades específicas de cada paciente y subtipo. Esta precisión en el diagnóstico optimiza las intervenciones terapéuticas, mejorando la calidad de vida del individuo.

Como acabamos de ver, tanto el diagnóstico del TDAH como de su subtipo dependen en gran medida de la imparcialidad de la información proporcionada por el entorno del paciente y del correcto análisis e interpretación por parte de los doctores. Con objeto de encontrar un método de diagnóstico con mayor objetividad y fiabilidad, en [2] y [3], se desarrolló un sistema basado en aprendizaje profundo (*Deep Learning*). Este sistema utilizando redes neuronales convolucionales (CNN) es capaz de clasificar al sujeto como sano o paciente con TDAH, a partir de señales actigráficas con un alto porcentaje de acierto.

En cuanto a la identificación de los subtipos de TDAH, en [4], se realizó un análisis con el objetivo de establecer diferencias entre el tipo inatento y combinado, mediante actimetría, redes convolucionales y técnicas de aprendizaje automático. Para el tipo hiperactivo no se realizó ningún análisis ya que el número de muestras disponibles de este tipo era reducido.

Mediante el uso de actimetría y diversas técnicas de interpretación y análisis de las salidas de las redes profundas usadas en [5] y [6], en este trabajo se busca elaborar un sistema basado en el aprendizaje automático que permita caracterizar los diferentes subtipos de TDAH, más concretamente el tipo hiperactivo (TDAH-H) que no pudo ser estudiado en [4].

## 1.2 OBJETIVOS

---

El trastorno por déficit de atención e hiperactividad de predominio hiperactivo (TDAH-H) es el subtipo menos diagnosticado entre las personas con TDAH. Según los criterios diagnósticos completos del DSM-IV, se estima que solo entre el 13 % y el 17 % de los individuos con TDAH cumplen los requisitos para ser diagnosticados con TDAH-H [7], tratándose del subtipo de TDAH menos diagnosticado.

Puesto que el TDAH de tipo hiperactivo es el subtipo de TDAH menos diagnosticado y el único tipo que no fue estudiado en [4], se busca obtener un sistema basado en actimetría que tenga la capacidad de identificar patrones de comportamiento distintivos que permita caracterizar el TDAH hiperactivo. De esta manera, se sigue la línea de investigación propuesta en [4], en este caso para el TDAH hiperactivo.

Este estudio tiene como objetivos principales:

- Crear un sistema inteligente basado en aprendizaje profundo que permita analizar el subtipo de TDAH de los pacientes, concretamente el TDAH de tipo hiperactivo.
- Interpretar el comportamiento de la salida de las redes neuronales profundas.
- Definir e identificar características acerca de cada uno de los subtipos de TDAH.

### 1.3 FASES Y MÉTODOS

---

Para cumplir los objetivos planteados en la sección anterior, se ha propuesto la siguiente dinámica de trabajo:

- Creación de espectrogramas (imágenes) a partir de las señales actigráficas de los pacientes.
- Sectorización de los espectrogramas en función de su tipo de TDAH diagnosticado previamente, así como en periodos de actividad, esto es, actividad diurna y nocturna.
- Creación de la red neuronal convolucional (CNN), es decir, cada una de las capas que la forman.
- Entrenamiento de la red para cada pareja de tipos y periodo de actividad (día o noche).
- Elaboración de los mapas de oclusión de cada paciente para los dos tipos de TDAH comparados y el periodo, en función del porcentaje de acierto.
- Modelado de los mapas de oclusión por distribuciones gaussianas, y cálculo de sus parámetros característicos y p-valores.
- Presentación y análisis de los resultados obtenidos con objeto de caracterizar los subtipos de TDAH y discusión de los mismos.

### 1.4 MEDIOS NECESARIOS EMPLEADOS PARA EL DESARROLLO

---

Durante la realización del trabajo, se han empleado las siguientes herramientas de *hardware* y *software*:

#### Hardware

- PC de sobremesa con distribución Linux del Laboratorio de Procesado de Imagen (LPI) de la Universidad de Valladolid (UVa) con las siguientes características:
  - Procesador 6xIntel®Core™i7-7700 3.60 GHz.
  - 16 GB de memoria RAM.
  - Disco duro HDD de 250 GB de capacidad.
  - GPU NVIDIA GeForce GTX 1050 con 2 GB de memoria RAM
- PC de sobremesa personal con Windows 11 con las siguientes características:
  - Procesador 6xIntel®Core™i7-8700 3.20 GHz.
  - 16 GB de memoria RAM.
  - Disco duro HDD de 1 TB de capacidad.
  - GPU NVIDIA GeForce GTX 1050 Ti con 4 GB de memoria RAM

## **Software**

- MATLAB R2023a [8]: Software de lenguaje de alto nivel que permite el desarrollo de algoritmos, el análisis de datos y computación numérica.
- L<sup>A</sup>T<sub>E</sub>X [9]: Software utilizado para la composición de documentos de texto de alta calidad, ampliamente utilizado en el ámbito académico para la creación de artículos científicos. En LaTeX, los documentos se escriben en un lenguaje de marcado que incluye comandos y estructuras específicas para controlar la apariencia del texto, el diseño de páginas, la creación de tablas, ecuaciones matemáticas, referencias bibliográficas, etc.

## 1.5 ESTRUCTURA DEL DOCUMENTO

---

El trabajo está formado por 6 capítulos, incluyendo este capítulo de introducción. Los capítulos que constituyen el trabajo son los siguientes:

**Capítulo 1- Introducción.** Se presenta el tema del documento, junto con la motivación, los objetivos planteados, las fases y métodos necesarios para lograrlos y la estructura del presente informe.

**Capítulo 2- Antecedentes y estado del arte.** En este capítulo se abordan los diferentes métodos de diagnóstico del TDAH y sus subtipos de TDAH que se utilizan actualmente.

**Capítulo 3- Aprendizaje automático** A lo largo de este capítulo, se ofrece una introducción detallada sobre el aprendizaje automático. Además, se explicará qué es el *Deep Learning*, las redes neuronales, especialmente, las redes neuronales convoluciones y las técnicas de interpretación de estas redes. Por último, se explican las técnicas para la evaluación del rendimiento de un sistema de reconocimiento de patrones.

**Capítulo 4- Métodos** En este capítulo se detalla la metodología y los pasos seguidos para la realización del trabajo. Incluye la creación y sectorización de los espectrogramas, la creación y entrenamiento de la red, la creación de los mapas de oclusión y el modelado de los mapas de oclusión por gaussianas.

**Capítulo 5- Resultados y discusión** En este capítulo, se mostrarán los resultados obtenidos durante la realización del trabajo. También, se llevará a cabo una interpretación y discusión acerca de los mismos.

**Capítulo 6- Conclusiones y líneas futuras** En el último apartado de este trabajo, se presenta una visión general del Trabajo de Fin de Grado, resaltando las conclusiones obtenidas. Además, se abordan las dificultades enfrentadas durante su desarrollo y se plantean posibles áreas de investigación a partir de los resultados obtenidos.

## Capítulo 2

# ANTECEDENTES Y ESTADO DEL ARTE

En este capítulo se van a explorar los métodos de diagnóstico tanto del TDAH como de sus tipos. Se van a presentar los principales estudios que sugieren otro tipo de técnicas a la hora del diagnóstico del TDAH y sus tipos

## 2.1 DIAGNÓSTICO CONVENCIONAL

---

Comúnmente, el diagnóstico del TDAH y su tipo implican una evaluación exhaustiva que combina información clínica, observación del comportamiento y los criterios establecidos en los manuales diagnósticos, como el *Diagnostic And Statistical Manual Of Mental Disorders (DSM-V)*. La evaluación suele incluir entrevistas con el individuo afectado, sus padres, docentes o profesionales de la salud, así como recopilación de información acerca del sujeto, evaluaciones y exámenes médicos y psicológicos. A través de estas evaluaciones, se determina el tipo de TDAH que presenta el individuo, que puede ser predominantemente hiperactivo-impulsivo, predominantemente inatento o una combinación de ambos [10].

El diagnóstico del TDAH y su subtipo, siguiendo los criterios establecidos por el *Diagnostic And Statistical Manual Of Mental Disorders (DSM-V)* se realiza de la siguiente manera. A partir de una lista de 10 síntomas de inatención y otros 10 de hiperactividad/impulsividad, se seleccionan aquellos síntomas que han perdurado durante al menos 6 meses, presentando un grado que no concuerda con el nivel de desarrollo y que impacta negativamente en las actividades sociales y académicas [1]. En función de los síntomas detectados, se diagnostica el subtipo de TDAH:

- TDAH con presentación predominante inatenta (TDAH-I): si se detectan 6 o más síntomas de inatención.
- TDAH con presentación predominante hiperactiva/impulsiva (TDAH-H): si se diagnostican 6 o más síntomas de hiperactividad/impulsividad.
- TDAH con presentación combinada (TDAH-C): si se detectan 6 o más síntomas tanto de inatención como de hiperactividad/impulsividad.

Sin embargo, como se ha explicado en la introducción, este diagnóstico puede implicar cierto grado de subjetividad debido a la naturaleza de la evaluación clínica. La interpretación de los síntomas y la recopilación de información a través de entrevistas, cuestionarios y observaciones pueden verse influenciadas por diferentes percepciones y opiniones. Además, el diagnóstico se basa en la interpretación de los criterios establecidos en manuales como el DSM-V y esto puede llevar a discrepancias y a la posibilidad de errores de diagnóstico.

En esta línea, existen varios artículos que recalcan que el diagnóstico de los subtipos del TDAH según el DSM es sensible a cómo se detectan y cuantifican los síntomas. Las decisiones de los médicos están influenciadas por los informantes y la instrumentación y métodos empleados. Por ello, se sugiere estandarizar el proceso de clasificación de tipo de TDAH para mejorar el diagnóstico [11, 12].

Un diagnóstico preciso y la correcta identificación del tipo de TDAH son fundamentales para desarrollar un plan de tratamiento personalizado que aborde las necesidades individuales del paciente. Es por ello, que en la actualidad se han desarrollado estudios e investigaciones que proponen el uso de otras técnicas de diagnóstico basadas en métodos objetivos para detectar los subtipos del TDAH.

## 2.2 MÉTODOS OBJETIVOS DE DIAGNÓSTICO

---

### 2.3 BASADOS EN IMAGEN POR RESONANCIA MAGNÉTICA (MRI)

---

La **imagen por resonancia magnética (MRI)** es una técnica de imagen médica no invasiva que utiliza campos magnéticos que se utiliza para obtener imágenes detalladas del interior del cuerpo humano. Esta tecnología proporciona una visión tridimensional de los órganos y tejidos blandos del cuerpo, como el cerebro, que en nuestro caso resultará de gran utilidad.

Asimismo, existe la imagen por resonancia magnética funcional (fMRI), una técnica de neuroimagen que permite estudiar la actividad cerebral de manera no invasiva. La fMRI se utiliza para obtener imágenes detalladas de la estructura cerebral, pero además, es capaz de medir la actividad cerebral asociada a tareas o estados mentales. La fMRI mide los cambios en el flujo sanguíneo y la concentración de oxígeno en el cerebro los cuales están relacionados con la actividad neuronal.

Existen diversos estudios que utilizan las imágenes por resonancia magnética del cerebro de los pacientes con el objetivo de lograr un diagnóstico objetivo del tipo de TDAH. Muchos de estos estudios combinan la MRI con técnicas de Deep Learning o aprendizaje automático a fin de realizar la clasificación de una manera automática y objetiva.

En la tabla 2.1 se presentan los principales estudios de clasificación de TDAH que se basan en MRI.

Artículo	Resumen
Sidhu et al. [13]	Este estudio analizó varios métodos de extracción de características para el diagnóstico automatizado del TDAH a partir de datos de fMRI y fenotípicos de ADHD-200. Se utilizaron técnicas de aprendizaje automático como el clasificador SVM que intentaron diferenciar entre pacientes con TDAH y controles sanos, así como entre pacientes TDAH-C y TDAH-I. Los resultados sugieren que la combinación de datos fenotípicos e imágenes de fMRI con extracción de características basada en FFT y kPCA-st puede mejorar la precisión del diagnóstico automatizado del TDAH.
dos-Santos-Siqueira et al. [14]	El estudio utilizó medidas de descripción gráfica como algoritmo de clasificación para clasificar entre niños con desarrollo típico y pacientes con TDAH utilizando fMRI de la base de datos ADHD-200. Los resultados sugieren que estas medidas pueden ser más útiles para distinguir entre diferentes subtipos de TDAH que para diferenciar entre pacientes con TDAH y sujetos sanos.
Deshpande et al. [15]	El artículo sugiere el uso de una FCC ANN (red neuronal artificial en cascada completamente conectada) para clasificar el TDAH a partir de datos fMRI. Logró una alta precisión de clasificación cercana al 90 % para diferenciar entre TDAH y sujetos sanos, y alrededor del 95 % para subtipos de TDAH. Las características de conectividad revelaron patrones alterados en regiones cerebrales específicas asociadas al TDAH como una conectividad reducida y alterada en la corteza orbitofrontal izquierda y varias regiones cerebelosas.
Park et al. [16]	Este estudio explora las diferencias de conectividad entre los subtipos de TDAH y busca clasificarlos basándose en características de neuroimagen. El estudio estaba compuesto por pacientes de tipo inactivo y combinado que se sometieron a fMRI con seis tareas diferentes. En las tareas con mejores resultados, la precisión del clasificador para distinguir entre los subtipos de TDAH fue del 91.18 %. Además, se encontraron diferencias significativas de conectividad en diversas áreas del cerebro.
Semrud-Clikeman et al. [17]	Se compararon grupos de niños con TDAH-C y TDAH-I y controles utilizando medidas de resonancia magnética volumétrica (MRI) con objeto de encontrar diferencias en partes del cerebro entre ellos. Se encontró que el grupo con TDAH-C tenía volúmenes más pequeños del córtex cingulado anterior (ACC) y el núcleo caudado en comparación con los otros dos grupos. Las observaciones de los padres de hiperactividad se relacionaron con el volumen del caudado, mientras que la atención se relacionó con el del ACC.

Qureshi et al. [18]	Este estudio utilizó imágenes de resonancia magnética (MRI) cortical de pacientes con TDAH para realizar una clasificación entre sujetos sanos y pacientes con TDAH-I y TDAH-C. Se usó un clasificador jerárquico de aprendizaje extremo (H-ELM) y se comparó su rendimiento con el de una máquina de soporte vectorial (SVM) y una máquina de aprendizaje extremo básica (ELM). Se logró una precisión de clasificación del 60.78 % utilizando la combinación de la eliminación recursiva de características basada en SVM (RFE-SVM) con H-ELM. Además, se encontraron que las características más importantes para la clasificación residían en partes concretas del cerebro.
Fair et al. [19]	El objetivo del trabajo era evaluar el impacto de las técnicas emergentes para controlar los micromovimientos y obtener nuevos conocimientos sobre los correlatos neurales de los subtipos de TDAH. Empleando técnicas de Deep Learning, se extrajo que los patrones de conectividad funcional en las personas son suficientes para diferenciar los dos subtipos de TDAH más destacados (TDAH-C y TDAH-I). Se observaron patrones de conectividad atípica en distintas áreas cerebrales para cada subtipo. Los resultados destacan la importancia de corregir rigurosamente los artefactos de movimiento en los estudios de MRI y muestran que los datos de fMRI pueden caracterizar a pacientes individuales con TDAH

TABLA 2.1: Estudios basados en imagen por resonancia magnética (MRI)

## 2.4 BASADOS EN ELECTROENCEFALOGRAMA (EEG)

Un **electroencefalograma (EEG)** es una prueba neurofisiológica que se utiliza para medir la actividad eléctrica de las células nerviosas del cerebro (neuronas). Para realizarla, se le colocan electrodos en el cuero cabelludo al paciente, dichos electrodos captan las señales eléctricas generadas por las neuronas y se registran. Como resultado se obtienen estas señales que indican la actividad eléctrica del cerebro la cual puede mostrarse como ondas en forma de patrones gráficos.

El EEG es una herramienta muy útil para diagnosticar condiciones como epilepsia, encefalopatías, tumores cerebrales, trastornos del sueño u otras afecciones neurológicas como en este caso el Trastorno por Déficit de Atención e Hiperactividad (TDAH).

Los electroencefalogramas se pueden definir en función de las oscilaciones neuronales las cuales se dividen en varias bandas. Cada una de estas bandas se asocia con distintos estados mentales y niveles de actividad cerebral. A continuación, se describen las principales bandas de frecuencia del EEG y el estado mental o actividad cerebral con que se relacionan [20]:

- Ondas delta (0.5-4Hz): sueño profundo.
- Ondas theta (4-8 Hz): sueño REM y meditación o relajación.

- Ondas alfa (8-14 Hz): relajación y descanso con los ojos cerrados, pero despierto.
- Ondas beta (14-30Hz): estado de vigilia y concentración activa
- Ondas gamma (más de 30Hz): estímulos sensoriales

En la tabla 2.2 se muestran los estudios más relevantes de clasificación de subtipos TDAH basados en electroencefalografía.

Artículo	Resumen
Slater et al. [21]	El TDAH se ha asociado con patrones atípicos de actividad neuronal medidos por electroencefalografía, pero debido a la heterogeneidad del TDAH, la identificación de biomarcadores de diagnóstico mediante EEG no ha sido posible. En este estudio se ha buscado relacionar el EEG con el diagnóstico del TDAH, sus tipos y la gravedad de sus síntomas. Los resultados resaltan el potencial de las medidas electrofisiológicas para proporcionar información significativa sobre el TDAH, aunque no como diagnóstico.
Clarke et al. (1998) [22]	El estudio comparó el EEG de niños con TDAH-C, TDAH-I y sujetos de control durante una condición de reposo con los ojos cerrados. Los sujetos con TDAH mostraron niveles más altos de ondas theta y deficiencias de alfa y beta en comparación con el grupo de control. Los niños con TDAH-I se diferenciaron más de los del tipo combinado y parecieron tener perfiles más cercanos a lo normal. Sin embargo, se sugiere que esto se debe en mayor medida a la gravedad del trastorno que a diferencias neurológicas entre tipos. Los resultados respaldan un modelo de retraso madurativo del sistema nervioso central en el TDAH.
Clarke et al. (marzo 2001) [23]	En este estudio, de nuevo, se comparó el EEG de niños con dos subtipos de TDAH y sujetos de control normales durante el reposo con ojos cerrados. Se encontraron diferencias significativas en las bandas theta, alfa y beta, así como en las proporciones theta/alfa y theta/beta y la frecuencia media del EEG total. Estos hallazgos respaldan que el TDAH es una desviación del sistema nervioso central en lugar de un retraso en la maduración del mismo y sugieren que los subtipos de TDAH pueden estar asociados con diferentes sistemas específicos del cerebro.
Clarke et al. (noviembre 2001) [24]	Nuevamente se estudiaron los EEG de sujetos de control y pacientes con el trastorno, en este caso TDAH-C. Ahora, se encontraron tres grupos EEG distintos en los niños con TDAH, cada uno con características específicas de actividad cerebral, lo que supone que los niños con TDAH no forman un grupo homogéneo en términos de perfil EEG. Clarke et al. concluye que, es necesario conocer esta variabilidad dentro de la población con TDAH para que el EEG pueda ser una herramienta válida de diagnóstico.

Mazaheri et al. [25]	En este artículo, se buscó identificar diferencias neurofisiológicas entre adolescentes con desarrollo típico y aquellos con TDAH de tipo inatento y combinado. Se llevaron a cabo los EEG de los participantes mientras estos realizaban una tarea de flanco (prueba de psicología de inhibición de respuestas que sirve para medir el procesamiento de la información y la atención selectiva ). En los resultados, se encontraron diferencias en las bandas de frecuencia entre los grupos y se concluyó que los cambios en las oscilaciones del EEG debido a la tarea de flanco proporcionan un método de diagnóstico objetivo de subtipos de TDAH.
Tenev et al. [26]	En este caso, se combinó la electroencefalografía con técnicas de <i>Machine Learning</i> . Las muestras analizadas incluían a adultos sanos y pacientes de los tres tipos de TDAH. Los EEG se realizaron en 4 condiciones diferentes: en reposo (ojos abiertos y cerrados) y dos pruebas neuropsicológicas (prueba de rendimiento continuo visual y prueba de rendimiento continuo emocional). Cada uno de estos 4 conjuntos de datos se utilizaron para entrenar un clasificador SVM diferente y más tarde se combinan los resultados. Los resultados mostraron que de esta manera, se mejora la discriminación entre subtipos de TDAH ya que cada subtipo tiene actividades cerebrales diferentes.
Ahmadi et al. [27]	En este artículo no se ofrece un diagnóstico concreto del subtipo de TDAH, sin embargo resulta interesante ya que utiliza una CNN al igual que para la realización del presente trabajo. Se propuso un sistema de diagnóstico asistido por ordenador basado en aprendizaje profundo para clasificar señales EEG de niños con TDAH (subtipos combinado e inatento) y niños sanos. Se utilizó una red neuronal convolucional (CNN) para extraer características espaciales y frecuenciales de las señales EEG. Se obtuvieron, valores de precisión y exactitud superiores al 99 %.

TABLA 2.2: Estudios basados en electroencefalograma (EEG)

## 2.5 BASADOS EN OTROS MÉTODOS

Además de los estudios basados en resonancia magnética y encefalograma, se han realizado estudios en los que se pretende clasificar el tipo de TDAH mediante otras técnicas y métodos objetivos.

En la tabla 2.3 se presentan los estudios más relevantes de clasificación de subtipos TDAH basados en otro tipo de técnicas.

Artículo	Resumen
Kral et al. [28]	El estudio se enfocó en caracterizar el TDAH en jóvenes que sufrían <b>epilepsia</b> . Se analizaron datos de niños y adolescentes con epilepsia, agrupándolos según el diagnóstico de TDAH (sanos, TDAH-C y TDAH-I), y se compararon variables neurocognitivas, relacionadas con las convulsiones y escalas de calificación del comportamiento medidas por padres y maestros. Se encontró una alta tasa de diagnóstico de TDAH, con mayor frecuencia de TDAH de tipo combinado. Las diferencias más notables entre los grupos fueron observadas en las escalas que evalúan falta de atención, hiperactividad y disfunción ejecutiva tomadas por los padres, mientras que diferían menos en cuanto a las convulsiones y las variables cognitivas.
Zhu et al. [29]	En este estudio se utilizó la <b>espectroscopia funcional de infrarrojo cercano</b> (fNIRS) con objeto de medir y estudiar la activación de la corteza prefrontal (CPF) en niños con diferentes subtipos de TDAH durante una tarea de función ejecutiva. En el estudio participaron niños con desarrollo típico y niños con TDAH tanto de tipo inatento como combinado. Se observó que los 3 grupos activaban el CPF derecho durante la prueba en la inhibición de las respuestas diferencias. Sin embargo, existían diferencias en el grado de activación del CPF derecho, por lo que su activación se relaciona negativamente con la sintomatología clínica. También se observaron activaciones alteradas en otras regiones cerebrales en los niños con TDAH. Los resultados sugieren que fNIRS podría ser un candidato como solución al diagnóstico de TDAH y su tipo.
Rostami et al. [30]	En este estudio, se empleó un método de <b>árbol de decisiones</b> para reconocer a niños con TDAH y sus subtipos (TDAH-I, TDAH-C y TDAH-H). Se utilizaron diferentes herramientas de evaluación, como la lista de verificación de comportamiento infantil (formulario que identifica el comportamiento problemático en los niños), una prueba visual y auditiva integrada, y un EEG para evaluar el nivel de marcadores de comportamiento, neuropsicología y electrofisiología respectivamente. Los resultados mostraron una alta precisión (100 %) para discriminar a niños con TDAH sanos y una precisión del 80,41 %, 84,17 % y 71,46 % para reconocer los subtipos combinado, inatento e hiperactivo, respectivamente. El método del árbol de decisiones podría ser una herramienta eficiente y precisa para el diagnóstico de TDAH y sus subtipos.

Smith et al. [31]	En este artículo, se buscó evaluar la posibilidad de utilizar medidas de <b>potencial relacionado con eventos</b> (PRE) para clasificar de manera fiable a niños y adolescentes con TDAH en comparación con controles normales, así como para distinguir entre los subtipos de TDAH (TDAH-C y TDAH-I). Un PRE es una medida de la respuesta cerebral frente a estímulos externos. Los resultados mostraron que para niños de 8 a 12 años, los subtipos de TDAH se clasificaron con una precisión del 69,4%. Sin embargo, la utilidad clínica del análisis de ERP disminuyó para adolescentes de 13 a 18 años, con una precisión de clasificación del 62,7%. Se recomienda usar las medidas ERP junto con otras medidas de la función cerebral para mejorar la precisión del diagnóstico.
-------------------	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

TABLA 2.3: Estudios basados en otros métodos

## 2.6 BASADOS EN ACTIMETRÍA

La **actimetría**, también conocida como actigrafía, es una técnica no invasiva que permite registrar de manera objetiva el movimiento a través de un dispositivo llamado actímetro. El actímetro es un pequeño sensor que se coloca cómodamente en la muñeca del paciente y mide la aceleración de los movimientos en las tres direcciones del espacio, se obtienen señales de actividad y descanso, permitiendo monitorizar los ciclos del sueño y vigilia. La facilidad de uso del actímetro es una ventaja significativa, ya que no afecta la rutina diaria ni el entorno social del paciente [32].

Esto contrasta con técnicas anteriores como la resonancia magnética o el electroencefalograma, que resultaban más intrusivas y menos amigable para el paciente. Además, la actimetría supone un método más económico y accesible que la resonancia magnética y el EEG. Por tanto, la actimetría se presenta como una prometedora herramienta en el diagnóstico de patologías y trastornos, permitiendo un diagnóstico objetivo de manera no invasiva y a un costo menor [32, 33].

La actimetría es la técnica en la que se basa este trabajo, concretamente, [4] es el punto de partida del trabajo. En [4] se emplean registros de actigrafía junto con redes convolucionales y técnicas de *Deep Learning* para obtener patrones diferenciadores entre sujetos con TDAH-I y TDAH-C, divididos en grupos en función de su edad y sexo. Para ello, se llevó a cabo un análisis de los mapas de oclusión de los sujetos los cuales fueron modelados mediante mezcla de gaussianas. De esta manera se extrajo qué parámetros de la gaussiana son los más importantes para la detección de los subtipos.

En esta línea, se han llevado a cabo estudios basados en actimetría para abordar el diagnóstico del TDAH y sus subtipos, los cuales servirán de base para este trabajo. En la tabla 2.4 se presentan estos estudios basados en métodos actimétricos:

Artículo	Resumen
Martín-Martínez et al. [33]	Se propone un método innovador para diagnosticar el TDAH combinado en niños y adolescentes utilizando registros actigráficos de 24 horas. Este enfoque es no invasivo y económico, con una sensibilidad del 96.77 % y especificidad del 84.38 % en datos reales. Además, se sugiere que el intervalo completo de 24 horas es el más importante a la hora de un diagnóstico preciso. Estos resultados superan a otros métodos basados en actigrafía y son comparables a métodos más costosos.
Casaseca-de-la-Higuera et al. [34]	En este artículo, se propone una nueva metodología basada en la evaluación conjunta de la complejidad de registros de actividad multicanal, en lugar de en un solo canal como hacían estudios anteriores. Los resultados en datos reales muestran una sensibilidad del 87.10 % y una especificidad del 84.38 %, mejorando aún más cuando se combinan con indicadores basados en complejidad de un solo canal. Esta metodología promete ser una herramienta útil y precisa para el diagnóstico de TDAH de manera más accesible y confiable.
Amado-Caballero et al. [2]	Se propone un método automático para diagnosticar el TDAH combinado en niños y adolescentes utilizando registros de actividad de 24 horas y redes neuronales convolucionales. Los resultados muestran una sensibilidad promedio del 97.62 %, especificidad del 99.52 % y valores de AUC superiores al 99 %. El artículo demuestra que combinar técnicas de aprendizaje profundo con actimetría puede llevar a un sistema eficaz y confiable para el diagnóstico objetivo del TDAH de manera económica y no invasiva.
Amado-Caballero et al. [5]	En este artículo, se propone una metodología para interpretar los resultados de diagnóstico de TDAH en poblaciones divididas por edad y género basada en inteligencia artificial. Utiliza redes neuronales convolucionales para analizar registros de actividad de 24 horas y destacar patrones en tiempo y frecuencia a través de mapas declusión. Los resultados muestran diferencias significativas en los patrones de frecuencia entre pacientes con TDAH y controles. Estas técnicas de interpretación podrían mejorar la precisión diagnóstica y proporcionar una comprensión más profunda del TDAH.
Muñoz-Organero et al. [35]	En este estudio, se analizaron datos de acelerómetros en 22 niños, 11 con TDAH y 11 controles. Los niños usaron dos acelerómetros durante la escuela, situados en la muñeca y en el tobillo de la mano y pierna dominante respectivamente. Se convirtieron las señales en imágenes de aceleración 2D y se empleó una red neuronal convolucional (CNN) para distinguir entre los grupos. Los resultados mostraron diferencias significativas en la actividad de la muñeca en ambos grupos y en el tobillo solo en los niños no medicados. La CNN para extraer información acerca de los patrones de aceleración, se logró una precisión del 87.5 % en la muñeca y del 93.75 % en el tobillo.

Mahony et al. [36]	Este estudio propone el uso de sensores inerciales inalámbricos para diagnosticar el TDAH objetivamente. Estos sensores han sido colocados en la cintura y tobillo dominantes y miden el movimiento lineal y rotacional y durante una consulta psiquiátrica. Utilizando un SVM para clasificar sujetos como TDAH o no TDAH se logra una precisión del 95 % o más. Se concluyó que el movimiento registrado durante una tarea de concentración forzada proporciona una mejor clasificación que durante el tiempo libre.
Wiebe et al. [37]	Se investigó la relación entre los patrones de sueño y la somnolencia diurna en niños con TDAH y niños con desarrollo típico. Se registró en sus hogares el sueño habitual durante cinco noches y polisomnografía durante una noche. La somnolencia fue evaluada al día siguiente mediante la prueba de latencia múltiple del sueño. Encontraron que en niños con desarrollo típico, un sueño más largo se relacionaba con una latencia de sueño más larga al día siguiente. En cambio, en niños con TDAH, la inquietud durante la noche y el tiempo en reposo lento se relacionaban con se relacionaron positivamente con la latencia media del sueño.
Alderson et al. [38]	Este estudio examinó la relación entre la actividad motora y la inhibición del comportamiento en niños con TDAH y niños con comportamiento típico. Se investigó la relación entre la actividad motora de los niños y la inhibición del comportamiento mediante varias tareas que exigen atención y control. Se midió la actividad motora mediante actígrafos. Todos los niños mostraron una mayor actividad en las tareas experimentales en comparación con las condiciones de control, y los niños con TDAH tuvieron más actividad en todas las condiciones. No hubo diferencias significativas en la actividad entre las tareas de inhibición y no inhibición, sugiriendo que la actividad motora se relaciona principalmente con procesos de inhibición atencionales en lugar de conductuales.
Nakatani et al. [39]	En este artículo se analiza el movimiento corporal durante el sueño en niños con y sin TDAH utilizando imágenes de vídeo. Se analizaron los grandes movimientos corporales brutos que ocurren durante la noche y se obtuvo la tasa de movimientos brutos y la duración del descanso. Se encontraron diferencias significativas en los movimientos corporales entre los dos grupos, con los niños con TDAH mostrando más movimiento y menos duración de sueño ininterrumpido. Además, se destacaron diferencias en el sueño REM ( $p < 0,05$ ). Los resultados sugieren la posibilidad de desarrollar en el futuro un dispositivo de diagnóstico para el TDAH basado el procesamiento de imágenes de vídeo.

TABLA 2.4: Estudios basados en otros métodos

Tras observar todas los métodos en la detección del TDAH y sus subtipos, podemos concluir que la actimetría ha demostrado ser una herramienta de interés en el diagnóstico del TDAH. La actimetría se presenta como una opción más económica y accesible en comparación con la resonancia magnética o el EEG, lo que la hace especialmente valiosa. Además, los avances en técnicas de aprendizaje automático han potenciado aún más su eficacia en la obtención de resultados significativos como en [3] y [4]. Es por ello que en el presente trabajo se opta por la actimetría como método de identificación del subtipo hiperactivo de TDAH.

## Capítulo 3

# APRENDIZAJE AUTOMÁTICO

Durante la elaboración de este trabajo se han empleado diversas técnicas de aprendizaje automático, concretamente redes neuronales artificiales. En el presente capítulo se busca abordar el tema del *Deep Learning* o aprendizaje profundo, así como su relación con los conceptos de Inteligencia Artificial y *Machine Learning*.

### 3.1 INTELIGENCIA ARTIFICIAL, *Machine Learning* Y *Deep Learning*

La **Inteligencia Artificial** (IA) es un campo de la informática que busca desarrollar sistemas capaces de imitar la inteligencia humana. Su objetivo es realizar tareas que realizamos los humanos como el razonamiento, el aprendizaje, la comprensión del lenguaje o la toma de decisiones. La Inteligencia Artificial busca crear programas y algoritmos que puedan simular procesos cognitivos humanos y resolver problemas de manera eficiente. La IA ha tenido un impacto significativo en la sociedad y se ha convertido en una parte integral de muchas industrias y aspectos de la vida cotidiana como los asistentes virtuales, la publicidad *online* personalizada o la conducción autónoma.

El *Machine Learning* (ML) o aprendizaje automático es un campo de la Inteligencia Artificial que se centra en el desarrollo de algoritmos y modelos que permite aprender a los sistemas informáticos o máquinas una tarea específica. El aprendizaje automático en las máquinas, se basa en modelos basados en la observación de datos. Este aprendizaje es el que diferencia al ML de otro tipo de algoritmos ya que en lugar de utilizar reglas predefinidas, el ML utiliza datos para entrenar modelos y tomar decisiones basadas en patrones y relaciones descubiertos en esos datos. Esto permite que las máquinas identifiquen patrones y realicen predicciones o tomen decisiones de manera similar a un humano.

El *Deep Learning* (DL) es una subdisciplina del *Machine Learning* cuyo objetivo es replicar el pensamiento y el procesamiento de la información que tenemos los humanos. El *Deep Learning* ha revolucionado numerosos campos de la inteligencia artificial y el aprendizaje automático debido a su capacidad para abordar tareas complejas de manera efectiva. El *Deep Learning* destaca en tareas sencillas para los humanos, pero complejas para las máquinas como el procesamiento de imágenes, el reconocimiento de voz, o el procesamiento del lenguaje natural.

El *Deep Learning* se basa en modelos jerárquicos de múltiples capas que permiten aprender a partir de grandes cantidades de datos, también conocidas como redes neuronales profundas. Estas redes están diseñadas para modelar y resolver problemas complejos de aprendizaje automático al aprender automáticamente patrones, a partir del entrenamiento de la red, y representaciones de datos a través de capas de neuronas interconectadas.

Comparando el *Machine Learning* con el *Deep Learning*, el DL aprende y extrae características acerca de los datos de forma automática, directamente del entrenamiento, mientras que el ML lo hace manualmente. Por otra parte, el *Deep Learning* utiliza modelos más complejos como las redes neuronales más complejas y profundas que el *Machine Learning*. Además, el DL puede trabajar con big data ya que el DL maneja mejor conjuntos de datos grandes que el ML, esto significa que necesite más recursos computacionales, como unidades de procesamiento gráfico (GPUs).

En resumen, la Inteligencia Artificial es el campo general que busca imitar la inteligencia humana, el *Machine Learning* es una técnica que permite a las máquinas aprender a partir de datos y el *Deep Learning* es una subdisciplina del *Machine Learning* que utiliza redes neuronales profundas para modelar datos más complejos. Estas tres áreas están relacionadas y se superponen en varios aspectos, pero se distinguen por sus enfoques y aplicaciones específicas [40, 41]. Esta relación se puede observar en la figura 3.1.

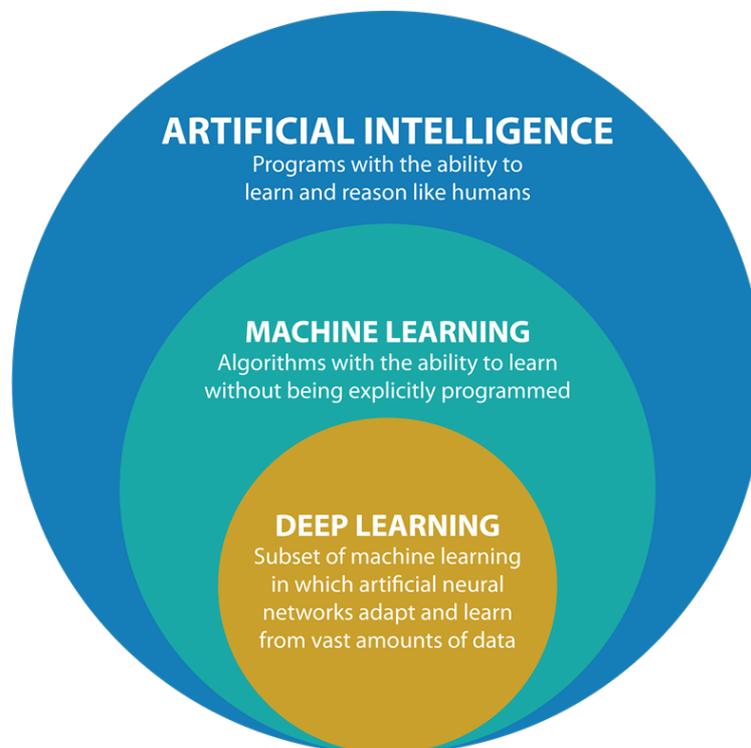


FIGURA 3.1: Relación entre Inteligencia Artificial, *Machine Learning* y *Deep Learning*

## 3.2 REDES NEURONALES

Las redes neuronales artificiales son un modelo computacional que se inspiran en la estructura y el funcionamiento básico de las neuronas y el cerebro humano. Las redes neuronales se basan en conjuntos de nodos o neuronas conectados entre sí formando capas. Estas redes son capaces de aprender y reconocer patrones a partir de datos, ajustando automáticamente sus conexiones ponderadas para realizar tareas complejas. Su estructura y capacidad de adaptación las han convertido en una herramienta fundamental en el campo de la inteligencia artificial.

### 3.2.1 ESTRUCTURA Y FUNCIONAMIENTO

La **neurona artificial** es la unidad básica de procesamiento que simula el comportamiento de las neuronas biológicas de nuestro cerebro. Cada neurona tiene un estado interno (nivel de activación) y recibe señales que le pueden hacer cambiar de estado. El funcionamiento de estas neuronas es el representado en la figura 3.2 [42, 43, 44]:

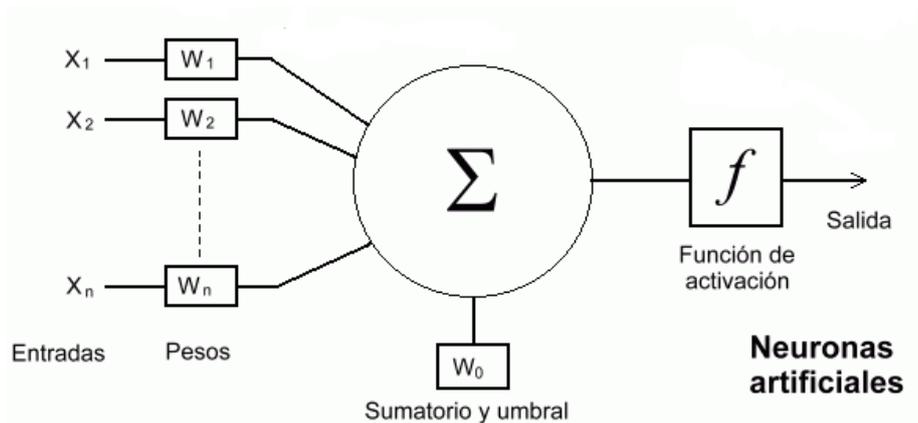


FIGURA 3.2: Funcionamiento de una neurona artificial

En la figura 3.2 se pueden observar los diferentes factores de los que depende la salida de una neurona artificial en una red neuronal [45, 46]:

- **Entradas** ( $x_1, x_2, \dots, x_n$ ): entradas que recibe la neurona artificial.
- **Pesos** ( $w_1, w_2, \dots, w_n$ ): los pesos indican la importancia de cada una de las entrada de la neurona. De esta manera se forman las entradas ponderadas, esto es, las entradas multiplicadas por su peso correspondiente.
- **Umbral o bias** ( $w_0$ ): constante ajustable que se agrega a las entradas ponderadas.
- **Sumatorio ponderado** ( $\sum w_i x_i$ ): se realiza una suma ponderada de las entradas multiplicadas por sus pesos correspondientes.
- **Función de activación** ( $\gamma$ ): se trata de una función que introduce no linealidad y determina la salida de la neurona en función del sumatorio de las entradas ponderadas y el *bias*.

Matemáticamente, la salida de neurona artificial se puede expresar de la siguiente manera [45]:

$$y = \gamma\left(\sum w_i x_i + w_0\right) \quad (3.1)$$

En cuanto a las funciones de activación, existen varios tipos de funciones. Funciones no lineales simples como la función escalón o la función signo se pueden emplear como funciones de activación. Sin embargo, funciones más complejas y sofisticadas como la sigmoide, la función ReLU (*Rectified Linear Unit*) o la tangente hiperbólica ofrecen mejores resultados, las cuales pueden observarse en la figura 3.3 [45, 47].

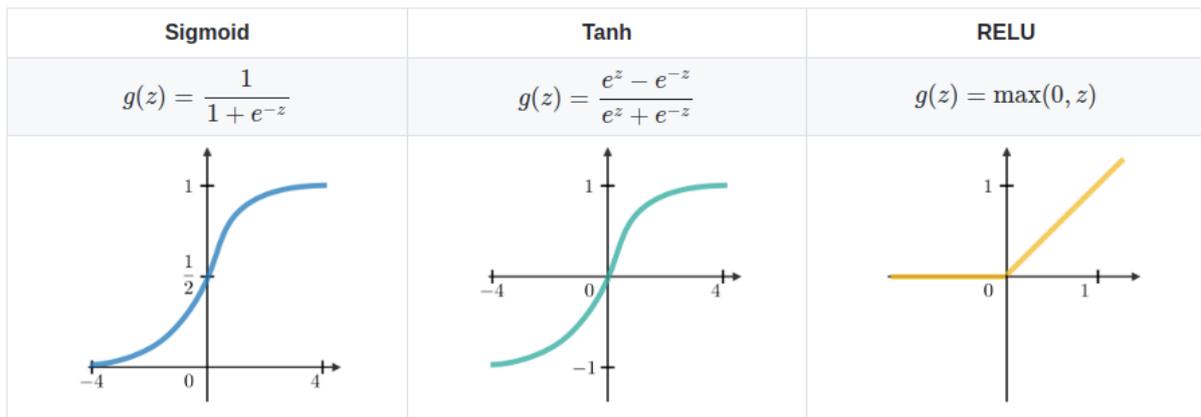


FIGURA 3.3: Funciones de activación

Una **red neuronal** multicapa, se forma agrupando las neuronas en capas en cascada. Estas capas son agrupaciones de neuronas que se conectan entre sí para procesar la información a medida que avanza a través de la red. La salida de una capa es la entrada de la siguiente capa. Cada una de estas capas puede tener una función específica dentro de la red. Existen tres tipos de capas en toda red neuronal [46, 47]:

- **Capas de entrada:** capas que reciben los datos procedentes del exterior de la red.
- **Capas ocultas:** capas internas de la red que procesan y transforman la información para extraer características complejas de los datos. El número de capas ocultas es variable en función de las necesidades de la red. Cuantas más capas ocultas haya, la profundidad y la capacidad de la red será mayor.
- **Capas de salida:** trasladan la información de salida de la red neuronal al exterior.

En la figura 3.4 se presenta la arquitectura de una red neuronal multicapa:

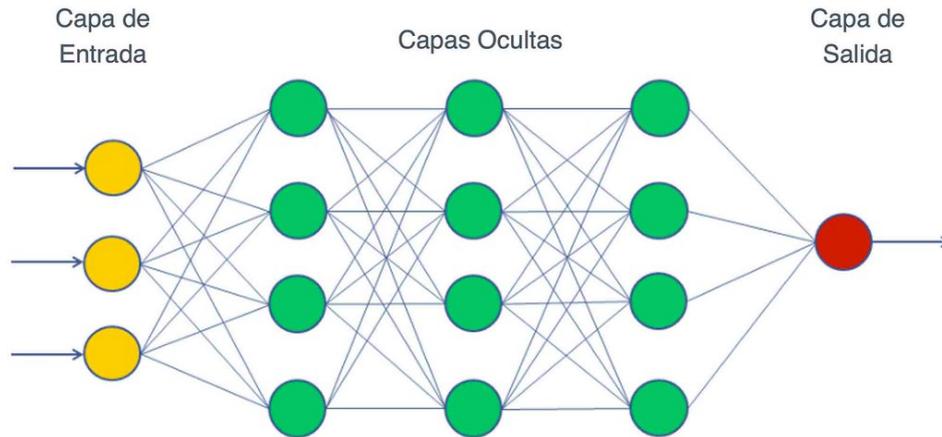


FIGURA 3.4: Arquitectura de una red neuronal multicapa

### 3.2.2 APRENDIZAJE Y ENTRENAMIENTO

El aprendizaje o entrenamiento en una red neuronal se refiere al proceso mediante el cual una red neuronal ajusta sus parámetros internos para que pueda realizar tareas específicas de manera más efectiva. En esencia, es el proceso mediante el cual la red neuronal aprende patrones y relaciones a partir de un conjunto de datos de entrada y las salidas correspondientes. El objetivo del entrenamiento es que a lo largo del proceso de aprendizaje, se vaya mejorando de manera iterativa el modelo hasta llegar a un nivel adecuado de rendimiento. Existen tres tipos de aprendizaje en el contexto de las redes neuronales [48, 49]:

- **Aprendizaje supervisado:** se proporciona a la red neuronal un conjunto de datos etiquetados, es decir, datos de entrada junto con las salidas deseadas correspondientes. La red aprende a mapear las entradas a las salidas a través del proceso de entrenamiento y busca minimizar la diferencia entre las salidas reales y las predicciones de la red.
- **Aprendizaje no supervisado:** la red neuronal es entrenada con datos no etiquetados. Su objetivo es descubrir patrones y estructuras inherentes en los datos. Al contrario que en el aprendizaje supervisado, no se tienen las salidas deseadas, por lo que la red debe encontrar relaciones interesantes y formar agrupaciones de aquellos datos con más parecidos entre sí (clústeres).
- **Aprendizaje por refuerzo:** en este caso, la red neuronal (llamada agente) aprende gracias al entorno. El agente aprende en base a la retroalimentación o recompensas (positivas o negativas) aportada al realizar dicha acción. Por lo tanto, el agente busca maximizar estas recompensas.

Como hemos explicado antes, el entrenamiento de una red neuronal es el proceso mediante el cual se ajustan los pesos de una red para que esta pueda aprender a realizar una tarea. Existen varios algoritmos de entrenamiento diseñados para optimizar la convergencia y el rendimiento de las redes neuronales, cada uno con sus propias características y ventajas, lo que permite adaptar el proceso de entrenamiento a las necesidades particulares de cada aplicación.

En nuestro caso, el algoritmo de entrenamiento que se ha utilizado en el trabajo ha sido el *Stochastic Gradient Descent with Momentum (SGDM)*, utilizado también en [3]. Se trata de un método iterativo que busca minimizar el gradiente de la función de pérdida, pero con la adición de un término de *momentum* o impulso que incorpora información acerca de los gradientes anteriores [50]:

$$\theta_{n+1} = \theta_n - \gamma \nabla \ell(\theta_n, \xi_{n+1}) + \beta(\theta_n - \theta_{n-1}) \quad (3.2)$$

Donde  $\theta_n$  son los parámetros en la iteración  $n$ ,  $\gamma$  es la tasa de aprendizaje o *learning rate*,  $\nabla \ell$  es el gradiente de la función de pérdida,  $\xi$  es una fuente de aleatoriedad y  $\beta$  es el *momentum*.

### 3.2.3 MODELOS DE REDES NEURONALES

En el ámbito del Aprendizaje Profundo, existen diferentes modelos de redes neuronales para abordar diversas problemáticas. En esta sección, se presentan los modelos más relevantes de redes neuronales.

#### 3.2.3.1 REDES NEURONALES FEED-FORWARD

Las **redes neuronales *feed-forward*** (feed-forward neural network, FNN) es una topología básica de red neuronal en la que las neuronas se agrupan formando capas. Este tipo de redes se caracterizan por tener una dirección unidireccional del flujo de información, es decir, la información fluye desde la capa de entrada hasta la de salida sin realimentaciones desde capas posteriores a otras anteriores.

Estas redes están compuestas por capas de neuronas interconectadas, incluyendo una capa de entrada, varias capas ocultas y una capa de salida y su estructura se puede observar en la figura 3.4. Si la red neuronal cuenta con varias capas ocultas, este tipo de redes reciben el nombre de perceptrón multicapa (*Multilayer Perceptron*, MLP) [43, 44].

En este tipo de redes, existe un algoritmo de entrenamiento muy destacable, el algoritmo de *backpropagation* o de retropropagación. Este algoritmo consiste en ajustar los pesos de las conexiones entre neuronas con el objetivo de minimizar el error entre las salidas predichas por la red y las salidas reales del conjunto de entrenamiento. El proceso consiste en propagar este error hacia atrás en cada capa ajustando los pesos. Mediante la repetición de este proceso en múltiples iteraciones, la red ajusta gradualmente sus pesos para mejorar sus resultados [51, 52].

En resumen, las redes FNN o el perceptrón multicapa es una arquitectura de red neuronal versátil y simple que se utiliza para abordar una variedad de tareas como procesamiento de información, clasificación, regresión o reconocimiento de patrones.

### 3.2.3.2 REDES NEURONALES RECURRENTES

Las **redes neuronales recurrentes** (*recurrent neural network*, RNN) forman junto con las redes neuronales feed-forward las arquitecturas básicas de redes neuronales artificiales. En contraste con las redes FNN que eran unidireccionales, las redes RNN son bidireccionales. La principal característica de las redes neuronales recurrentes es que existen conexiones recurrentes o realimentaciones entre neuronas que permiten que la salida de la red en un momento dado se utilice como entrada en el siguiente paso de tiempo, formando así un bucle de realimentación [53].

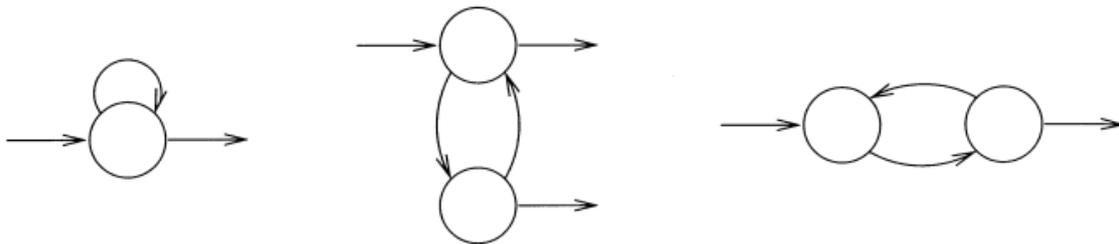


FIGURA 3.5: Conexiones recurrentes o realimentaciones entre neuronas

En la figura 3.5, se pueden ver las realimentaciones que se dan entre una neurona y ella misma, entre neuronas de una misma capa o entre neuronas de capas diferentes. Gracias a estas realimentaciones, la red neuronal es capaz de tener una memoria interna y noción del tiempo. Por ello, este tipo de redes son especialmente útiles para tareas que involucran secuencias de datos, ya que permiten a la red modelar y comprender cómo los elementos de la secuencia están relacionados entre sí a lo largo del tiempo [43].

### 3.2.3.3 REDES NEURONALES DE BASE RADIAL

Las **redes neuronales de base radial** (*Radial Basis Function Networks*, RBF) son un tipo de red neuronal que utilizan funciones de base radial como funciones de activación. Las funciones de base radial son funciones matemáticas cuyos valores únicamente dependen de la distancia entre un punto de entrada y un punto fijo (centro) [54, 55].

Estas redes están formadas por una capa de entrada, una única capa oculta y una capa de salida. Esta capa oculta, es lo que las distingue del perceptrón multicapa. En esta capa, se encuentran las neuronas con funciones de base radial y de esta manera se introducen no linealidades.

En la figura 3.6 se puede ver la estructura básica de una red de base radial.

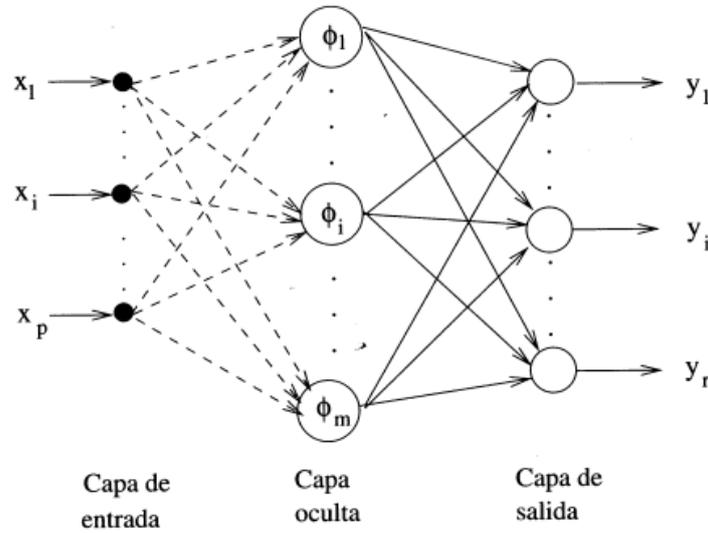


FIGURA 3.6: Estructura de una red neuronal de base radial

Las salidas de una red neuronal de base radial como en la figura 3.6 con  $p$  neuronas de entrada,  $m$  en la capa oculta y  $r$  neuronas de salida viene dada por la siguiente expresión [43]:

$$y_k(n) = \sum_{i=1}^m w_{ik} \phi_i(n) + u_k \quad \text{con } k = 1, \dots, r \quad (3.3)$$

Siendo  $w_{ik}$  los pesos de cada conexión de cada neurona,  $u_k$  el umbral de cada neurona y  $\phi$  la función de activación. Como hemos comentado antes, las funciones de activación son funciones de base radial. Estas funciones ( $\phi$ ) determinan las activaciones de las neuronas las cuales se pueden expresar como [43, 56]:

$$\phi_i(n) = \phi \left( \frac{\|X(n) - C_i\|}{d_i} \right) \quad (3.4)$$

Donde  $\phi$  es la función de base radial,  $X(n)$  es el vector de entrada,  $C_i$  el vector con los centros de la función y  $d_i$  la desviación de la función  $\phi$ . Por lo tanto, la activación depende de la distancia euclídea entre los puntos de entrada y los centros. En cuanto a la función de base radial las más utilizadas son [43]:

- Función gaussiana:

$$\phi(r) = e^{\left(\frac{-r^2}{2}\right)} \quad (3.5)$$

- Función inversa cuadrática:

$$\phi(r) = \frac{1}{1 + r^2} \quad (3.6)$$

- Función inversa multicuadrática:

$$\phi(r) = \frac{1}{\sqrt{1+r^2}} \quad (3.7)$$

### 3.2.3.4 REDES NEURONALES CONVOLUCIONALES

Las **redes neuronales convolucionales** (*Convolutional Neural Networks*, CNN) son un tipo de redes neuronales artificiales basadas en el mecanismo de percepción visual natural de los seres vivos. Las CNN son un tipo especializado de arquitectura de redes neuronales diseñadas principalmente para el procesamiento y análisis de datos en forma de matrices, como imágenes 2D. Por lo tanto, las redes neuronales convolucionales son ampliamente usadas en tareas de detección o clasificación de imágenes. Además de imágenes, las CNN también pueden trabajar con datos secuenciales como texto o series temporales como vídeo [56, 57].

La característica fundamental de las CNN es su capacidad para obtener patrones en los datos. Para ello, este tipo de redes se basan en la operación de convolución. Toda red neuronal convolucional cuenta con las tres siguientes tipos de capas [56, 58]:

- **Capa convolucional:** desempeña el papel fundamental a la hora de detectar características y patrones visuales en los datos de entrada. Utiliza operaciones de convolución para aplicar un conjunto de filtros (*kernels*) a regiones pequeñas del dato de entrada. Esta operación de convolución consiste en realizar operaciones de suma y multiplicación entre la imagen de entrada y el filtro. Cada filtro extrae características específicas al resaltar patrones como bordes, texturas o formas en la imagen. De esta manera, se generan mapas de características que representan la activación de determinadas características en diferentes ubicaciones de la imagen. En la figura 3.7 se representa el funcionamiento de la capa convolucional.

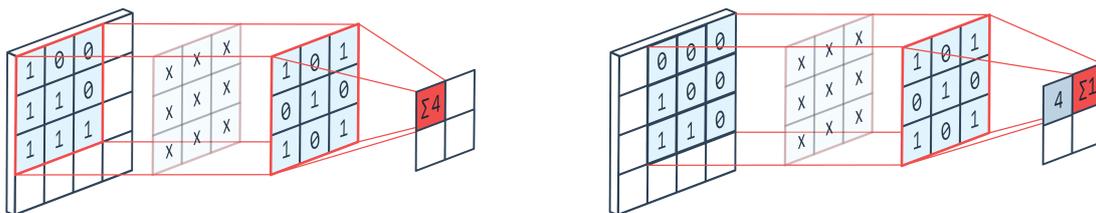


FIGURA 3.7: Funcionamiento de la capa convolucional

- **Capa de reducción o pooling:** tiene como función principal reducir la dimensionalidad de las características extraídas de la imagen de entrada. Esta capa selecciona los valores más significativos en regiones pequeñas de la imagen lo que contribuye a la detección de patrones relevantes y a una mayor eficiencia en el procesamiento de datos en la red. Utiliza métodos como el *max pooling* en la que se selecciona el valor máximo o el *average pooling* con el cual se calcula el promedio de todos los valores. En la figura 3.8, se observa cómo funciona el *max pooling* y el *average pooling* en esta capa.

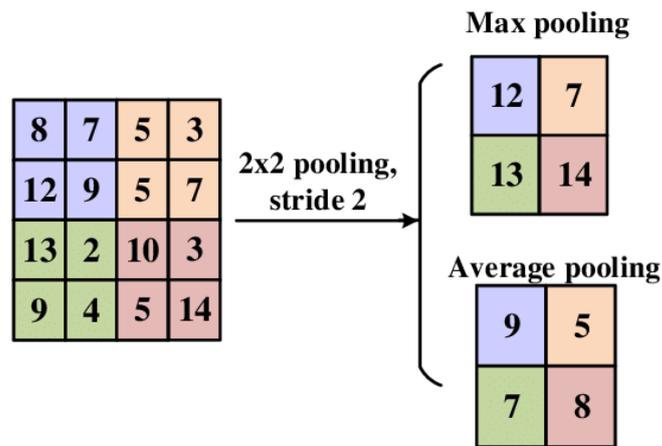


FIGURA 3.8: Operaciones de *max pooling* y *average pooling* en la capa de *pooling*

Normalmente, en las CNN se alternan capas de convolución y capas de *pooling* con objeto de extraer gradualmente más características a medida que se reduce la resolución espacial. El número tanto de capas de convolución como de *pooling* en una CNN es variable, dependiendo este de la complejidad del problema.

- **Capa totalmente conectada o *fully connected*:** es la capa encargada de combinar las características extraídas en las etapas anteriores. La capa *fully connected* consiste en neuronas directamente enlazadas con las neuronas en las capas vecinas, sin conexiones internas, siguiendo la estructura de una red neuronal convencional. En tareas de clasificación, a la salida de la capa *fully connected*, a menudo se agrega una capa Softmax encargada de calcular las probabilidades de clasificación de las diferentes clases.

En definitiva, las redes neuronales convolucionales consisten en múltiples capas de filtros convolucionales de una o más dimensiones. Un ejemplo de estructura de CNN se puede observar en la figura 3.9 en la que al principio se encuentra la fase de extracción de características, compuesta de neuronas convolucionales y de reducción o *pooling* y al final de la red se encuentran neuronas de perceptrón sencillas encargadas de realizar la clasificación final.

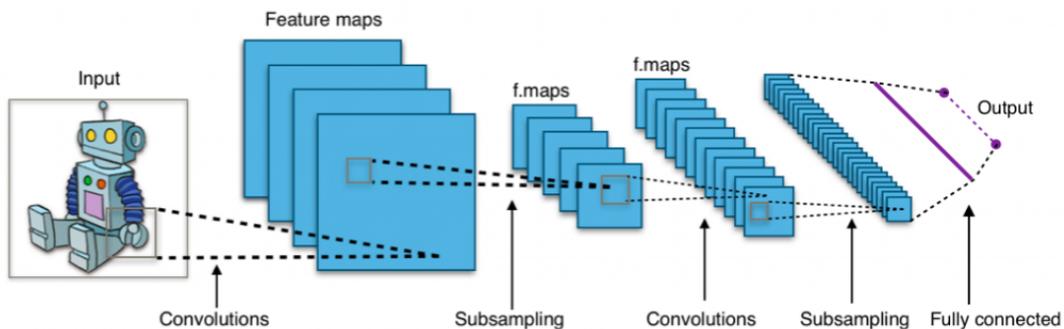


FIGURA 3.9: Ejemplo de estructura de una red neuronal convolucional

## 3.2.3.5 OTROS MODELOS

A continuación, se presentan brevemente otros modelos interesantes de redes neuronales artificiales:

- **Autoencoder:** Un *autoencoder* o autocodificador, es un tipo de red neuronal que se emplea para aprender representaciones compactas y eficientes de datos no etiquetados. Este modelo de red neuronal tiene dos partes esenciales: un codificador que transforma los datos de entrada en una representación codificada, y un decodificador que intenta reconstruir los datos originales a partir de esta representación codificada. El codificador y el decodificador son redes neuronales que se pueden implementar utilizando cualquier arquitectura [56].

A través del proceso de entrenamiento, el *autoencoder* busca minimizar la diferencia entre la entrada y la reconstrucción (función de pérdidas), logrando así la captura de características relevantes de los datos. Los *autoencoders* son útiles para reducir la dimensionalidad, eliminar ruido y generar datos similares y se pueden emplear en imágenes 2D o 3D, videos, texto, etc [59].

A continuación, en la figura 3.10, se presenta un ejemplo de estructura de autoencoder.

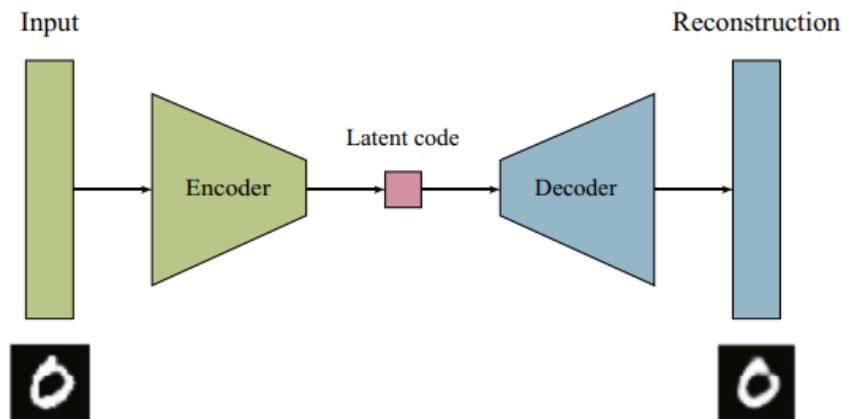


FIGURA 3.10: Estructura de un autoencoder

- **Red neuronal de impulsos** (*Spiking Neural Networks, SNN*): son redes neuronales donde las neuronas se comunican mediante pulsos discretos en lugar de valores continuos, imitando el comportamiento de las neuronas biológicas. Estos impulsos o disparos simulan el proceso de activación y propagación de señales en el cerebro real. Debido a su semejanza funcional con el cerebro humano, las SNN destacan en tareas como procesamiento rápido de señales, detección de eventos, clasificación, o reconocimiento de voz [60, 61].

## 3.3 INTERPRETABILIDAD

---

### 3.3.1 HERRAMIENTAS DE INTERPRETACIÓN

---

Las redes profundas son extremadamente efectivas a la hora de realizar tareas de clasificación. Sin embargo, resulta complicado obtener las razones por las cuales el sistema toma una decisión u otra, debido a que las redes profundas actúan como cajas negras. Para poder comprender qué sucede en el interior de las redes profundas existen diversas herramientas o técnicas que nos permiten analizar las redes neuronales. Algunas de estas herramientas para analizar redes convolucionales (CNN) son:

- **DeepDream:** algoritmo creado por Google que permite visualizar los patrones aprendidos por una red neuronal. Para ello se envía una imagen a través de la red y se calcula el gradiente de la imagen con respecto a las activaciones de una capa específica. Como resultado se genera una imagen que refleja la activación máxima de la red para las clases analizadas [5, 6].
- **Mapas de activación:** muestran la activación de las neuronas a las entradas de la red, donde los rectángulos representan neuronas y los colores indican su intensidad de activación. Para cada entrada se crea un mapa cuyo tamaño depende de las neuronas de la red. Luego, estos mapas se promedian para obtener un solo mapa por sujeto [5, 6].
- **Mapas de activación Grad-Cam:** mapas de calor que permiten visualizar qué partes de una imagen influyen más en la decisión de una red neuronal. Se basa en el método anterior, pero utilizando los gradientes para calcular la agrupación promedio de la capa convolucional [5, 6].
- **Mapas de oclusión:** son una técnica utilizada en el campo del aprendizaje profundo, para comprender y visualizar cómo una red neuronal comprende y procesa características en una imagen. Se trata de una herramienta útil para la interpretación y comprensión de redes neuronales ya que estos nos permiten observar aquellas regiones de las imágenes que tienen una mayor importancia en la toma de decisiones de la red. En las redes neuronales convolucionales (CNN), esta técnica nos permite observar qué áreas de la imagen de entrada producen una mayor activación de la red. En nuestro caso, podremos observar qué zonas del dominio temporal y frecuencial son de mayor importancia.

Un mapa de oclusión se basa en la ocultación de varias regiones de la imagen de entrada de la red y así observar la relevancia de dicha zona en la clasificación de la red, véase en la figura 3.11. El procedimiento para la generación de mapas de oclusión es el siguiente [62, 63]:

- Se elige una máscara rectangular la cual ocultará una determinada región de la imagen de entrada.
- Se utiliza la imagen con la máscara como imagen de entrada de la red neuronal.
- Se registran los cambios en la puntuación de confianza de la imagen con la máscara con respecto a la imagen sin alterar. Un cambio significativo en la confianza indica

que la región ocluida es importante para la clasificación.

- Se repite este proceso moviendo la máscara en cada etapa y se crea el mapa de oclusión a partir de la información de los cambios en la confianza de la red para cada zona de la imagen.

En la figura 3.11, se observa cómo se crean los mapas de oclusión a partir de la ocultación de ciertas regiones de la imagen.

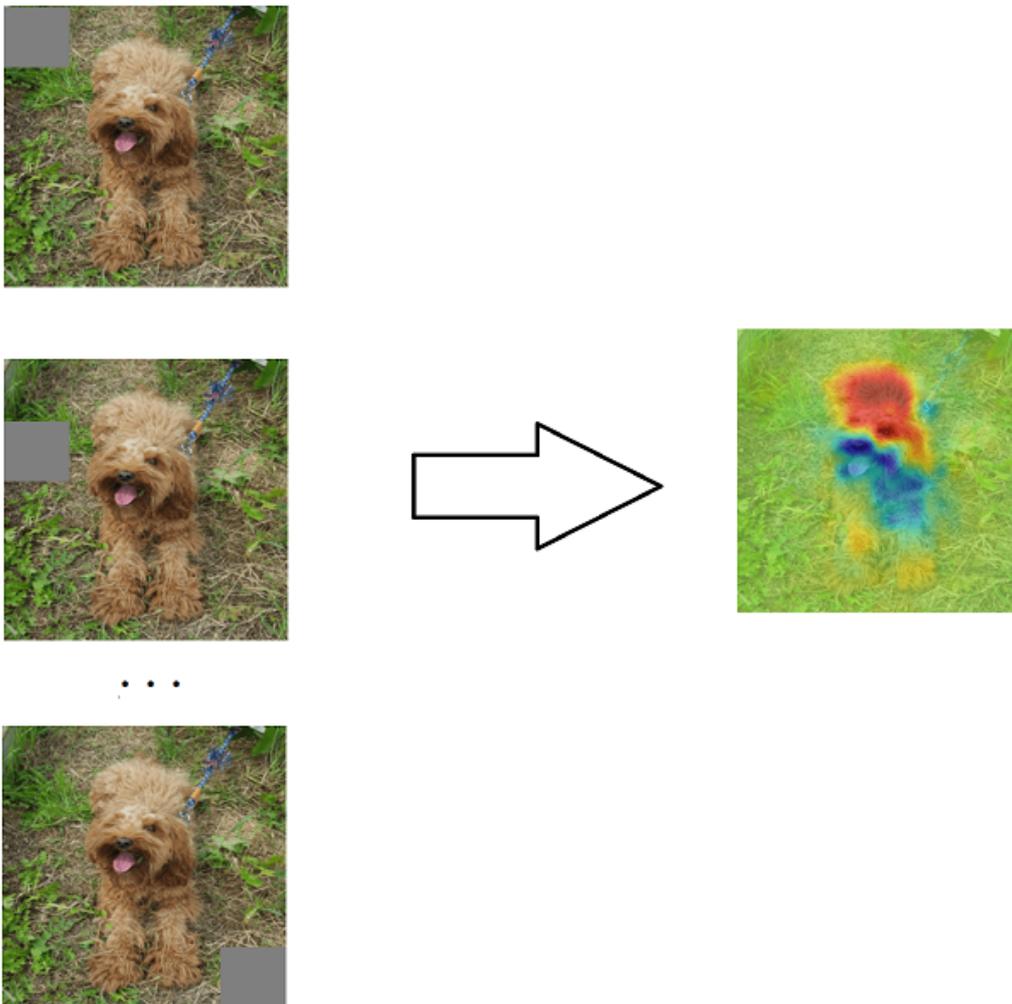


FIGURA 3.11: Proceso de creación de mapas de oclusión

De todas las herramientas que se han visto, en este trabajo se van a utilizar los mapas de oclusión ya que resultan ser la mejor opción en nuestro caso. En [5], se sugiere que los mapas de oclusión son más regulares por lo que el modelado por gaussianas es más sencillo y además, se pueden explicar más fácilmente en función del tiempo y de la frecuencia; mientras que los mapas de activación que son más dispersos y más difíciles de analizar.

### 3.3.2 MODELADO MEDIANTE MEZCLA DE GAUSSIANAS

El **modelado mediante mezcla de gaussianas** (Gaussian Mixture Model, GMM) es un tipo de modelo estadístico utilizado en campos como la estadística o el aprendizaje automático para describir distribuciones de probabilidad multidimensionales en forma de una combinación de distribuciones gaussianas [4, 5]:

A continuación se describe el proceso del modelado mediante mezcla de gaussianas:

- **Definición del número de componentes:** se determina el número de componentes, es decir, el número de distribuciones gaussianas que se van a utilizar para representar los datos.
- **Caracterización de las gaussianas:** cada componente de la mezcla se caracteriza por su media y matriz de covarianza. Estos parámetros definen la forma y la orientación de la distribución gaussiana.
- **Asignación de pesos:** cada componente de la mezcla se pondera con un peso que representa la importancia relativa de esa componente en la mezcla total. Estos pesos deben sumar 1.
- **Estimación de los parámetros:** se estiman los parámetros (medias, desviaciones típicas y pesos) que mejor se ajusten a los datos observados. En nuestro caso se han ajustado los parámetros con la siguiente expresión:

$$\min_{p_1, p_2, \theta_1, \theta_2} \sum_{(x,y) \in \chi} \left| m(x,y) - \sum_{i=1}^N p_i f(x,y; \theta_i) \right| \quad (3.8)$$

Donde  $m(x,y)$  es el mapa de oclusión en el punto  $(x,y)$  perteneciente a un dominio  $\chi \subset \mathbb{Z}^2$ ,  $f(x,y; \theta_i)$  es la función de densidad de la gaussiana 2D cuyo vector de parámetros es  $\theta_i$  que contiene los parámetros característicos de una gaussiana 2D  $(\eta_{x_i}, \eta_{y_i}, \sigma_{x_i}, \sigma_{y_i}, \rho_{x_i y_i})$ ,  $p_i$  es del peso de la gaussiana  $i$  y  $N$  es el número de gaussianas empleado en el modelado.

### 3.3.3 P-VALORES

Para la interpretación de los resultados se van a calcular los ***p-valores*** de los parámetros mencionados para cada una de las gaussianas utilizadas. Los ***p-valores*** son una medida estadística que define la probabilidad de observar un valor igual o mayor a los observados en el estudio bajo la hipótesis nula  $H_0$ , siendo la hipótesis nula la suposición de que no hay una diferencia significativa entre los parámetros comparados.

Un ***p-valor*** pequeño indicaría que es improbable que se dé un cierto resultado bajo la hipótesis nula y se puede rechazar la hipótesis nula, es decir. Esto quiere decir que aquellos ***p-valores*** pequeños indican que existen diferencias significativas entre los parámetros comparados. Típicamente, se suele tomar 0.05 como valor lo suficientemente pequeño para descartar la hipótesis nula [64].

El cálculo de los p-valores se ha llevado a cabo mediante la prueba t de dos muestras si la distribución de los datos es normal, o mediante la suma de rangos de Wilcoxon bilateral si la distribución de los datos no es normal:

- **Prueba t de dos muestras:** es una prueba paramétrica que compara el parámetro de localización de dos muestras de datos independientes y se utiliza para comparar las medias de dos muestras diferentes. Se basa en la suposición de que los datos siguen una distribución normal y permite evaluar si hay evidencia suficiente para concluir que existe una diferencia real entre las muestras. Matemáticamente, el resultado de la prueba es [65]:

$$t = \frac{\bar{x} - \bar{y}}{\sqrt{\frac{s_x^2}{n} + \frac{s_y^2}{m}}} \quad (3.9)$$

Donde  $\bar{x}$  y  $\bar{y}$  son las medias de las muestras,  $s_x$  y  $s_y$  son las desviaciones estándar de las muestras, y  $n$  y  $m$  son los tamaños de las muestras. Si se asume que las dos muestras de datos proceden de poblaciones con varianzas iguales, la estadística de la prueba bajo la hipótesis nula tiene la distribución *t de Student* con  $n + m - 2$  grados de libertad, y las desviaciones estándar de las muestras son sustituidas por la desviación estándar combinada:

$$s = \sqrt{\frac{(n-1)s_x^2 + (m-1)s_y^2}{n+m-2}} \quad (3.10)$$

En el caso en el que no se asume que las dos muestras de datos proceden de poblaciones con varianzas iguales, la estadística de la prueba bajo la hipótesis nula tiene una distribución *t de Student* aproximada con un número de grados de libertad dado por la aproximación de *Satterthwaite*.

- **Suma de rangos de Wilcoxon bilateral** o prueba U de Mann-Whitney: es una prueba no paramétrica para dos poblaciones cuando las muestras son independientes, determinando si existen diferencias significativas entre ellos sin requerir supuestos sobre la distribución de los datos. La estadística de la prueba,  $U$ , es el número de veces que una  $y$  precede a una  $x$  en un *array* ordenado de los elementos de dos muestras independientes  $X$  e  $Y$ . Está relacionada con la estadística de la suma de rangos de Wilcoxon mediante la siguiente expresión, siendo  $n_X$  el tamaño de la muestra  $X$  [66]:

$$U = W - \frac{n_X(n_X + 1)}{2} \quad (3.11)$$

Si las muestras son grandes, se utiliza una estadística  $z$  para calcular el valor p aproximado de la prueba, a partir de la media y la desviación típica de  $W$ :

$$z = \frac{W - \eta_W}{\sigma_W} \quad (3.12)$$

## 3.4 TÉCNICAS PARA LA EVALUACIÓN DEL RENDIMIENTO DE UN SISTEMA

### 3.4.1 RECONOCIMIENTO DE PATRONES

El **reconocimiento de patrones** se refiere a la disciplina científica que se ocupa de extraer información valiosa de conjuntos de datos. Se dedica a analizar un conjunto de datos para identificar características específicas o patrones, con el propósito de establecer propiedades que permitan su clasificación de manera efectiva.

El proceso de reconocimiento de patrones generalmente consta de varias fases o etapas que se realizan de manera secuencial para extraer información y conocimiento útil de los datos:

- **Adquisición de datos de entrada.**
- **Extracción de características.**
- **Clasificación.**

#### 3.4.1.1 ADQUISICIÓN DE DATOS DE ENTRADA

Esta fase se centra en la recopilación de datos necesarios para el análisis. Puede involucrar la captura de imágenes, señales, texto u otros tipos de información, dependiendo del problema de reconocimiento de patrones. La calidad y la cantidad de datos adquiridos son factores cruciales que afectarán al rendimiento del proceso de reconocimiento.

#### 3.4.1.2 EXTRACCIÓN DE CARACTERÍSTICAS

En esta etapa, se seleccionan y se extraen las características más relevantes de los datos adquiridos. Las características son propiedades o atributos que representan aspectos específicos de los datos y que son útiles para el proceso de clasificación posterior. Una extracción de características eficaz es esencial para reducir la dimensionalidad y resaltar la información relevante. Existen dos estrategias a la hora de la selección de atributos y características en el contexto del reconocimiento de patrones [67]:

- **Wrapper Approach** (Enfoque de Envoltura): evalúa subconjuntos de características utilizando modelos de aprendizaje automático para encontrar la combinación óptima que maximiza el rendimiento del modelo, en base al mecanismo de reconocimiento utilizado.
- **Filtering Approach** (Enfoque de Filtrado): selecciona características antes del entrenamiento del modelo mediante medidas estadísticas, reduciendo la dimensionalidad y eliminando características redundantes.

### 3.4.1.3 CLASIFICACIÓN

Una vez que se han extraído las características, la etapa de clasificación consiste en asignar las muestras a distintas clases o categorías. Este proceso se lleva a cabo utilizando algoritmos y modelos de *Machine Learning* que han sido previamente entrenados.

Algunos de los clasificadores más relevantes son: el basado en árbol de decisión, K-Nearest Neighbors (KNN), Support Vector Machines (SVM) o clasificadores bayesianos.

### 3.4.2 MÉTRICAS DE EVALUACIÓN DE CLASIFICACIÓN

---

Las métricas de clasificación son herramientas clave para evaluar el rendimiento de redes neuronales. Para obtener medidas acerca de su comportamiento se dividen en cuatro grupos en función de su clase y su predicción:

- **Verdaderos positivos** (True Positive, TP): número de elementos positivos a los que el modelo ha clasificado correctamente como positivos.
- **Verdaderos negativos** (True Negative, TN): número de elementos negativos a los que el modelo ha clasificado correctamente como negativos.
- **Falsos positivos** (False Positive, FP): número de elementos negativos a los que el modelo ha clasificado erróneamente como positivos.
- **Falsos negativos** (False Negative, FN): número de elementos positivos a los que el modelo ha clasificado incorrectamente como negativos.

El hecho de que un elemento sea positivo o negativo indica si este pertenece a una clase determinada o no. En el contexto de este trabajo, esto significará si un determinado paciente padece un tipo de TDAH u otro.

Para poder representar estas métricas de forma conjunta, existe la matriz de confusión. La matriz de confusión muestra la comparación entre las predicciones realizadas por el modelo y las clases reales de los datos y así ofrece una forma de visualizar la fiabilidad de las predicciones de un modelo de clasificación [68]. En la figura 3.12 se puede observar un ejemplo de matriz de confusión.

		Predicted	
		Negative (N) -	Positive (P) +
Actual	Negative -	True Negative (TN)	False Positive (FP) Type I Error
	Positive +	False Negative (FN) Type II Error	True Positive (TP)

FIGURA 3.12: Matriz de confusión

### 3.4.3 VALIDACIÓN CRUZADA

La validación cruzada es una técnica utilizada en el campo del aprendizaje automático para evaluar el rendimiento de un modelo de manera más robusta y precisa. La validación cruzada es una técnica que se implementa con el propósito de estimar el rendimiento de un modelo en otro tipo de situaciones en los que no ha sido entrenado.

Para ello, los datos son divididos en los siguientes conjuntos:

- Conjunto de **entrenamiento**: se emplean para ajustar y entrenar el modelo.
- Conjunto de **validación**: se usa para evaluar el rendimiento durante el entrenamiento y ajustar los hiperparámetros (parámetros que se utiliza para controlar el proceso de aprendizaje del modelo).
- Conjunto de **test**: se utiliza para evaluar el rendimiento final del modelo entrenado.

en un conjunto de entrenamiento y otro de test. En el conjunto de entrenamiento, los datos son utilizados para ajustar y entrenar el modelo, mientras que el conjunto de test es utilizado para evaluar el rendimiento del modelo entrenado.

La validación cruzada es útil para evitar problemas como el *overfitting* (sobreajuste). El *overfitting* sucede cuando el modelo se ha ajustado demasiado a un conjunto específico de datos de entrenamiento y no generaliza bien ante otras situaciones.

Por otra parte, la validación cruzada es gran utilidad cuando se dispone de un conjunto de datos limitado, ya que maximiza la cantidad de información utilizada tanto para el entrenamiento como para el test. Normalmente, en el ámbito clínico, las muestras de datos son pequeñas ya que en este campo resulta más complicado obtener datos y pruebas de los pacientes. Por lo tanto, la validación cruzada resulta de gran ayuda en el marco de este trabajo.

Existen varios métodos de validación cruzada, cada uno con sus propias características en función de cómo se seleccionan los conjuntos. A continuación, se exponen las principales técnicas [69]:

- **Método de *holdout* o validación cruzada aleatoria:** es una técnica simple de validación cruzada en la que se divide el conjunto de datos aleatoriamente en dos partes principales el conjunto de entrenamiento y el de test. Es el método más sencillo de validación cruzada y fácil de implementar, sin embargo, tiene algunas limitaciones ya que al no usarse todos los datos, el modelo es altamente dependiente de la división inicial de los datos. En la figura 3.13 se muestra un ejemplo de validación cruzada aleatoria.

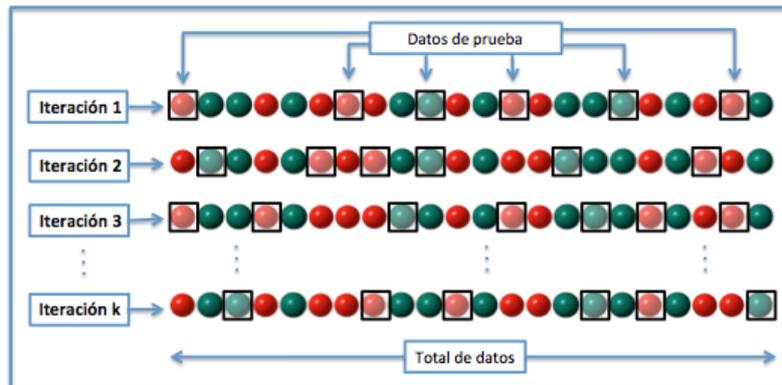


FIGURA 3.13: Validación cruzada aleatoria o método *holdout*

- **Validación cruzada de *k-fold*:** se dividen los datos en  $k$  *folds* (pliegues) de tamaño  $k$ . Luego, se selecciona uno de esos *folds* como conjunto de test y el resto  $k-1$  *folds* como conjunto de entrenamiento. Este proceso se repite  $k$  veces, alternando el subconjunto de test en cada iteración para que de esta manera se empleen todos los datos. En la figura 3.14 se observa un ejemplo de validación cruzada de *k-fold*.

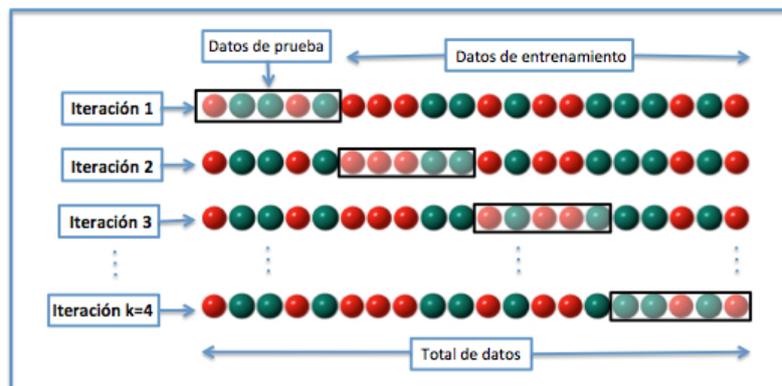
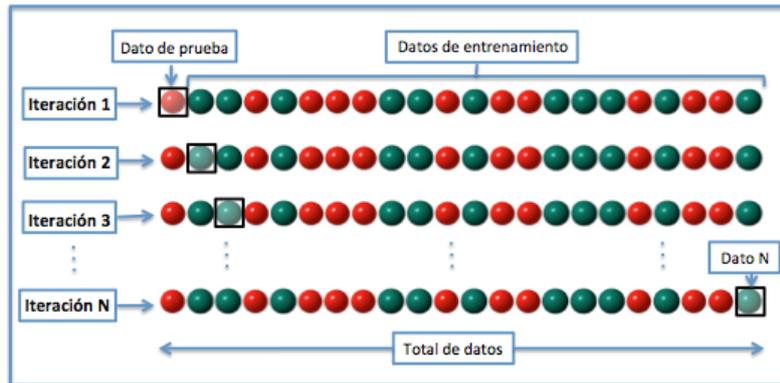


FIGURA 3.14: Validación cruzada de *k-fold*

- Validación cruzada de *leave-one-out*** : es un caso especial de validación *k-fold* en la que  $k$  es el tamaño total de la muestra. Por tanto, se utilizan todos los datos menos uno para entrenar (conjunto de entrenamiento) y se prueba con ese dato no seleccionado (conjunto de test). Este método ofrece buenos resultados, pero computacionalmente es muy costoso ya que el proceso anterior se repite para cada uno de los datos. En la figura 3.15 está representado un ejemplo de validación cruzada de *leave-one-out*.

FIGURA 3.15: Validación cruzada de *leave-one-out*

- Validación cruzada anidada**: se trata de un tipo de validación cruzada a la que se le añade un nivel adicional de división de los datos con objeto de optimizar la selección de los hiperparámetros. Se divide el conjunto de datos en múltiples conjuntos de entrenamiento y validación y otros conjuntos de test, de manera que en cada iteración se realizan dos validaciones cruzadas: la interna para la selección de los hiperparámetros y la externa para la evaluación de la calidad del modelo. En la figura 3.16 se puede ver un ejemplo de validación anidada.

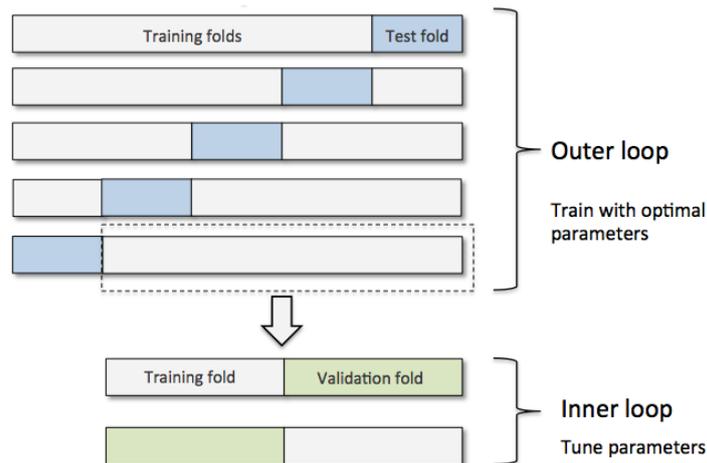


FIGURA 3.16: Validación cruzada anidada

## Capítulo 4

# MÉTODOS

El objetivo del presente trabajo es elaborar un sistema capaz de diferenciar subtipos de TDAH y caracterizar el tipo hiperactivo mediante el análisis y la interpretación de una red neuronal a partir de la actividad de los pacientes. En trabajos previos [3], se introdujo un método de diagnóstico del TDAH a partir de señales actigráficas y la utilización de una red neuronal convolucional (CNN). En [4], se realizó un análisis para diferenciar los subtipos combinado e inatento mediante el uso de mapas de oclusión y modelado de mezcla de gaussianas. Por lo tanto, se pretende realizar un sistema capaz de encontrar diferencias y caracterizar el TDAH de tipo hiperactivo que no pudo ser estudiado en [4].

En este capítulo, se presentan los métodos y procedimientos seguidos para la realización del trabajo, concretamente:

- Presentación de los datos de partida empleados, las señales actigráficas provenientes de los pacientes, y su conversión en imágenes (espectrogramas).
- Sectorización de los pacientes y entrenamiento de la red neuronal convolucional (CNN) creada.
- Análisis e interpretación de la salida de las redes neuronales mediante mapas de oclusión.
- Modelado mediante mezcla de gaussianas de los mapas de oclusión y cálculo de sus parámetros de interés.

En la figura 4.1 se puede observar el flujo de trabajo y la metodología seguida. Esta metodología es explicada en detalle en los siguientes apartados del presente capítulo.

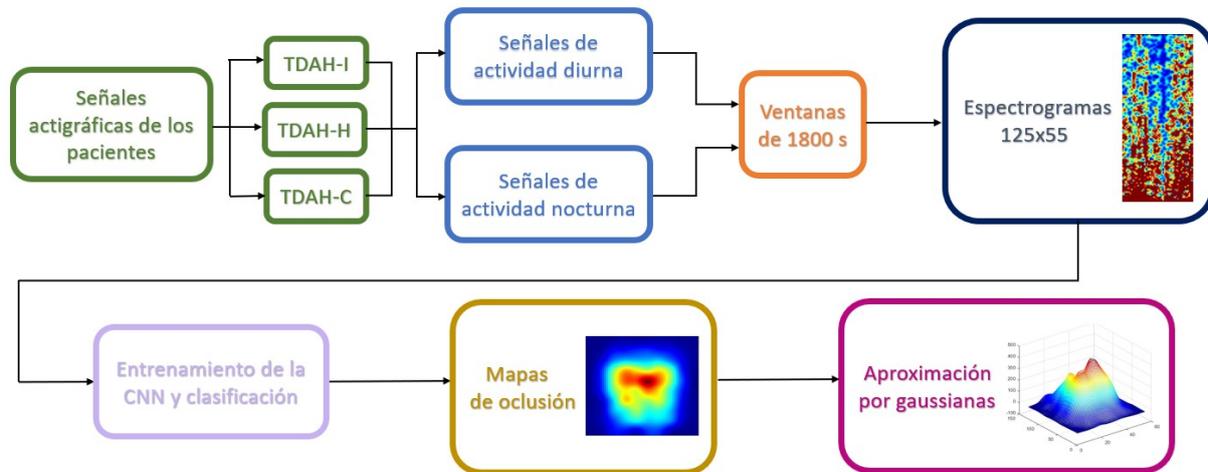


FIGURA 4.1: Flujo de trabajo realizado

## 4.1 PRESENTACIÓN DE LOS DATOS DE ENTRADA

### 4.1.1 SEÑALES ACTIGRÁFICAS

Tanto en [3] como [4], los datos de entrada empleados han sido señales actigráficas. Estas señales actigráficas, son señales 1D las cuales son grabadas mediante un actígrafo (*ActiGraph GT3x*) colocado en la muñeca de los pacientes. El actígrafo mide la aceleración en los tres ejes cartesianos a lo largo de un día y se registra la media de estas tres aceleraciones. El actígrafo *ActiGraph GT3x* opera a una frecuencia de 1 Hz, por lo que registra una muestra por segundo. Por lo tanto, se obtienen 86400 muestras para cada paciente.

A la hora de trabajar con las señales, la señal de cada sujeto es dividida en subconjuntos de actividad diurna y actividad nocturna. Estos subconjuntos son escogidos según diferentes periodos de actividad, puesto que los pacientes tienen comportamientos diferentes en función de este periodo.

Además, estos dos subconjuntos son divididos en ventanas de 1800 segundos (30 minutos) con objeto de reflejar la actividad asociada a actividades o tareas durante un intervalo de tiempo. En [3] y [4], se fragmentó la señal en ventanas de 60 segundos, de 300 segundos y de 1800 segundos que representan actividades de corta duración de media duración y de larga duración respectivamente. En dichos estudios se observó que las ventanas de 1800 segundos, en general obtienen mejores resultados, por lo que en este trabajo usaremos solo ventanas de este tamaño.

### 4.1.2 ESPECTROGRAMAS

En el presente trabajo, se emplea una red neuronal convolucional, las CNN son un tipo de red particularmente útil a la hora identificar patrones en imágenes, como se explicó en la sección 3.2.3.4. Por ende, vamos a transformar nuestras señales de entrada 1D en imágenes 2D. Para ello se ha empleado la técnica del espectrograma.

Un **espectrograma** es una representación visual de la variación de la energía de las frecuencias de una señal a lo largo del tiempo. Los espectrogramas son representaciones tridimensionales. En el eje de abscisas está representado el tiempo, en el eje de ordenadas se representa la frecuencia y los colores indican la potencia de la señal. En nuestro caso, el azul indica las potencias más bajas, mientras que los colores cálidos representan las potencias más altas.

Matemáticamente, un espectrograma consiste en el cuadrado de la Transformada de Fourier de tiempo corto (*Short Time Fourier Transform*, STFT) de la señal:

$$\mathbf{spectrogram}(t, \omega) = |STFT(x[n])|^2 \quad (4.1)$$

La Transformada de Fourier de tiempo corto consiste en dividir una señal en segmentos cortos y aplicar la Transformada de Fourier a cada segmento para obtener su representación en el dominio de la frecuencia. La STFT discreta viene dada por la siguiente expresión:

$$\mathbf{STFT}(x[n]) = X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n]w[n-m]e^{-j\omega n} \quad (4.2)$$

Donde  $x[n]$  es la señal de entrada discreta,  $w[n-m]$  es la función de ventana que permite segmentar la señal.

Otros parámetros importantes que además hay que tener en cuenta a la hora de la creación de los espectrogramas en *Matlab* son el tamaño de la ventana, la frecuencia de muestreo, el tamaño de *overlap* o solapamiento y el tamaño de la DFT. Un mayor tamaño de solapamiento y un mayor tamaño de DFT están relacionado con una mayor resolución temporal (eje temporal mayor) y una mayor resolución frecuencial (eje frecuencial mayor) respectivamente.

En nuestro caso, como se explicó en la sección 4.1.1, hemos empleado ventanas de duración de 1800 segundos, la frecuencia de muestreo es de 1 Hz, como la de la señal. En cuanto a los otros parámetros, se ha utilizado un tamaño de *overlap* de 150 y un tamaño de DFT de 256 [3]. Estos parámetros dan lugar a espectrogramas de 129x55 píxeles, es decir, la intensidad de la actividad de cada uno de los espectrogramas está representado con 129 frecuencias y 55 momentos de tiempo diferentes. En la figura 4.2, se puede observar un ejemplo de espectrograma.

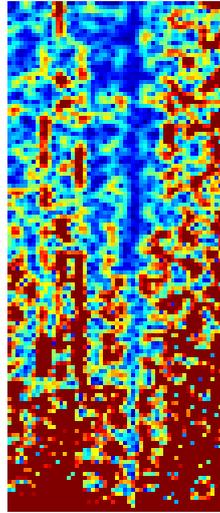


FIGURA 4.2: Ejemplo de uno de los espectrogramas obtenidos de 129x55 píxeles (imagen ampliada)

En resumen, los espectrogramas permiten visualizar cómo cambian las características espectrales de una señal a lo largo del tiempo y son ampliamente utilizados en el análisis de señales 1D para identificar patrones, detectar eventos y extraer información relevante sobre el contenido espectral de la señal. Emplearemos estos espectrogramas como entrada de nuestra red neuronal convolucional.

## 4.2 CLASIFICACIÓN DE PACIENTES

---

### 4.2.1 SECTORIZACIÓN DE PACIENTES

---

El objetivo del trabajo es diferenciar entre distintos subtipos de TDAH por lo que es necesario dividir previamente a los sujetos en función de su tipo.

Se tienen datos actigráficos acerca de 118 sujetos diagnosticados con TDAH. De los 118 sujetos, 40 han sido diagnosticados con TDAH de tipo inatento (TDAH-I), 62 fueron diagnosticados con TDAH de tipo combinado (TDAH-C) y 16 sujetos con TDAH de tipo hiperactivo (TDAH-H). Tanto el diagnóstico de la enfermedad como su subtipo se basaron en los criterios del *Diagnostic And Statistical Manual Of Mental Disorders (DSM-V)* [1]. Se puede apreciar que el número de pacientes diagnosticados con TDAH-H es considerablemente menor, lo cual supone uno de los retos del trabajo. De los 118 pacientes, 93 son hombres y 25 son mujeres, por lo que la presencia masculina es superior a la femenina. En cuanto a la edad de los sujetos, se tienen pacientes desde los 6 hasta los 15 años, de manera que se tienen datos tanto de niños pequeños como de adolescentes.

A partir de ahora, denominaremos *Tipo1* a aquellos pacientes diagnosticados con TDAH-I, *Tipo2* a los pacientes con TDAH-C y *Tipo3* a los sujetos con TDAH-H.

En la figura 4.1, se representan el número de sujetos y el porcentaje de cada uno de los tipos.

Tipo de TDAH	Grupo	Número	Porcentaje
TDAH-I	Tipo1	40	33.9 %
TDAH-C	Tipo2	62	52.5 %
TDAH-H	Tipo3	16	13.6 %

TABLA 4.1: Sujetos de estudio de cada grupo

#### 4.2.2 DISEÑO DE LA CNN

Como hemos explicado en la sección 4.1.2, vamos a emplear los espectrogramas como imágenes de entrada de nuestra red neuronal convolucional (CNN). La estructura de la CNN utilizada es la siguiente y se puede observar en la figura 4.3 [3]:

- 3 capas convolucionales de 32, 64 y 128 filtros los cuales tienen un tamaño de 10x10. Después de cada capa convolucional, se incluye una capa de normalización *Batch* y una capa ReLU que ayudan a que la red sea más eficiente y rápida.
- 2 capas de *pooling*, concretamente *max pooling*, de 2x1 por lo que en cada una de ellas se reduce la altura de las imágenes a la mitad. Además después de estas, se incluye una capa de *Dropout* para evitar el *overfitting* o sobreajuste al desactivar una fracción de neuronas aleatoriamente.

A medida que se reduce el tamaño de las imágenes, se introduce un mayor número de filtros a fin de extraer más características, pero sin aumentar la carga de la red.

- 1 capa *fully connected* con 2 neuronas o salidas, una para cada clase.
- 1 capa *Softmax* que toma la decisión de clasificación.

Esta estructura de capas, permite a la CNN obtener buenos resultados de clasificación así como una duración razonable de los entrenamientos [3].

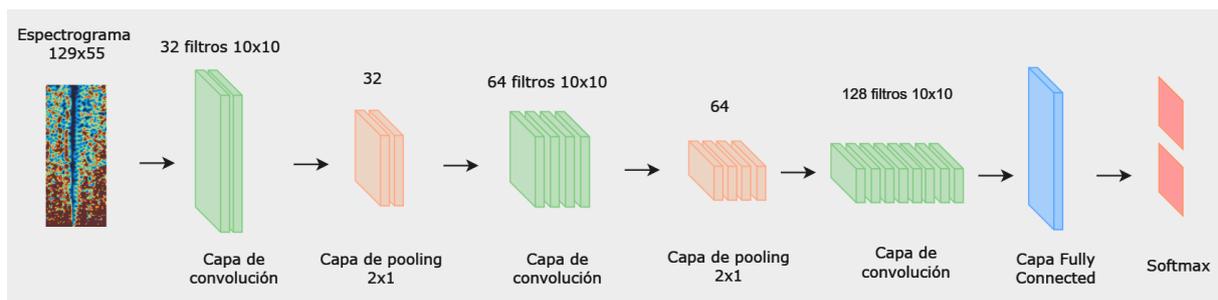


FIGURA 4.3: Ejemplo de uno de los espectrogramas obtenidos de 129x55 píxeles (imagen ampliada)

### 4.2.3 ENTRENAMIENTO DE LA RED

Siguiendo el mismo procedimiento de entrenamiento que en [3], se entrena la red para clasificar tipos de TDAH. Por lo tanto, se realizan diferentes entrenamientos en función de los tipos de TDAH y del periodo de actividad, esto es, actividad diurna o nocturna.

En [4], se entrenó la red para diferenciar entre los tipos inatento y combinado. En nuestro caso, puesto que uno de los objetivos de este trabajo es caracterizar el TDAH de tipo hiperactivo (TDAH-H), se va a entrenar la red para identificar este subtipo. Por ello, a la hora de entrenar se han realizado dos tipos de entrenamientos diferentes de la red. Un primer bloque de entrenamientos en el que se ha entrenado la red para diferenciar entre TDAH-I y TDAH-H (*Tipo1 vs Tipo3*) y otro conjunto de entrenamientos comparando el TDAH-C y el TDAH-H (*Tipo2 vs Tipo3*).

Para el entrenamiento de la red, se ha empleado validación cruzada con 10 *folds* utilizándose una proporción de 70 % como conjunto de entrenamiento y el 30 % restante como conjunto de test. Por lo tanto, se crearon 10 *folds* con sujetos Tipo1 y Tipo3 y otros 10 *folds* con sujetos Tipo2 y Tipo3. La precisión de la red se calcula a partir de los datos de test, pero no se obtiene un diagnóstico por cada persona. Si se quisiese obtener un diagnóstico, sería necesario utilizar clasificadores. Por lo tanto a red etiqueta cada uno de los espectrogramas de un paciente como un tipo u otro.

Como se observa en la tabla 4.2, el número de muestras entre los tipos no está balanceado, habiendo muchas menos muestras de Tipo3, tanto para la actividad diurna como nocturna. En el entrenamiento de una red neuronal, es importante que las muestras estén balanceadas para garantizar un proceso de aprendizaje efectivo y una generalización adecuada del modelo y de esta manera evitar el *overfitting*.

Grupo	Nº espectrogramas Dia	Nº espectrogramas Noche
Tipo1	3343	1288
Tipo2	5155	2120
Tipo3	1339	557

TABLA 4.2: Número de espectrogramas disponibles para cada tipo

Con el objetivo de balancear el número de muestras de cada tipo, se crearon *folds* balanceados en los que se seleccionaban el mismo número de sujetos para los dos tipos. De esta manera crearon *folds* balanceados y sin balancear. En la tablas 4.3 y 4.4 se muestra la distribución de los *folds* balanceados y no balanceados respectivamente:

Red	Grupo	Porcentaje	Entrenamiento	Test
<b>Tipo1 vs Tipo3</b>	Tipo1	50 %	12	4
	Tipo2	50 %	12	4
<b>Tipo2 vs Tipo3</b>	Tipo2	50 %	12	4
	Tipo3	50 %	12	4

TABLA 4.3: Distribución de los *folds* balanceados

Red	Grupo	Porcentaje	Entrenamiento	Test
<b>Tipo1 vs Tipo3</b>	Tipo1	71.4 %	28	12
	Tipo3	28.6 %	12	4
<b>Tipo2 vs Tipo3</b>	Tipo2	79.5 %	44	18
	Tipo3	20.5 %	12	4

TABLA 4.4: Distribución de los *fold*s no balanceados

Tras entrenar la red para cada uno de los dos tipos de *fold*s, en general, se obtuvieron mejores valores de precisión en el test en aquellas redes que fueron entrenadas con los *fold*s sin balancear. Estas precisiones pueden observarse en la tabla 4.5. Por lo tanto de ahora en adelante, los resultados obtenidos se basarán únicamente en las redes entrenadas con los *fold*s no balanceados

Red	Periodo	<i>fold</i> s no balanceados	<i>fold</i> s balanceados
<b>Tipo1 vs Tipo3</b>	Día	62,8 %	59.3 %
	Noche	59.7 %	60.7 %
<b>Tipo2 vs Tipo3</b>	Día	69,9 %	52.96 %
	Noche	69.6 %	57.5 %

TABLA 4.5: Media de las precisiones del test de la red entrenada con 10 *fold*s

Como explicamos en la sección 3.2.2, el algoritmo de entrenamiento utilizado fue el *Stochastic Gradient Descent with Momentum* (SGDM). En la tabla 4.6, se muestra la selección de los parámetros configurables que ofrece *Matlab* a la hora de entrenar la red:

Parámetro	Valor
Número de épocas máximas	75
Tamaño de <i>MiniBatch</i>	32
Tasa de aprendizaje inicial	0.01

TABLA 4.6: Número de espectrogramas disponibles para cada tipo

### 4.3 MAPAS DE OCLUSIÓN

Como hemos visto en la sección 3.3.1, el uso de herramientas de interpretación nos van a permitir analizar las redes neuronales convolucionales y sus resultados. Concretamente vamos a utilizar la técnica de los mapas de oclusión que nos permite visualizar las áreas más importantes para la red.

Se va a crear un mapa de oclusión para cada paciente, a partir de sus espectrogramas. Para la creación de los mapas de oclusión, se utilizan aquellos espectrogramas del paciente con un alto porcentaje de acierto en la clasificación de la red a fin de seleccionar aquellas imágenes más significativas que maximizan la activación de la red. En las tablas 4.7 y 4.8 se muestra el número de imágenes que hay para cada conjunto para diferentes porcentajes de acierto:

	Periodo	80 %	90 %	100 %
<b>Tipo1</b>	Día	3096 (92.61 %)	2652 (79.33 %)	1624 (48.58 %)
	Noche	1126 (87.42 %)	936 (72.67 %)	562 (43.63 %)
<b>Tipo3</b>	Día	770 (57.51 %)	413 (30.84 %)	132 (9.86 %)
	Noche	300 (53.86 %)	153 (27.47 %)	54 (9.69 %)

TABLA 4.7: Número de imágenes y porcentaje con respecto al total en función del tipo y el porcentaje de acierto para *Tipo1 vs Tipo3*

	Periodo	80 %	90 %	100 %
<b>Tipo2</b>	Día	4890 (94.861 %)	4487 (87.04 %)	3048 (59.13 %)
	Noche	1978 (93.30 %)	1793 (84.58 %)	1304 (61.51 %)
<b>Tipo3</b>	Día	619 (42.23 %)	280 (20.91 %)	34 (2.54 %)
	Noche	210 (37.70 %)	76 (13.64 %)	16 (2.87 %)

TABLA 4.8: Número de imágenes y porcentaje con respecto al total en función del tipo y el porcentaje de acierto para *Tipo2 vs Tipo3*

Como se puede observar en las tablas, el número de espectrogramas aumenta o disminuye en función del porcentaje de acierto. Para un porcentaje de acierto más estricto se tienen menos imágenes que para porcentajes más bajos. Utilizando el mejor porcentaje de acierto, 100 %, a pesar de que el número de imágenes de Tipo1 y Tipo2 es grande, el número de imágenes de Tipo3 se reduce drásticamente y resulta complicado trabajar con tan pocas muestras. Para el 90 % de porcentaje de acierto, el número de imágenes Tipo3 aumenta con respecto al 100 %, sin embargo, siguen resultando pocas imágenes para formar los espectrogramas. Para el 80 % de porcentaje de acierto, se incrementan considerablemente el número de imágenes de los tres tipos. Puesto que uno de los objetivos del trabajo es caracterizar el Tipo3 (TDAH-H), se utilizará el porcentaje de acierto del 80 %, ya que para 90 % y 100 % no se tienen suficientes imágenes de Tipo3, a pesar de que el 80 % sea el porcentaje más bajo y seleccione imágenes no óptimas.

En la figura 4.4 se presenta un ejemplo de los mapas de oclusión obtenidos (80 % de porcentaje de acierto). Estos mapas de oclusión, tienen unas dimensiones de 129x55 al igual que los espectrogramas. Los colores cálidos corresponden a aquellas zonas de mayor importancia para la clasificación de la imagen, mientras que el color azul representa las de menos importancia.

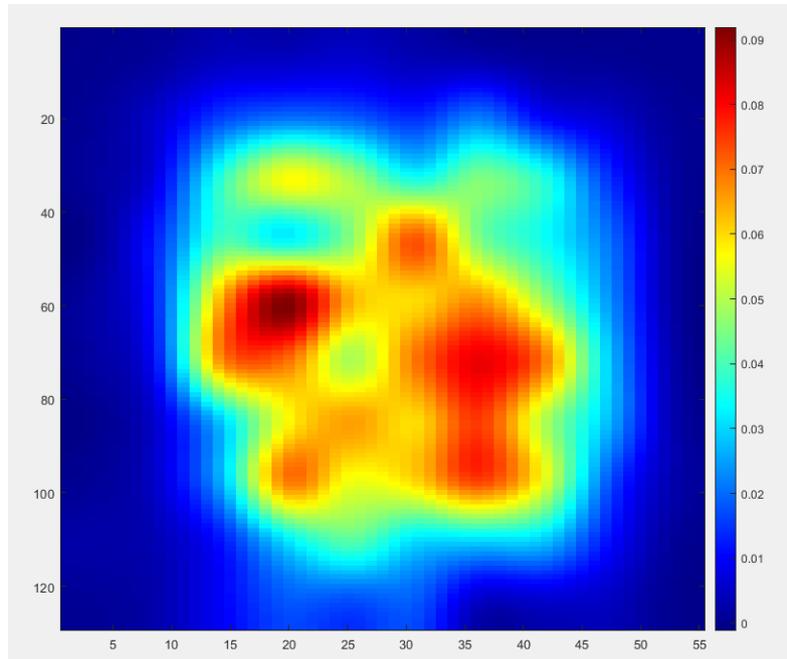


FIGURA 4.4: Ejemplo de mapa de oclusión

#### 4.4 MODELADO MEDIANTE MEZCLA DE GAUSSIANAS

Una vez creados los mapas de oclusión, se realiza un modelado por gaussianas para cada uno de ellos. Cada uno de los mapas de oclusión es aproximado por gaussianas 2D mediante un modelo de mezcla gaussiana como fue explicado en el apartado 3.3.2.

Cada una de las gaussianas empleadas en el modelado cuenta con los siguientes parámetros característicos:

- Media del eje X:  $\eta_x$
- Media del eje Y:  $\eta_y$
- Desviación típica del eje X:  $\sigma_x$
- Desviación típica del eje Y:  $\sigma_y$
- Coeficiente de correlación:  $\rho_{xy}$

Además de estos parámetros, para un análisis más completo de las gaussianas se han añadido dos nuevos parámetros. El primero de ellos es la diferencia de pesos  $|p_i - p_j|$  que consiste en el valor absoluto de la diferencia entre los pesos de las gaussianas empleadas para cada mapa. El segundo es la divergencia de *Kullback-Leibler* ( $D_{KL}$ ), una medida empleada para cuantificar la diferencia entre dos distribuciones de probabilidad [70]. La expresión de la divergencia de *Kullback-Leibler* para dos distribuciones normales multivariantes  $P_1$  y  $P_2$  con los vectores de medias  $\mu_1$  y  $\mu_2$  y matrices de covarianza  $\Sigma_1$  y  $\Sigma_2$  [71]:

$$D_{KL}(P_1 \parallel P_2) = \frac{1}{2} \left( \log \left( \frac{\det \Sigma_2}{\det \Sigma_1} \right) - n + \text{tr} \left( \Sigma_2^{-1} \Sigma_1 \right) + (\mu_2 - \mu_1)^T \Sigma_2^{-1} (\mu_2 - \mu_1) \right) \quad (4.3)$$

La divergencia de *Kullback-Leibler* ( $D_{KL}$ ) no es simétrica. Esto significa que  $D_{KL}(P_1 \parallel P_2)$  no es igual a  $D_{KL}(P_2 \parallel P_1)$ , por lo que el orden en que se comparan las distribuciones importa y puede dar como resultado valores diferentes.

Con el objetivo de representar detalladamente los mapas, se han realizado modelados de los mapas de oclusión tanto con 2 como con 3 gaussianas cada una de ellas con sus parámetros anteriormente mencionados. Estas gaussianas, se ordenan en función del parámetro de peso de la gaussiana  $p_i$ . Aquella gaussiana con un mayor peso será la gaussiana dominante, siendo esta la que aporta la información más relevante. En las figuras 4.5 y 4.6 se muestra un mapa de oclusión junto con su modelado por mezcla gaussianas con 2 y 3 gaussianas respectivamente.

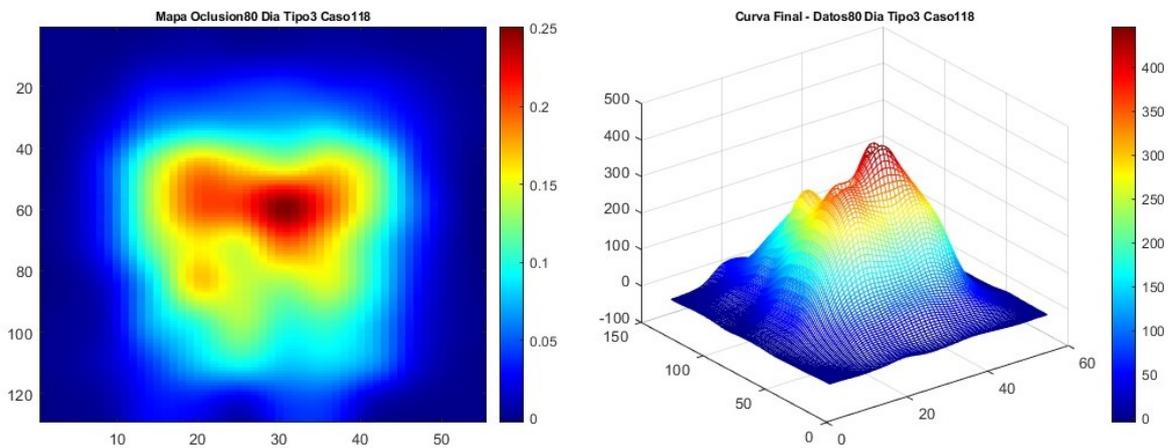


FIGURA 4.5: Mapa de oclusión y modelado por mezcla de 2 gaussianas

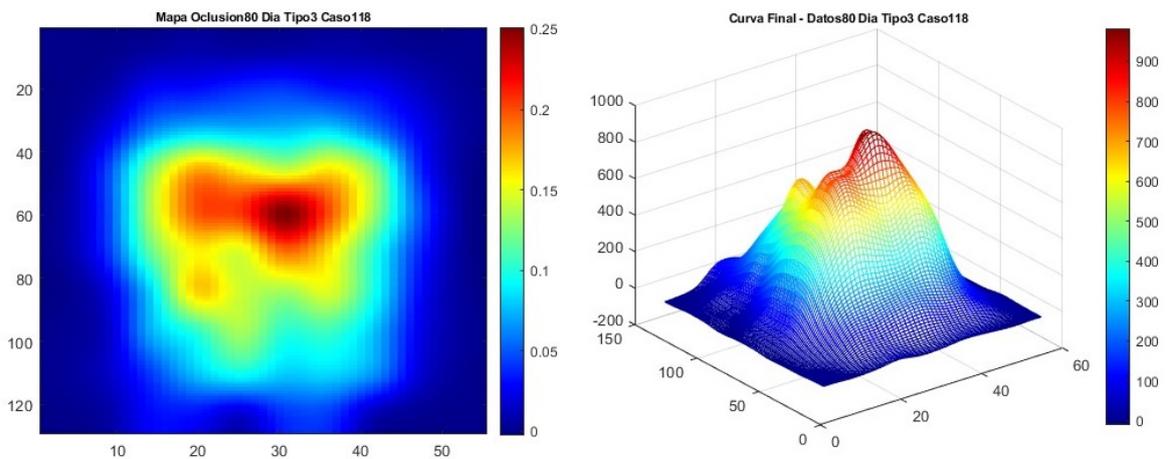


FIGURA 4.6: Mapa de oclusión y modelado por mezcla de 3 gaussianas

## RESULTADOS Y DISCUSIÓN

En el presente capítulo se presentan los resultados obtenidos tras emplear la metodología descrita en el capítulo 4. El objetivo es ofrecer resultados que puedan ser interpretados de manera visual y sencilla. Se llevarán a cabo las siguientes tareas:

- Presentación de los resultados mediante la representación de mapas de oclusión promedio y *boxplots* de parámetros de interés.
- Discusión y análisis de los resultados y caracterización de los subtipos.

### 5.1 PRESENTACIÓN DE LOS RESULTADOS

---

En esta sección se mostrarán por separado, los resultados obtenidos empleando 2 gaussianas o 3 gaussianas en el modelado mediante mezcla de gaussianas de los mapas de oclusión.

En primer lugar, se representarán los mapas de oclusión medios de cada tipo para actividad diurna y nocturna. El mapa de oclusión medio consiste en el promedio de todos los mapas de oclusión de cada paciente para un determinado tipo.

A fin de analizar las diferencias entre tipos, se mostrarán los *p-valores* obtenidos de los parámetros de las gaussianas expuestos en el apartado 4.4. Como se explicó en el apartado 3.3.3, si un parámetro tiene un *p-valor* inferior a 0.05, esto indica que este parámetro es relevante y se pueden encontrar diferencias significativas entre los tipos en dicho parámetro.

Después, aquellos parámetros con *p-valores* pequeños que resulten de interés serán representados en *boxplots*. Un *boxplot* o diagrama de caja es una herramienta gráfica utilizada en estadística y análisis de datos para representar la distribución de un conjunto de datos numéricos mediante sus cuartiles. En los *boxplots* se pueden reconocer las siguientes partes:

- **Caja:** Representa el rango intercuartílico, esto es, la distancia entre el primer cuartil (Q1) y el tercer cuartil (Q3). La longitud de la caja indica la dispersión de los datos en el centro de la distribución.
- **Mediana:** La línea que divide la caja en dos partes iguales, se trata del valor central de los datos.

- **Bigotes:** Líneas que se extienden desde la caja hacia arriba y hacia abajo que representan los datos por debajo del Q1 y por encima del Q3 respectivamente.
- **Outliers:** Puntos individuales que se encuentran más allá de los límites de los bigotes, se consideran valores atípicos en la distribución de los datos.

### 5.1.1 COMPARATIVA ENTRE TIPO1 Y TIPO3

Los mapas de oclusión medios obtenidos para la red entrenada para diferenciar entre Tipo1 y Tipo3 se pueden observar en las figuras 5.1 y 5.2 para actividad nocturna y diurna respectivamente.

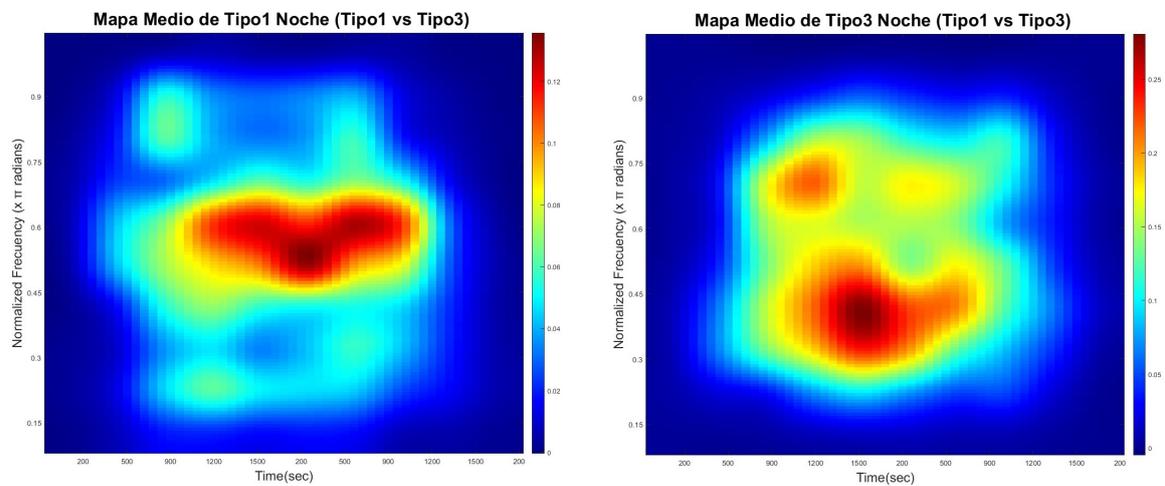


FIGURA 5.1: Mapas de oclusión medios de Tipo1 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo1 y Tipo3 para actividad nocturna

Para la actividad nocturna (figura 5.1), en los dos tipos, la actividad de mayor importancia se da en rangos intermedios del eje temporal. Con respecto al eje frecuencial, la actividad más relevante para el Tipo1 se da en frecuencias intermedias, mientras que para el Tipo3 se da en frecuencias más bajas además de que se tiene actividad algo menos relevante en frecuencias mayores.

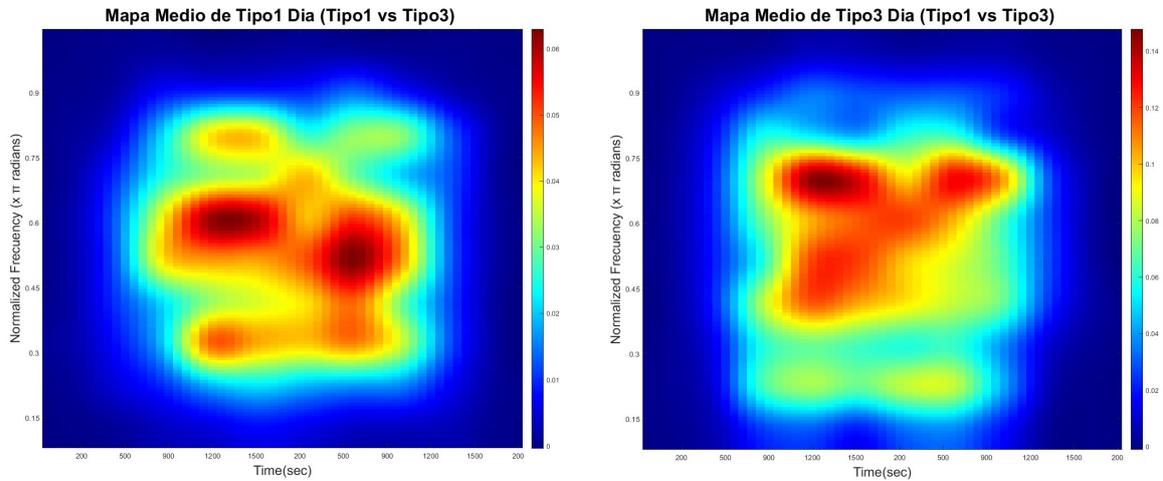


FIGURA 5.2: Mapas de oclusión medios de Tipo1 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo1 y Tipo3 para actividad diurna

En cuanto a la actividad diurna (figura 5.2), se observan 2 modos marcados para el Tipo1 y un modo para el Tipo3. En el eje temporal, la actividad de mayor importancia se tiene en intervalos de tiempo centrales. Respecto a la frecuencia, la actividad más importante se observa a frecuencias intermedias en el Tipo1 y ligeramente superiores en el Tipo3.

En las tablas 5.1 y 5.2 se representan los  $p$ -valores de los parámetros utilizando 2 gaussianas y 3 gaussianas respectivamente para la comparativa entre Tipo1 y Tipo3, resaltando aquellos  $p$ -valores menores de 0.05.

<i>Tipo1 vs Tipo3</i>				
Parámetros	1ª GAUSSIANA		2ª GAUSSIANA	
	Noche	Día	Noche	Día
$p$	0.5754	<b>0.0142</b>	0.5754	<b>0.0142</b>
$\eta_x$	0.3851	0.0671	<b>3.0449E-04</b>	0.1123
$\eta_y$	<b>2.4314E-04</b>	<b>9.5743E-05</b>	<b>5.8682E-04</b>	<b>0.0040</b>
$\sigma_x$	<b>0.0321</b>	<b>3.5316E-04</b>	0.1475	0.7401
$\sigma_y$	0.1957	0.7668	0.1422	0.8311
$\rho$	<b>0.0053</b>	0.1320	0.0557	0.5366
$ p_1 - p_2 $	0.5754	<b>0.0142</b>	0.5754	<b>0.0142</b>
$D_{KL}$	0.3287	<b>0.0013</b>	0.3299	<b>3.2798E-04</b>

TABLA 5.1:  $p$ -valores obtenidos de los parámetros de estudio con 2 gaussianas para *Tipo1 vs Tipo3*

Tipo1 vs Tipo3						
	1ª GAUSSIANA		2ª GAUSSIANA		3ª GAUSSIANA	
Parámetros	Noche	Día	Noche	Día	Noche	Día
$p$	0.0535	0.7869	0.1891	0.9078	0.3675	0.3060
$\eta_x$	1.7325E-04	0.8923	0.1994	0.9538	0.0200	0.6377
$\eta_y$	0.0012	2.7794E-05	5.0846E-04	1.1655E-05	6.7631E-04	0.6643
$\sigma_x$	0.0048	0.0353	0.0058	0.0929	0.0065	0.0142
$\sigma_y$	0.0058	0.0277	0.0019	0.0584	0.0021	0.0097
$\rho$	0.9420	0.0021	0.6902	0.2388	0.3463	0.1764
$ p_1 - p_2 $	0.0637	0.3440	0.1530	0.2710	0.1764	0.8167
$ p_1 - p_3 $	0.0695	0.9384	0.6521	0.9384	0.3440	0.1370
$D_{KL_1}$	0.2674	0.1388	0.3235	0.3230	0.3647	0.3241
$D_{KL_2}$	0.1129	0.2246	0.3197	0.3136	0.1595	0.2376

TABLA 5.2:  $p$ -valores obtenidos de los parámetros de estudio con 3 gaussianas para Tipo1 vs Tipo3

Los parámetros más significativos observados en las tablas 5.1 y 5.2, son los siguientes:

- **Pesos ( $p_1$ ) y diferencia de pesos de las gaussianas ( $|p_1 - p_2|$ ) para día:** en el caso de el modelado por 2 gaussianas, estos parámetros ofrecen la misma información. En la figura 5.3 aparecen representados ambos y se puede apreciar un mayor peso de la gaussiana dominante para Tipo1 y por tanto, una mayor diferencia entre los pesos de la primera y segunda gaussiana para el Tipo1 que para el Tipo3. Esto significa que, por lo general, en el Tipo1 se encontrará una gaussiana predominante, mientras que para el Tipo3 las dos gaussianas contribuyen de manera similar a la mezcla.

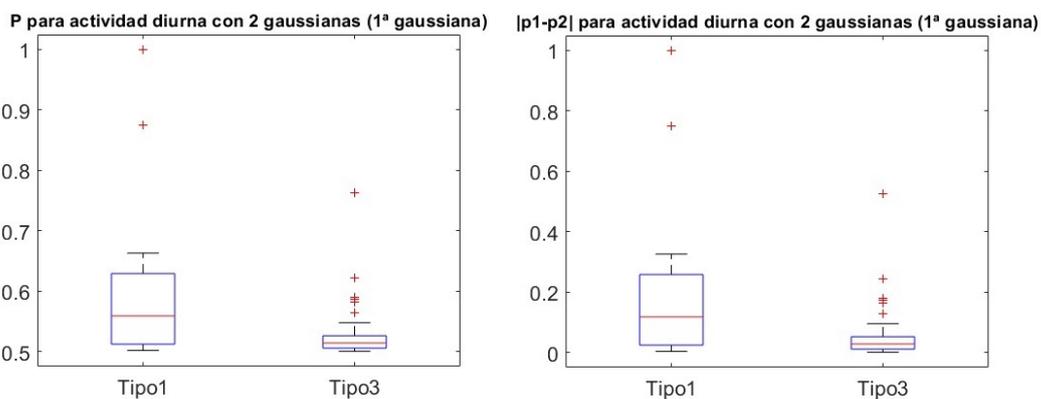


FIGURA 5.3: *boxplots* del peso de la primera gaussiana ( $p_1$ ) (derecha) y de la diferencia de pesos ( $|p_1 - p_2|$ ) entre la primera y segunda gaussiana (izquierda), para actividad diurna y modelado por 2 gaussianas (Tipo1 vs Tipo3)

- **$\eta_y$  (media del eje frecuencial) para noche y día:** se encuentran diferencias en el parámetro  $\eta_y$  tanto para el modelado por 2 como por 3 gaussianas. Para la actividad nocturna, en las figuras 5.4 y 5.5, se observa que se obtienen valores más altos de  $\eta_y$  para Tipo1 que para

Tipo3.

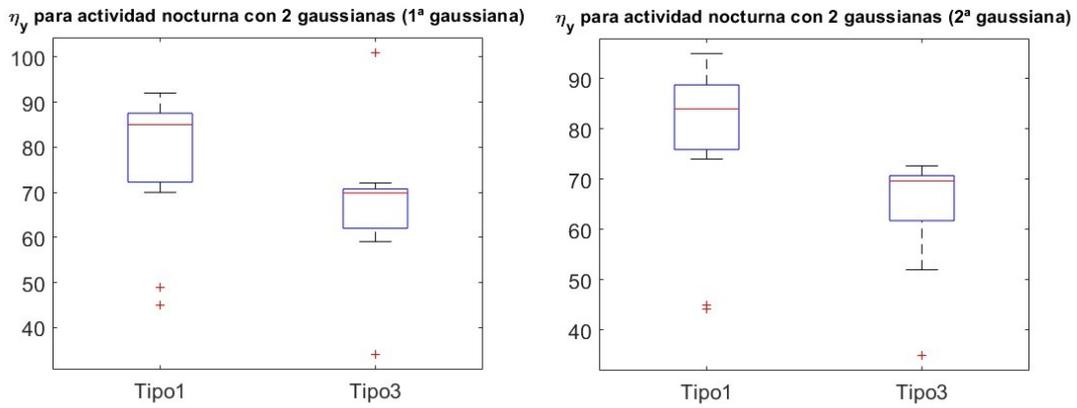


FIGURA 5.4: *boxplots* de  $\eta_y$  para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad nocturna y modelado por 2 gaussianas (*Tipo1 vs Tipo3*)

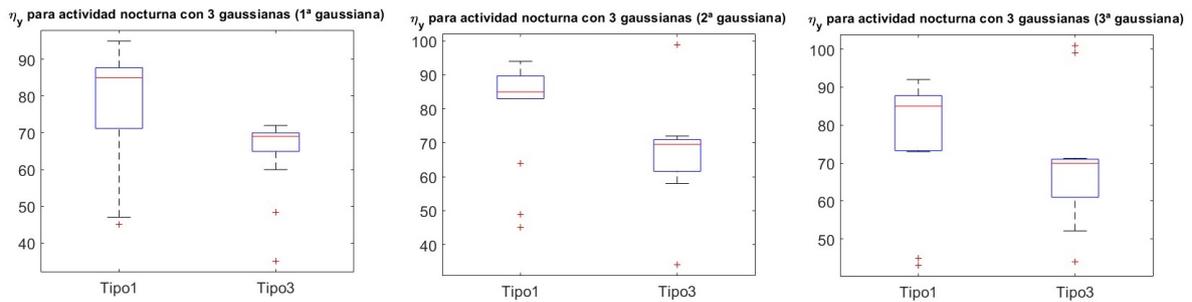


FIGURA 5.5: *boxplots* de  $\eta_y$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (*Tipo1 vs Tipo3*)

Por otro lado, para actividad diurna, en las figuras 5.6 y 5.7 se presentan los valores mayores de este parámetro para Tipo3 y más bajos para Tipo1.

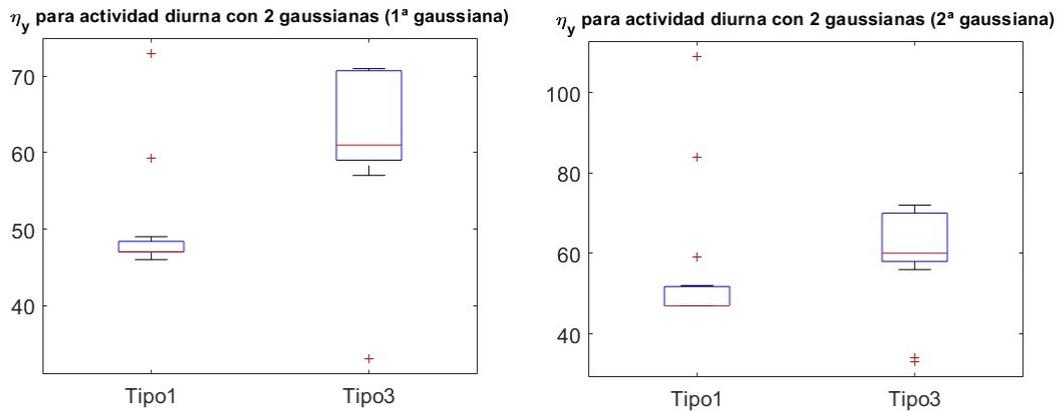


FIGURA 5.6: *boxplots* de  $\eta_y$  para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (*Tipo1 vs Tipo3*)

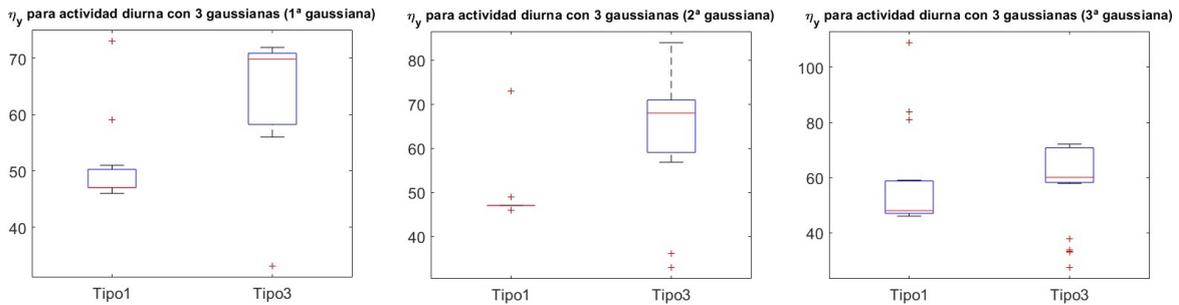


FIGURA 5.7: *boxplots* de  $\eta_y$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (*Tipo1 vs Tipo3*)

Estas observaciones encajan con los mapas de ocusión de las figuras 5.1 y 5.2 donde se observa valores de frecuencia mayores para Tipo1 en la actividad nocturna, mientras que para actividad diurna se presencian las frecuencias más altas para Tipo3.

- $\sigma_x$  (desviación típica del eje temporal) para noche y día: en la figura 5.8 se aprecian diferencias en  $\sigma_x$  para la actividad nocturna para el modelado por 3 gaussianas. Se observan valores mayores de  $\sigma_x$  para Tipo3 y valores menores para Tipo1.

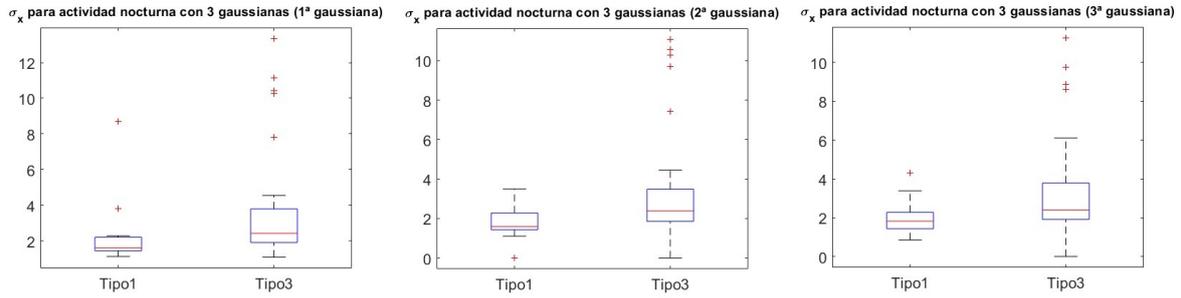


FIGURA 5.8: *boxplots* de  $\sigma_x$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (*Tipo1 vs Tipo3*)

Para la actividad diurna, en la figuras 5.9 y 5.10, para 2 y 3 gaussianas respectivamente, se tienen valores superiores de  $\sigma_x$  para Tipo3 e inferiores para Tipo1.

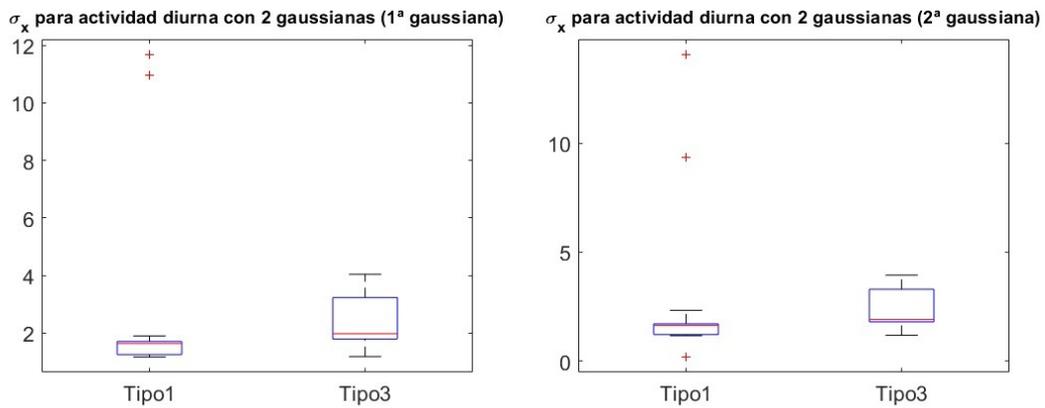


FIGURA 5.9: *boxplots* de  $\sigma_x$  para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (*Tipo1 vs Tipo3*)

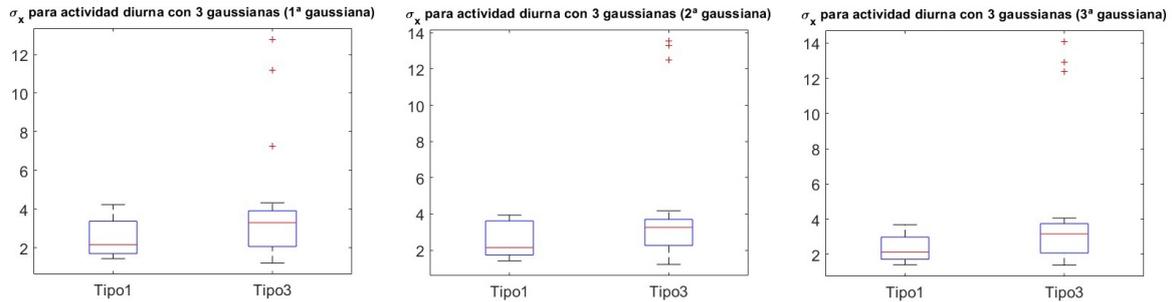


FIGURA 5.10: *boxplots* de  $\sigma_x$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (*Tipo1 vs Tipo3*)

Comparando estos resultados con las figuras 5.1 y 5.2, tanto para noche como para día, se observa que para Tipo3 la actividad importante para la red se prolonga más durante el tiempo lo que provoca que se tengan valores más altos de  $\sigma_x$ . En el mapa de Tipo1 para actividad diurna (figura 5.2), se observa una bimodalidad más marcada por lo que los valores de  $\sigma_x$  serán menores ya que estos modos están más concentrados.

- $\sigma_y$  (desviación típica del eje frecuencial) para noche y día: al igual que en el caso anterior, para el modelado por 3 gaussianas, para la actividad nocturna en la figura 5.11, se observan valores más altos de  $\sigma_y$  para Tipo3 y más bajos para Tipo1.

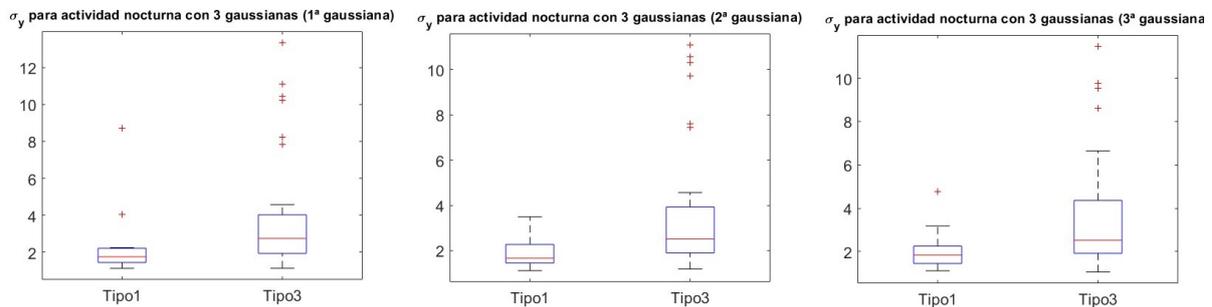


FIGURA 5.11: *boxplots* de  $\sigma_y$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (*Tipo1 vs Tipo3*)

De igual modo, en la actividad diurna, los valores más altos de  $\sigma_y$  se presentan en el Tipo3 y valores más bajos el Tipo1, para el modelado por 3 gaussianas, véase la figura y 5.12.

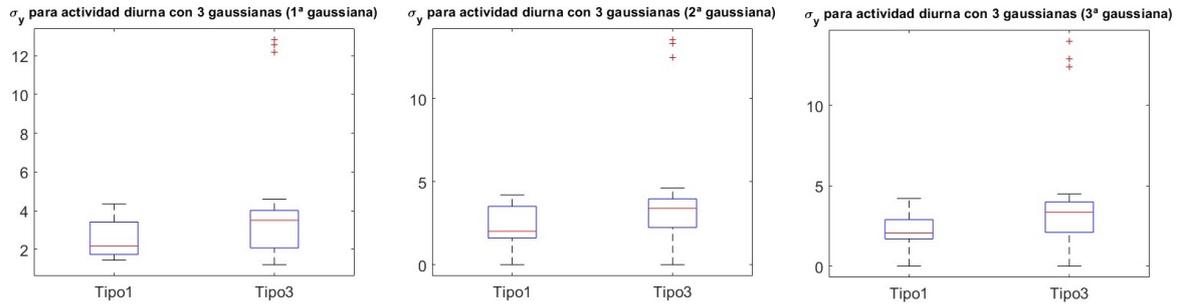


FIGURA 5.12: *boxplots* de  $\sigma_y$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (*Tipo1 vs Tipo3*)

De nuevo, tanto para actividad diurna como nocturna, observando las figuras 5.1 y 5.2, los valores más altos de  $\sigma_y$  se deben a que en el Tipo3 la actividad importante se extiende por un rango de frecuencias más grande, mientras que en el Tipo1 está más concentrada en determinadas frecuencias.

- Divergencia de Kullback-Leibler ( $D_{KL}$ ) para día:** en la figura 5.13 se representan las divergencias de *Kullback-Leibler* entre ambas gaussianas. Como se explicó en el apartado 4.4, la divergencia de *Kullback-Leibler* no es simétrica, por ello, se muestra la divergencia de la primera gaussiana con la segunda ( $D_{KL}(G_1 \parallel G_2)$ ) y la divergencia de la segunda con la primera ( $D_{KL}(G_2 \parallel G_1)$ ). Asimismo, para mejorar la representación de los *boxplots*, se han representado los logaritmo en base 10 de las divergencias ya que estas tenían valores muy diferentes entre sí.

En la figura 5.13 se aprecia que se tienen valores mayores de divergencia *Kullback-Leibler* para el Tipo1 y valores más pequeños para el Tipo3. Esto indica que para la actividad diurna, las distribuciones de probabilidad gaussianas de Tipo1 son más diferentes entre sí que las de Tipo3. En nuestro caso, eso significa que para el Tipo1, los modos (gaussianas), están más alejados entre sí y para el Tipo3, los modos están más cerca.

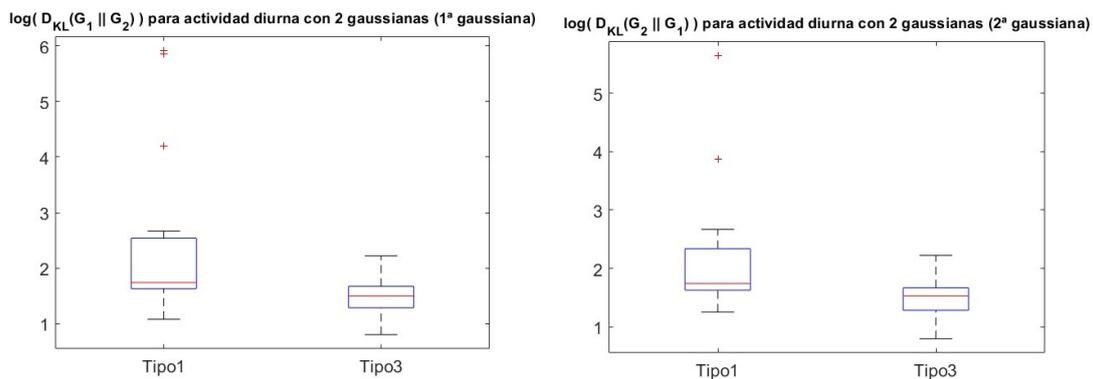


FIGURA 5.13: *boxplots* de la divergencia de *Kullback-Leibler* entre la primera y segunda gaussiana ( $D_{KL}(G_1 \parallel G_2)$ ) (derecha) y entre la segunda y la primera gaussiana ( $D_{KL}(G_2 \parallel G_1)$ ) (izquierda), para actividad diurna y modelado por 2 gaussianas (*Tipo1 vs Tipo3*)

### 5.1.2 COMPARATIVA ENTRE TIPO2 Y TIPO3

Los mapas de oclusión medios obtenidos en la comparativa entre Tipo2 y Tipo3 se pueden observar en las figuras 5.14 y 5.15 para actividad nocturna y diurna respectivamente.

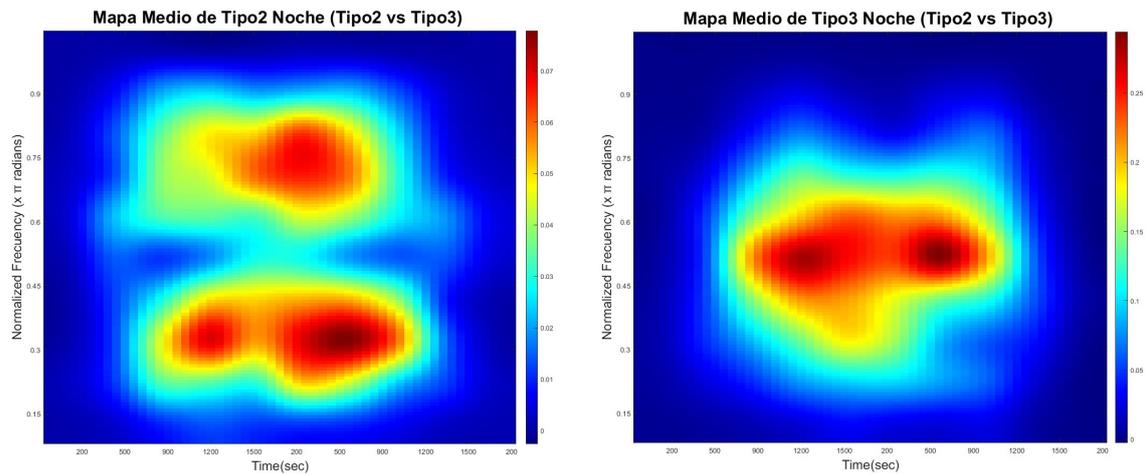


FIGURA 5.14: Mapas de oclusión medios de Tipo2 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo2 y Tipo3 para actividad nocturna

Para la actividad nocturna (figura 5.14) se aprecian 3 modos marcados para el Tipo2 y 2 modos para el Tipo3. El Tipo2 tiene la actividad más relevante para la red en frecuencias bajas y altas, mientras que el Tipo3 en frecuencias intermedias. En cuanto al eje temporal, en los dos tipos la actividad más importante está en el centro.

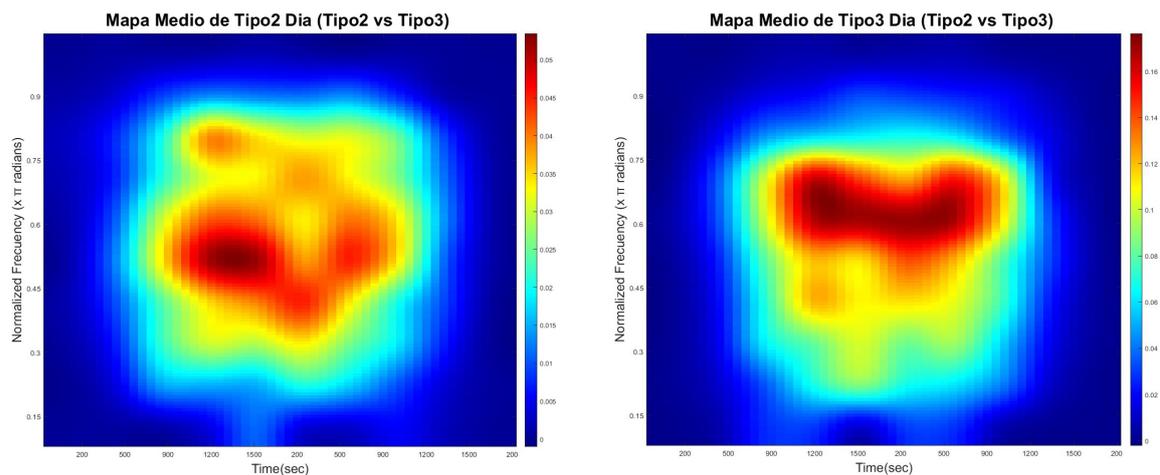


FIGURA 5.15: Mapas de oclusión medios de Tipo2 (izquierda) y Tipo3 (derecha) para la comparativa entre Tipo2 y Tipo3 para actividad diurna

Para la actividad diurna (figura 5.15) la información de mayor relevancia se da en frecuencias mayores para el Tipo3 que para el Tipo2 y se prolonga por la zona intermedia del eje temporal.

En las tablas 5.3 y 5.4 se representan los  $p$ -valores de los parámetros utilizando 2 gaussianas y 3 gaussianas respectivamente para la comparativa entre Tipo2 y Tipo3, resaltando aquellos  $p$ -valores menores de 0.05.

<i>Tipo2 vs Tipo3</i>				
Parámetros	1ª GAUSSIANA		2ª GAUSSIANA	
	Noche	Día	Noche	Día
$p$	0.3729	0.0579	0.3729	0.0579
$\eta_x$	0.1497	0.7125	0.2867	<b>0.0372</b>
$\eta_y$	<b>0.0040</b>	<b>9.3814E-05</b>	0.0674	<b>0.0134</b>
$\sigma_x$	0.0545	0.9412	<b>0.0305</b>	0.4410
$\sigma_y$	<b>0.0240</b>	0.4023	<b>0.0187</b>	0.6535
$\rho$	0.2382	0.1357	0.4023	0.0841
$ p_1 - p_2 $	0.3729	0.0579	0.3729	0.0579
$D_{KL}$	0.3215	0.3353	0.1667	0.2341

TABLA 5.3:  $p$ -valores obtenidos de los parámetros de estudio con 2 gaussianas para *Tipo2 vs Tipo3*

<i>Tipo2 vs Tipo3</i>						
Parámetros	1ª GAUSSIANA		2ª GAUSSIANA		3ª GAUSSIANA	
	Noche	Día	Noche	Día	Noche	Día
$p$	<b>0.0012</b>	0.3117	0.2007	0.7025	<b>4.5822E-04</b>	0.2632
$\eta_x$	<b>0.0496</b>	0.1824	0.6730	0.9093	0.2519	0.6059
$\eta_y$	0.2007	<b>0.0107</b>	<b>0.0039</b>	<b>0.0026</b>	<b>0.0022</b>	<b>0.0018</b>
$\sigma_x$	0.0528	<b>0.0134</b>	<b>0.0240</b>	<b>0.0018</b>	<b>0.0223</b>	<b>4.8182E-04</b>
$\sigma_y$	<b>0.0162</b>	<b>0.0011</b>	<b>0.0105</b>	<b>4.2462E-05</b>	<b>0.0010</b>	<b>5.8806E-04</b>
$\rho$	0.5510	0.4899	0.8775	0.2304	0.6439	0.6385
$ p_1 - p_2 $	<b>3.7417E-04</b>	0.4023	<b>1.0733E-05</b>	0.8010	<b>9.5634E-04</b>	0.3876
$ p_1 - p_3 $	<b>0.0187</b>	0.3313	<b>0.0201</b>	0.6535	<b>2.1134E-04</b>	0.4901
$D_{KL_1}$	0.1564	0.3218	<b>0.0267</b>	0.3218	0.0939	0.3270
$D_{KL_2}$	0.2578	0.9863	0.1520	0.3387	0.2138	0.3924

TABLA 5.4:  $p$ -valores obtenidos de los parámetros de estudio con 3 gaussianas para *Tipo2 vs Tipo3*

En las tablas 5.3 y 5.4 están representados todos los parámetros calculados para la comparativa entre Tipo2 y Tipo3. Los parámetros más significativos son los siguientes:

- **Pesos ( $p$ ) y diferencia de pesos de las gaussianas  $|p_i - p_j|$  para noche y día:** para el modelado por 3 gaussianas, en la figura 5.16 se puede ver cómo para Tipo3, la primera y segunda gaussiana tienen un peso mayor que para Tipo2, mientras que para la tercera gaussiana el Tipo2 tiene un mayor peso que el Tipo3. Observando la figura 5.14, esta diferencia de pesos en la tercera gaussiana se debe a que el mapa medio de oclusión para Tipo2 presenta 3 modos marcados, mientras que el Tipo3 presenta 2.

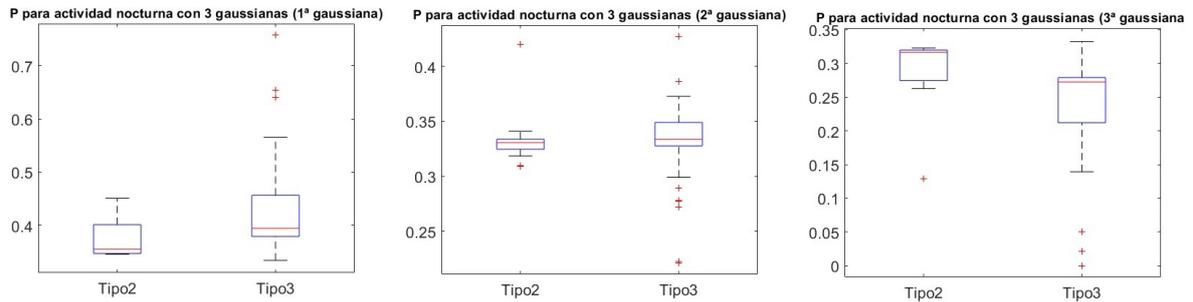


FIGURA 5.16: *boxplots* del peso de la primera gaussiana ( $p_1$ ) (derecha), de la segunda gaussiana ( $p_2$ ) (centro) y de la tercera gaussiana ( $p_3$ ) (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo2 vs Tipo3)

En relación a las diferencias entre los pesos para este caso, se puede apreciar algo similar. En la figura 5.17, donde debido a la presencia de los 3 modos más marcados para el Tipo2, la diferencia entre los pesos de las gaussianas es menor, en comparación con el Tipo3 que solo presenta 2.

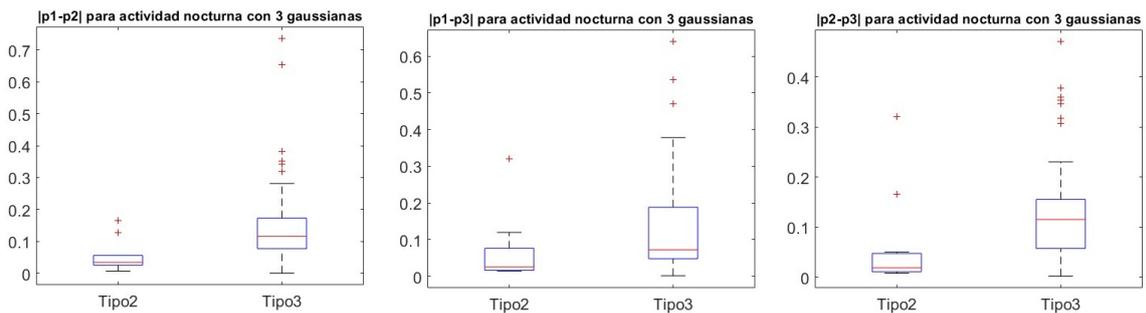


FIGURA 5.17: *boxplots* de diferencia de pesos de las gaussianas entre las gaussianas: entre la primera y la segunda ( $|p_1 - p_2|$ ) (izquierda), entre la primera y la tercera ( $|p_1 - p_3|$ ) (centro) y entre la segunda y la tercera ( $|p_2 - p_3|$ ) (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo2 vs Tipo3)

- $\eta_x$  (media del eje temporal) para día: en la figura 5.18 se muestran los valores de se observan valores de  $\eta_x$  para la segunda gaussiana para la actividad diurna y modelado por 2 gaussianas. Se observan valores de  $\eta_x$  más grande para Tipo3 que para Tipo2. Esto se relaciona con que el Tipo3 cuenta con la actividad más importante en instantes de tiempos más cercanos al final (figura 5.15).

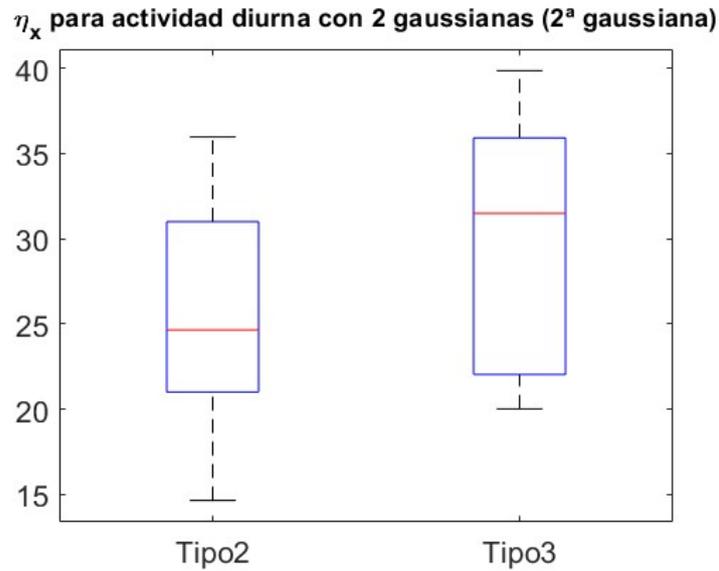


FIGURA 5.18: *boxplots*  $\eta_x$  de la segunda gaussiana, para actividad diurna y modelado por 2 gaussianas (Tipo2 vs Tipo3)

- $\eta_y$  (media del eje frecuencial) para noche y día: en cuanto a la actividad nocturna, para el modelado por 3 gaussianas, en la figura 5.19 se aprecian valores ligeramente mayores de  $\eta_y$  en las gaussianas de Tipo2. Esto puede deberse a la presencia de actividad de mayor importancia a frecuencias mayores en el Tipo2, en comparación al Tipo3 (figura 5.14).

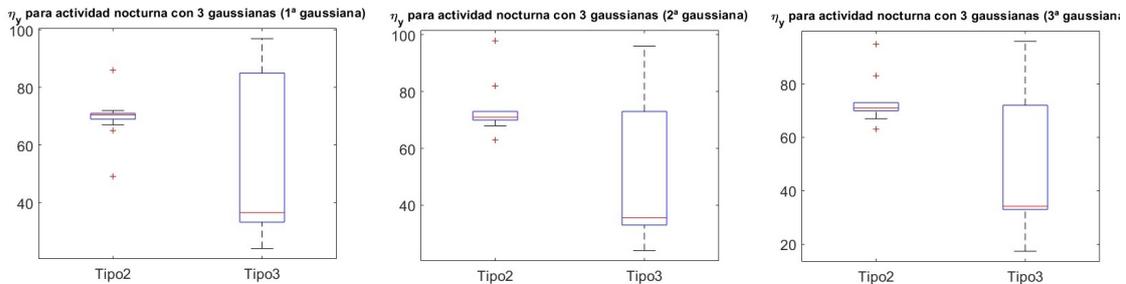


FIGURA 5.19: *boxplots* de  $\eta_y$  para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (Tipo2 vs Tipo3)

Para la actividad diurna, tanto para 2 como para 3 gaussianas, se detectan diferencias en el parámetro  $\eta_y$ . En las figuras 5.20 y 5.21, se presentan valores mayores del parámetro  $\eta_y$  para Tipo3 y menores para Tipo2. Esta diferencia se puede observar en la figura 5.15, donde para el Tipo3 la actividad más relevante se tiene a frecuencias superiores a las del Tipo2.

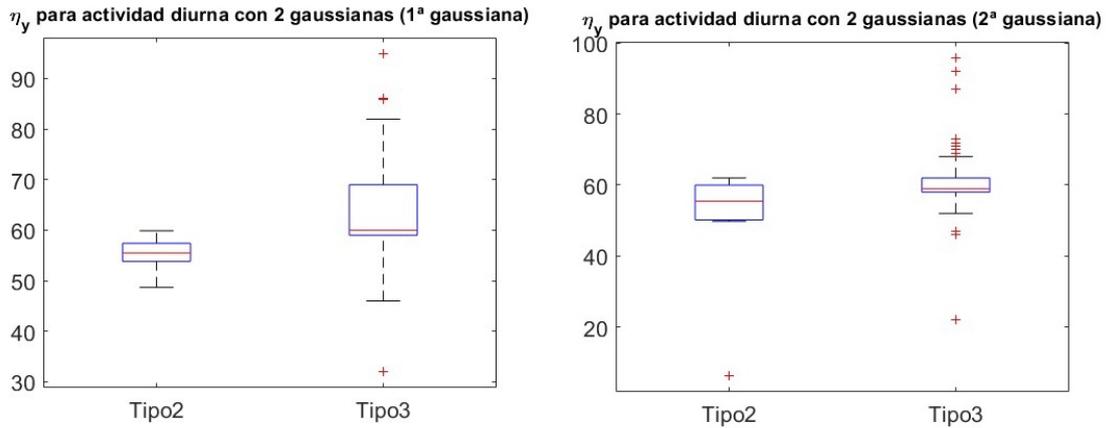


FIGURA 5.20: *boxplots* de  $\eta_y$  para la primera gaussiana (izquierda) y la segunda gaussiana (derecha), para actividad diurna y modelado por 2 gaussianas (*Tipo2 vs Tipo3*)

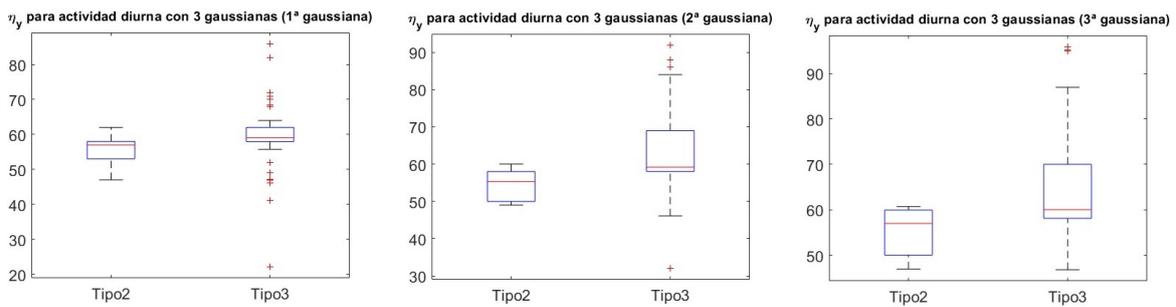


FIGURA 5.21: *boxplots* de  $\eta_y$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (*Tipo2 vs Tipo3*)

- $\sigma_x$  (desviación típica del eje temporal) para noche y día: para el modelado por 3 gaussianas, tanto para la actividad nocturna como diurna, se tienen valores mayores de  $\sigma_x$  para Tipo3. En las figuras 5.22 y 5.23, se observa que el Tipo3 presenta valores más altos de  $\sigma_x$ , mientras que el Tipo2 valores más bajos.

Esto se debe a que en las figuras 5.14 y 5.15, en ambas se aprecia que los intervalos de tiempo en los que se tiene la actividad más importante son más grandes en el Tipo3 que en el Tipo2.

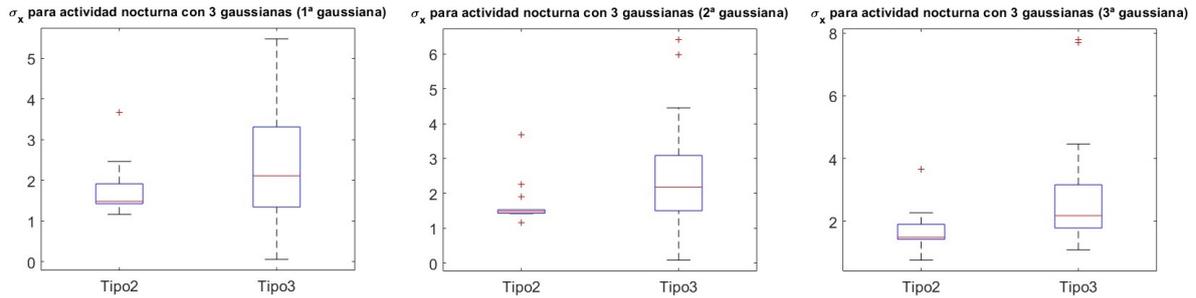


FIGURA 5.22: *boxplots* de  $\sigma_x$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (*Tipo2 vs Tipo3*)

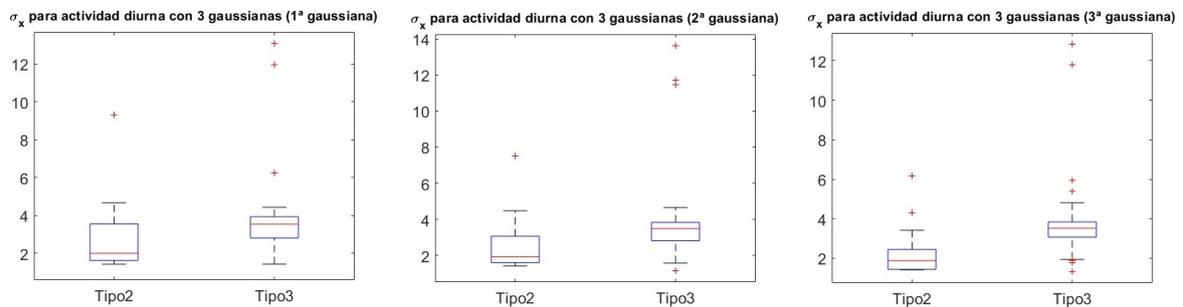


FIGURA 5.23: *boxplots* de  $\sigma_x$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (*Tipo2 vs Tipo3*)

- $\sigma_y$  (desviación típica del eje frecuencial) para noche y día: en las figuras 5.24 y 5.25, se observan diferencias en los valores del parámetro  $\sigma_y$ , para modelado por 3 gaussianas. Tanto para la actividad nocturna como diurna, los valores más altos de  $\sigma_y$  se presentan para el Tipo3 y los valores más bajos para el Tipo2.

Observando los mapas de occlusión medios para día y noche (figuras 5.14 y 5.15), las diferencias en el parámetro  $\sigma_y$  se deben a que el Tipo3 presenta actividad de mayor relevancia en rangos frecuenciales más grandes que el Tipo2.

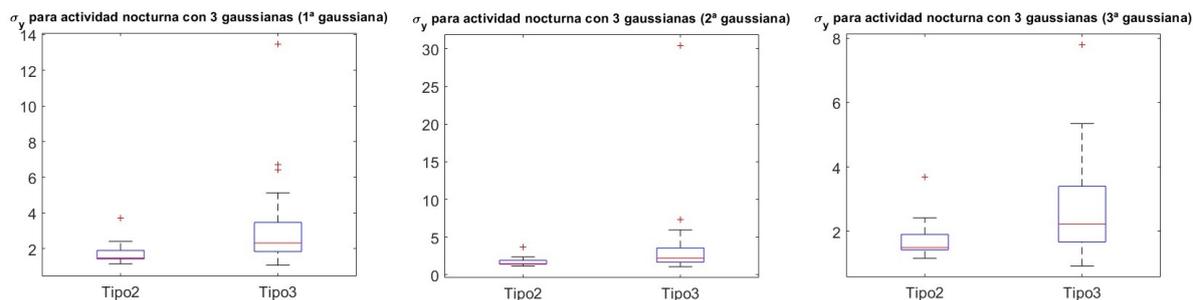


FIGURA 5.24: *boxplots* de  $\sigma_y$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad nocturna y modelado por 3 gaussianas (Tipo2 vs Tipo3)

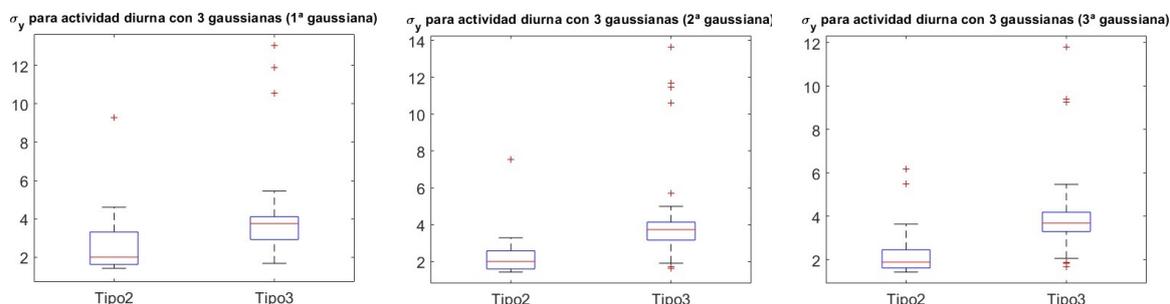


FIGURA 5.25: *boxplots* de  $\sigma_y$  para la primera gaussiana (izquierda), la segunda gaussiana (centro) y la tercera gaussiana (derecha), para actividad diurna y modelado por 3 gaussianas (Tipo2 vs Tipo3)

## 5.2 DISCUSIÓN DE LOS RESULTADOS

En primer lugar, cabe resaltar que, en líneas generales, el modelado por 3 gaussianas es mejor que el modelado por 2 gaussianas. Esto se debe a que ajusta mejor los modelos al tener más parámetros, especialmente cuando se presentan 3 modos marcados. A partir de las tablas 5.1 a 5.4 y de las figuras 5.3 a 5.25, se ha creado la tabla 5.5 en la que se comparan los resultados obtenidos para los modelados por 2 y 3 gaussianas.

	<i>Tipo1 vs Tipo3</i>		<i>Tipo2 vs Tipo3</i>	
	2 gaussianas	3 gaussianas	2 gaussianas	3 gaussianas
N° de <i>p-valores</i> inferiores a 0.05 (total)	14	18	7	26
N° de <i>p-valores</i> inferiores a 0.05 por gaussiana	7	6	3.5	8.67
N° parámetros representados en <i>boxplots</i>	5	6	3	7

TABLA 5.5: Tabla comparativa entre el modelado por 2 y 3 gaussianas

Por lo general, se obtienen un mayor número de *p-valores* de interés (inferiores a 0.05), así como más parámetros de interés utilizados para representar los *boxplots* para el modelado por 3 gaussianas. Gracias a tener una gaussiana más, permite ajustar y modelar mejor cada uno de los mapas de oclusión. Esto se nota especialmente, en la comparativa entre Tipo2 y Tipo3 donde se acentúa el aumento de *p-valores* bajos para 3 gaussianas. Esto se debe a que los mapas de oclusión del Tipo2 presentan 3 o más modos marcados, cada uno de ellos es modelado por una gaussiana, por lo que el modelado por 3 gaussianas modela mejor este caso (véase la figura 5.14).

Ahora, se realizará un pequeño resumen de los resultados obtenidos. Además, se llevará a cabo un análisis e interpretación de los mismos, esto es, la extracción de características y propiedades de cada uno de los tipos de TDAH.

Para ello, en las siguientes tablas se han sintetizado los resultados obtenidos de la representación e interpretación de los *boxplots* de los apartados 5.1.1 y 5.1.2 respectivamente. En ellas se muestra aquellos parámetros que han sido representados mediante *boxplots* y se indica qué tipo es el que obtuvo mayores valores de dicho parámetro para cada *boxplot*.

<i>Tipo1 vs Tipo3</i>			
Parámetro <i>boxplot</i>	Figuras <i>boxplots</i>	Noche	Día
Pesos gaussianas	5.3	Tipo1	
Diferencia pesos	5.3	Tipo1	
$\eta_y$	5.4 a 5.7	Tipo1	Tipo3
$\sigma_x$	5.8 a 5.10	Tipo3	Tipo3
$\sigma_y$	5.11 a 5.12	Tipo3	Tipo3
$D_{KL}$	5.13	Tipo1	

TABLA 5.6: Tabla resumen que indica qué tipo obtuvo mayores valores para cada parámetro representado en los *boxplots*, para la comparativa entre Tipo1 y Tipo3

<i>Tipo2 vs Tipo3</i>			
<b>Parámetro <i>boxplot</i></b>	<b>Figuras <i>boxplots</i></b>	<b>Noche</b>	<b>Día</b>
<b>Pesos gaussianas</b>	5.16	Tipo2 (solo 3ª gaussiana)	
<b>Diferencia pesos</b>	5.17	Tipo2	
$\eta_x$	5.18		Tipo2 (2ª gaussiana)
$\eta_y$	5.19 a 5.21	Tipo2	Tipo3
$\sigma_x$	5.22 a 5.23	Tipo3	Tipo3
$\sigma_y$	5.24 a 5.25	Tipo3	Tipo3

TABLA 5.7: Tabla resumen que indica qué tipo obtuvo mayores valores para cada parámetro representado en los *boxplots*, para la comparativa entre Tipo2 y Tipo3

En las tablas 5.6 y 5.7 se observan los siguiente patrones que nos permiten caracterizar cada uno de los tipos:

- En ambas comparativas, podemos observar que para el Tipo3 se obtienen valores mayores de  $\sigma_x$  y de  $\sigma_y$  tanto para la actividad nocturna como diurna. Estos parámetros son la desviación típica de las gaussianas en el eje temporal y frecuencial respectivamente. Por lo tanto, podemos relacionar actividades de mayor importancia del Tipo3 con mayores intervalos de tiempo ( $\sigma_x$ ) y con un mayor rango de frecuencias ( $\sigma_y$ ).
- En cuanto al parámetro  $\eta_y$  para la actividad diurna, en ambas tablas se detecta que se tienen valores más grandes para el Tipo3. Por ende, podemos asociar las actividades de mayor importancia con frecuencias altas al Tipo3 (TDAH-H), mientras que las frecuencias más bajas a Tipo1 (TDAH-I) y Tipo2 (TDAH-C).
- Para la actividad nocturna del parámetro  $\eta_y$ , se han observado los valores mayores para el Tipo1 y el Tipo2. Al contrario que en el caso anterior, para la actividad nocturna, se asocian las actividades de mayor relevancia para la red con frecuencias más bajas para el Tipo3 y con frecuencias superiores para los tipos 1 y 2.
- Respecto a la comparativa entre Tipo1 y Tipo3, para actividad nocturna, podemos asociar valores mayores de pesos de gaussianas, diferencia de pesos y divergencia de *Kullback-Leibler* al Tipo1. Por lo que podemos relacionar al Tipo1 (TDAH-I) con tener un primer modo (gaussiana) predominante y más alejado de la segunda gaussiana, mientras que el Tipo3 (TDAH-H) se asocia con dos modos más homogéneos y cercanos (figura 5.1).
- Para la comparativa entre Tipo2 y Tipo3, en relación a los pesos y la diferencia de pesos podemos concluir que para actividad nocturna, el Tipo2 (TDAH-C) presenta una clara trimodalidad, esto es, tres modos marcados (figura 5.14).
- En relación a la actividad diurna para la comparativa entre Tipo2 y Tipo3, observando el parámetro  $\eta_x$  para la segunda gaussiana, se detecta que el Tipo3 (TDAH-H) cuenta con la actividad más importante en instantes de tiempos más cercanos al final (figura 5.15).

## CONCLUSIONES Y LÍNEAS FUTURAS

### 6.1 CONCLUSIONES

---

El objetivo del trabajo consistía en elaborar un sistema basado en el aprendizaje profundo y actimetría que sea capaz de identificar y caracterizar el subtipo hiperactivo de TDAH. Para ello, se ha realizado un sistema basado en redes neuronales convolucionales entrenadas para clasificar los subtipos comparados. Como datos de entrada, se han utilizado espectrogramas sectorizados por subtipo y periodo creados a partir de señales actigráficas provenientes de los pacientes.

Como herramientas de interpretación de las salidas de las redes, se emplearon mapas de oclusión. Estos mapas de oclusión permiten visualizar las zonas en las que se produce una mayor activación de la red neuronal, es decir, aquellas zonas que resultan de mayor importancia para la clasificación del espectrograma.

Tras la obtención de los mapas de oclusión, se realizó una aproximación por gaussianas mediante un modelo de mezcla gaussiana. Posteriormente, se ha llevado a cabo un análisis de los parámetros característicos de las gaussianas mediante el cálculo de p-valores y representación de *boxplots*.

Después de evaluar y analizar los resultados obtenidos, se pueden extraer las siguientes conclusiones:

- El uso de técnicas basadas en aprendizaje profundo, concretamente redes neuronales convolucionales, es una herramienta eficaz para identificar patrones y extraer características acerca de los diferentes subtipos de TDAH.
- El empleo de técnicas como los mapas de oclusión y su aproximación mediante modelos de mezcla de gaussianas constituyen un buen método a la hora de analizar e interpretar las activaciones y salidas de las CNN.
- El cálculo de los p-valores de los parámetros de las gaussianas así como su representación mediante *boxplots* nos permiten reflejar visualmente las diferencias entre los subtipos de TDAH.

- El TDAH de tipo hiperactivo se caracteriza por mayores valores de desviación típica en ambos ejes para el día y para la noche.
- La media en el eje frecuencial ofrece información de interés para la identificación de los tipos. En cuanto a la actividad nocturna, este parámetro es mayor para los tipos inatento y combinado; mientras que para la actividad diurna es mayor para el hiperactivo.
- Para la actividad diurna, los pesos de las gaussianas del TDAH-H son más similares en contraste con el TDAH-I y TDAH-C, los cuales presentan una gaussiana más dominante.

Por lo tanto, podemos relacionar el TDAH-H con actividades de mayor relevancia para la red con rangos en tiempo y frecuencia más extensos así como con frecuencias mayores para el día y menores para la noche, en comparación con el TDAH inatento y combinado. También puede asociarse con la presencia de modos más parejos entre sí.

## 6.2 LIMITACIONES Y LÍNEAS FUTURAS

---

Durante la realización del trabajo se han encontrado algunas limitaciones como la escasez de muestras de Tipo3 (TDAH-H). Esta escasez provocaba que a la hora de crear los folds, la cantidad de muestras de cada tipo no estuviese balanceada. Sin embargo, mediante las técnicas descritas en el trabajo como los mapas de oclusión y aproximación gaussiana, los resultados obtenidos fueron adecuados.

Como línea de estudio futura, sería interesante realizar un clasificador general de todos los subtipos de TDAH incluyendo los resultados obtenidos en [4]. Además resultaría de interés llevar a cabo la clasificación global de los tipos mediante clasificadores y evaluar sus métricas de clasificación.

En resumen, los resultados y hallazgos de este Trabajo de Fin de Grado son alentadores para el propósito establecido, pero aún se requiere más trabajo e investigación para que la metodología descrita en el trabajo tenga aplicación clínica como diagnóstico de subtipo de TDAH.

## BIBLIOGRAFÍA

- [1] American Psychiatric Association. Diagnostic And Statistical Manual Of Mental Disorders, (DSM-V). *American Journal of Psychiatry*, 5ª edición, 2013.
- [2] Patricia Amado-Caballero, Pablo Casaseca-de-la Higuera, Susana Alberola-López, Jesus María Andrés-de Llano, Jose Antonio López-Villalobos, Jose Ramón Garmendia-Leiza, and Carlos Alberola-López. Objective adhd diagnosis using convolutional neural networks over daily-life activity records. *IEEE journal of biomedical and health informatics*, 24(9):2690–2700, 2020.
- [3] Patricia Amado-Caballero et al. Ayuda al diagnóstico de tdah en la infancia mediante técnicas de procesamiento de señal y aprendizaje. 2019.
- [4] Paula Álvarez Tavera. Análisis de mapas de oclusión en una red convolucional para la obtención de patrones interpretables en pacientes de TDAH. 2022.
- [5] Patricia Amado-Caballero, Pablo Casaseca de-la Higuera, Susana Alberola-López, Jesús María Andrés de Llano, José Antonio López-Villalobos, and Carlos Alberola-López. Insight into adhd diagnosis with deep learning on actimetry: Quantitative interpretation of occlusion maps in age and gender subgroups. *Artificial Intelligence in Medicine*, 143: 102630, 2023. ISSN 0933-3657. doi: <https://doi.org/10.1016/j.artmed.2023.102630>. URL <https://www.sciencedirect.com/science/article/pii/S0933365723001446>.
- [6] Patricia Amado-Caballero. Contribuciones a la detección automática de TDAH en la infancia mediante soluciones basadas en Deep Learning. 2021.
- [7] Erik G Willcutt. The prevalence of dsm-iv attention-deficit/hyperactivity disorder: a meta-analytic review. *Neurotherapeutics*, 9(3):490–499, 2012.
- [8] MathWorks MATLAB for Deep Learning. <https://es.mathworks.com/>, Último acceso Septiembre 2023.
- [9] Stefan Kottwitz. *LaTeX - Beginner's Guide*. Packt Publishing, 2011.
- [10] Mark L Wolraich, Joseph F Hagan Jr, Carla Allan, Eugenia Chan, Dale Davison, Earls Marian, Steven W Evans, Susan K Flinn, Tanya Froehlich, Jennifer Frost, Joseph R Holbrook, Christoph Ulrich Lehmann, Herschel Robert Lessin, Kymika Okechukwu, Karen L Pierce, Jonathan D Winner, and William Zurhellen. ADHD: Clinical Practice Guideline for

- the Diagnosis, Evaluation, and Treatment of Attention-Deficit/Hyperactivity Disorder in Children and Adolescents. *Pediatrics*, 128(5):1007–1022, 2011.
- [11] Shana Valo and Rosemary Tannock. Diagnostic instability of dsm-iv adhd subtypes: Effects of informant source, instrumentation, and methods for combining symptom reports. *Journal of Clinical Child & Adolescent Psychology*, 39(6):749–760, 2010. doi: 10.1080/15374416.2010.517172. URL <https://doi.org/10.1080/15374416.2010.517172>. PMID: 21058123.
- [12] Andrew S. Rowland, Betty Skipper, David L. Rabiner, David M. Umbach, Lil Stallone, Richard A. Campbell, Richard L. Hough, A. J. Naftel, and Dale P. Sandler. The shifting subtypes of adhd: Classification depends on how symptom reports are combined jo - journal of abnormal child psychology. *Journal of Abnormal Child Psychology*, 36(5):731–743, 2008. doi: 10.1007/s10802-007-9203-7. URL <https://doi.org/10.1007/s10802-007-9203-7>.
- [13] G. S. Sidhu, N. Asgarian, R. Greiner, and M. R.. Brown. Kernel principal component analysis for dimensionality reduction in fmri-based diagnosis of adhd. *Frontiers in systems neuroscience*, 6(74), 2012. URL <https://doi.org/10.3389/fnsys.2012.00074>.
- [14] A. dos Santos Siqueira, C. E. Biazoli Junior, W. E. Comfort, L. A. Rohde, and J. R. Sato. Abnormal functional resting-state networks in adhd: graph theory and pattern recognition analysis of fmri data. *BioMed research international*, 2014. doi: 10.1155/2014/380531. URL <https://doi.org/10.1155/2014/380531>.
- [15] Wang P. Deshpande, G., D. Rangaprakash, and B. Wilamowski. Fully connected cascade artificial neural network architecture for attention deficit hyperactivity disorder classification from functional magnetic resonance imaging data. *IEEE transactions on cybernetics*, 45(12): 2668–2679, 2015. doi: 10.1109/TCYB.2014.2379621.
- [16] Bo yong Park, Mansu Kim, Jong Man Seo, Jong min Lee, and Hyunjin Park. Connectivity analysis and feature classification in attention deficit hyperactivity disorder sub-types: A task functional magnetic resonance imaging study. *Brain Topography*, 29:429–439, 2015. URL <https://doi.org/10.1007/s10548-015-0463-1>.
- [17] Margaret Semrud-Clikeman, Jodene Fine, Jesse Bledsoe, and David Zhu. Regional volumetric differences based on structural mri in children with two subtypes of adhd and controls. *Journal of attention disorders*, 21(12):1040–1049, 2014. doi: 10.1177/1087054714559642. URL <https://doi.org/10.1177/1087054714559642>.
- [18] Muhammad Naveed Iqbal Qureshi, Beomjun Min, Hang Jo, and Boreom Lee. Multiclass classification for the differential diagnosis on the adhd subtypes using recursive feature elimination and hierarchical extreme learning machine: Structural mri study. *PLOS ONE*, 11:e0160697, 2016. doi: 10.1371/journal.pone.0160697.
- [19] Damien Fair, Joel Nigg, Swathi Iyer, Deepti Bathula, Kathryn Mills, Nico Dosenbach, Bradley Schlaggar, Maarten Mennes, David Gutman, Saroja Bangaru, Jan Buitelaar, Daniel Dickstein, Adriana Di Martino, David Kennedy, Clare Kelly, Beatriz Luna, Julie Schweitzer, Katerina Velanova, Yu-Feng Wang, and Michael Milham. Distinct neural signatures detected

- for adhd subtypes after controlling for micro-movements in resting state functional connectivity mri data. *Frontiers in systems neuroscience*, 6:80, 2012. doi: 10.3389/fnsys.2012.00080. URL <https://doi.org/10.3389/fnsys.2012.00080>.
- [20] Mohammed Abo-Zahhad, Sabah Ahmed, and Sherif Nagib Seha. A new eeg acquisition protocol for biometric identification using eye blinking signals. *International Journal of Intelligent Systems and Applications (IJISA)*, 6:48–54, 2015. doi: 10.5815/ijisa.2015.06.05.
- [21] Jessica Slater, Ridha Joober, Brenda Lynn Koborsy, Samantha Mitchell, Ella Sahlas, and Caroline Palmer. Can electroencephalography (eeg) identify adhd subtypes? a systematic review. *Neuroscience Biobehavioral Reviews*, 139:104752, 2022. doi: <https://doi.org/10.1016/j.neubiorev.2022.104752>. URL <https://www.sciencedirect.com/science/article/pii/S014976342200241X>.
- [22] Adam R Clarke, Robert J Barry, Rory McCarthy, and Mark Selikowitz. Eeg analysis in attention-deficit/hyperactivity disorder: a comparative study of two subtypes. *Psychiatry Research*, 81(1):19–29, 1998. doi: [https://doi.org/10.1016/S0165-1781\(98\)00072-9](https://doi.org/10.1016/S0165-1781(98)00072-9). URL <https://www.sciencedirect.com/science/article/pii/S0165178198000729>.
- [23] A. R. Clarke, R. J. Barry, R. McCarthy, and M. Selikowitz. Electroencephalogram differences in two subtypes of attention-deficit/hyperactivity disorder. *Psychophysiology*, 38:212–221, 2001.
- [24] Adam R Clarke, Robert J Barry, Rory McCarthy, and Mark Selikowitz. Eeg-defined subtypes of children with attention-deficit/hyperactivity disorder. *Clinical Neurophysiology*, 112(11):2098–2105, 2001. doi: [https://doi.org/10.1016/S1388-2457\(01\)00668-X](https://doi.org/10.1016/S1388-2457(01)00668-X). URL <https://www.sciencedirect.com/science/article/pii/S138824570100668X>.
- [25] Ali Mazaheri, Catherine Fassbender, Sharon Coffey-Corina, Tadeus Hartanto, Julie Schweitzer, and George Mangun. Differential oscillatory electroencephalogram between attention-deficit/hyperactivity disorder subtypes and typically developing adolescents. *Biological psychiatry*, 76(5):422–429, 2013. doi: 10.1016/j.biopsych.2013.08.023.
- [26] Aleksandar Tenev, Silvana Markovska-Simoska, Ljupco Kocarev, Jordan Pop-Jordanov, Andreas Müller, and Gian Candrian. Machine learning approach for classification of adhd adults. *International Journal of Psychophysiology*, 93(1):162–166, 2014. doi: <https://doi.org/10.1016/j.ijpsycho.2013.01.008>. URL <https://www.sciencedirect.com/science/article/pii/S0167876013000238>.
- [27] Amirmasoud Ahmadi, Mehrdad Kashefi, Hassan Shahrokhi, and Mohammad Ali Nazari. Computer aided diagnosis system using deep convolutional neural networks for adhd subtypes. *Biomedical Signal Processing and Control*, 63:102227, 2021. doi: <https://doi.org/10.1016/j.bspc.2020.102227>. URL <https://www.sciencedirect.com/science/article/pii/S1746809420303578>.
- [28] Mary Kral, Michelle Lally, and Andrea Boan. Identification of adhd in youth with epilepsy. *Journal of pediatric rehabilitation medicine*, 9(3):223–229, 2016.

- [29] Y. Zhu, S. Liu, F. Zhang, Y. Ren, T. Zhang, J. Sun, X. Wang, L. Wang, and J. Yang. Response inhibition in children with different subtypes/presentations of attention deficit hyperactivity disorder: A near-infrared spectroscopy study. *Frontiers in neuroscience*, 17, 2023. doi: 10.3389/fnins.2023.1119289.
- [30] Mohammad Rostami, Sajjad Farashi, Reza Khosrowabadi, and Hamidreza Pouretamad. Discrimination of adhd subtypes using decision tree on behavioral, neuropsychological and neural markers. *Basic and Clinical Neuroscience Journal*, 11(3):359–367, 2019. doi: 10.32598/bcn.9.10.115.
- [31] J. L. Smith, S. J. Johnstone, and R. J. Barry. Aiding diagnosis of attention-deficit/hyperactivity disorder and its subtypes: discriminant function analysis of event-related potential data. *Journal of child psychology and psychiatry, and allied disciplines*, 44(7):1067–1075, 2003. doi: 10.1111/1469-7610.00191.
- [32] Elena Martín-Gonzalez et al. Intervalos de normalidad en medidas de actimetría: un estudio para diferentes tipos de actímetros. 2017.
- [33] D Martín-Martínez, P Casaseca-De-La-Higuera, S Alberola-López, J Andrés-de Llano, JA López-Villalobos, J Ardura-Fernández, and C Alberola-López. Nonlinear analysis of actigraphic signals for the assessment of the attention-deficit/hyperactivity disorder (adhd). *Medical engineering & physics*, 34(9):1317–1329, 2012.
- [34] Pablo Casaseca-de-la Higuera, Diego Martín-Martínez, Susana Alberola-López, Jesús María Andrés-de Llano, José Antonio López-Villalobos, José Ramón-Garmendia Leiza, and Carlos Alberola-López. Automatic diagnosis of adhd based on multichannel nonlinear analysis of actimetry registries. In *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 4204–4207. IEEE, 2012.
- [35] Mario Muñoz-Organero, Lauren Powell, Ben Heller, Val Harpin, and Jack Parker. Automatic extraction and detection of characteristic movement patterns in children with adhd based on a convolutional neural network (cnn) and acceleration images. *Sensors*, 18(11):3924, 2018.
- [36] Niamh O’Mahony, Blanca Florentino-Liano, Juan J Carballo, Enrique Baca-García, and Antonio Artés Rodríguez. Objective diagnosis of adhd using imus. *Medical engineering & physics*, 36(7):922–926, 2014.
- [37] Sabrina Wiebe, Julie Carrier, Sonia Frenette, and Reut Gruber. Sleep and sleepiness in children with attention deficit/hyperactivity disorder and controls. *Journal of Sleep Research*, 22(1):41–49, 2013.
- [38] R. Matt Alderson, Mark D. Rapport, Lisa J. Kasper, Dustin E. Sarver, and Michael J. Kofler. Hyperactivity in boys with attention deficit/hyperactivity disorder (adhd): The association between deficient behavioral inhibition, attentional processes, and objectively measured activity. *Child Neuropsychology*, 18(5):487–505, 2012. doi: 10.1080/09297049.2011.631905.
- [39] Masahiro Nakatani, Shima Okada, Sachiko Shimizu, Ikuko Mohri, Yuko Ohno, Masako Taniike, and Masaaki Makikawa. Body movement analysis during sleep for children with

- adhd using video image processing. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 6389–6392. IEEE, 2013.
- [40] Pariwat Ongsulee. Artificial intelligence, machine learning and deep learning. pages 1–6, 2017. doi: 10.1109/ICTKE.2017.8259629.
- [41] D. Jakhar and I. Kaur. Artificial intelligence, machine learning and deep learning: definitions and differences. *Clinical and Experimental Dermatology*, 45(1):131–132, 2020. doi: 10.1111/ced.14029. URL <https://doi.org/10.1111/ced.14029>.
- [42] Fernando Izaurieta and Carlos Saavedra. Redes neuronales artificiales. *Departamento de Física, Universidad de Concepción Chile*, 2000.
- [43] Pedro. Isasi-Viñuela. *Redes de neuronas artificiales: un enfoque practico*. Pearson Education, 2003. ISBN 8420540250.
- [44] F. Berzal. *Redes Neuronales and Deep Learning*. Fernando Berzal, 2018. ISBN 9781731265388.
- [45] Rodrigo Salas. Redes neuronales artificiales. *Universidad de Valparaíso. Departamento de Computación*, 1, 2004.
- [46] Xabier Basogain Olabe. *Redes neuronales artificiales y sus aplicaciones*. 2008.
- [47] Damián J. Matich. *Ayuda al diagnóstico de tdah en la infancia mediante técnicas de procesado de señal y aprendizaje*. 2001.
- [48] E. Bernard. *Introduction to Machine Learning*. Wolfram Media, Incorporated, 2021. ISBN 9781579550455. URL <https://books.google.es/books?id=x6K7zgEACAAJ>.
- [49] Stuart Russell and Peter Norvig. *Artificial Intelligence: A Modern Approach*. Prentice Hall, 3 edition, 2010.
- [50] Jerry Chee and Ping Li. Understanding and detecting convergence for stochastic gradient descent with momentum. In *2020 IEEE International Conference on Big Data (Big Data)*, pages 133–140, 2020. doi: 10.1109/BigData50022.2020.9378129.
- [51] Daniel Svozil, Vladimír Kvasnicka, and Jirí Pospichal. Introduction to multi-layer feed-forward neural networks. *Chemometrics and Intelligent Laboratory Systems*, 39(1):43–62, 1997. ISSN 0169-7439. doi: [https://doi.org/10.1016/S0169-7439\(97\)00061-0](https://doi.org/10.1016/S0169-7439(97)00061-0).
- [52] Murat H Sazli. A brief review of feed-forward neural networks. *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, 50(01), 2006.
- [53] Stephen Grossberg. Recurrent neural networks. *Scholarpedia*, 8(2):1888, 2013. URL [http://www.scholarpedia.org/article/Recurrent\\_neural\\_networks](http://www.scholarpedia.org/article/Recurrent_neural_networks).
- [54] J. "Ghosh, A."Nag, and Lakhmi C."Jain. *An Overview of Radial Basis Function Networks*. Physica-Verlag HD, 2001. ISBN 978-3-7908-1826-0. doi: 10.1007/978-3-7908-1826-0\_1.
- [55] John Mark. Introduction to radial basis function networks. 1996. URL <https://api.semanticscholar.org/CorpusID:31438158>.

- [56] Charu C. Aggarwal. *Neural Networks and Deep Learning*. Springer, 2018. ISBN 978-3-319-94462-3. doi: 10.1007/978-3-319-94463-0.
- [57] Jiuxiang Gu, Zhenhua Wang, Jason Kuen, Lianyang Ma, Amir Shahroudy, Bing Shuai, Ting Liu, Xingxing Wang, Gang Wang, Jianfei Cai, and Tsuhan Chen. Recent advances in convolutional neural networks. *Pattern Recognition*, 77:354–377, 2018. ISSN 0031-3203. doi: <https://doi.org/10.1016/j.patcog.2017.10.013>. URL <https://www.sciencedirect.com/science/article/pii/S0031320317304120>.
- [58] Keiron O’Shea and Ryan Nash. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015.
- [59] Walter Hugo Lopez Pinaya, Sandra Vieira, Rafael Garcia-Dias, and Andrea Mechelli. Chapter 11 - autoencoders. pages 193–208. Academic Press, 2020. ISBN 978-0-12-815739-8. doi: <https://doi.org/10.1016/B978-0-12-815739-8.00011-0>. URL <https://www.sciencedirect.com/science/article/pii/B9780128157398000110>.
- [60] Filip Ponulak and Andrzej Kasinski. Introduction to spiking neural networks: Information processing, learning and applications. *Acta neurobiologiae experimentalis*, 71(4):409–433, 2011.
- [61] André Grüning and Sander M Bohte. Spiking neural networks: Principles and challenges. In *ESANN*. Bruges, 2014.
- [62] Matthew D Zeiler and Rob Fergus. Visualizing and understanding convolutional networks. In *Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6–12, 2014, Proceedings, Part I 13*, pages 818–833. Springer, 2014.
- [63] MathWorks MATLAB for Deep Learning. Understand network predictions using occlusion, Último acceso Septiembre 2023.
- [64] Juliana Carvalho Ferreira and Cecilia Maria Patino. What does the p value really mean? *Jornal Brasileiro de Pneumologia*, 41(5):485, 2015.
- [65] MathWorks MATLAB for Deep Learning. Matlab (ttest2), Último acceso Septiembre 2023.
- [66] MathWorks MATLAB for Deep Learning. Matlab (ranksum), Último acceso Septiembre 2023.
- [67] Jesús A. Carrasco-Ochoa and José F. Martínez-Trinidad. Reconocimiento de patrones. *Komputer Sapiens*, 2, 2011.
- [68] Gareth James, Daniela Witten, Trevor Hastie, and Robert Tibshirani. *An Introduction to Statistical Learning: with Applications in R*. Springer, 2013.
- [69] Payam Refaeilzadeh, Lei Tang, and Huan Liu. Cross-validation. *Encyclopedia of Database Systems*, pages 532–538, 2009. doi: 10.1007/978-0-387-39940-9\_565. URL [https://doi.org/10.1007/978-0-387-39940-9\\_565](https://doi.org/10.1007/978-0-387-39940-9_565).
- [70] Solomon Kullback and Richard A Leibler. On information and sufficiency. *The annals of mathematical statistics*, 22(1):79–86, 1951.

- [71] John Duchi. Derivations for linear algebra and optimization. *Berkeley, California*, 3(1): 2325–5870, 2007.