

APOYO AL DIAGNÓSTICO DE TDAH CON TÉCNICAS DE DEEP LEARNING EN  
IMÁGENES DE RESONANCIA MAGNÉTICA FUNCIONALES (IRMf)

David Esteban Arteaga Vicuña  
Brayan Camilo Lagos Santacruz

Programa de Ingeniería de sistemas  
Facultad de Ingeniería  
Universidad CESMAG  
Pasto – Nariño  
2024

APOYO AL DIAGNÓSTICO DE TDAH CON TÉCNICAS DE DEEP LEARNING EN  
IMÁGENES DE RESONANCIA MAGNÉTICA FUNCIONALES (IRMF)

**Autores:**

David Esteban Arteaga Vicuña

Brayan Camilo Lagos Santacruz

Informe final de trabajo de grado presentado como requisito para optar al título de Ingeniero de  
Sistemas, en modalidad investigación.

**Asesor:**

Mg. Héctor Andrés Mora Paz

Programa de Ingeniería de sistemas

Facultad de Ingeniería

Universidad CESMAG

Pasto – Nariño

2025

**Nota de aceptación**

---

---

---

---

---

**Firma del Jurado**

---

**Firma del Jurado**

---

**Nota de exclusión**

---

---

---

---

---

**Firma del Jurado**

---

**Firma del Jurado**

---

## **DEDICATORIA**

Yo, Brayan Camilo Lagos Santacruz, quisiera dedicar este trabajo a todas las personas que han sido fundamental en mi camino a la culminación de mi tesis. En primer lugar, agradezco profundamente a Dios por permitido vivir esta experiencia, que no solo me hizo crecer como persona, sino que también me brindó conocimientos valiosos para mi vida profesional.

A mi familia, especialmente a mis padres, les expreso mi más sincero agradecimiento. Gracias a su esfuerzo constante, pude acceder a una educación de calidad. Cada sacrificio que hicieron no fue en vano: hoy recogemos los frutos de su dedicación, apoyo y motivación diaria. Sus consejos y enseñanzas me dieron la fuerza y las herramientas necesarias para avanzar con determinación.

No puedo dejar de mencionar a mi compañero de trabajo de grado, quien más que un colega, se convirtió en un gran amigo que me dio la universidad. Gracias a su compromiso, sus consejos y su compañía, hemos llegado juntos a esta etapa, compartiendo recuerdos, superando frustraciones y fortaleciendo nuestro carácter para enfrentar cada desafío con la mejor actitud.

También agradezco a nuestro asesor de tesis, por estar presente en los momentos clave, compartiendo sus conocimientos y orientaciones que fueron esenciales para la culminación de nuestra investigación.

Finalmente, quiero expresar mi gratitud a mis compañeros y profesores, quienes a lo largo de la carrera me brindaron conocimientos, consejos y motivación. Su influencia fue determinante para superar cada obstáculo que se presentó en el camino.

A todos ustedes, quienes han sido parte de este proceso, les brindo mis más sinceros y profundos agradecimientos. Su presencia dejó huellas imborrables en mí y contribuyó significativamente a este logro.

Yo, David Esteban Arteaga Vicuña, dedico este trabajo a todas aquellas personas que fueron un pilar y apoyo fundamental para que este proceso académico y profesional se haya llevado a cabo. Inicialmente se lo dedico a mis padres por haber sido el pilar principal, brindándome su amor, apoyo, comprensión y paciencia a lo largo de este proceso formativo.

A mi familia, por respaldarme con su amor, por apoyarme en cada decisión e impulsarme en cada paso hasta haber logrado la culminación de este proyecto.

Extiendo mi dedicatoria a mi gran colega y amigo Brayan Lagos por haber sido parte de este proyecto, impulsados siempre a aprender uno del otro. También a mi compañera, por haber sido mi gran motivación y haberme brindado paciencia, motivación y confianza.

A mis compañeros, a cada uno de ellos por su apoyo, no solo en este proyecto, sino durante todo este proceso académico universitario.

Por último, pero no menos importante, a nuestros asesores, el profe Héctor Mora y Dalila Pachajo, por habernos acompañado y brindado un tesoro tanpreciado como lo es su conocimiento, y a cada uno de los docentes que contribuyeron a que este trabajo se haya realizado. A cada uno de ustedes muchas gracias y Dios los bendiga.

## **AGRADECIMIENTOS**

Yo, Brayan Camilo Lagos Santacruz, quisiera expresar mis más profundo agradecimientos en especial a director de tesis, el Mg. Héctor Andres Mora Paz, por su orientación, paciencia, conocimientos y motivación. Su apoyo y consejos fueron muy importantes para la etapa de esta investigación donde aprendimos mucho sobre nuestro proyecto y no hizo darnos cuentas de las capacidades que teníamos para cumplir con la finalización del proyecto.

Un especial agradecimiento a la profe Dalila Mercedes Pachajo Pachajoa, por sus asesorías en momentos claves de la investigación, su apoyo constante fue fundamental para nuestro desempeño del proyecto de investigación, gracias a sus consejos, conocimientos y motivación. Hoy concluimos con éxito esta etapa de nuestras vidas.

Yo, David Esteban Arteaga Vicuña, en primera instancia agradezco profundamente a Dios, por haberme brindado salud, sabiduría y fortaleza durante el desarrollo de este proceso académico, también contengo un profundo agradecimiento a nuestro asesor, el Mg. Héctor Andres Mora Paz y a la Mg. Dalila Mercedes Pachajo Pachajoa, por habernos acompañado durante todo este proceso, brindándonos y compartiéndonos sus conocimientos, ayudándonos a crecer en el ámbito personal y profesional. Siempre guiándonos con paciencia y disposición, a ustedes muchas gracias, aunque el camino no fue nada fácil, muchas gracias.

## TABLA DE CONTENIDO

	Pág.
<b>INTRODUCCIÓN.....</b>	<b>1</b>
<b>I. PROBLEMA DE INVESTIGACIÓN .....</b>	<b>2</b>
A. Objeto o Tema de Investigación.....	2
B. Línea de Investigación. ....	2
C. Sub línea de Investigación.....	2
D. Planteamiento del problema.....	2
E. Formulación del problema. ....	4
F. Objetivos .....	4
1) General.....	4
2) Específicos .....	4
G. Justificación.....	5
H. Viabilidad.....	6
1) Operativa.....	6
2) Técnica.....	7
3) Económica.....	7
I. Delimitación .....	7
<b>II. MARCO TEÓRICO .....</b>	<b>8</b>
A. Antecedentes .....	8
1) Internacionales .....	8
2) Nacionales.....	11
3) Regionales.....	16
B. Supuestos teóricos de investigación.....	19
1) Trastorno déficit de atención hiperactividad (TDAH).....	19
2) Imágenes de Resonancia Magnética Funcionales (IRMF): .....	20

3)	Machine Learning .....	21
4)	Deep learning .....	22
C.	Variables de Estudio.....	24
D.	Definición nominal de las variables .....	24
1)	Variables Independientes: .....	24
2)	Variables Dependientes: .....	25
E.	Definición Operativa De Variables .....	25
1)	Variables Independientes: .....	25
2)	Variables Dependientes: .....	25
F.	Formulación de hipótesis .....	26
1)	Hipótesis de investigación .....	26
2)	Hipótesis nula.....	26
3)	Hipótesis alterna.....	27
<b>III.</b>	<b>METODOLOGÍA .....</b>	<b>28</b>
A.	Paradigma.....	28
B.	Enfoque .....	28
C.	Método .....	28
D.	Tipo de Investigación .....	29
E.	Diseño de Investigación .....	29
F.	Población.....	30
G.	Técnicas de recolección de la información .....	30
H.	Validez de la técnica .....	31
I.	Confiabilidad de la técnica.....	31
J.	Instrumento de recolección de datos .....	31
K.	Desarrollo metodológico según los objetivos de investigación .....	32

<b>IV. RESULTADOS DE LA INVESTIGACIÓN.....</b>	<b>33</b>
A. Consolidación Del Conjunto De Datos .....	33
1) Selección de datos:.....	33
2) Exploración de datos:.....	34
B. Construcción Marco Experimental.....	37
1) Preprocesar dataset: .....	38
2) Transformar dataset: .....	39
3) Elaborar diseño experimental: .....	48
4) Ejecutar diseño experimental (Minería de datos): .....	50
C. Recopilación De Métricas .....	51
1) Extraer métricas del diseño experimental: .....	51
2) Elaborar gráficas de entrenamiento .....	53
3) Otros entrenamientos .....	55
4) Elaborar reportes de métricas.....	59
5) Elaborar gráficos comparativos .....	61
<b>V. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS .....</b>	<b>62</b>
<b>CONCLUSIONES.....</b>	<b>64</b>
<b>RECOMENDACIONES.....</b>	<b>65</b>
<b>BIBLIOGRAFÍA.....</b>	<b>66</b>

## LISTA DE FIGURAS

	<b>Pág.</b>
Fig. 1 Configuración del entorno e instalación de librerías requeridas para la descarga del dataset ADHD-200. ....	33
Fig. 2. Evidencia de la descarga validada del conjunto de datos ADHD-200. ....	34
Fig. 3. Ejemplos de cortes cerebrales en planos axial, coronal y sagital de las imágenes IRMF seleccionadas. ....	35
Fig. 4. Validación de las etiquetas diagnósticas (TDAH y control) en el dataset depurado ADHD-200. ....	36
Fig. 5. Homogeneidad estructural y dimensiones finales de las imágenes IRMF seleccionadas. .	37
Fig. 6. Ejemplo del conjunto de datos inicial de imágenes de IRMF, mostrando la organización de archivos y etiquetas correspondientes a los grupos TDAH y Control.....	38
Fig. 7. Estructura de carpetas utilizadas para clasificar las imágenes según el grupo: TDAH y No_Tiene_TDAH. ....	38
Fig. 8. Ejemplo de imágenes de resonancia magnética funcional (IRMf) tras aplicar técnicas de transformación: rotación, traslación y escalado. ....	39
Fig. 9. Resultado del proceso de data augmentation, mostrando la organización de las imágenes transformadas dentro del repositorio del proyecto. ....	40
Fig. 10. Instalación de librerías y configuración del entorno de desarrollo para el procesamiento de imágenes IRMF. ....	41
Fig. 11. Script inicial para la carga y conversión de archivos NIfTI (.nii) en el entorno Google Colab, mostrando la configuración de directorios y listas para almacenamiento de imágenes y etiquetas.....	42
Fig. 12. Función para la carga y normalización de volúmenes NIfTI, incluyendo la lectura, redimensionamiento y estandarización de imágenes mediante las librerías NiBabel y NumPy.....	43
Fig. 13. Fragmento de código para el procesamiento y conversión de volúmenes en arrays multidimensionales de NumPy, consolidando la recopilación y conteo estructurado de los datos IRMF.....	43

Fig. 14. Script para el guardado de los datos procesados en formato NumPy (.npz) y conversión de los arrays en tensores de PyTorch, garantizando la compatibilidad con modelos de aprendizaje profundo. ....	44
Fig. 15. Verificación final del proceso de carga y preprocesamiento de datos, mostrando las métricas estructurales y dimensionales del conjunto de imágenes y etiquetas procesadas. ....	45
Fig. 16. Flujo de Preprocesamiento y Conversión de Datos .....	45
Fig. 17. Carga de los volúmenes preprocesados en formato .npz para el conjunto de entrenamiento. ....	46
Fig. 18. División inicial de los datos: separación del 15 % del conjunto total para la prueba. ....	47
Fig. 19. División estratificada del 85 % restante: asignación del conjunto de validación. ....	47
Fig. 20. Distribución final de los subconjuntos de entrenamiento, validación y prueba. ....	48
Fig. 21. Configuración de la arquitectura CNN3D empleada en el modelo propuesto. ....	49
Fig. 22. Proceso de entrenamiento del modelo con validación y detención temprana (early stopping). ....	51
Fig. 23. Configuración de métricas generales y específicas. ....	52
Fig. 24. Comportamiento del modelo basado en convergencia temprana y eficiencia. ....	52
Fig. 25. Resultados obtenidos del modelo de entrenamiento CNN3D. ....	53
Fig. 26. Gráfica de la evolución de la exactitud (accuracy) a lo largo de 100 épocas. ....	54
Fig. 27. Gráfica que muestra la evolución de la función de pérdida (loss) a lo largo de 100 épocas. ....	54
Fig. 28. curvas de aprendizaje correspondientes a la exactitud y la función de pérdida para los conjuntos de entrenamiento y validación .....	57
Fig. 29. Reporte de clasificación generado mediante la librería scikit-learn, utilizando las métricas de precisión (precision), exhaustividad (recall) y puntaje F1 (f1-score).....	60
Fig. 30. Gráfico comparativo de los modelos entrenados. ....	61

## LISTA DE ECUACIONES

	<b>Pág.</b>
Ecuación 1. ACCURACY.....	25
Ecuación 2. PRECISION .....	26
Ecuación 3. RECALL .....	26

## LISTA DE TABLAS

	Pág.
Tabla I. ANTECEDENTE (DELGADO CHICO,2023) .....	8
Tabla II. ANTECEDENTE (CABALLERO AMADO,2021) .....	9
Tabla III. ANTECEDENTE (ZAPATA CHAPARRO ,2022).....	9
Tabla IV. ANTECEDENTE (LAYME TEJADAO ,2020).....	10
Tabla V. ANTECEDENTE (WERNER SHTANIKLAO ,2023).....	11
Tabla VI. ANTECEDENTE (LEONEL MERA-JIMÉNEZ, JOHN F. OCHOA-GÓMEZ ,2021) .....	11
Tabla VII. ANTECEDENTE (MARIA CAMILA CASTAÑO, JONNATAN ARIAS GARCIA, WALTER SERNA SERNA, ALVARO ANGEL OROZCO GUTIERREZ, DAVID AUGUSTO CARDENAS PEÑA ,2024).....	12
Tabla VIII. ANTECEDENTE (CADAVID GIL, SANTIAGO ,2023).....	13
Tabla IX. ANTECEDENTE (RAFAEL EDUARDO AGUIRRE-GONZÁLEZ, LUIS CARLOS CORREA-ORTIZ ,2022) .....	14
Tabla X. ANTECEDENTE (CÁRDENAS CARREÑO, ERIKA NATALIA, CORRALES SANTAMARIA, BENIGNO ALEXANDER ,2022) .....	15
Tabla XI. ANTECEDENTE (CASTILLO ROSERO ,2023).....	16
Tabla XII. ANTECEDENTE (DAZA OSCAR ,2024) .....	16
Tabla XIII. ANTECEDENTE (CALPA DELGADO ,2024).....	17
Tabla XIV. ANTECEDENTE (LAGOS CABEZAS, DILSA YANE ,2024).....	18
Tabla XV. ANTECEDENTE (CARLOS DAVID CORREA LOZANO, JUAN ANDRÉS LOZANO THOME, DIEGO FERLEY URREA BURGOS,2021).....	19
Tabla XX TABLA TÉCNICA DE LOS MODELOS .....	58
Tabla XXI TABLA DE RENDIMIENTO DE LOS MODELOS .....	60

## GLOSARIO

### **ADHD-200:**

Repositorio público de neuroimágenes funcionales que contiene datos de resonancia magnética funcional (fMRI) provenientes de pacientes diagnosticados con Trastorno por Déficit de Atención e Hiperactividad (TDAH) y de sujetos control. Es utilizado internacionalmente para la investigación en neurociencia y aprendizaje profundo.

### **Algoritmo:**

Conjunto de instrucciones lógicas y matemáticas que permiten a un modelo procesar datos, aprender patrones y tomar decisiones o realizar predicciones.

### **Aprendizaje Automático (Machine Learning):**

Subcampo de la inteligencia artificial que permite a los sistemas aprender automáticamente a partir de datos sin requerir programación explícita, optimizando su desempeño mediante la experiencia.

### **Aprendizaje Profundo (Deep Learning):**

Rama avanzada del aprendizaje automático que utiliza redes neuronales con múltiples capas ocultas, capaces de aprender representaciones jerárquicas y complejas de los datos.

### **Área Bajo la Curva ROC (AUC):**

Métrica utilizada para evaluar el desempeño de un modelo de clasificación binaria, representando su capacidad de distinguir entre clases positivas y negativas.

### **Arquitectura de Red Neuronal:**

Diseño estructural que define la disposición de las capas, conexiones y parámetros de una red neuronal artificial, determinando su modo de procesamiento y aprendizaje.

### **CNN (Convolutional Neural Network):**

Tipo de red neuronal profunda especializada en el análisis y reconocimiento de patrones en datos con estructura espacial, como imágenes o señales. Se compone de capas convolucionales, de agrupamiento y totalmente conectadas.

### **CNN 3D / LSTM :**

Variantes de las redes neuronales convolucionales, empleadas para procesar datos volumétricos o series temporales espaciales, como imágenes médicas en resonancia magnética funcional (fMRI).

### **Data Augmentation (Aumento de Datos):**

Conjunto de técnicas aplicadas a los datos de entrenamiento con el propósito de aumentar su diversidad mediante transformaciones geométricas o de color, evitando el sobreajuste y mejorando la capacidad de generalización del modelo.

### **Dataset (Conjunto de Datos):**

Colección estructurada de información que se utiliza para entrenar, validar o probar modelos de aprendizaje automático, conteniendo ejemplos representativos del fenómeno de estudio.

### **Deep Learning Framework:**

Entorno o biblioteca de programación que facilita la implementación, entrenamiento y validación de modelos de aprendizaje profundo, como TensorFlow o PyTorch.

### **fMRI (Functional Magnetic Resonance Imaging / Imagen de Resonancia Magnética Funcional):**

Técnica de neuroimagen que permite observar la actividad cerebral midiendo los cambios en el flujo sanguíneo asociados al consumo de oxígeno en distintas regiones del cerebro.

### **KDD (Knowledge Discovery in Databases):**

Metodología para la extracción sistemática de conocimiento a partir de grandes volúmenes de datos. Incluye etapas de selección, preprocesamiento, transformación, minería de datos y evaluación de resultados.

**Métrica:**

Indicador cuantitativo empleado para medir el rendimiento de un modelo de aprendizaje automático, como la precisión (accuracy), exhaustividad (recall) o exactitud (precision).

**Neurona Artificial:**

Unidad fundamental de una red neuronal artificial que simula el comportamiento de una neurona biológica, procesando señales de entrada mediante funciones de activación para generar una salida.

**Overfitting (Sobreajuste):**

Fenómeno en el que un modelo se ajusta en exceso a los datos de entrenamiento, perdiendo capacidad para generalizar frente a nuevos datos.

**Precisión (Accuracy):**

Proporción de predicciones correctas realizadas por el modelo con respecto al total de predicciones efectuadas.

**Red Neuronal Artificial (ANN):**

Modelo computacional inspirado en la estructura del cerebro humano, compuesto por múltiples neuronas artificiales interconectadas, capaz de aprender patrones a partir de datos.

**TDAH (Trastorno por Déficit de Atención e Hiperactividad):**

Condición neurobiológica caracterizada por dificultades para mantener la atención, controlar impulsos y regular el comportamiento. Puede manifestarse en la infancia y persistir en la edad adulta.

**Tensor:**

Estructura matemática multidimensional utilizada para representar los datos de entrada, salida y pesos en las redes neuronales profundas.

**Validación Cruzada (Cross Validation):**

Técnica estadística que evalúa el rendimiento de un modelo dividiendo el conjunto de datos en múltiples subconjuntos para su entrenamiento y validación repetida, garantizando resultados más confiables.

## RESUMEN

La presente investigación propone desarrollar modelos de aprendizaje profundo para asistir en la identificación del Trastorno por Déficit de Atención e Hiperactividad (TDAH), analizando imágenes de resonancia magnética funcional (IRMf). Este estudio busca reducir la carga subjetiva y agilizar los diagnósticos tradicionales, ofreciendo a los expertos de salud mental herramientas predictivas de apoyo.

Para el estudio se empleó la base de datos ADHD-200, que contiene IRMFs tanto de personas diagnosticadas como de un grupo de control sano. Estas imágenes se prepararon, modificaron y ampliaron (rotándolas, moviéndolas y escalándolas) para optimizar el modelo y su habilidad para generalizar. En este proyecto, se siguieron los procesos KDD (Descubrimiento de Conocimiento en Bases de Datos) y experimental, utilizando redes neuronales convolucionales CNN 3D y redes recurrentes LSTM 3D para capacitar, validar y contrastar los resultados.

El análisis se enfocó en evaluar indicadores como la precisión, exactitud, exhaustividad y el área bajo la curva ROC, además del tiempo requerido para el entrenamiento y la predicción. Los hallazgos muestran que las estructuras CNN 3D y LSTM 3D rinden mejor que los modelos convencionales, mejorando la identificación de patrones cerebrales relacionados con el TDAH.

Este estudio es un aporte importante tanto para la medicina como para la ingeniería de sistemas, uniendo inteligencia artificial con neuroimagen funcional para crear modelos de capacitación destinados al diagnóstico clínico asistido. También establece bases metodológicas y experimentales aplicables en la investigación de otras afecciones neurológicas, reforzando el vínculo entre tecnología, salud y ciencia de datos.

Palabras claves: Diagnostico, TDAH, Deep Learning, Resonancia magnética

## ABSTRACT

This research proposes the development of deep learning models to assist in the identification of Attention Deficit Hyperactivity Disorder (ADHD) through the analysis of functional magnetic resonance imaging (fMRI). The study aims to reduce the subjectivity and time consumption inherent in traditional diagnostic methods by providing mental health professionals with predictive support models that enhance diagnostic accuracy and efficiency.

The research utilized the ADHD-200 dataset, which contains fMRI scans from both diagnosed individuals and healthy control subjects. These images were preprocessed, transformed, and augmented (through rotation, translation, and scaling) to optimize model performance and improve generalization. The project followed both the KDD (Knowledge Discovery in Databases) and experimental methodologies, employing 3D and LSTM3D Convolutional Neural Networks (CNNs) for model training, validation, and comparative evaluation.

The analysis focused on evaluating metrics such as accuracy, precision, recall, and area under the ROC curve (AUC), along with training and prediction times. The findings indicate that 3D CNN and LSTM3D architectures outperform conventional models, achieving improved recognition of brain activity patterns associated with ADHD.

This study represents a significant contribution to both the medical and computer engineering fields by integrating artificial intelligence with functional neuroimaging to develop advanced training models for computer-assisted clinical diagnosis. Furthermore, it establishes methodological and experimental foundations applicable to the study of other neurological disorders, strengthening the intersection between technology, health, and data science.

Keywords: Diagnosis, ADHD, Deep learning, Magnetic resonance imaging

## INTRODUCCIÓN

El trastorno por déficit de atención e hiperactividad (TDAH) es un trastorno el cual, en los últimos años se ha convertido en uno de los más estudiados, es una condición neurobiológica la cual se identifica en edades muy tempranas entre los 4 y 5 años cuyos síntomas pueden presentarse hasta en edades adultas. Las dificultades que presentan las personas con este trastorno pueden ser dificultades en el control y regulación del comportamiento, de las emociones y también influyendo en el cumplimiento de normas establecidas, a esto se le puede atribuir problemas de adaptabilidad a los ambientes familiares, escolares o el simple hecho de poder relacionarse con las demás personas. [1]

El TDAH es un trastorno que lo presentan muchas personas en el mundo, la manera de poder identificar de manera efectiva este trastorno se debe mucho a LA EFICACIA DE LOS ESPECIALISTAS QUE LO PUEDAN DIAGNOSTICAR, pero al mismo tiempo los expertos están de acuerdo en que el trastorno por déficit de atención e hiperactividad (TDAH) lo pueden sobre diagnosticar, lo que se busca es poder tener una herramienta que de apoyo a los especialistas que se encargan del diagnóstico del TDAH.[2]

En la actualidad, las investigaciones pueden apoyarse de tecnologías como la inteligencia artificial. Estas herramientas tecnológicas han demostrado ser útiles en el diagnóstico de enfermedades, aumentando la confianza en su uso y en el caso del TDAH no es la excepción. En este sentido, inicialmente se hará uso de un dataset denominado ADHD-200, el cual cuenta con imágenes de resonancia magnética funcionales (IRMf). Dichas imágenes serán procesadas con la ayuda de redes neuronales convolucionales (CNN) 3D y redes recurrentes LSTM3D para medir y obtener la relación de área bajo la curva ROC y el tiempo de predicción. Lo que se busca es apoyar al dictamen de este tipo de trastorno mediante la reducción de tiempo y confiabilidad en el diagnóstico.

## **I. PROBLEMA DE INVESTIGACIÓN**

### ***A. Objeto o Tema de Investigación.***

Apoyo al diagnóstico médico de TDAH mediante modelos de inteligencia artificial sobre imágenes de resonancia magnética funcional.

### ***B. Línea de Investigación.***

El trabajo de investigación se enfocará en el análisis de datos y el área de la inteligencia artificial, especialmente en el campo del aprendizaje automático.

Este estudio se apoya en la línea de la inteligencia artificial y el manejo de información, lo que permitirá desarrollar un modelo más preciso para apoyar el diagnóstico del TDAH. Para ello, se hará uso de una base de datos que incluye imágenes de resonancia magnética funcionales (IRMF), lo que permitirá proporcionar el conocimiento necesario para la creación del modelo. En este proceso, se extraerán características de las IRMF mediante el uso de técnicas de deep learning, más concretamente mediante redes neuronales convolucionales (CNN), que permitirán una extracción eficaz de diferentes características de las imágenes.

### ***C. Sub línea de Investigación.***

El Deep Learning se establecerá como la sublínea investigativa del presente proyecto, dado que la investigación se centrará en evaluar la eficiencia de la predicción del TDAH utilizando modelos de Deep Learning entrenados con imágenes de resonancia magnética funcionales (IMRF).

### ***D. Planteamiento del problema.***

El TDAH es un trastorno que, en los últimos años, se ha convertido en uno de los más investigados. es una alteración neurobiológica donde se identifica en edades muy tempranas entre los 4 y 5 años, cuyos síntomas pueden presentarse hasta una edad adulta. Detectar este trastorno puede ser

complicado ya que algunos síntomas pueden confundirse con los comportamientos propios de la edad.

Las personas con este trastorno pueden presentar dificultades en el control y regulación del comportamiento y las emociones, también influye en el comportamiento de seguimiento de normas, esto puede causar problemas de adaptabilidad en ambientes familiares, escolares o en interacciones con otras personas. [1]

El TDAH se puede encontrar en todo el mundo, esto significa que no solamente se limita a regiones o países, la forma más efectiva para diagnosticar este trastorno es en gran medida a las capacidades de los especialistas, sin embargo, existen probabilidades muy altas de un sobre diagnóstico, por esa razón se busca desarrollar herramientas que apoyen a los especialistas en la detección de esta alteración.[2]

El diagnóstico puede ser un proceso prolongado, los psicólogos, psiquiatras infantojuveniles y los neuropediatras infantiles [3] pueden presentar resultados tardíos esto se debe a la complejidad del proceso, los especialistas deben aplicar una serie de pruebas que ayudan a identificar si la persona presenta síntomas [4], pero también existen herramientas de apoyo, que lastimosamente no cuentan con la precisión y la confianza requerida. [5]

En los centros de salud, en muchas ocasiones se presentan problemas como la congestión para agendar citas o pueden presentarse la liquidación de las EPS, estos factores externos agravan la crisis en el diagnóstico [6], las pruebas suelen ser extensas, incluyendo la elaboración de una historia clínica, entrevistas, exploraciones físicas, evaluación psicológicas y por último escalas del TDAH, todo este protocolo lleva tiempo de ejecución [7].

Adicionalmente, las señales cerebrales han sido ampliamente usadas en dar una valoración médica, al proporcionar parámetros físicos del cerebro de forma objetiva. Para esto encontramos señales EEG, Rx, Resonancia, Resonancia magnética y resonancia magnética funcional. Esta última señal ofrece una de las mayores complejidades tanto en la caracterización de la señal (ya que es una señal en 4 dimensiones), como del lado del apoyo al diagnóstico médico mediante IA. Estudios como los de Calzada; Castillo y Mora [5] muestran que una exactitud de 80%, aunque parece una métrica favorable otros tipos de señales superan hasta en 12 puntos porcentuales como lo muestra Salazar Castro con señales EEG. Sin embargo, los estudios de Calzada; Castillo y Mora, tienen algunos

vacíos experimentales, como es el caso del uso de redes neuronales convolucionales 3D y redes recurrentes LSTM3D, que, según los estudios, la aplicación de convoluciones en la topología de la señal mejora la extracción de características automática y por tanto puede también mejorar la clasificación Calzada; Castillo y Mora. [5]

### ***E. Formulación del problema.***

¿En qué cantidad porcentual mejora la eficiencia en el diagnóstico médico utilizando CNN 3D y LSTM3D aplicadas a imágenes de resonancia magnética funcional (IRMF)?

### ***F. Objetivos***

#### ***1) General***

Medir la eficiencia en la predicción de TDAH en un conjunto de modelos de Deep Learning entrenados con imágenes de resonancia magnética funcionales como apoyo al diagnóstico médico mediante la relación del área bajo la curva ROC y el tiempo de predicción.

#### ***2) Específicos***

- Consolidar un dataset de imágenes de resonancia magnética funcional etiquetadas con pre diagnóstico de déficit de atención e hiperactividad (TDAH) como fuente primaria para el entrenamiento de un conjunto de modelos de Deep Learning.
- Construir un marco experimental con la combinación de filtros de imágenes de resonancia magnética funcional, redes neuronales convolucionales con arquitecturas diferentes y propias que consolidan un cuadro comparativo de métricas de aprendizaje automático y tiempos de entrenamiento y predicción.
- Recolectar un conjunto de métricas que permitan la evaluación de la eficiencia en cada combinación definida en el marco experimental mediante la construcción de cada modelo y ejecución de cada entrenamiento respectivo.

## *G. Justificación*

La presente investigación tiene como objetivo el desarrollo de un modelo que facilite el diagnóstico temprano del TDAH, con el fin de obtener resultados que puedan apoyar el pronóstico de este trastorno en pacientes que presenten sintomatología altamente indicativa de la condición. El sistema a desarrollar permitirá que el paciente identifique la probabilidad de que esté presente el trastorno, motivándolo a consultar a un especialista. De este modo, los resultados generados por la herramienta no solo servirán como un apoyo en el diagnóstico, sino también para promover la acción temprana en busca de un tratamiento adecuado. Además, en el ámbito de la ingeniería de sistemas, aun no se han aplicado redes neuronales convolucionales (CNN) para analizar imágenes de resonancia magnética funcionales (IRMF).

Abordar esta problemática, que afecta a personas de todas las edades a nivel mundial, es fundamental, especialmente cuando se trata de la salud física y mental. El TDAH, una condición que no solo impacta a niños, sino también a los adultos, presenta un riesgo considerable cuando no se diagnostica a tiempo. Como se menciona, desafortunadamente, los adultos que no fueron diagnosticados adecuadamente en su infancia enfrentan dificultades en actividades sociales y personales.[8]. Además, este trastorno se puede considerar como un peligro en términos sociales, escolares y académicos, pero también en el ámbito personal, puede generar que el paciente el cual padece de este trastorno, tenga alto riesgo de presentar embarazo adolescente, abuso de sustancias, criminalidad y pobreza [9]

La investigación propuesta se orienta a desarrollar una solución que apoye el diagnóstico del TDAH mediante redes neuronales convolucionales (CNN), una técnica avanzada del aprendizaje automático, que se apoya en principios de Deep Learning [10]. Según expertos, “las redes neuronales convolucionales son ampliamente usadas en tareas de detección o clasificación de imágenes” [11], lo que las convierte en una herramienta idónea para la clasificación de imágenes de resonancia magnética funcionales (IRMF) y la identificación de características del TDAH. Esta técnica del Deep Learning destaca por su capacidad de manejar grandes volúmenes de datos e identificar patrones complejos, lo que permite obtener resultados altamente precisos durante el proceso de entrenamiento. Aunque se han realizado investigaciones previas sobre el diagnóstico temprano del TDAH utilizando diferentes técnicas de inteligencia artificial, esta propuesta busca

mejorar la exactitud de los resultados mediante el uso de aprendizaje profundo en imágenes de resonancia magnética funcionales (IRMF).

El proyecto se apoya en antecedentes sobre el uso de señales IRMF y recursos bibliográficos que abarcan tanto el diagnóstico del TDAH como las técnicas del deep learning, en particular las redes neuronales convolucionales (CNN). En este sentido, se cuenta con conjuntos de datos como el repositorio ADHD-200, que contiene imágenes de IRMF gratuitas para el entrenamiento del modelo. Como se señala textualmente, “Los datos fueron utilizados por varios equipos que compitieron en la Competencia Global ADHD-200, incluido el trabajo ganador de un grupo de bioestadísticos. Hasta donde sabemos, la versión preprocesada de ADHD-200 fue el primer recurso público de gran tamaño de datos de fMRI” [12]. Además, se están realizando procesos de colaboración con profesionales del ámbito neurológico e ingenieril, cuyas experiencias contribuirán de manera significativa al desarrollo de esta investigación.

Los aportes de este proyecto a la disciplina serán relevantes tanto para los “experimentos” enfocados en el análisis de señales IRMF como para el avance en técnicas de diagnóstico del TDAH, mediante el uso de metodologías innovadoras. Este estudio también beneficiará al campo de la ingeniería en el desarrollo de sistemas de entrenamiento para el diagnóstico temprano del TDAH [5] . Las contribuciones generadas ayudarán a la detección oportuna de este trastorno, lo cual permitirá que los pacientes reciban un tratamiento temprano y, en consecuencia, mitigar los síntomas del TDAH.

## ***H. Viabilidad***

### ***1) Operativa***

El presente proyecto es viable operativamente ya que cuenta con la experiencia en la línea de investigación suscrita dada por la formación en los espacios electivos, la experiencia del asesor el cual cuenta con formación en inteligencia artificial, donde además cuenta con varios proyectos de investigación desarrollados y uno de ellos está directamente asociado al objeto de investigación del presente estudio. Adicionalmente a lo anterior, se cuenta con antecedentes relacionados con el objeto de estudio los cuales aportan en la ejecución metodológica de la presente investigación.

## **2) Técnica**

Desde el punto de vista del desarrollo tecnológico, se cuenta con investigaciones que aportan en cuanto a la implementación del tratamiento de señales y estructuración de modelos de aprendizaje automático. Además, se cuenta con un conjunto de datos de imágenes de resonancia magnética funcional de uso libre y previamente etiquetado. Finalmente, las redes neuronales convolucionales a estudiar están implementadas en varias bibliotecas de deep learning y herramientas computacionales que permiten el uso de hardware especializado (GPU, TPU) que permiten realizar entrenamientos con alto costo computacional.

## **3) Económica**

Al hacer uso del dataset ADHD-200 al ser un repositorio libre, se cuenta con los recursos necesarios y disponibles los cuales correrán por cuenta de los integrantes del grupo de trabajo. Igualmente, el uso de plataformas para el entrenamiento como Kagle y Colab las cuales ofrecen una capa gratuita. No obstante, en el último apartado de requerir hardware con características más robustas se asumirán los gastos con recursos propios.

### **1. Delimitación**

El proyecto de investigación se desarrollará mediante la técnica de redes neuronales convolucionales (CNN) 3D y redes recurrentes LSTM3D, específicamente para la clasificación y entrenamiento de imágenes de resonancia magnética funcionales (IRMF), las cuales se encuentran almacenadas en un repositorio público. Planeando desarrollar y entrenar un algoritmo de entrenamiento que se basara en la metodología KDD y el método experimental, brindando una solución útil hacia expertos que podrían usar este modelo y apoyando el diagnóstico del TDAH. El tiempo estimado para la realización del proyecto es de 8 meses comenzando en el periodo A del 2025 y finalizando en el periodo B del mismo año.

## II. MARCO TEÓRICO

### A. Antecedentes

A continuación, se presentan un conjunto de registros investigativos y científicos, los cuales servirán de soporte para el presente proyecto.

#### 1) Internacionales

Tabla I.  
ANTECEDENTE (DELGADO CHICO,2023)

#### **Interpretación de redes neuronales profundas como herramienta para diferenciar subtipos de TDAH a partir de patrones de actividad**

Autor (as, es)	GUILLERMO CHICO DELGADO
Fecha	20 de septiembre de 2023
País	España
Resumen	El trastorno de TDAH, es una condición que puede afectar a niños y adultos. El TDAH se divide en tres subtipos, los cuales se han sometido a evaluaciones médicas con importantes componentes subjetivos. Su correcto diagnóstico es crucial para brindarle al paciente un correcto tratamiento. En la actualidad se han presentado diferentes estudios que comprueban que el aprendizaje profundo es óptimo a la hora de diagnosticar el trastorno de TDAH y sus subtipos. Uno de los subtipos y el menos estudiado debido a sus bajos niveles de diagnóstico es el TDAH predominante hiperactivo, el cual se va a caracterizar mediante espectrogramas divididos por subtipos y el entrenamiento de redes neuronales convolucionales.[11]
Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento mediante la metodología respecto a espectrogramas divididos por subtipos en relación a las redes convolucionales (CNN)

Fuente: Uva doc

Tabla II.  
ANTECEDENTE (CABALLERO AMADO,2021)

**Contribuciones a la detección de TDAH en la infancia mediante soluciones basadas en Deep Learning**

Autor (as, es)	PATRICIA AMADO CABALLERO
Fecha	22 de septiembre de 2021
País	España
Resumen	El trastorno de TDAH es una de las condiciones más frecuentes en niños y niñas, con un porcentaje previamente al 5% y con niveles mayores en varones, debido a la dificultad de encontrar marcadores significativos en las mujeres que determinen la presencia de la patología en este grupo poblacional en particular, sumándole la dificultad de diagnosticar el trastorno al avance de la edad. Se usarán registros de astigrafía enlazados con aprendizaje profundo para la búsqueda y reconocimiento de patrones que ayuden a identificar diferencias entre niños y niñas los cuales hayan sido diagnosticados con TDAH, empleando mapas de oclusión para observar las distintas características y posteriormente realizar la respectiva clasificación.[13]
Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento mediante la metodología respecto a la astigrafía y mapas de oclusión en relación a las redes convolucionales (CNN) y como fue el debido proceso de entrenamiento.

Fuente: Uva doc

Tabla III.  
ANTECEDENTE (ZAPATA CHAPARRO ,2022)

**Pre-diagnóstico de amigdalitis por procesamiento de imágenes usando redes neuronales convolucionales, 2021**

Autor (as, es)	Chaparro Zapata, José Leonardo, Rosales Palacios, Ashly Alexandra
Fecha	2022
País	Perú

Resumen	La amigdalitis es una enfermedad que afecta a muchas personas, se hace uso del procesamiento de imágenes para obtener un prediagnóstico de la enfermedad de forma automatizada, además, para llevar a cabo el entrenamiento del sistema, se hará uso de las redes neuronales convolucionales para obtener resultados más acertados, se han elaborado fichas de registro para llevar información relevante de la enfermedad, las cuales permiten llevar un control adecuado respecto a las iteraciones de las imágenes encargadas del entrenamiento del sistema. Ayudando a la eficiencia en las consultas realizadas por pacientes.[14]
---------	---

Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento mediante la metodología respecto a fichas de registro en relación a las redes convolucionales (CNN) para la obtención de resultados acertados.
-------------------------------------	---

Fuente: UNIVERSIDAD CÉSAR VALLEJO - repositorio digital institucional

*Tabla IV.  
ANTECEDENTE (LAYME TEJADAO ,2020)*

### **Arquitectura de red neuronal convolucional para diagnóstico de cáncer de piel**

Autor (as, es)	Giorzinio Maikol Tejada Layme, Renzo Pascual Gonzales Chama
----------------	---

Fecha	2020
-------	------

País	Perú
------	------

Resumen	El aprendizaje automático ha sido utilizado en muchos aplicativos en los últimos años, siendo el Deep learning una técnica de aprendizaje muy eficiente a la hora de entrenar y analizar imágenes médicas, facilitando el diagnóstico de diferentes enfermedades en pacientes y así ayudando a la toma de decisiones sobre su salud. Se analizó distintas redes neuronales convolucionales, las cuales puedan identificar con una mejor exactitud, características del cáncer de piel por medio de las imágenes tomadas. El modelo que se establece, se basa en una clasificación binaria, siendo 1 igual a maligno y 0 en benigno, el melanoma se identificará de forma temprana, empleando una nueva arquitectura de entrenamiento de tres capas usando repositorios de imágenes. [15]
---------	--

Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento mediante la metodología de clasificación binaria y la implementación de tres o más capas de aprendizaje profundo de las redes neuronales.
-------------------------------------	--

Fuente: UNIVERSIDAD TECNOLÓGICA DEL PERÚ - repositorio institucional

*Tabla V.*  
*ANTECEDENTE (WERNER SHTANIKLAO ,2023)*

**Sistema de Diagnóstico del Alzheimer basado en Imágenes de Resonancia Magnética mediante el Algoritmo VGG16**

Autor (as, es)	Ucañay Barreto, Werner Shtaniklao; Coral Ygnacio, Marco Antonio
Fecha	23 octubre 2023
País	Ecuador
Resumen	El diagnóstico temprano del alzhéimer es crucial para los pacientes que tienden a padecer esta condición y posteriormente brindarles un buen tratamiento. Se ha desarrollado un sistema con ayuda del entrenamiento de imágenes IRM mediante el uso de redes neuronales convolucionales (CNN) mediante el algoritmo VGG16. Se utilizaron imágenes de pacientes con y sin alzhéimer, las cuales se usaron para que el sistema reconociera patrones de la enfermedad y posteriormente se usó un nuevo conjunto de imágenes para evaluar la exactitud del diagnóstico. Finalmente, el algoritmo VGG16 obtuvo una precisión superior al 82% para reconocer dichos síntomas.[16]
Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento mediante la metodología de clasificación y entrenamiento de imágenes IRM mediante redes neuronales convolucionales (CNN) mediante el algoritmo VGG16.

Fuente: Latin-American Journal of Computing - Escuela Politécnica Nacional, Ecuador

**2) Nacionales**

*Tabla VI.*  
*ANTECEDENTE (LEONEL MERA-JIMÉNEZ, JOHN F. OCHOA-GÓMEZ ,2021)*

**Redes neuronales convolucionales para la clasificación de componentes independientes de rs-fMRI**

Autor (as, es)	Leonel Mera-Jiménez, John F. Ochoa-Gómez
Fecha	01 Marzo 2021

País	Colombia
Resumen	<p>La resonancia magnética funcional en estado de reposo (rs-fMRI) es una de las técnicas más relevantes en exploración cerebral. No obstante, la misma es susceptible a muchos factores externos que pueden ocultar la señal de interés. En este orden de ideas, las imágenes rs-fMRI han sido estudiadas desde diferentes enfoques, existiendo un especial interés en las técnicas de eliminación de artefactos a través del Análisis de Componentes Independientes (ICA por sus siglas en inglés). El enfoque es una herramienta poderosa para la separación ciega de fuentes donde es posible eliminar los elementos asociados al ruido. Sin embargo, dicha eliminación está sujeta a la identificación o clasificación de las componentes entregadas por ICA. En ese sentido, esta investigación se centró en encontrar una estrategia alternativa para la clasificación de las componentes independientes. El problema se abordó en dos etapas. En la primera de ellas, se redujeron las componentes (volúmenes 3D) a imágenes mediante el Análisis de Componentes Principales (PCA por sus siglas en inglés) y con la obtención de los planos medios. Los métodos lograron una reducción de hasta dos órdenes de magnitud en peso de los datos y, además, demostraron conservar las características espaciales de las componentes independientes. En la segunda etapa, se usaron las reducciones para entrenar seis modelos de redes neuronales convolucionales. Las redes analizadas alcanzaron precisiones alrededor de 98 % en la clasificación e incluso se encontró una red con una precisión del 98.82 %, lo cual refleja la alta capacidad de discriminación de las redes neuronales convolucionales.[17]</p>
Aspectos útiles al presente estudio	Este proyecto aporta en la parte de entrenamiento del modelo con las redes neuronales convolucionales

Fuente: Scielo

*Tabla VII.*

*ANTECEDENTE (MARIA CAMILA CASTAÑO, JONNATAN ARIAS GARCIA, WALTER SERNA SERNA, ALVARO ANGEL OROZCO GUTIERREZ, DAVID AUGUSTO CARDENAS PEÑA ,2024)*

### **Implementación de un modelo predictivo basado en redes neuronales convolucionales 3D en el paso de deterioro cognitivo leve a Alzheimer sobre imágenes por resonancia magnética.**

Autor (as, es)	Maria Camila Castaño, Jonnatan Arias Garcia, Walter Serna Serna, Alvaro Angel Orozco Gutierrez, David Augusto Cardenas Peña
Fecha	01 Julio 2024
País	Colombia

---

Resumen

La enfermedad del Alzheimer es un trastorno neurológico que causa la pérdida de autonomía y memoria en las personas que la padecen. Debido al aumento de casos de este padecimiento y la falta de precisión de las herramientas de diagnóstico se da paso al desarrollo de nuevas herramientas capaces de disminuir esta problemática. El objetivo principal de este trabajo investigativo es implementar un modelo de red neuronal convolucional tridimensional con estructura base tipo AlexNet3D para obtener la predicción de un posible diagnóstico de la enfermedad Alzheimer (AD) a partir del análisis de imágenes por resonancia magnética, utilizando como etapa temprana el síndrome de deterioro cognitivo leve (MCI). Este proyecto brindará la explicación de cada fase planteada, las cuales fueron divididas en selección de las bases de datos, elección de características, procesamiento de los datos, desarrollo del modelo para su entrenamiento y validación, y por último, resultados obtenidos a partir de las pruebas de predicción. Con las cuales pudo obtenerse un porcentaje del 72,22 %, permitiendo catalogar al modelo K-Net95 como una red estable y eficiente, a pesar de las limitaciones computacionales a las que se vio limitado el proyecto. [18]

---

Aspectos útiles al presente estudio

Este proyecto nos permitirá entender cómo apoyar el diagnóstico del TDAH, también permitirá ver cómo funciona un modelo hecho con la red neuronal convolucional tridimensional.

---

Fuente: UNIVERSIDAD EIA - revista EIA

*Tabla VIII.*  
*ANTECEDENTE (CADAVID GIL, SANTIAGO ,2023)*

**Comparación de desempeño de modelos clásicos y cuánticos de redes neuronales convolucionales para la detección de patrones en señales electrocardiográficas**

---

Autor (as, es)	Cadauid Gil, Santiago
----------------	-----------------------

---

Fecha	2023
-------	------

---

País	Colombia
------	----------

---

---

**Resumen**

En el presente trabajo de grado, se abordó el desafío de clasificar complejos QRS en señales de electrocardiograma (ECG) mediante la aplicación de tres enfoques de modelado diferentes. El problema de clasificación de complejos QRS reviste una gran importancia en el campo de la cardiología y el monitoreo de la salud, ya que permite identificar patrones cardíacos anormales que pueden requerir atención médica. Se evaluó el uso de tres modelos distintos: un modelo clásico de red neuronal convolucional, un modelo híbrido que combina convolución en el dominio clásico con una capa cuántica de salida, y otro modelo híbrido que emplea convolución en el dominio cuántico. La evaluación de estos modelos se centró en su exactitud y su complejidad temporal. Los resultados obtenidos indican que los tres modelos demostraron un desempeño excepcional en términos de exactitud. Tanto el modelo clásico como la simulación del modelo híbrido con convolución en el dominio cuántico alcanzaron altas tasas de precisión. Este alto nivel de exactitud los posiciona como opciones viables para tareas de clasificación binaria de complejos QRS en señales de ECG. La elección del modelo más adecuado dependerá de la criticidad de la aplicación y las necesidades específicas del contexto. En lo que respecta al desempeño en función del tiempo, el modelo híbrido con convolución en el dominio cuántico sobresalió al exhibir una complejidad temporal significativamente mejorada en comparación con los otros dos modelos. Esta eficiencia temporal es especialmente relevante en aplicaciones que requieren un procesamiento rápido de señales. Si bien el modelo clásico y el modelo híbrido con capa de salida cuántica presentaron un rendimiento similar en términos de complejidad temporal, el modelo clásico mostró una ligera ventaja.[19]

---

**Aspectos útiles al presente estudio**

Este proyecto nos permitirá entender cómo podremos abordar la clasificación de un modelo con respecto al tema de investigación y cuál sería el más adecuado para el apoyo al diagnóstico de TDAH .

---

Fuente: UNIVERSIDAD DE ANTIOQUIA repositorio institucional

*Tabla IX.*

*ANTECEDENTE (RAFAEL EDUARDO AGUIRRE-GONZÁLEZ, LUIS CARLOS CORREA-ORTIZ ,2022)*

---

**Software para ayudar a psicólogos en el diagnóstico y tratamiento de niños con TDAH**

---

Autor (as, es)	Rafael Eduardo AGUIRRE-GONZÁLE1, Luis Carlos CORREA-ORTIZ2
----------------	--

---

Fecha	2022
-------	------

---

País	Colombia
------	----------

---

Resumen	El objetivo general es crear software con IA para ayudar en la toma de decisiones de los psicólogos para mejorar el diagnóstico y el tratamiento de niños con TDAH, con base en los objetivos específicos, como el desarrollo de la IA para analizar datos contextuales de situaciones personales y de la plataforma para los psicólogos.[20]
Aspectos útiles al presente estudio	Este proyecto permite entender cómo el modelo puede ser de gran ayuda para el apoyo al diagnóstico del TDAH.

Fuente: UNIVERSIDAD MANIZALES

*Tabla X.*  
*ANTECEDENTE (CÁRDENAS CARREÑO, ERIKA NATALIA, CORRALES SANTAMARIA, BENIGNO ALEXANDER ,2022)*

### **Clasificador de tumores cerebrales primarios basado en redes neuronales convolucionales**

Autor (as, es)	Cárdenas Carreño, Erika Natalia, Corrales Santamaria, Benigno Alexander
Fecha	19 septiembre 2022
País	Colombia
Resumen	El siguiente documento presenta el desarrollo de un modelo basado en redes neuronales convolucionales para la clasificación por imágenes de tumores cerebrales primarios (glioma, meningioma e hipófisis) y pacientes sanos (no tumorales). Para ello se establece un conjunto de experimentos donde se evalúan diferentes hiper parámetros, comparando su desempeño en base a índices de desempeño, con el fin de seleccionar un modelo útil. Finalmente, se presenta una arquitectura CNN con una precisión global del 98,25% para cuatro clases.[21]
Aspectos útiles al presente estudio	Este proyecto no permitirá entender la clasificación de las imágenes de resonancia magnética.

Fuente: UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS - repositorio institucional

### 3) Regionales

Tabla XI.  
ANTECEDENTE (CASTILLO ROSERO ,2023)

#### **“MODELDX-TDAH” MODELO PARA APOYAR EL DIAGNÓSTICO TEMPRANO DE TDAH CON TÉCNICAS DE MACHINE LEARNING**

Autor (as, es)	LIZETH BEATRIZ CASTILLO ROSERO, KEVIN GIANCARLO CALZADA RIVAS
Fecha	Agosto 2023
País	Colombia
Resumen	El trastorno de TDAH es una condición que afecta a personas de todas las edades siendo su principal sistema, la dificultad de controlar sus impulsos y mantener la atención, pero no siendo un patrón general para todos los que padecen de esta condición. En la actualidad se han llevado a cabo diferentes estudios respecto a la inteligencia artificial y de cómo esta puede ayudar a la detección de enfermedades. Se construyó un sistema para el diagnóstico temprano del TDAH usando algoritmos de machine learning haciendo uso de imágenes de resonancia magnética funcionales para el debido entrenamiento en cada algoritmo finalizando con la evaluación y determinación de cual modelo fue más exacto. Todo esto con ayuda del conjunto de imágenes ADHD-200 y la metodología (KDD).[5]
Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento de imágenes (IRMF) mediante la metodología (KDD) por medio del conjunto de imágenes ADHD-200.

Fuente:UNIVERSIDAD DE NARIÑO

Tabla XII.  
ANTECEDENTE (DAZA OSCAR ,2024)

#### **Desarrollo e implementación de un algoritmo de aprendizaje automático para la reconstrucción de imágenes electrocardiográficas (ECGI).**

Autor (as, es)	Oscar Daza Renza, Santiago Holguín Torres
Fecha	2024
País	Colombia
Resumen	<p>El trabajo realizado se centra en la implementación de algoritmos de aprendizaje automático para el procesamiento en señales ECG, para optimizar el rendimiento de hiperparámetros, permitiendo diseñar un sistema eficaz para detectar características de la electroencefalografía proporcionando resultados confiables. El estudio se centra desde la recopilación de los datos, en este caso de las imágenes encefalográficas, posteriormente pasando por distintos métodos de regresión y finalmente evaluando cuál modelo de aprendizaje fue más preciso. Siendo los hiperparámetros eficaces a la hora de mejorar el rendimiento del modelo seleccionado, haciendo uso de técnicas como GridSearch para encontrar la mejor combinación de parámetros.[22]</p>
Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento mediante la metodología de implementación de algoritmos de procesamiento de imágenes en señales ECG.

Fuente:UNIVERSIDAD MARIANA - repositorio institucional

*Tabla XIII.*  
*ANTECEDENTE (CALPA DELGADO ,2024)*

### **Comparativo de funciones kernel en la predicción de enfermedades cardiovasculares en Redes Neuronales Artificiales (ANN) y Máquinas de Soporte Vectorial (SVM)**

Autor (as, es)	Michael Rafael Rodríguez Rodríguez, Claudia Alejandra Delgado Calpa
Fecha	2024
País	Colombia

Resumen	En la actualidad, las enfermedades cardiovasculares son las responsables de la mayoría de las muertes en todo el mundo, existiendo diferentes causas y desafíos como la ineficiencia a nivel hospitalario, la dificultad o limitación tecnológica o diagnósticos tardíos. Haciendo uso del machine learning se plantea la realización de un sistema que por medio de la función kernel, redes neuronales artificiales (ANN) y máquinas de soporte vectorial (SVM) comparando cada una de las funciones determinando cual es su exactitud y tiempo de predicción. Integrando esas funciones a la biblioteca scikit learn logrando una configuración adecuada para la predicción de que una persona pueda padecer una enfermedad cardiovascular.[23]
---------	--

Aspectos útiles al presente estudio	Este proyecto aporta en el conocimiento de cómo se llevó a cabo el entrenamiento mediante funciones kernel, máquinas de soporte vectorial y redes neuronales.
-------------------------------------	---

Fuente: UNIVERSIDAD CESMAG - repositorio institucional

*Tabla XIV.*  
*ANTECEDENTE (LAGOS CABEZAS, DILSA YANE ,2024)*

**Técnicas de procesamiento digital de imágenes para el reconocimiento y monitoreo de los residentes en conjuntos urbanos en la ciudad de San Juan de Pasto**

Autor (as, es)	Lagos Cabezas, Dilsa Yane
----------------	---------------------------

Fecha	23 noviembre 2024
-------	-------------------

País	Colombia
------	----------

Resumen	En el siguiente informe, se presentan los resultados de la investigación del reconocimiento facial a residentes de una urbanización con un modelo predictivo, por tal motivo se elaboró una herramienta con el mejor modelo para la identificación de residentes y monitoreo, donde esta herramienta ayudó al personal de vigilancia a controlar el ingreso de personas autorizadas o no al conjunto urbano.[24]
---------	--

Aspectos útiles al presente estudio	Este proyecto aportaría técnicas de procesamiento imágenes no permitirá entender segmentar una imagen.
-------------------------------------	--

Fuente: UNIVERSIDAD CESMAG - repositorio institucional

## EVALUACIÓN DE MÉTODOS DE REDUCCIÓN DE DIMENSION PARA LA PRESERVACION TOPOLÓGICA DE LOS DATOS MEDIANTE MÉTRICAS RNX

Autor (as, es)	Carlos David Correa Lozano, Juan Andrés Lozano Thome, Diego Ferley Urrea Burgos
Fecha	28 Noviembre 2021
País	Colombia
Resumen	En la actualidad la masiva cantidad de datos generada de diversas fuentes convierte la tarea del análisis de datos en algo complejo y tardío, puesto que los datos pueden contener información que no sea relevante para un algoritmo de Machine Learning generando resultados poco confiables, por lo cual se vuelve necesario procesar los datos antes de aplicarlos al algoritmo, dentro de este proceso de transformación se encuentra la reducción de dimensión (RD), la cual permite obtener un espacio de menor dimensión a partir de un conjunto de datos de mayor dimensión, con el fin de que atributos irrelevantes, no muy relevantes o redundantes sean eliminados. Los métodos RD son de gran ayuda puesto que transforman los datos ingresados en una representación de los mismos mucho más manejable, una noción visual del desempeño de las técnicas RD, es la preservación topológica o la medida en que el espacio de incrustamiento conserva la estructura de los datos de mayor dimensión, por tal motivo se hace necesario medir cuantitativamente dicha preservación de la topología. Por lo anterior, el presente proyecto implementó las curvas de calidad RNX propuestas por John Lee y Michael Verleysen, que permiten evaluar el desempeño de los algoritmos RD, generando una representación gráfica de la preservación topológica.[25]
Aspectos útiles al presente estudio	Este proyecto permitirá entender de qué manera podemos analizar los datos que usaremos para el desarrollo el proyecto, con esto lo que se buscara es obtener las características más relevantes para el proyecto.

Fuente: UNIVERSIDAD CESMAG - repositorio institucional

### ***B. Supuestos teóricos de investigación***

#### ***1) Trastorno déficit de atención hiperactividad (TDAH)***

El déficit de atención e hiperactividad (TDAH) es un trastorno que se ha encontrado presente en la sociedad por más de dos siglos. en 1798 se comenzó a hablar por primera vez de los síntomas

de esta condición en la obra del médico escocés Alexander Crichton, titulada “Una investigación sobre la naturaleza y el origen de la enajenación mental”, donde habla sobre las dificultades que tienen las personas que sufren de este trastorno a la hora de aprender, de concentrarse, mantener la atención.[26]

El TDAH como ya lo hemos mencionado anteriormente se considera un trastorno de origen neurobiológico, la principal causa que influye en esta patología se debe a que puede ser hereditario la probabilidad de que esto pase es 76%.

Estudios realizados de neuroimagen cerebral han demostrado que varias regiones del cerebro que son afectadas TDAH.

**a) *La corteza prefrontal***

Se encarga de funciones ejecutivas tales como planificar acciones, iniciarlas, identificar errores y corregirlos, evita la distracciones y flexibilidad ante las circunstancias.

**b) *El cuerpo calloso***

Se encarga de la comunicación entre dos hemisferios cerebrales esto asegura un trabajo en conjunto y complementario.

**c) *Los ganglios basales***

Se encargan del control de los impulsos coordina y filtra la información que recibe las otras regiones del cerebro e “inhibir las respuestas automáticas”.

**d) *El cíngulo anterior***

Se encarga de gestionar las emociones, la atención y regulación de las distracciones. [27]

**2) *Imágenes de Resonancia Magnética Funcionales (IRMF):***

Las imágenes (IRMF) se consideran una técnica la cual ayuda a visualizar el comportamiento del cerebro frente a un estímulo o actividad [28], la cual Mide los niveles de oxígeno de un área específica del cerebro que se activan mediante la realización de tareas esto produce un consumo de oxígeno en los tejidos locales de aproximadamente de un 5%, el cual es un procedimiento el cual sirve para ayudar en la toma de decisiones para procedimientos médicos.

Las imágenes de resonancia magnética funcionales, permiten observar la actividad cerebral, una técnica la cual se basa en el estudio y registro de la señal BOLD, una señal que se basa en medir los niveles de oxígeno en la sangre, la cual llega hasta las neuronas, causando una activación de estas mismas, lo cual genera que se lleve el registro de la actividad cerebral, hay dos momentos, cuando la sangre llega oxigenada a la neurona se le denomina diamagnética, es decir que emite mayor señal, y por otra parte, la sangre que deja a la neurona es paramagnética, es decir, emite menor señal [29].

### **3) *Machine Learning***

Se define al machine learning como un conjunto de metodologías o modelos capaces de identificar y procesar conjuntos de datos. un avance o evolución de algoritmos computacionales, los cuales tiene el objetivo de emular la inteligencia de los seres humanos, recibiendo datos y aprendiendo de ellos. [30]

Es una tecnología capaz de dar solución a problemas por medio del aprendizaje y análisis de un conjunto de datos. La solución brindada, será de mayor calidad, siempre y cuando la cantidad de datos también lo sea. La manera en que trabaja machine learning es por medio del procesamiento de datos, se usan datos de entrada, datos de entrenamiento y datos de salida.[32]

#### ***a) Algoritmos:***

algunos de los algoritmos más importantes del machine learning son:

- **Regresión lineal:** usada para realizar predicciones futuras e identificar la relación que existe entre una variable dependiente y una o más variables independientes.[31]
- **Redes Neuronales:** es una técnica inmersa en el aprendizaje profundo, un tipo de algoritmo que intenta asemejarse al cerebro humano en el aspecto de tomar decisiones y realizar mejoras continuas teniendo en cuenta errores y realizar mejoras.[32]
- **Árboles de Decisión:** es un algoritmo de aprendizaje usado para realizar clasificación de datos. Su estructura consta de un nodo raíz, ramas, nodos internos y nodos hojas.[33]

### ***b) Tipos de Aprendizaje:***

- Aprendizaje Supervisado: es un tipo de aprendizaje del machine learning, el cual se clasifica a un conjunto de datos, los cuales se encuentran etiquetados, para que el modelo de aprendizaje pueda realizar la clasificación de esos datos o una predicción confiable. [34]
- Aprendizaje No Supervisado: es la forma en la que el modelo recibe datos, los cuales no se encuentran etiquetados y el mismo algoritmo puede identificar características o patrones en ese grupo de datos sin la necesidad de instrucciones.[35]
- Aprendizaje por refuerzo: es la técnica de aprendizaje, la cual usa el algoritmo para “aprender” de su propia experiencia y optimizar la manera de clasificar o encontrar patrones en los datos. [36]

### ***4) Deep learning***

Es un algoritmo que intenta imitar el funcionamiento del cerebro humano por medio de la combinación de la entrada y el procesamiento de los datos. Empleando un conjunto de elementos los cuales trabajan en complemento para reconocer, clasificar y describir con precisión los objetos dentro de los datos.[37]

Las redes neuronales se componen de varias capas que se confirman por nodos que se encuentra interconectados, cada capa es usada para refinar y optimizar la predicción o la categorización, en una red se aplican una serie de cálculos a esto se le denomina una propagación hacia adelante.

En el deep learning encontramos diferentes tipos de redes neuronales esto también permite abordar diferentes problemas o conjunto de datos con esto encontramos un algoritmo que se denomina redes neuronales convolucionales (CNN).[38]

#### ***a) Redes convolucionales (CNN)***

Es una técnica del Deep learning considerada como una arquitectura de red la cual se aprende por medio de datos. Las redes neuronales convolucionales (CNN) trabajan por medio de capas, las

cuales se clasifican en capas de entrada, salida y ocultas, las cuales van aprendiendo a identificar características muy específicas dentro de una imagen.

Estas redes, son usadas para identificar y aprender patrones clave dentro de un conjunto específico de datos e información, una tecnología primordial para llevarse a cabo en aplicativos como: captura de imágenes médicas, procesamiento de audio, detección de objetos, generación de datos sintéticos, entre otras.[39]

### **Capas:**

- **Convolución:** es una capa que se compone por filtros, cada filtro tiene la característica de ser pequeño, pero se extiende a través de toda la profundidad de entrada, por ejemplo un primer filtro, regularmente puede componerse por dimensiones de  $7 \times 7 \times 3$ , esto quiere decir, 7 pixeles de ancho, 7 de alto y 3 de profundidad por los respectivos canales de color.[40]
- **Unidad Lineal Rectificada (ReLU):** es una capa en la cual se generan una salida dependiendo del dato de entrada, su funcionalidad se basa en que si el dato entrante es negativo, la salida va a ser cero, pero si la entrada es positiva el valor de la salida será igual al entrante. En los últimos años se ha establecido como una de las técnicas más usadas para modelos con aprendizaje profundo, debido a que no existe tanta saturación y su fácil implementación computacional en comparación a otras funciones.[41]
- **Agrupación:** es una capa en la cual se reduce el tamaño los datos sin perder información primordial, es usada usualmente en el procesamiento de imágenes, lo cual hace que el modelo de entrenamiento sea mucho más eficiente.[42]

### **Clasificación de Capas**

- **Capas de entrada:** la capa de inicio, por donde se ingresan los datos y los nodos de entrada realizan el procesamiento de la información, realizan el análisis y proceden a clasificar los datos.[32]
- **Capas ocultas:** se encuentra entre la capa de entrada y la de salida, el número de capas puede variar, puede ser una o varias capas en las que se encuentran neuronas interconectadas entre sí.[43]

- Capas de salida: es la capa final, donde se refleja el resultado del entrenamiento del modelo neuronal, existen dos casos, donde el resultado es binario (donde la solución se asemeja a un sí o no) o multiclase (donde el resultado tiene distintas soluciones).[44]

### ***C. Variables de Estudio***

Las variables son usadas para identificar características o elementos [45] esto a su vez permite observar cambios, analizar, medir y permite controlar la variable durante el proceso de investigación.[46]

### ***D. Definición nominal de las variables***

Entendemos que una variable nominal nos ayuda a identificar y a entender una variante en términos generales en el caso de este proyecto logramos identificar 5 variables las cuales se clasifican en variables independientes y variables dependientes.[47]

#### ***1) Variables Independientes:***

Es aquella que no se ve afectada por ninguna otra variable, sin embargo, si una variable independiente cambia automáticamente también lo hace la variable dependiente [48].

- Conjunto de Datos: Es una colección estructurada de información que se utiliza para entrenar, validar o evaluar modelos de aprendizaje automático, conteniendo ejemplos representativos del problema que el modelo busca resolver, como imágenes, texto, audio o datos tabulares.
- Filtros: Son técnicas o procesos aplicados a los datos para seleccionar, transformar o eliminar información irrelevante, ruido o inconsistencias, con el objetivo de mejorar la calidad de los datos y optimizar el rendimiento del modelo.
- Algoritmos: Son conjuntos de instrucciones o reglas matemáticas diseñadas para que un modelo procese datos, aprenda patrones y tome decisiones o predicciones de manera automatizada y eficiente.

## 2) *Variables Dependientes:*

- Métricas: Se evaluará el tiempo entrenamiento y tiempo predicción del modelo usando estas métricas Accuracy, Precisión, Recall
- Eficiencia: Se consideran aspectos como el tiempo de entrenamiento y el tiempo de predicción.

### *E. Definición Operativa De Variables*

Una vez identificamos las variables vamos a descomponer el concepto generalizado de nuestras variables esto nos permitirá identificar y analizar de mejor manera las variables usadas y con los resultados, obtendremos una delimitación para llevar a cabo el cumplimiento de los objetivos propuestos.[45]

#### *1) Variables Independientes:*

Conjunto de Datos: Se utilizará un dataset llamado ADHD-200, que almacena imágenes de resonancia magnética funcionales, será transformaciones especiales de rotación y traslación, que buscará analizar el impacto en los resultados en el entrenamiento del modelo.

Filtros: Se busca comparar las configuraciones con o sin Smith evaluando la influencia en su rendimiento

Algoritmos: se usarán para el análisis de los datos, como las redes neuronales convolucionales CNN3D y redes recurrentes LSTM3D examinar como influyen a la clasificación y precisión.

#### *2) Variables Dependientes:*

Accuracy (Precisión global del modelo), esta métrica determinará la correcta clasificación de clases positivas como las negativas, esto representa el porcentaje de predicciones correctas mediante verdadero positivos y verdaderos negativos.

*Ecuación 1. ACCURACY*

$$Accuracy = \frac{(TP+TN)}{(TP+FP+TN+FN)} \dots\dots\dots (1)$$

Precisión (Proporción de verdadero positivos entre las predicciones positivas), el propósito es medir los casos del modelo que son realmente positivos, se centran en verdadero positivos.

*Ecuación 2. PRECISION*

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots (2)$$

Recall (proporción de verdaderos positivos entre todos los positivos reales), proporciona la cantidad de casos positivos que han sido correctamente clasificados por el modelo.

*Ecuación 3. RECALL*

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots (3)$$

TP = Verdaderos positivos: Son casos reales que el modelo clasifica como correctamente positivos

TN = Verdaderos negativos: Son casos negativos reales que el modelo ha clasificado correctamente negativos.

FP = Falsos positivos Son casis negativos reales que el modelo ha clasificado incorrectamente positivos.

FN = Falsos negativos: Son casos positivos reales que el modelo ha clasificado incorrectamente como negativos [49]

***F. Formulación de hipótesis***

***1) Hipótesis de investigación***

Las CNN3D y LSTM3D mejoran la eficiencia en el apoyo al diagnóstico médico de TDAH con IRMF comparado con las CNN2D, LSTM, combinaciones de ambas y algoritmos de Machine learning tradicionales.

***2) Hipótesis nula***

Las CNN3D y LSTM3D no mejoran la eficiencia en el apoyo al diagnóstico médico de TDAH con IRMF comparado con las CNN y algoritmos de Machine learning tradicionales.

### 3) *Hipótesis alterna*

Las CNN3D y LSTM3D permiten la identificación de patrones en las imágenes de IRMF que podrían ser aplicables a otros trastornos neurológicos o psicológicos, abriendo nuevas posibilidades para su uso en la investigación clínica más allá del TDAH.

### **III. METODOLOGÍA**

#### ***A. Paradigma***

El presente proyecto tuvo un enfoque positivista debido a que se ajustó muy bien a las características realistas y precisas que correspondían a los objetivos que componen a esta investigación.

El positivismo se determinó como una herramienta metodológica que afirmaba que la verdad era absoluta y medible, donde los resultados que se consideraban acertados o verídicos eran los únicos que tienen el derecho de ser medibles y no existían puntos medios. [50]

El paradigma positivista y su enfoque cuantitativo permitieron a la investigación medir el margen de acierto en el apoyo al diagnóstico del trastorno de déficit de atención e hiperactividad (TDAH) y optimizar el procedimiento de su diagnóstico.

#### ***B. Enfoque***

El presente proyecto de investigación se basó en el enfoque metodológico cuantitativo, ya que se ajustó más a las necesidades y características de este trabajo.

El enfoque cuantitativo se consideró como una característica metodológica del positivismo, por medio de la cual se catalogó a una investigación encaminada a la búsqueda de resultados cuantificables, medibles y estadísticos. [51]

Un enfoque cuantitativo fue ideal para la presente investigación, ya que se pretendió realizar la comparación y evaluación de los datos obtenidos por el modelo de entrenamiento y reflejados en matrices.

#### ***C. Método***

En la presente investigación, se llevaron a cabo tanto la metodología experimental como la metodología KDD (Knowledge Discovery in Databases), ya que los algoritmos de aprendizaje automático, en este caso, el entrenamiento de datos con redes neuronales convolucionales (CNN) 3D y redes recurrentes LSTM3D, se acoplaron mucho más a este proyecto.

El método experimental consistió en investigar, indagar y observar ciertos patrones o características de algún grupo de personas, objetos o datos, con el fin de recolectar información y ejercer algún tipo de acción y posteriormente llevar cierto tipo de registro que reflejara dicha acción actuó sobre esa población o ese conjunto de datos e información. [52]

El KDD (Knowledge Discovery in Databases) fue una metodología utilizada para el proceso de entrenamiento de datos que, en los últimos años, ha aumentado su relevancia debido al crecimiento del volumen de la información. Se catalogó como un proceso de varias etapas para identificar características importantes de la información. [53]

El método experimental y KDD, aportaron significativamente al desarrollo de la investigación, ya que se utilizó un gran volumen de datos los cuales sirvió como material de entrenamiento para un modelo capaz de identificar ciertos patrones dentro de dichos datos, en este caso, de las imágenes de resonancia magnética funcionales (IRMF).

#### ***D. Tipo de Investigación***

En el presente proyecto, se llevó a cabo una investigación descriptiva, ya que se ajustó a los resultados esperados y metodologías empleadas en esta investigación.

La investigación descriptiva fue una técnica metodológica utilizada para describir e interpretar las características de un entorno y comprender sus funcionalidades. [57]

En el siguiente proyecto, la investigación descriptiva resultó ideal, ya que se buscó obtener métricas con altos niveles de exactitud frente a la variable de precisión, exactitud, tiempo de entrenamiento de los datos y el tiempo de predicción.

#### ***E. Diseño de Investigación***

Durante la investigación se tomó en cuenta el diseño cuasi-experimental ya que se adaptó mejor a las características del proyecto en comparación a otros tipos de diseños investigativos.

“El diseño cuasi-experimental es una forma metodológica de encontrar la relación entre dos o más variables de estudio. Es muy similar a la experimental, pero en este tipo no se tiene un control absoluto de las variables de estudio” [58]

A lo largo de la investigación se requirió de un diseño cuasi-experimental ya que se planeó la realización de distintas pruebas con las diferentes variables de estudio como los conjuntos de datos,

las métricas, los filtros y algoritmos para medir la eficacia del modelo y obtener resultados importantes como el tiempo de entreno y tiempo de predicción, mediante la técnica de entrenamiento basado en redes neuronales convolucionales CNN 3D y redes recurrentes LSTM3D.

#### ***F. Población***

Normalmente, se entiende a la población como un grupo de personas en específico con características similares, las cuales sirven como modelo de estudio para llevar a cabo una investigación, sin embargo, en el proyecto desarrollado, al haber tomado enfoques teóricos y matemáticos respecto a la búsqueda de la funcionalidad y eficacia de un modelo de entrenamiento basado en redes neuronales convolucionales (CNN) y recurrentes, no fue necesario contar con una población ni una muestra. Al haber sido un trabajo investigativo que tuvo como base fundamental un grupo de datos, se empleó la prueba de redes convolucionales CNN 3D y redes recurrentes LSTM3D frente a un gran conjunto de datos, en este caso, imágenes de resonancia magnética funcionales (IRMF), las cuales se obtuvieron del repositorio ADHD-200.

#### ***G. Técnicas de recolección de la información***

El estudio realizado, al haber estado inmerso en el marco de Data Driven Approach (análisis y toma de decisiones basada en datos)[59], requirió de la técnica de “Datos secundarios”, debido a que resultó idónea para la recolección de información respecto con la extracción de imágenes de resonancia magnética funcionales (IRMF) del dataset ADHD-200, conjunto de datos que había sido previamente validado de forma científica. Esta metodología permitió llevar a cabo un trabajo investigativo eficiente, tanto en el proceso como en el tiempo destinado a la recolección de la información.

**ADHD-200:** constituyó la primera herramienta empleada para la obtención de información. Fue el dataset donde se encontraron los datos necesarios para realizar el entrenamiento del modelo.

Se trató de un conjunto de datos de acceso público, conformado por 40 imágenes de resonancia magnética funcional (IRMF), en las cuales cada imagen correspondía a un video tridimensional

(3D). Esto significó que cada voxel estuvo compuesto por tres dimensiones espaciales más una dimensión temporal.

Las dimensiones específicas fueron (61, 73, 61, 176), donde cada voxel representó el volumen del tejido cerebral del paciente. El voxel se definió como una unidad tridimensional dentro de la imagen, compuesta por tres ejes: dos correspondientes al área (píxeles) y un tercero al grosor del corte, además de incluir 176 marcas de tiempo.

El dataset ADHD-200 se obtuvo mediante la plataforma NITRC (Colaboratorio de Herramientas y Recursos de Neuroimagen), y estuvo conformado por un conjunto de datos de resonancias magnéticas funcionales en estado de reposo y datos anatómicos recopilados y extraídos de distintos centros de investigación[5]

#### ***H. Validez de la técnica***

Se garantizo mediante

- Uso de un base estándar y valida “ADHD-200”.
- Protocolos de preprocesamiento, donde se incluyeron transformaciones en cada uno de los frames que compone a las imágenes de resonancia magnética funcional, basados en las documentaciones de la literatura como la documentación oficial tensorflow y pedregosa.
- Métricas objetivas y pruebas estadísticas para comprar configuraciones.

#### ***I. Confiabilidad de la técnica***

- Replicación de scrips versionados en Git .
- Ejecución en entornos como Google Colab y Google Colab Pro configurados de formas diferentes.
- Se realizó separación de los datos en entrenamiento, prueba y validación.

#### ***J. Instrumento de recolección de datos***

- Base de datos ADHD-200.
- Software: Python, TensorFlow, Keras, PyTorch,
- Hardware: Colab con GPU, RAM se sistema 12.7GB y Disco 101.7GB y Colab Pro con GPU A100, RAM se sistema 83.5GB, RAM de GPU 40.0 GB y Disco 112.6 GB.

### ***K. Desarrollo metodológico según los objetivos de investigación***

El desarrollo metodológico de la presente investigación se elaboró en base a los objetivos planteados, garantizando la ejecución oportuna de la propuesta investigativa.

En relación con el primer objetivo específico, se consolidó un dataset de imágenes de resonancia magnética funcionales (IRMF), previamente etiquetadas, haciendo uso del repositorio público ADHD-200 como fuente principal de datos. Este dataset fue sometido a técnicas de preprocesamiento y transformación, de las cuales estuvieron incluidas: rotación, traslación y escalado. Permitiendo así que el tamaño del dataset aumente y generando que los modelos a entrenar tengan mayor capacidad de recolección y tratamiento de los datos.

Para el segundo objetivo específico, se diseñó y ejecutó un marco experimental compuesto por dos modelos: la primera que se centra en las CNN 3D y la segunda en las LSTM3D. Cada arquitectura fue entrenada bajo la metodología KDD y cuasi-experimental, aplicando técnicas de partición de datos en conjuntos de entrenamiento, validación y prueba. En cada uno de los métodos elaborados se experimentó con parámetros tales como el batch size, la tasa de aprendizaje y el número de épocas mediante estrategias de early stopping la cual consiste en detener el proceso de entrenamiento cuando el modelo ya no aprende eficientemente y así optimizar recursos. Este marco permitió la comparación sistemática del rendimiento de las arquitecturas en términos de precisión, estabilidad y capacidad de generalización.

Finalmente, para el tercer objetivo específico, se recolectó un conjunto de métricas las cuales fueron producto del proceso de entrenamiento de los modelos. Estas métricas fueron utilizadas para evaluar la eficiencia de cada modelo e identificar que tan eficientes fueron los procesos empleados en cada uno de los modelos, en base a la relación con cada una de las hipótesis de investigación. De este modo, la metodología implementada brindó fundamentos para lograr interpretaciones de los resultados obtenidos y la verificación de las hipótesis formuladas.

## IV. RESULTADOS DE LA INVESTIGACIÓN

### A. Consolidación Del Conjunto De Datos

El proceso de consolidación de datos tuvo como propósito el garantizar la adecuación necesaria de las imágenes empleadas para cada uno de los modelos de entrenamiento.

#### 1) Selección de datos:

Para la investigación se usó el dataset ADHD-200, conformada por 947 conjuntos de imágenes de resonancia magnética funcional (IRMF), de los cuales 362 corresponden a sujetos diagnosticados con TDAH y 585 a pacientes sano.

Como primer paso se preparó el entorno de trabajo, dentro de este proceso se incluyeron fases como la instalación e importación de librerías las cuales fueron necesarias para el debido manejo de datos durante la elaboración de cada uno de los modelos de entrenamiento, como se muestra en la Figura 1, donde se evidencia la instalación de las dependencias requeridas para el proceso de adquisición.

```
!pip install nilearn
from nilearn import datasets
import shutil #Se importa para manejar archivos
shutil.rmtree('/root/nilearn_data/adhd', ignore_errors=True) # Borra el dataset corrupto

# Ahora intenta descargar nuevamente
adhd_data = datasets.fetch_adhd(n_subjects=100)
```

Fig. 1 Configuración del entorno e instalación de librerías requeridas para la descarga del dataset ADHD-200.

Posteriormente, se llevó a cabo la descarga del dataset. Este procedimiento aseguró la obtención de un conjunto de datos completo y funcional, tal como se observa en la Figura 2, donde se presenta el registro exitoso de la descarga de las imágenes IRMF.

```
Installing collected packages: nilearn
Successfully installed nilearn-0.11.1
[add_readme_to_default_data_locations] Added README.md to /root/nilearn_data
[get_dataset_dir] Dataset created in /root/nilearn_data/adhd
/usr/local/lib/python3.11/dist-packages/nilearn/datasets/func.py:311: UserWarning: Warning: there are only 40 subjects
  warnings.warn(f"Warning: there are only {max_subjects} subjects")
[fetch_single_file] Downloading data from https://www.nitrc.org/frs/download.php/7783/adhd40_metadata.tgz ...
[fetch_single_file] ...done. (0 seconds, 0 min)

[uncompress_file] Extracting data from
/root/nilearn_data/adhd/70e750a7f0032a8c913a00e1d04e059/adhd40_metadata.tgz...
[uncompress_file] .. done.

[fetch_single_file] Downloading data from https://www.nitrc.org/frs/download.php/7782/adhd40_0010042.tgz ...
[_chunk_report_] Downloaded 19743098 of 44414948 bytes (43.7%%, 1.3s remaining)
[fetch_single_file] ...done. (2 seconds, 0 min)

[uncompress_file] Extracting data from
/root/nilearn_data/adhd/49718167d03b032094ad6d17e64b4e49/adhd40_0010042.tgz...
[uncompress_file] .. done.

[fetch_single_file] Downloading data from https://www.nitrc.org/frs/download.php/7784/adhd40_0010064.tgz ...
[_chunk_report_] Downloaded 28557312 of 45583539 bytes (62.6%%, 0.6s remaining)
[fetch_single_file] ...done. (2 seconds, 0 min)

[uncompress_file] Extracting data from
/root/nilearn_data/adhd/49718167d03b032094ad6d17e64b4e49/adhd40_0010064.tgz...
[uncompress_file] .. done.

[fetch_single_file] Downloading data from https://www.nitrc.org/frs/download.php/7785/adhd40_0010128.tgz ...
[_chunk_report_] Downloaded 28721152 of 45461055 bytes (63.2%%, 0.6s remaining)
[fetch_single_file] ...done. (2 seconds, 0 min)

[uncompress_file] Extracting data from
/root/nilearn_data/adhd/49718167d03b032094ad6d17e64b4e49/adhd40_0010128.tgz...
[uncompress_file] .. done.
```

Fig. 2. Evidencia de la descarga validada del conjunto de datos ADHD-200.

## 2) Exploración de datos:

Una vez descargado el conjunto de datos, se revisaron las imágenes IRMF, con el objetivo de detectar anomalías, o distorsiones que pudieran afectar el análisis. Este proceso permitió verificar cada elemento, sus volúmenes y descartar imágenes corruptas o vacías. En la Figura 3 se muestran ejemplos de cortes cerebrales en los planos axial, coronal y sagital, donde se confirma la uniformidad estructural de las imágenes procesadas.




Fig. 3. Ejemplos de cortes cerebrales en planos axial, coronal y sagital de las imágenes IRMF seleccionadas.

Durante esta exploración de los elementos, también se evaluó la correcta asignación de las etiquetas, validando que las imágenes estuvieran categorizadas adecuadamente entre los grupos TDAH y control. Esta verificación se realizó sobre una base de tabulación basada en metadatos,

como se evidencia en la Figura 4, donde la columna adhd representa a los casos positivos tomando el valor de "1" y los negativos tomando el valor de "0".

Unnamed: 0	Subject	Rest.Scan	sex	tdc	adhd	l_inatten
1	2014113	rest_1	M	0	1	
2	3902469	rest_1	M	1	0	
3	4275075	rest_1	F	0	1	
4	7774305	rest_1	F	1	0	
5	1019436	rest_1	M	0	1	
6	3699991	rest_1	M	1	0	
7	3154996	rest_1	M	0	1	
8	3884955	rest_1	M	1	0	
10	4134561	rest_1	M	1	0	
12	6115230	rest_1	M	1	0	
14	8409791	rest_1	M	1	0	
16	3007585	rest_1	M	1	0	
17	8697774	rest_1	M	0	1	0
18	9750701	rest_1	M	1	0	0
23	2497695	rest_1	M	0	1	0
24	4164316	rest_1	M	1	0	0
25	1552181	rest_1	F	0	1	
26	4046678	rest_1	F	1	0	
28	1679142	rest_1	M	1	0	
29	1206380	rest_1	M	0	1	
31	4016887	rest_1	M	0	1	
32	1418396	rest_1	M	1	0	
33	2950754	rest_1	M	0	1	0
34	3994098	rest_1	M	1	0	0
35	3520880	rest_1	M	0	1	29

Fig. 4. Validación de las etiquetas diagnósticas (TDAH y control) en el dataset depurado ADHD-200.

Finalmente, se revisaron las dimensiones espaciales de cada imagen para garantizar la uniformidad del conjunto de datos antes del preprocesamiento. Los resultados de esta revisión se muestran en la Figura 5, que indican un fragmento de la tabla con las dimensiones finales del dataset normalizado.

1	Sujeto	Archivo	Ruta	Dimensiones	Num_Volumenes
2	1	0010042_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0010042/	(61, 73, 61, 176)	176
3	2	0010064_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0010064/	(61, 73, 61, 176)	176
4	3	0010128_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0010128/	(61, 73, 61, 176)	176
5	4	0021019_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0021019/	(61, 73, 61, 175)	175
6	5	0023008_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0023008/	(61, 73, 61, 77)	77
7	6	0023012_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0023012/	(61, 73, 61, 77)	77
8	7	0027011_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0027011/	(61, 73, 61, 261)	261
9	8	0027018_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0027018/	(61, 73, 61, 260)	260
10	9	0027034_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0027034/	(61, 73, 61, 260)	260
11	10	0027037_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/0027037/	(61, 73, 61, 261)	261
12	11	1019436_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/1019436/	(61, 73, 61, 152)	152
13	12	1206380_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/1206380/	(61, 73, 61, 78)	78
14	13	1418396_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/1418396/	(61, 73, 61, 78)	78
15	14	1517058_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/1517058/	(61, 73, 61, 235)	235
16	15	1552181_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/1552181/	(61, 73, 61, 78)	78
17	16	1562298_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/1562298/	(61, 73, 61, 236)	236
18	17	1679142_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/1679142/	(61, 73, 61, 78)	78
19	18	2014113_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/2014113/	(61, 73, 61, 124)	124
20	19	2497695_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/2497695/	(61, 73, 61, 176)	176
21	20	2950754_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/2950754/	(61, 73, 61, 236)	236
22	21	3007585_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/3007585/	(61, 73, 61, 261)	261
23	22	3154996_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/3154996/	(61, 73, 61, 124)	124
24	23	3205761_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/3205761/	(61, 73, 61, 236)	236
25	24	3520880_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/3520880/	(61, 73, 61, 235)	235
26	25	3624598_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/3624598/	(61, 73, 61, 236)	236
27	26	3699991_rest_tshift_RPI_voreg_mni.nii.gz	/root/nilearn_data/adhd/data/3699991/	(61, 73, 61, 152)	152

Fig. 5. Homogeneidad estructural y dimensiones finales de las imágenes IRMF seleccionadas.

Por último, fue analizada la cantidad de datos con su respectiva etiqueta, esto con el fin de ver cuantas imágenes había con la etiqueta respectiva (TDAH , NO\_TDAH), como se mencionó anteriormente no se pudo ver el balance correcto de los datos porque estaban mezclados.

### B. Construcción Marco Experimental

Esta etapa concretó el conjunto de procedimientos necesarios para entrenar y validar cada uno de los modelos. Se estableció un modelo de trabajo estructurado que incluyó el preprocesamiento, la transformación y conversión de las imágenes IRMF, la división de los datos y el diseño de las arquitecturas CNN3D y LSTM3D.

El propósito de este marco fue garantizar la preparación óptima de los datos y la configuración eficiente de los modelos, asegurando resultados alineados con los objetivos de la investigación sobre el apoyo al diagnóstico del TDAH.

### 1) Preprocesar dataset:

En esta etapa se organizó el conjunto de imágenes de resonancia magnética funcional (IRMF), clasificándolas según sus etiquetas correspondientes de TDAH y Control. Este proceso permitió estructurar el dataset de forma ordenada facilitando su posterior procesamiento y análisis, como se muestra en la Figura 6.

```
Total de imágenes: 40
Imágenes TDAH: 20
Imágenes Control: 20

Lista guardada en: /content/drive/MyDrive/Google AI Studio/etiquetas_imagenes.csv

Ejemplos de imágenes TDAH:
Nombre_Archivo \
0 0010042_rest_tshift_RPI_voreg_mni.nii.gz
1 0010064_rest_tshift_RPI_voreg_mni.nii.gz
5 0023012_rest_tshift_RPI_voreg_mni.nii.gz
6 0027011_rest_tshift_RPI_voreg_mni.nii.gz
7 0027018_rest_tshift_RPI_voreg_mni.nii.gz

Ruta_Completa Etiqueta Grupo
0 /root/nilearn_data/adhd/data/0010042/0010042_r... 1 TDAH
1 /root/nilearn_data/adhd/data/0010064/0010064_r... 1 TDAH
5 /root/nilearn_data/adhd/data/0023012/0023012_r... 1 TDAH
6 /root/nilearn_data/adhd/data/0027011/0027011_r... 1 TDAH
7 /root/nilearn_data/adhd/data/0027018/0027018_r... 1 TDAH

Ejemplos de imágenes Control:
Nombre_Archivo \
2 0010128_rest_tshift_RPI_voreg_mni.nii.gz
3 0021019_rest_tshift_RPI_voreg_mni.nii.gz
4 0023008_rest_tshift_RPI_voreg_mni.nii.gz
12 1418396_rest_tshift_RPI_voreg_mni.nii.gz
13 1517058_rest_tshift_RPI_voreg_mni.nii.gz

Ruta_Completa Etiqueta Grupo
2 /root/nilearn_data/adhd/data/0010128/0010128_r... 0 Control
3 /root/nilearn_data/adhd/data/0021019/0021019_r... 0 Control
4 /root/nilearn_data/adhd/data/0023008/0023008_r... 0 Control
12 /root/nilearn_data/adhd/data/1418396/1418396_r... 0 Control
13 /root/nilearn_data/adhd/data/1517058/1517058_r... 0 Control
```

Fig. 6. Ejemplo del conjunto de datos inicial de imágenes de IRMF, mostrando la organización de archivos y etiquetas correspondientes a los grupos TDAH y Control.


En este punto, se consolidó la estructura final del conjunto de datos, conformada por carpetas independientes que agrupan las imágenes de los pacientes diagnosticados con TDAH y aquellos que pertenecen al de control. Esta organización permitió garantizar la trazabilidad, el balance y la correcta asignación de etiquetas, facilitando el acceso y procesamiento posterior de los datos, como se muestra en la Figura 7.



Fig. 7. Estructura de carpetas utilizadas para clasificar las imágenes según el grupo: TDAH y No\_Tiene\_TDAH.

## 2) *Transformar dataset:*

El conjunto de datos inicial estuvo compuesto por 40 imágenes de resonancia magnética funcionales IRMF organizadas en carpetas específicas y con nombres únicos para asegurar su trazabilidad dentro del repositorio del proyecto. A cada imagen se le aplicaron tres técnicas principales de transformación: rotación, traslación y escalado, con el propósito de incrementar el tamaño del dataset y mejorar el rendimiento del modelo, como se muestra en la Figura 8.



*Fig. 8. Ejemplo de imágenes de resonancia magnética funcional (IRMf) tras aplicar técnicas de transformación: rotación, traslación y escalado.*

Como se mencionó anteriormente, con el propósito de incrementar el número de elementos del dataset, se generaron tres variaciones por cada técnica de transformación, obteniendo así nueve subimágenes derivadas de cada volumen principal. Este proceso denominado "data augmentation" permitió ampliar significativamente la base de datos, pasando de 40 a 526 imágenes de resonancia magnética funcionales IRMF. La Figura 9 ilustra el resultado del proceso de apaleamiento del dataset y la variedad estructural alcanzada tras la aplicación de las transformaciones.




Fig. 9. Resultado del proceso de data augmentation, mostrando la organización de las imágenes transformadas dentro del repositorio del proyecto.

### Conversión a formato compatible con CNN:

En esta fase se realizó la conversión de las imágenes de resonancia magnética funcional (IRMf) al formato .nii/.nii.gz, permitiendo su interpretación por las arquitecturas CNN3D y LSTM3D implementadas en el proyecto. Posteriormente, cada elemento fue transformado en estructuras de datos NumPy (.npy), optimizadas para su procesamiento en entornos de deep learning.

Este procedimiento fue esencial, ya que aunque las imágenes originales poseen un formato estándar en neuroimagen, no resultan óptimas para entrenamientos de modelos profundos debido a las operaciones de lectura que incrementan el costo computacional. El formato .npy resolvió esta limitación al ofrecer:

- Almacenamiento directo en estructuras matriciales, representando los vóxeles como tensores multidimensionales.
- Acceso rápido y eficiente, reduciendo significativamente los tiempos de carga y procesamiento.
- Compatibilidad nativa con frameworks de deep learning como TensorFlow y PyTorch, garantizando un flujo de trabajo continuo y reproducible.

En el marco del procesamiento de imágenes IRMF mediante técnicas de Deep learning, se llevó a cabo la instalación de las librerías necesarias para el desarrollo del proyecto. A través del gestor de paquetes pip, se integraron nibabel, la cual fue la encargada de la lectura y manipulación de archivos en formato NIfTI (.nii o .nii.gz), y NumPy, fundamental para el manejo de estructuras que componían al conjunto de datos. Además, se incluyeron de forma opcional las librerías Torch y TensorFlow, orientadas al posterior entrenamiento de los modelos.

La configuración de este entorno, ilustrada en la Figura 10, aseguró la compatibilidad del sistema y un rendimiento óptimo durante las etapas de carga y preprocesamiento de los conjuntos de datos.

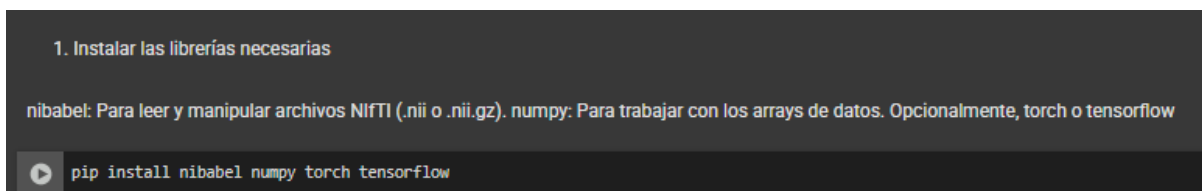


Fig. 10. Instalación de librerías y configuración del entorno de desarrollo para el procesamiento de imágenes IRMF.

Durante el desarrollo del proyecto, enfocado en analizar imágenes de resonancia magnética funcional (IRMF) para apoyar el diagnóstico del TDAH, se creó el primer script encargado de cargar y convertir los archivos en formato NIfTI (.nii). En esta parte del trabajo se importaron varias librerías necesarias para manejar y procesar los datos, entre ellas os, usada para gestionar archivos del sistema; nibabel, para trabajar con volúmenes de neuroimagen; NumPy, que facilita el manejo de arreglos de datos; glob, para localizar archivos dentro de carpetas; y la función zoom del módulo SciPy, que se utilizó para normalizar las imágenes y mantenerlas en una escala uniforme.

Como se muestra en la Figura 11, el entorno de trabajo se configuró en Google Colab usando la función `drive.mount('/content/drive')`, lo que permitió acceder directamente a los archivos almacenados en Google Drive. Luego se organizaron las carpetas principales para cada grupo de estudio: `tdah_dir`, con los casos diagnosticados con TDAH, y `control_dir`, con las imágenes de los sujetos sanos. Finalmente, se crearon listas para guardar los volúmenes y las etiquetas correspondientes, asegurando que los datos se cargaran de forma ordenada y continua durante todo el proceso de preprocesamiento.

## 2. Script para cargar y convertir imágenes .nii

```
import os
import nibabel as nib
import numpy as np
from glob import glob
from scipy.ndimage import zoom

# Montar Google Drive
# from google.colab import drive
# drive.mount('/content/drive')

# Directorios principales
tdah_dir = "/content/drive/MyDrive/Descarga_BD/adhd/data/TDAH"
no_tdah_dir = "/content/drive/MyDrive/Descarga_BD/adhd/data/TDAH"

# Listas para almacenar imágenes y etiquetas
images = []
labels = []
```

Fig. 11. Script inicial para la carga y conversión de archivos NIfTI (.nii) en el entorno Google Colab, mostrando la configuración de directorios y listas para almacenamiento de imágenes y etiquetas.

Después de esta fase, se desarrolló una función llamada `load_images_from_subfolder`, la cual tuvo como fin facilitar la importación y conversión de archivos NIfTI (.nii y .nii.gz) que se encontraban en diferentes subdirectorios del conjunto de datos. Esta función ayudó a mantener un procedimiento más organizado y consistente en la lectura de las imágenes, garantizando que todas siguieran los mismos pasos de transformación y normalización.

Como se ilustra en la Figura 12, la función empleó la biblioteca “glob” para localizar los archivos de origen y utilizó “nibabel” para leerlos de forma adecuada. Posteriormente, los datos fueron transformados al tipo `float32` para simplificar su procesamiento numérico. Además, el procedimiento incluyó verificaciones de tamaño, modificaciones en las dimensiones mediante la función `resize_image`, y una normalización con “normalize\_image”, todo organizado de tal manera para prevenir errores y mantener la estabilidad en el proceso.

Con este sistema, se logró establecer un sistema óptimo para la preparación de los volúmenes de las imágenes IRMF, que funcionó como un pilar fundamental entre la recolección de datos y la fase de entrenamiento de los modelos de aprendizaje profundo.

```

# Función para cargar imágenes .nii y .nii.gz de una subcarpeta y sus transformaciones
def load_images_from_subfolder(subfolder_path, label):
    count = 0
    # Buscar archivos .nii y .nii.gz originales
    original_files = glob(os.path.join(subfolder_path, "*.nii*"))
    print(f"Archivos originales encontrados en {subfolder_path}: {original_files}")
    for file in original_files:
        try:
            img = nib.load(file)
            img_data = img.get_fdata().astype(np.float32)
            print(f"Imagen original cargada: {file}, forma: {img_data.shape}")
            # Reducir a 3D si es necesario (descomenta si usas CNN3D)
            # img_data = reduce_to_3d(img_data)
            # Redimensionar si es necesario
            if img_data.shape != target_shape:
                img_data = resize_image(img_data, target_shape)
            # Normalizar
            img_data = normalize_image(img_data)
            images.append(img_data)
            labels.append(label)
            count += 1
        except Exception as e:
            print(f"Error al cargar imagen original {file}: {e}")

```

Fig. 12. Función para la carga y normalización de volúmenes NIfTI, incluyendo la lectura, redimensionamiento y estandarización de imágenes mediante las librerías NiBabel y NumPy.

Una vez concluida la fase anterior, se finalizó la gestión de los archivos que contenían los datos de ambos conjuntos de estudio. Para ello, se utilizó la herramienta `process_main_folder` sobre las carpetas “`tdah_dir`” y “`no_tdah_dir`”. Dicha herramienta exploró cada carpeta interna, verificó los ficheros existentes y contó cuántas unidades se gestionaron en cada grupo. Así, se guardaron los valores de `tdah_subfolder_count` para las personas diagnosticadas con TDAH y `no_tdah_subfolder_count` para el grupo control.

Como se aprecia en la Figura 13, esta etapa mejoró la estructura de los datos, dando una visión más precisa del número de imágenes de IRMF empleadas. Finalmente, las listas creadas se cambiaron a matrices usando NumPy, con las funciones `np.array(images)` y `np.array(labels)`. Esto ayudó a gestionar los datos de manera más organizada y eficiente, facilitando a su vez las operaciones numéricas necesarias para el entrenamiento de los modelos de aprendizaje profundo.

```

# Procesar ambas carpetas
tdah_subfolder_count = process_main_folder(tdah_dir, label=1)
no_tdah_subfolder_count = process_main_folder(no_tdah_dir, label=0)

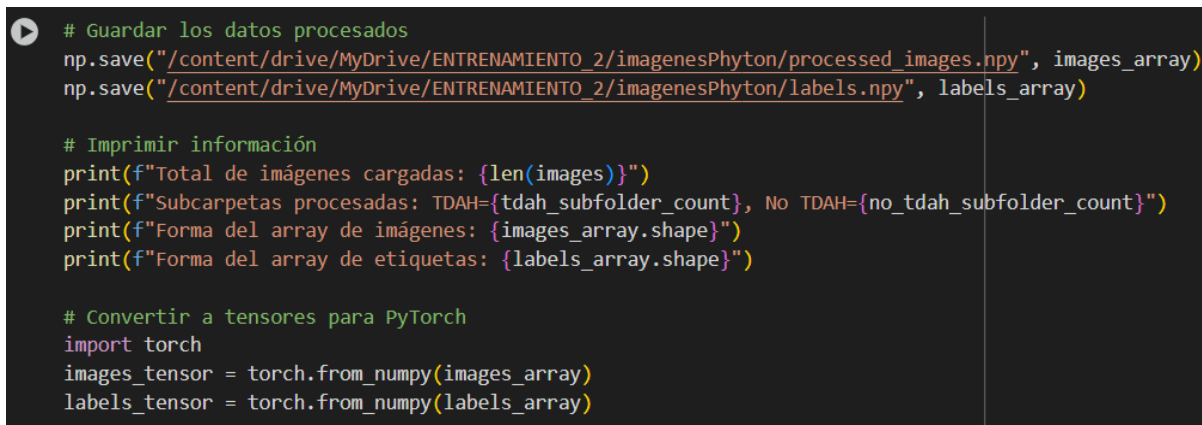
# Convertir listas a arrays de NumPy
images_array = np.array(images)
labels_array = np.array(labels)

```

Fig. 13. Fragmento de código para el procesamiento y conversión de volúmenes en arrays multidimensionales de NumPy, consolidando la recopilación y conteo estructurado de los datos IRMF.

A continuación, se almacenaron todos los datos utilizando la función `np. save`, lo cual facilitó guardar tanto el conjunto de imágenes como el de etiquetas en las ubicaciones adecuadas en Google Drive. En este caso, las fotografías se registraron en `/content/drive/MyDrive/ENTRENAMIENTO_2/imagenesPython/processed_images.npy` y las etiquetas en `/content/drive/MyDrive/ENTRENAMIENTO_2/imagenesPython/labels.npy`. De este modo, los datos fueron organizados de manera que se podían reutilizar fácilmente en el futuro sin la necesidad de realizar un nuevo procesamiento desde el principio.

Como se ve en la Figura 14, se comprobó que el almacenamiento se había realizado correctamente, imprimiendo el total de imágenes que fueron cargadas, la cantidad de subcarpetas procesadas para los grupos TDAH y No TDAH, así como las dimensiones finales de los arreglos mediante la función `.shape`. Finalmente, los arrays de NumPy fueron convertidos en tensores de PyTorch usando `torch. from_numpy`, lo que dio lugar a `images_tensor` y `labels_tensor`. Este paso fue crucial, ya que garantizó que los datos estuvieran listos y totalmente compatibles para ser utilizados en el entrenamiento de los modelos de aprendizaje profundo.



```
# Guardar los datos procesados
np.save("/content/drive/MyDrive/ENTRENAMIENTO_2/imagenesPhyton/processed_images.npy", images_array)
np.save("/content/drive/MyDrive/ENTRENAMIENTO_2/imagenesPhyton/labels.npy", labels_array)

# Imprimir información
print(f"Total de imágenes cargadas: {len(images)}")
print(f"Subcarpetas procesadas: TDAH={tdah_subfolder_count}, No TDAH={no_tdah_subfolder_count}")
print(f"Forma del array de imágenes: {images_array.shape}")
print(f"Forma del array de etiquetas: {labels_array.shape}")

# Convertir a tensores para PyTorch
import torch
images_tensor = torch.from_numpy(images_array)
labels_tensor = torch.from_numpy(labels_array)
```

Fig. 14. Script para el guardado de los datos procesados en formato NumPy (.npy) y conversión de los arrays en tensores de PyTorch, garantizando la compatibilidad con modelos de aprendizaje profundo.

Después de terminar la carga y el preprocesamiento de todas las imágenes, se realizó una última verificación para asegurar de que todo el proceso se hubiera ejecutado correctamente. En esta parte se imprimieron algunas métricas importantes que confirmaron la correcta recopilación de 526 imágenes IRMF, distribuidas de manera equilibrada entre los dos grupos: 20 subcarpetas para los casos con TDAH y 20 subcarpetas para el grupo control. Esto permitió comprobar que los datos estaban bien organizados y balanceados antes de continuar con la siguiente etapa.

Como se muestra en la Figura 15, se revisó también la forma de los arreglos generados. En el caso de las imágenes, el array tenía una forma de (526, 64, 64, 64, 10), lo que corresponde a los volúmenes estandarizados en cuatro dimensiones espaciales más un canal adicional. Por su parte, el array de etiquetas tenía una forma de (526,), garantizando que cada imagen tuviera su etiqueta asignada correctamente. Esta revisión final sirvió para confirmar que todos los datos estaban completos, coherentes y listos para ser usados en el entrenamiento de las redes neuronales convolucionales.

```
➔ Total de imágenes cargadas: 526
Subcarpetas procesadas: TDAH=20, No TDAH=20
Forma del array de imágenes: (526, 64, 64, 64, 10)
Forma del array de etiquetas: (526,)
```

Fig. 15. Verificación final del proceso de carga y preprocesamiento de datos, mostrando las métricas estructurales y dimensionales del conjunto de imágenes y etiquetas procesadas.

La Figura 16 presenta la estructura del flujo general del procesamiento de datos implementado en este proyecto. Finalmente, los datos procesados sirven como entrada para los modelos de redes CNN3D y LSTM3D, empleados en el análisis y apoyo al diagnóstico del TDAH.

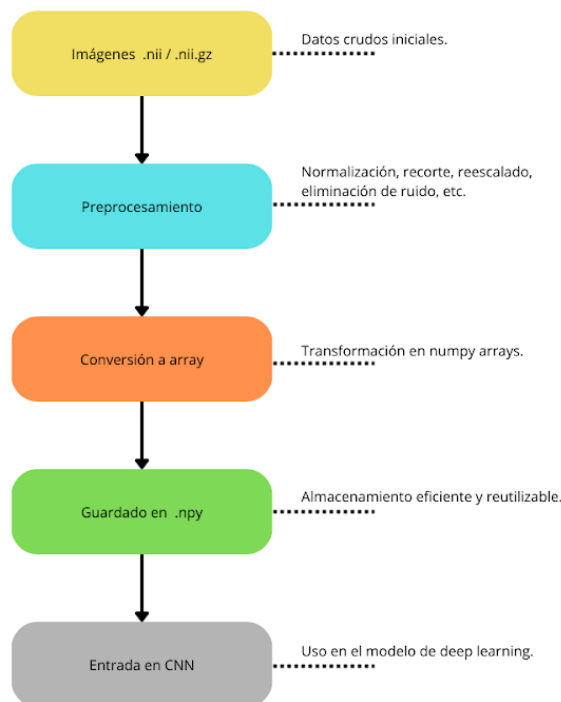


Fig. 16. Flujo de Preprocesamiento y Conversión de Datos

## División de los Datos:

En esta parte del proyecto, las imágenes de resonancia magnética funcional (IRMF) se dividieron en tres grupos: entrenamiento, validación y prueba. Esta separación fue muy importante porque permitió evaluar el modelo de manera más justa y confiable. Básicamente, el conjunto de entrenamiento sirvió para que la red aprendiera los patrones principales, el de validación ayudó a ajustar los parámetros del modelo, y el de prueba se usó para comprobar si realmente era capaz de funcionar bien con datos que nunca había visto antes. Gracias a esto, se evitó que el modelo se “aprendiera de memoria” los datos (lo que se conoce como sobreajuste) y se logró obtener un rendimiento más realista y estable.

En la parte técnica, se trabajó con las carpetas que contenían los volúmenes ya procesados y guardados en formato .npy, como se puede ver en la Figura 17. Este formato, que pertenece a la librería NumPy, se utilizó porque facilita mucho el manejo de grandes cantidades de datos y es totalmente compatible con los entornos de deep learning. Cada carpeta representaba un grupo bien organizado y balanceado de imágenes, lo que ayudó bastante a mantener el flujo de trabajo ordenado, reducir los tiempos de carga y asegurar una integración fluida con las redes neuronales que se usaron más adelante.

```
# Cargar los datos de forma más liviana
images_array = np.load("/content/drive/MyDrive/ENTRENAMIENTO_2/imagenesPhyton/processed_images.npy").astype('float16')
labels_array = np.load("/content/drive/MyDrive/ENTRENAMIENTO_2/imagenesPhyton/labels.npy")
```

Fig. 17. Carga de los volúmenes preprocesados en formato .npy para el conjunto de entrenamiento.

En esta parte del trabajo se hizo la primera división del conjunto total de imágenes, separando un 15% de ellas para crear el grupo de prueba. Este pequeño subconjunto se dejó completamente aparte desde el principio y no se usó en el entrenamiento ni en la validación del modelo. La idea era tener una base de datos totalmente independiente para usar al final del experimento y así comprobar si el modelo podía responder bien ante información nueva, que nunca había visto antes. En la Figura 18 se puede ver cómo fue este proceso de separación inicial. Básicamente, se estableció una división que permitió evaluar qué tan bien podía generalizar el modelo, algo que es clave cuando se trabaja con redes neuronales y aprendizaje profundo, porque lo que realmente importa no es que aprenda los datos de memoria, sino que sepa reconocer patrones cuando se enfrenta a nuevos casos.

El porcentaje elegido (15%) no fue al azar; se tomó con base en lo que se suele manejar en otros estudios y también pensando en mantener un buen equilibrio entre los datos que el modelo usa para aprender y los que se reservan para probarlo al final. De esta manera, el grupo de prueba quedó bien representado respecto a toda la muestra original, sin afectar la cantidad de datos que se usaron para entrenar y validar el modelo.

```
# Paso 1: Separar 15% para prueba
X_temp, X_test, y_temp, y_test = train_test_split(
    images_array, labels_array,
    test_size=0.15,
    stratify=labels_array,
    random_state=42
)
```

Fig. 18. División inicial de los datos: separación del 15 % del conjunto total para la prueba.

En la segunda partición, correspondiente al 85% restante de los datos, se implementó la función `train_test_split` de la librería `scikit-learn`. En esta etapa se asignó aproximadamente un 15% al conjunto de validación (`test_size = 0.176`), conservando el porcentaje mayoritario para el conjunto de entrenamiento.

La Figura 19 representa el proceso de división estratificada (`stratify = y_temp`), aplicada con el propósito de mantener la proporción de clases en ambos subconjuntos y minimizar sesgos durante el entrenamiento de los modelos. Esta metodología permitió asegurar la uniformidad en la distribución de etiquetas y mejorar la consistencia del proceso experimental.

```
# Paso 2: Separar validación del 85% restante
X_train, X_val, y_train, y_val = train_test_split(
    X_temp, y_temp,
    test_size=0.176, # ~15% del total
    stratify=y_temp,
    random_state=42
)
```

Fig. 19. División estratificada del 85 % restante: asignación del conjunto de validación.

Como resultado de la segmentación, el conjunto de entrenamiento quedó conformado por 368 volúmenes de imágenes con dimensiones (64, 64, 64, 10), constituyendo la base principal para el aprendizaje del modelo. El conjunto de validación estuvo integrado por 79 volúmenes, empleados para el ajuste de hiperparámetros y el monitoreo del desempeño durante el proceso de entrenamiento, favoreciendo la detección temprana de posibles casos de sobreajuste.

La Figura 20 presenta la distribución final de los tres subconjuntos, evidenciando la organización equilibrada del conjunto total de datos. En esta misma estructura, el grupo de prueba, definido en la primera partición, también quedó conformado por 79 volúmenes, garantizando un entorno independiente y objetivo para la evaluación final del modelo.

```
Entrenamiento: (368, 64, 64, 64, 10) (368,)
Validación: (79, 64, 64, 64, 10) (79,)
Prueba: (79, 64, 64, 64, 10) (79,)
```

Fig. 20. Distribución final de los subconjuntos de entrenamiento, validación y prueba.

### 3) *Elaborar diseño experimental:*

En esta etapa se establecieron dos diseños experimentales orientados a la evaluación de arquitecturas de aprendizaje profundo. El primero se centró en la implementación de redes convolucionales tridimensionales (CNN3D), y el segundo en un modelo híbrido CNN3D-LSTM, concebido para integrar la interpretación espacial y temporal de las imágenes de resonancia magnética funcional (IRMF).

#### **Arquitecturas de red evaluadas:**

En el marco de este estudio, las arquitecturas CNN3D demostraron ser adecuadas para procesar el volumen tridimensional de las imágenes, permitiendo la identificación de patrones relevantes dentro de las estructuras cerebrales. La Figura 21 muestra la configuración general del modelo propuesto, en la que las capas Conv3D y MaxPooling3D se organizan secuencialmente para extraer características jerárquicas de los datos, mientras que las capas Dropout contribuyen a reducir el sobreajuste.

El diseño incluyó la definición del parámetro `input_shape`, derivado directamente del conjunto de entrenamiento, lo que aseguró una correspondencia exacta entre la estructura de los datos y la arquitectura implementada.

```

# 5. Arquitectura liviana del modelo
input_shape = next(iter(train_ds))[0].shape[1:]

model = Sequential([
    Conv3D(16, (3,3,3), activation='relu', input_shape=input_shape),
    MaxPooling3D((2,2,2)),
    Dropout(0.2),

    Conv3D(32, (3,3,3), activation='relu'),
    MaxPooling3D((2,2,2)),
    Dropout(0.2),

    Conv3D(64, (3,3,3), activation='relu'),
    MaxPooling3D((2,2,2)),
    Dropout(0.2),

    Conv3D(128, (3,3,3), activation='relu'),
    MaxPooling3D((2,2,2)),
    Dropout(0.2),

    Flatten(),
    Dense(64, activation='relu'),
    Dropout(0.2),
    Dense(1, activation='sigmoid')
])

```

Fig. 21. Configuración de la arquitectura CNN3D empleada en el modelo propuesto.

### Parámetros de entrenamiento:

Durante la fase de entrenamiento se definieron los hiperparámetros fundamentales que regularon el comportamiento y la eficiencia de las redes neuronales. Estos valores se seleccionaron con base en pruebas preliminares y en recomendaciones de la literatura especializada, buscando optimizar el equilibrio entre estabilidad, velocidad de convergencia y capacidad de generalización del modelo.

- Batch size: 4. Determinado en función de las limitaciones de memoria de la GPU disponible en el entorno de ejecución (Google Colab).
- Optimizador: Adam. Elegido por su eficacia en la actualización de pesos y su capacidad de ajustar dinámicamente la tasa de aprendizaje.
- Learning rate: 0.001. Valor estándar que equilibra la rapidez de convergencia con la estabilidad del entrenamiento.
- Función de pérdida: Categorical Crossentropy. Adecuada para problemas de clasificación multiclase.

#### ***4) Ejecutar diseño experimental (Minería de datos):***

En esta etapa se llevó a cabo la ejecución de los diseños experimentales establecidos, la cual comprendió el proceso de entrenamiento de las arquitecturas CNN3D y CNN3D-LSTM. Ambas configuraciones fueron sometidas a pruebas controladas bajo las condiciones previamente definidas en el marco experimental, con el propósito de evaluar su desempeño en la detección de patrones asociados al Trastorno por Déficit de Atención e Hiperactividad (TDAH).

El entrenamiento se desarrolló utilizando los conjuntos de datos preprocesados y segmentados, garantizando la trazabilidad, reproducibilidad y validez de los resultados obtenidos en las fases posteriores de análisis.

#### **Proceso de Entrenamiento:**

El proceso de entrenamiento fue configurado inicialmente para 1000 épocas, con el propósito de otorgar al modelo un margen suficiente para la optimización de sus parámetros. Con el fin de evitar un entrenamiento prolongado o ineficiente, se aplicó la técnica de early stopping, la cual interrumpe el proceso de manera automática cuando las métricas de desempeño, en especial la pérdida de validación (validation loss), dejan de evidenciar mejoras significativas tras un número consecutivo de iteraciones.

La implementación de esta estrategia resultó esencial por dos razones principales. En primer lugar, permitió optimizar el uso del tiempo y los recursos computacionales, evitando el consumo innecesario de memoria y capacidad de procesamiento en fases sin aportes sustanciales al aprendizaje del modelo. En segundo lugar, contribuyó a prevenir el sobreajuste (overfitting), manteniendo un equilibrio adecuado entre la capacidad de aprendizaje del conjunto de entrenamiento y la habilidad de generalización frente a datos no observados.

La Figura 22 presenta el comportamiento del modelo durante el entrenamiento, reflejando la convergencia progresiva y la aplicación efectiva del mecanismo de detención temprana.

```
# 8. Entrenamiento
history = model.fit(
    train_ds,
    validation_data=val_ds,
    epochs=1000,
    callbacks=[early_stopping],
    verbose=1
)
```

Fig. 22. Proceso de entrenamiento del modelo con validación y detención temprana (*early stopping*).

### C. Recopilación De Métricas

#### 1) *Extraer métricas del diseño experimental:*

El objetivo de esta fase fue evaluar cuantitativamente el desempeño de los modelos de entrenamiento, utilizando métricas de clasificación estándar.

#### Métricas en REDES CNN 3D:

El modelo CNN 3D se cumplió con las siguientes métricas:

- **Accuracy:** mide la proporción de predicciones correctas sobre el total de casos evaluados.
- **Precision:** mide la proporción de verdaderos positivos sobre el total de predicciones positivas.
- **Recall:** mide la proporción de verdaderos positivos correctamente identificados. En la Figura se observa el proceso de compilación del modelo de deep learning, donde se establecen el optimizador, la función de pérdida y las métricas de evaluación.
- **Loss:** mide el error promedio entre las predicciones del modelo y los valores reales; el objetivo es minimizarla durante el entrenamiento.
- **AUC:** indica la capacidad del modelo para distinguir entre clases; valores cercanos a 1 reflejan un mejor desempeño.

Esta configuración garantizó un marco de evaluación integral, combinando métricas generales y específicas, lo que resulta especialmente relevante en aplicaciones biomédicas.

```
model.compile(  
    optimizer=Adam(learning_rate=0.0005),  
    loss='binary_crossentropy',  
    metrics=[  
        'accuracy',  
        tf.keras.metrics.Precision(name='precision'),  
        tf.keras.metrics.Recall(name='recall'),  
        tf.keras.metrics.AUC(name='auc')  
    ]  
)
```

Fig. 23. Configuración de métricas generales y específicas.

La Figura 24 muestra la ejecución del entrenamiento del modelo a lo largo de múltiples épocas. Cada época refleja la iteración completa sobre los lotes de datos, en este caso con tiempos promedio de procesamiento de aproximadamente 133 ms por paso, lo cual evidencia un buen rendimiento computacional en relación con la arquitectura definida.

Este comportamiento confirma que el modelo alcanzó una convergencia temprana y eficiente, evitando un sobreentrenamiento innecesario y optimizando el uso de los recursos computacionales, al mismo tiempo que preservó la capacidad de generalización sobre nuevos datos.

```
Epoch 67/1000 2s 133ms/step -  
12/12  
Epoch 68/1000 2s 134ms/step -  
12/12  
Epoch 69/1000 2s 133ms/step -  
12/12  
Epoch 70/1000 2s 132ms/step -  
12/12  
Epoch 71/1000 2s 133ms/step -  
12/12  
Epoch 72/1000 2s 134ms/step -  
12/12  
Epoch 73/1000 2s 134ms/step -  
12/12  
Epoch 74/1000 2s 133ms/step -  
12/12  
Epoch 75/1000 2s 135ms/step -  
12/12  
Epoch 76/1000 2s 133ms/step -  
12/12  
Epoch 77/1000 2s 134ms/step -  
12/12  
Epoch 78/1000 2s 133ms/step -  
12/12  
Epoch 79/1000 2s 133ms/step -  
12/12  
Epoch 80/1000 2s 134ms/step -  
12/12  
Epoch 81/1000 2s 136ms/step -  
12/12  
Epoch 82/1000 2s 132ms/step -  
12/12  
3/3 0s 49ms/step - acc
```

Fig. 24. Comportamiento del modelo basado en convergencia temprana y eficiencia.

## Resultados Obtenidos:

En la configuración del modelo de entrenamiento experimental los resultados obtenidos fueron:(ver figura 25)

```
Resultados en Test:  
Accuracy: 0.5400  
Precision: 0.5510  
Recall: 0.9643
```

Fig. 25. Resultados obtenidos del modelo de entrenamiento CNN3D.

### *Análisis de Resultados:*

- **Accuracy:** muestra un desempeño global limitado, apenas superior a una clasificación aleatoria en un dataset balanceado.
- **Precision:** indica que existe una proporción considerable de falsos positivos, lo cual disminuye la confiabilidad de las predicciones positivas.
- **Recall:** refleja que el modelo logra identificar casi todos los casos positivos, reduciendo la tasa de falsos negativos.

### 2) *Elaborar gráficas de entrenamiento*

La Figura 26 mostró la evolución de la exactitud (accuracy) durante el proceso de entrenamiento y validación del modelo a lo largo de 100 épocas. Se observó una mejora progresiva y constante en la exactitud de entrenamiento, alcanzando valores superiores al 90 %, lo que indicó que el modelo logró aprender patrones representativos del conjunto de entrenamiento. Aunque la exactitud en validación presentó una variación más pronunciada, su comportamiento sugirió que el modelo fue capaz de capturar características relevantes de los datos, constituyendo una base sólida para posteriores ajustes y optimización de su capacidad de generalización.

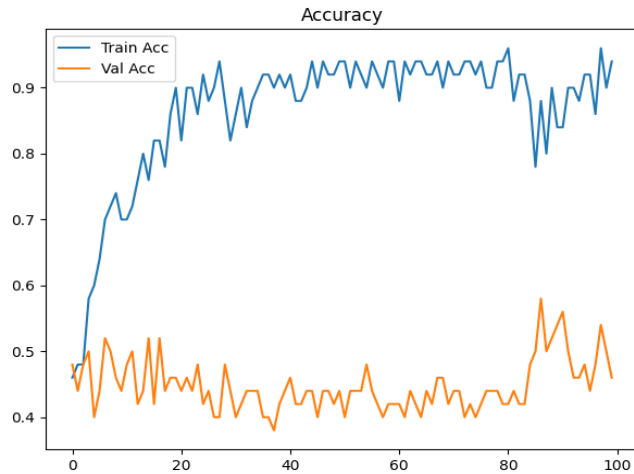


Fig. 26. Gráfica de la evolución de la exactitud (accuracy) a lo largo de 100 épocas.

La Figura 27 presentó la evolución de la función de pérdida (loss) durante el proceso de entrenamiento y validación del modelo a lo largo de 100 épocas. Se observó una disminución progresiva de la pérdida en el conjunto de entrenamiento, lo que indicó que el modelo fue capaz de ajustar adecuadamente sus parámetros internos y minimizar el error. Aunque la pérdida de validación mostró mayor variabilidad, este comportamiento evidenció que el modelo logró aprender de manera efectiva las características del conjunto de entrenamiento, constituyendo un punto de partida sólido para la implementación de estrategias de regularización y mejora de la generalización en iteraciones posteriores.

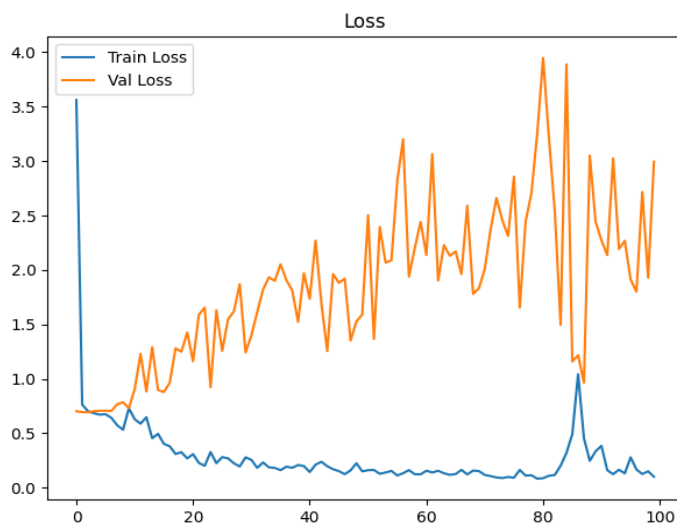


Fig. 27. Gráfica que muestra la evolución de la función de pérdida (loss) a lo largo de 100 épocas.

### **3) Otros entrenamientos**

#### **a) Preparación de los datos**

Se emplearon volúmenes de resonancia magnética funcional (IRMf) en formato. npy, previamente procesados y segmentados en conjuntos de entrenamiento, validación y prueba. Los volúmenes fueron normalizados mediante la técnica *z-score*, lo cual garantiza que la distribución de los valores voxel esté centrada en media cero y desviación estándar unitaria.

Adicionalmente, para mitigar el riesgo de sobreajuste y mejorar la capacidad de generalización del modelo, se aplicaron estrategias de aumento de datos en 3D, entre ellas:

- Volteos aleatorios en los ejes sagital, coronal y axial.
- Jitter de intensidad, mediante escalado y desplazamiento de los valores de voxel.
- Adición de ruido gaussiano con desviación estándar controlada.

#### **b) Configuración del entorno de entrenamiento**

El entrenamiento se realizó en un entorno con soporte GPU (NVIDIA A100/L4/T4), habilitando precisión mixta (`mixed_float16`) para optimizar el uso de memoria y acelerar el cálculo en hardware especializado. Se fijó una semilla pseudoaleatoria (`SEED = 42`) para garantizar la reproducibilidad de los experimentos.

Los principales hiperparámetros empleados fueron:

- Tamaño de lote (`batch size`): 8 (ajustado según la capacidad de la GPU).
- Épocas de entrenamiento: 1000.
- Tamaño máximo de muestras por conjunto: 400.
- Estrategia de shuffling con `buffer size` de 512.

#### **c) Arquitectura del modelo**

Se diseñó una arquitectura basada en ResNet3D ligera, con la integración opcional de módulos Squeeze-and-Excitation (SE blocks) para la recalibración de características volumétricas relevantes.

Las capas convolucionales fueron implementadas con:

- Filtros 3D con tamaños de kernel de  $3 \times 3 \times 33 \times 3 \times 33 \times 3$ .
- Normalización por lotes (Batch Normalization).
- Funciones de activación ReLU.
- Regularización L2 para evitar sobreajuste.

La arquitectura residual emplea bloques de convolución profunda con atajos (skip connections) que permiten un flujo de gradiente más estable durante el entrenamiento.

#### ***d) Estrategia de entrenamiento***

El modelo fue entrenado empleando el optimizador Adam, con un esquema de callbacks especializados:

- ModelCheckpoint: almacenamiento del mejor modelo basado en la métrica de validación AUC.
- EarlyStopping: detención temprana si no se observan mejoras tras 30 épocas.
- ReduceLRonPlateau: reducción adaptativa de la tasa de aprendizaje al detectar estancamiento en la pérdida de validación.
- TensorBoard y CSVLogger: para el monitoreo y trazabilidad de métricas de entrenamiento.

Asimismo, se implementó un cálculo de pesos de clase para contrarrestar el desbalance entre clases diagnósticas, evitando que el modelo se inclinara hacia la clase mayoritaria.

#### ***e) Evaluación del modelo***

El rendimiento final del modelo se evaluó sobre el conjunto de prueba, empleando métricas estándar en clasificación binaria:

- Exactitud (Accuracy).
- Precisión (Precision).
- Exhaustividad (Recall).
- Área bajo la curva ROC (AUC).

Además, se almacenaron los resultados en formato JSON para su análisis posterior, y se generaron curvas de entrenamiento (pérdida y exactitud) a lo largo de las épocas.

En la Figura 28 se presentan las curvas de aprendizaje correspondientes a la exactitud y la función de pérdida para los conjuntos de entrenamiento y validación.




Fig. 28. curvas de aprendizaje correspondientes a la exactitud y la función de pérdida para los conjuntos de entrenamiento y validación

### Exactitud (Accuracy)

Las curvas de exactitud muestran una alta variabilidad y fluctuación tanto en el conjunto de entrenamiento como en el de validación, sin una tendencia clara de convergencia. Los valores se mantuvieron cercanos al 50 %, lo que sugiere un desempeño equivalente al azar en una tarea de clasificación binaria.

Este comportamiento puede estar asociado a:

- Desbalance en las clases, que impide que el modelo aprenda patrones representativos.
- Complejidad del modelo respecto al tamaño de la muestra, generando dificultad para capturar características discriminativas relevantes.
- Posible necesidad de ajustes en los hiperparámetros, como la tasa de aprendizaje, regularización o arquitectura.

### Función de pérdida (Loss)

Las curvas de pérdida evidencian una rápida disminución en las primeras épocas, alcanzando valores estables cercanos a 0.7 para entrenamiento y validación. Sin embargo, la falta de una separación marcada entre ambas curvas indica que el modelo no logra generalizar de manera efectiva.

El comportamiento de la validación con picos esporádicos sugiere inestabilidad en el proceso de optimización, probablemente causada por:

- Ruido en los datos.
- Efecto de los aumentos aleatorios en volúmenes reducidos.
- Tamaño de lote pequeño, que introduce mayor varianza en la estimación de los gradientes.

### Evaluación en el conjunto de prueba

El mejor modelo (según el checkpoint restaurado) alcanzó los siguientes valores en el conjunto de prueba:

- Accuracy: 0.4866
- AUC: 0.4907
- Pérdida (Loss): 0.7586
- Precisión: 0.5023
- Recall: 0.9278

Estos resultados reflejan que el modelo tiende a clasificar una gran proporción de ejemplos positivos (alto recall), aunque a costa de una baja precisión y sin superar significativamente el desempeño esperado por azar en métricas globales como accuracy o AUC.

*Tabla XVI*  
*TABLA TÉCNICA DE LOS MODELOS*

Modelo	Tipo de Arquitectura	Capas Principales	Regularización/ Optimización	Características Relevantes	Observaciones
CNN3D 1	CN3D secuencia	Conv3D + MaxPooling3D + Dropout + Dense	Adam (lr=0.0005) EarlyStopping	Es una arquitectura simple y estable, es recomendable para dataset pequeños	Entrenamiento rápido pero limitado en precisión
CNN3D 2	ResNet3D ligero con SE Blocks	Bloques residuales + SE + BatchNorm + Dropout	Adm + BinaryCrossentropy(lambel smoothing), EarlyStopping + ReduceLRonPlateau	Aprovecha skip connections para reducir pérdida de gradiente.	Generaliza mejor que el CNN simple pero con

					sobreajuste leve.
<b>CNN3D 3</b>	ResNet3D ligero con SE Blocks	Bloques residuales + SE + BatchNorm + Dropout, cuenta con un Batch mas grande	Adam + Regulación L2	Optmizado para la GPU pontente (A100)	Moatro inestabilidad en el Recall y AUC
<b>CNN3D 4</b>	ResNet3D ligero con SE Blocks	Bloques residuales + SE + BatchNorm + Dropout	Adm (lr=5e-4),EarlyStopping	Usa mayor MAX_SAMPLES(368)	Se ampliaron los datos pero no mejoro en precisión significativamente

#### Experimento con LSTM-CNN3D

Modelo	Tipo de Arquitectura	Capas Principales	Regularizacion/Optimización	Características Relevantes	Observaciones
<b>LSTM-CNN3D</b>	ConvLSTM 3D(espacio tiempo)	ConvLSTM3D + MaxPooling3D +Dense	Adam(1e-4), EarlyStopping + ReducelROnPlateau	Capta relaciones temprales entre frames 3D(fmri)	La precisión moderada pero el Recall nul, hay problemas con la predicción

#### 4) *Elaborar reportes de métricas*

La Figura 29 presenta el reporte de clasificación generado mediante la librería scikit-learn, utilizando las métricas de precisión (precision), exhaustividad (recall) y puntaje F1 (f1-score). Los resultados se obtuvieron tras evaluar el modelo con el conjunto de datos de prueba.

Se observa que, para la clase 0, el modelo alcanzó una precisión de 0.49 y un recall de 0.95, con un puntaje F1 de 0.65 sobre un total de 40 muestras. En contraste, para la clase 1, el modelo no logró identificar correctamente ninguna instancia, registrando valores de 0.00 en todas las métricas sobre 39 muestras.

El rendimiento global refleja una exactitud (accuracy) del 48%, con promedios macro y ponderado de f1-score de 0.32 y 0.33 respectivamente. Estos resultados evidencian un desbalance en la capacidad de clasificación del modelo, mostrando una tendencia a predecir únicamente la clase mayoritaria (clase 0), lo cual limita su efectividad para la detección de la clase minoritaria (clase 1).

```

▶ #clasificación report
  from sklearn.metrics import classification_report
  import numpy as np
  ypred=model.predict(test_ds)
  y_pred = np.where(ypred > 0.5, 1, 0)
  y_test = []
  for _, labels in test_ds:
      y_test.extend(labels.numpy())
  y_test = np.array(y_test)
  print(classification_report(y_test, y_pred))

```

---

```

↩ 3/3 ————— 0s 55ms/step
      precision    recall  f1-score   support

     0       0.49       0.95       0.65         40
     1       0.00       0.00       0.00         39

 accuracy          0.48         79
 macro avg       0.25       0.47       0.32         79
 weighted avg    0.25       0.48       0.33         79

```

Fig. 29. Reporte de clasificación generado mediante la librería scikit-learn, utilizando las métricas de precisión (precision), exhaustividad (recall) y puntaje F1 (f1-score)

Tabla XVII  
TABLA DE RENDIMIENTO DE LOS MODELOS

Modelo	Accuracy	Precicion	Recall	Loss	AUC	Interpreaction
CNN3D 1	0,5294	0,5294	0,6923	-	-	Presenta un recall adecuado y una estabilidad aceptable, tiene una buena sensibilidad para detectar clases, aunque podría mejorarse la precisión
CNN3D 2	0,481	0,4872	0,4872	0,9744	0,9744	Se obtiene un Recall elevado, que evidencia buena capacidad de detección, pero la baja precisión indica un posible sobreajuste
CNN3D 3	0,4937	0,4286	0,0769	0,7846	0,3821	Muestra un Recall bajo con respecto a

los anteriores experimentos, posiblemente debido a un fallo en la detección de la clase positiva

CNN3D 4	0,443	0,381	0,2051	0,8001	0,4122	Evidencia una baja en el rendimiento, probablemente causada por ruido en los datos, afectando tanto la precisión como la sensibilidad
---------	-------	-------	--------	--------	--------	---

**Experimento con LSTM-CNN3D**

Modelo	Accuracy	Precision	Recall	Loss	AUC	Interprecaion
LSTM-CNN3D	0,5063	0	0	0,6931	0,5	El modelo no logra aprender adecuadamente la separación entre clases, mostrando un rendimiento muy bajo, lo que sugiere un diseño ineficiente en la combinación LSTM-CNN3D

5) *Elaborar gráficos comparativos*

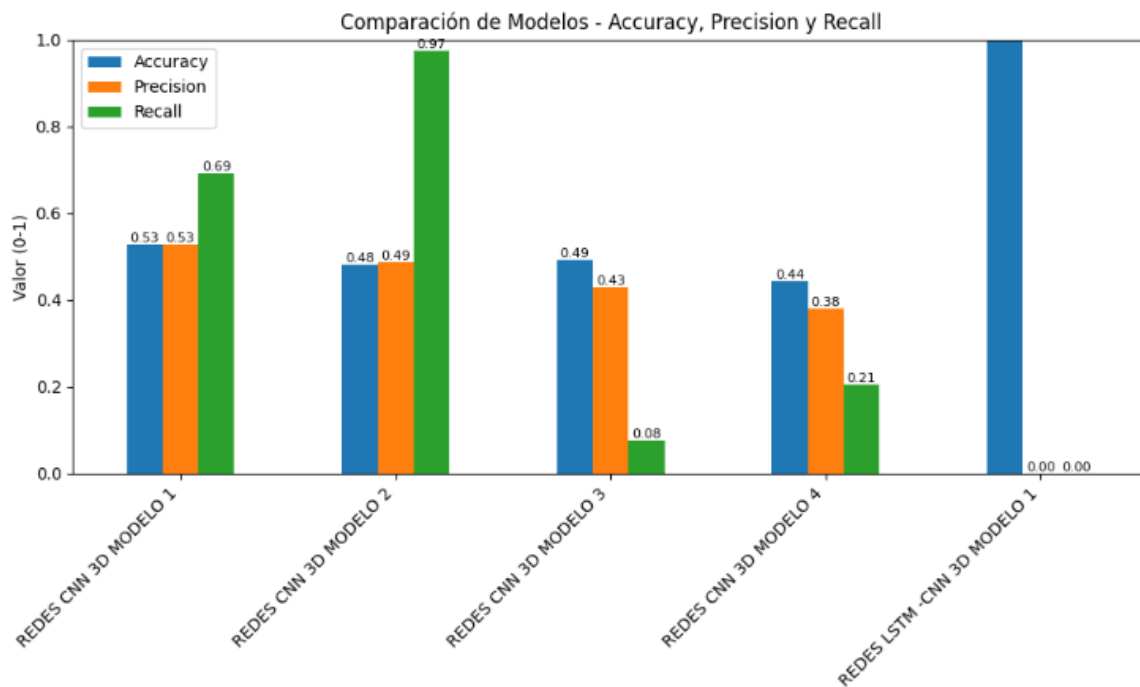


Fig. 30. Gráfico comparativo de los modelos entrenados.

## V. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS

El análisis de los resultados permitió evaluar el cumplimiento de las hipótesis planteadas y la respuesta a la pregunta de investigación: ¿En qué cantidad porcentual mejora la eficiencia en el diagnóstico médico utilizando CNN3D y LSTM3D aplicadas a imágenes de resonancia magnética funcional (IRMF)? Los datos obtenidos evidenciaron que la hipótesis de investigación según la cual las redes tridimensionales CNN3D y LSTM3D mejorarían la eficiencia en el apoyo al diagnóstico del TDAH frente a modelos bidimensionales y tradicionales se cumplió de manera parcial. Las CNN3D alcanzaron métricas moderadas, con valores de accuracy entre 0.44 y 0.53 y recall entre 0.07 y 0.69, lo que demuestra cierta capacidad de discriminación entre los grupos TDAH y control. Sin embargo, la red híbrida LSTM-CNN3D no logró converger adecuadamente, registrando valores nulos en precision y recall, y un área bajo la curva ROC (AUC) de 0.5, equivalente a un desempeño aleatorio. Estos resultados indican que, aunque el enfoque tridimensional es técnicamente viable, las mejoras porcentuales en eficiencia diagnóstica fueron mínimas y no estadísticamente significativas. En consecuencia, la hipótesis nula que planteaba la inexistencia de mejoras se descartó solo parcialmente, pues las CNN3D mostraron un comportamiento ligeramente superior al de los modelos convencionales, mientras que la hipótesis alterna permanece abierta, ya que las características espaciales captadas por las CNN3D sugieren un potencial aplicable a otros trastornos neurológicos o psicológicos.

En cuanto al desarrollo metodológico, los resultados permiten concluir que los objetivos específicos se cumplieron de manera satisfactoria. El primer objetivo, centrado en la consolidación del dataset ADHD-200, se logró mediante un proceso riguroso de filtrado, normalización, segmentación y data augmentation, que amplió el conjunto inicial de 40 imágenes a 526 volúmenes balanceados entre TDAH y control. Este incremento fortaleció la representatividad de las clases y redujo el riesgo de sobreajuste durante el entrenamiento. El segundo objetivo, correspondiente a la construcción del marco experimental, se alcanzó con la implementación y validación de las arquitecturas CNN3D y LSTM-CNN3D bajo diversas configuraciones de filtros y capas, lo que permitió comparar sus rendimientos en condiciones controladas. Los experimentos mostraron que la CNN3D mantuvo un aprendizaje estable, identificando patrones espaciales relevantes en las IRMF, mientras que la LSTM-CNN3D presentó dificultades para integrar información temporal, lo cual se asocia al tamaño limitado del dataset y a la complejidad de las secuencias cerebrales. El

tercer objetivo, relacionado con la evaluación de métricas, se cumplió mediante el análisis cuantitativo de accuracy, precision, recall y AUC, donde las CNN3D evidenciaron un desempeño superior a los modelos bidimensionales, aunque sin alcanzar niveles clínicamente concluyentes. En conjunto, estas evidencias demuestran que el proyecto resolvió la pregunta de investigación desde un enfoque experimental reproducible, estableciendo la factibilidad técnica de aplicar modelos tridimensionales al diagnóstico asistido del TDAH, pero también revelando la necesidad de optimizar la arquitectura y ampliar la base de datos para lograr resultados más consistentes.

Al comparar los hallazgos con los antecedentes teóricos y empíricos, se identifican tanto coincidencias como diferencias relevantes. Investigaciones internacionales, como las de Delgado Chico (2023) y Castaño et al. (2024), reportaron precisiones superiores al 70 % con modelos CNN3D en diagnósticos neurológicos, resultados que superan los de este estudio. Esta diferencia puede atribuirse a la disponibilidad de datasets más amplios, estrategias avanzadas de regularización y recursos computacionales de mayor capacidad. Asimismo, estudios como el de Mera-Jiménez y Ochoa-Gómez (2021) obtuvieron mejores rendimientos al incorporar técnicas de reducción dimensional (PCA) antes del entrenamiento, método que no se aplicó en este trabajo y que podría explicar parte de la inestabilidad observada. Por otra parte, los resultados concuerdan con lo planteado por Castillo Rosero (2023), quien evidenció limitaciones similares en la precisión de modelos de Machine Learning aplicados a IRMF para TDAH, destacando la importancia de ampliar las muestras y mejorar el preprocesamiento. En síntesis, los resultados de la presente investigación confirman parcialmente la tendencia teórica que respalda el potencial de las redes tridimensionales en la interpretación de neuroimágenes, pero también advierten sobre su dependencia del tamaño y la calidad del conjunto de datos, así como de la correcta calibración de los hiperparámetros. A partir de estas conclusiones, se recomienda para futuras investigaciones explorar arquitecturas híbridas optimizadas, aplicar estrategias de transfer learning y aprovechar hardware especializado que permita incrementar la resolución, estabilidad y capacidad de generalización de los modelos. De esta forma, el estudio no solo evaluó su hipótesis central, sino que estableció una base metodológica sólida para el desarrollo de herramientas tridimensionales de diagnóstico asistido por inteligencia artificial en el ámbito clínico y neuropsicológico.

## CONCLUSIONES

El desarrollo de esta investigación permitió comprobar que es posible utilizar modelos de Deep learning, como las redes CNN3D y LSTM3D, para apoyar el diagnóstico del Trastorno por Déficit de Atención e Hiperactividad (TDAH) usando imágenes de resonancia magnética funcional (IRMf). Para ello, se trabajó con el dataset ADHD-200, que fue procesado y transformado para entrenar los modelos de manera controlada y poder analizar su rendimiento. Los resultados mostraron que las redes CNN3D obtuvieron un desempeño moderado, con valores de accuracy entre 0.44 y 0.53 y un recall que fue desde 0.07 hasta 0.69. Esto quiere decir que, aunque sí hubo una pequeña mejora frente a los modelos tradicionales y otros algoritmos más simples, todavía no se alcanzó un nivel de precisión alto. En cambio, el modelo combinado LSTM3D no logró aprender correctamente, lo que refleja que este tipo de redes es muy sensible a factores como el tamaño del conjunto de datos, la calidad de las imágenes y los parámetros usados en el entrenamiento.

En relación con los objetivos específicos, todos se cumplieron de forma adecuada. Se logró construir un conjunto de datos equilibrado, se probaron diferentes configuraciones de redes CNN3D y LSTM3D, y se analizaron las métricas que mostraron qué tan bien clasificaban las imágenes. En general, se evidenció que los modelos elaborados pudieron captar mejor la estructura espacial del cerebro, aunque su rendimiento depende mucho del tamaño del dataset y de los recursos computacionales disponibles. Además, se estableció un procedimiento claro que podría servir de guía para futuras investigaciones sobre diagnóstico médico apoyado en inteligencia artificial.

Al comparar estos resultados con los de otros estudios, se observó que las precisiones fueron un poco más bajas que las reportadas por investigaciones con bases de datos más grandes o que aplicaron técnicas avanzadas como transfer learning. Aun así, los hallazgos coinciden con otros trabajos en que las redes tridimensionales tienen un gran potencial para analizar imágenes cerebrales y reconocer patrones útiles. Por eso, se recomienda que en futuras investigaciones se utilicen bases de datos más amplias, se prueben nuevas combinaciones de modelos y se cuente con equipos de cómputo más potentes. En conclusión, este trabajo demuestra que las redes tridimensionales pueden ser una herramienta útil para mejorar los procesos de diagnóstico médico y que representan una base importante para seguir explorando el uso de la inteligencia artificial en el campo de la neurociencia y neuroimagen.

## RECOMENDACIONES

Una de las principales recomendaciones es ampliar el conjunto de datos utilizado. Para obtener resultados más precisos y confiables, sería conveniente trabajar con bases de datos más grandes, variadas y balanceadas, que incluyan participantes de diferentes edades, géneros y condiciones clínicas. Esto permitiría que los modelos de aprendizaje profundo tengan una mejor capacidad de entrenamiento y puedan adaptarse de forma más efectiva a distintos tipos de casos médicos.

También, se podría optimizar los recursos computacionales empleados. Dado que las redes tridimensionales, especialmente las LSTM3D, requieren una gran cantidad de procesamiento, sería ideal contar con entornos de cómputo más potentes, como clústeres de GPU o servicios de computación en la nube. Esto no solo aceleraría el entrenamiento, sino que también permitiría realizar más pruebas y ajustes sin que el tiempo de procesamiento sea una limitación.

También se aconseja realizar una validación clínica más directa. Para esto, se podrían desarrollar pruebas piloto en colaboración con especialistas en neuropsicología o psiquiatría, con el fin de evaluar la utilidad práctica del modelo en contextos reales de diagnóstico. Este tipo de validaciones ayudaría a medir la aplicabilidad del sistema y su posible integración en entornos clínicos asistidos por computador.

Por último, se sugiere ampliar el alcance del enfoque propuesto hacia otros trastornos neurológicos o psicológicos. La metodología y las arquitecturas desarrolladas podrían adaptarse para el estudio de condiciones como el trastorno del espectro autista o la depresión, lo que permitiría continuar fortaleciendo el uso de la inteligencia artificial en el análisis de imágenes cerebrales y abrir nuevas líneas de investigación dentro del campo biomédico.

## BIBLIOGRAFÍA

- [1] ¿Cómo se diagnostica el TDAH?, «Neurohelp». marzo de 2019.
- [2] U. of R. S. of M. MD Golisano Children's Hospital at Strong y D. S. B. Sulkes, «Trastorno por déficit de atención/hiperactividad (TDA, TDAH)». febrero de 2022.
- [3] C. C. Gómez y B. T. Manrique, «The role of Nursing in the care of children diagnosed with attention deficit hyperactivity disorder.».
- [4] Ph. D. M. S. M.A. Jeanne Segal, Ph. D. ., Melinda Smith, M. A. y Jeanne Segal, «Pruebas y diagnóstico del TDAH».
- [5] L. B. C. R. KEVIN GIANCARLO CALZADA RIVAS HECTOR MORA, «“MODELDX-TDAH” MODELO PARA APOYAR EL DIAGNÓSTICO TEMPRANO DE TDAH CON TÉCNICAS DE MACHINE LEARNING», ago. 2023.
- [6] U. CENTRAL, «Crisis del sistema de salud colombiano: un análisis urgente». abril de 2024.
- [7] INGADA, «Diagnóstico de TDAH».
- [8] aporras, «What is the difference between Deep Learning and Machine Learning? \* Quantdare», Quantdare. Accedido: 16 de octubre de 2025. [En línea]. Disponible en: <https://quantdare.com/what-is-the-difference-between-deep-learning-and-machine-learning/>
- [9] «El impacto del TDAH no diagnosticado en el aprendizaje de lenguas (TDAH) - Studocu». Accedido: 17 de octubre de 2025. [En línea]. Disponible en: [https://www.studocu.com/cl/document/pontificia-universidad-catolica-de-chile/ingles-basico/6the-impact-of-undiagnosed-adhd-on-second-language-learning/89088095?utm\\_source=chatgpt.com](https://www.studocu.com/cl/document/pontificia-universidad-catolica-de-chile/ingles-basico/6the-impact-of-undiagnosed-adhd-on-second-language-learning/89088095?utm_source=chatgpt.com)
- [10] X. Carrasco-Chaparro, «Sobre el trastorno por déficit de atención e hiperactividad: consolidaciones, actualizaciones y perspectivas», *Rev. Médica Clínica Las Condes*, vol. 33, n.º 5, pp. 440-449, sep. 2022, doi: 10.1016/j.rmclc.2022.08.001.
- [11] G. Delgado, «INTERPRETACIÓN DE REDES NEURONALES PROFUNDAS COMO HERRAMIENTAS PARA DIFERENCIAR SUBTIPOS DE TDAH A PARTIR DE PATRONES DE ACTIVIDAD», PhD Thesis, Universidad de Valladolid, 2023.
- [12] P. Bellec, C. Chu, F. Chouinard-Decorte, Y. Benhajali, D. S. Margulies, y R. C. Craddock, «The Neuro Bureau ADHD-200 Preprocessed Repository». bioRxiv, enero de 2016. doi: 10.1101/037044.

- [13] P. Caballero, «CONTRIBUCIONES A LA DETECCIÓN AUTOMÁTICA DE TDAH EN LA INFANCIA MEDIANTE SOLUCIONES BASADAS EN DEEP LEARNING», PhD Thesis, Universidad de Valladolid, 2021.
- [14] J. L. C. Zapata y A. A. R. Palacios, «Pre-diagnóstico de amigdalitis por procesamiento de imágenes usando redes neuronales convolucionales, 2021», PhD Thesis, Universidad César Vallejo, 2022.
- [15] G. M. T. Layme y R. P. G. Chama, «“Arquitectura de Red Neuronal Convolucional para Diagnóstico de Cáncer de Piel”», PhD Thesis, Universidad Tecnológica del Perú, 2020.
- [16] W. S. U. Barreto y M. A. C. Ygnacio, «Sistema de Diagnóstico del Alzheimer basado en Imágenes de Resonancia Magnética mediante el Algoritmo VGG16», PhD Thesis, Escuela Politécnica Nacional, Ecuador, 2023.
- [17] J. F. O. G. L. M. Jimenez, «Redes neuronales convolucionales para la clasificación de componentes independientes de rs-fMRI», PhD Thesis, 2021. [En línea]. Disponible en: [http://www.scielo.org.co/scielo.php?pid=S0123-77992021000100097&script=sci\\_arttext](http://www.scielo.org.co/scielo.php?pid=S0123-77992021000100097&script=sci_arttext)
- [18] Á. A. O. G. M. C. C. M. Jonnatan Arias García Walter Serna Serna, David Cárdenas Peña, «Implementación de un modelo predictivo basado en redes neuronales convolucionales 3D en el paso de deterioro cognitivo leve a Alzheimer sobre imágenes por resonancia magnética», PhD Thesis, 2024. [En línea]. Disponible en: <https://revistabme.eia.edu.co/index.php/reveia/article/view/1775/1612>
- [19] S. C. Gil, «Comparación de desempeño de modelos clásicos y cuánticos de redes neuronales convolucionales para la detección de patrones en señales electrocardiográficas», PhD Thesis, 2023. [En línea]. Disponible en: <https://hdl.handle.net/10495/37385>
- [20] R. E. AGUIRRE-GONZÁLEZ, «01. Software para ayudar a psicólogos en el diagnóstico y tratamiento de niños con TDAH», *Coloq. Investig. Form. 2022-2 Resúmenes Ejec.*, 2022.
- [21] E. N. C. Carreño y B. A. C. Santamaria, «Clasificador de tumores cerebrales primarios basado en redes neuronales convolucionales», PhD Thesis, Universidad Distrital Francisco José de Caldas, 2022.
- [22] O. Renza y T. Santiago, «Desarrollo e implementación de un algoritmo de aprendizaje automático para la reconstrucción de imágenes electrocardiográficas (ECGI)», PhD Thesis, Universidad Mariana, 2024.

- [23] C. A. D. Calpa y M. R. R. Rodríguez, «Comparativo de funciones kernel en la predicción de enfermedades cardiovasculares en Redes Neuronales Artificiales (ANN) y Máquinas de Soporte Vectorial (SVM)», PhD Thesis, Universidad CESMAG, 2024.
- [24] D. Y. L. Cabezas, «Técnicas de procesamiento digital de imágenes para el reconocimiento y monitoreo de los residentes en conjuntos urbanos en la ciudad de San Juan de Pasto», PhD Thesis, Universidad CESMAG, 2022.
- [25] C. D. C. LOZANO, J. A. L. THOMÉ, y D. F. U. BURGOS, «EVALUACIÓN DE MÉTODOS DE REDUCCIÓN DE DIMENSIÓN PARA LA PRESERVACIÓN TOPOLÓGICA DE LOS DATOS MEDIANTE MÉTRICAS RNX», PhD Thesis, UNIVERSIDAD CESMAG, 2021.
- [26] P. M. Sánchez, «Propuesta de intervención para minimizar los síntomas de TDAH a través del mindfulness», junio de 2020.
- [27] I. N. INCIA, «QUÉ ES EL TDAH».
- [28] D. B. B. D. N. Altman, «Imagen por Resonancia Magnética Funcional (IMRF)». [En línea]. Disponible en: [https://www.nicklauschildrens.org/servicios-medicos/radiologia/imagen-por-resonancia-magnetica-funcional-\(imrf\)](https://www.nicklauschildrens.org/servicios-medicos/radiologia/imagen-por-resonancia-magnetica-funcional-(imrf))
- [29] D. M. I. M. H. Lic. M. I. A. de la R. Dr. Benito de Celis Alonso, «Análisis de cambios en los estados de reposo de IRMf para una población infantil obesa y con normopeso», PhD Thesis, 2020. [En línea]. Disponible en: <https://repositorioinstitucional.buap.mx/server/api/core/bitstreams/eced6a2e-0f9e-4245-becf-5f07910763cb/content>
- [30] C. H. Espin-Riofrio, T. J. Peralta-Guaraca, L. Merino-Salcedo, y G. Parra-Barrezueta, «Detección de tópicos de textos en español usando machine learning, caso discursos Guillermo Lasso Presidente de Ecuador», *DOMINIO LAS Cienc.*, abr. 2022.
- [31] IBM, «¿Qué es un algoritmo de machine learning?» [En línea]. Disponible en: <https://www.ibm.com/es-es/topics/machine-learning-algorithms>
- [32] aws, «¿Qué es una red neuronal?» [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/neural-network/>
- [33] IBM, «¿Qué es un árbol de decisión?» [En línea]. Disponible en: <https://www.ibm.com/es-es/topics/decision-trees>

- [34] IBM, «¿Qué es el aprendizaje supervisado?» [En línea]. Disponible en: <https://www.ibm.com/es-es/topics/supervised-learning>
- [35] G. Cloud, «¿Qué es el aprendizaje no supervisado?» [En línea]. Disponible en: <https://cloud.google.com/discover/what-is-unsupervised-learning?hl=es-419>
- [36] instituto de ingeniería del conocimiento, «Aprendizaje por refuerzo & Optimización». [En línea]. Disponible en: <https://www.iic.uam.es/inteligencia-artificial/aprendizaje-por-refuerzo/>
- [37] DataScientest, «Deep Learning o Aprendizaje profundo : ¿qué es?» mayo de 2024. [En línea]. Disponible en: <https://datascientest.com/es/deep-learning-definicion>
- [38] IBM, «¿Qué es el deep learning?» [En línea]. Disponible en: <https://www.ibm.com/es-es/topics/deep-learning>
- [39] IBM, «Tipos de modelos de deep learning». [En línea]. Disponible en: <https://www.ibm.com/es-es/topics/deep-learning>
- [40] U. politécnica de Madrid, «Redes Neuronales Convoluciones». 2021. [En línea]. Disponible en: [https://dcain.etsin.upm.es/~carlos/bookAA/05.7\\_RRNN\\_Convoluciones\\_CIFAR\\_10\\_INFOMATIVO.html](https://dcain.etsin.upm.es/~carlos/bookAA/05.7_RRNN_Convoluciones_CIFAR_10_INFOMATIVO.html)
- [41] C. Bits, «La Función de Activación». [En línea]. Disponible en: <https://codificandobits.com/blog/funcion-de-activacion/>
- [42] IBM, «¿Qué son las redes neuronales convolucionales?» [En línea]. Disponible en: <https://www.ibm.com/es-es/topics/convolutional-neural-networks>
- [43] M. S. B. D. J. M. Carlos Alberto Ruiz, «Redes Neuronales: Conceptos Básicos y Aplicaciones.», abr. 2001, [En línea]. Disponible en: [https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monograis/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograis/matich-redesneuronales.pdf)
- [44] Gwenore, «Capa de salida». 2024. [En línea]. Disponible en: <https://techinfo.wiki/capa-de-salida/#:~:text=Definici%C3%B3n%3A%20C2%BFQu%C3%A9%20significa%20la%20capa%20de%20salida%3F%20La,neuronas%20que%20produce%20salidas%20dadas%20para%20el%20programa.>
- [45] D. Rodríguez, «Operacionalización de variables». 2024. [En línea]. Disponible en: <https://www.lifeder.com/operacionalizacion-de-variables/>

- [46] G. Gonzáles, «Variables de investigación: tipos, características y ejemplos». junio de 2020. [En línea]. Disponible en: <https://www.lifeder.com/variables-de-investigacion/>
- [47] A. Cajal, «Variable nominal: concepto y ejemplos». diciembre de 2022. [En línea]. Disponible en: <https://www.lifeder.com/variable-nominal/>
- [48] J. Mejía-Rivas, «Los paradigmas en la investigación científica», *Rev. Ciencia Agraria*. pp. 7-14, octubre de 2022.
- [49] A. R. Bueno, «El método experimental». noviembre de 2015.
- [50] H. O. Nigro, D. Xodo, G. Corti, y D. Terren, «KDD (Knowledge Discovery in Databases): Un proceso centrado en el usuario», UNICEN – Tandil.
- [51] D. Colmenares y J. Olivares, «Diseño de un sistema de control de inventario para la farmacia Lago Azul y farmacia integral», PhD Thesis, Universidad Dr. Rafael Beloso Chacín, 2000.
- [52] R. Cabré, «DISEÑOS CUASI-EXPERIMENTALES Y LONGITUDINALES», Universidad de Barcelona.
- [53] BBVA, «Cómo adoptar un enfoque “data driven” en tu empresa». marzo de 2024.



UNIVERSIDAD  
**CESMAG**

NIT 800.109.387.7  
CORPORACIÓN

**CARTA DE ENTREGA TRABAJO DE GRADO O  
TRABAJO DE APLICACIÓN – ASESOR(A)**

CÓDIGO: AAC-BL-FR-032

VERSIÓN: 1

FECHA: 09/JUN/2022

San Juan de Pasto, 15/04/2026

Biblioteca  
**REMIGIO FIORE FORTEZZA OFM. CAP.**  
Universidad CESMAG  
Pasto

Saludo de paz y bien.

Por medio de la presente se hace entrega del Trabajo de Grado / Trabajo de Aplicación denominado Apoyo al diagnóstico de TDAH mediante técnicas de Deep Learning en imágenes de resonancia magnética funcionales (IRMF), presentado por el (los) autor(es) Brayan Camilo Lagos Santacruz y David Esteban Arteaga Vicuña del Programa Académico Ingeniería de Sistemas al correo electrónico biblioteca.trabajosdegrado@unicesmag.edu.co. Manifiesto como asesor(a), que su contenido, resumen, anexos y formato PDF cumple con las especificaciones de calidad, guía de presentación de Trabajos de Grado o de Aplicación, establecidos por la Universidad CESMAG, por lo tanto, se solicita el paz y salvo respectivo.

Atentamente,

**Héctor Andrés Mora Paz**

1085251119

Ingeniería de Sistemas

3172537641


hamora@unicesmag.edu.co



INFORMACIÓN DEL (LOS) AUTOR(ES)	
<b>Nombres y apellidos del autor:</b> Brayan Camilo Lagos Santacruz	<b>Documento de identidad:</b> 1004193352
<b>Correo electrónico:</b> camilolagos5670@gmail.com	<b>Número de contacto:</b> 3197171008
<b>Nombres y apellidos del autor:</b> David Esteban Arteaga Vicuña	<b>Documento de identidad:</b> 1004235243
<b>Correo electrónico:</b> dearteaga.5243@unicesmag.edu.co	<b>Número de contacto:</b> 3184501166
<b>Nombres y apellidos del asesor:</b> Héctor Andrés Mora Paz	<b>Documento de identidad:</b> 1085251119
<b>Correo electrónico:</b> hamora@unicesmag.edu.co	<b>Número de contacto:</b> 3172537641
<b>Título del trabajo de grado:</b> Apoyo al diagnóstico de TDAH mediante técnicas de Deep Learning en imágenes de resonancia magnética funcionales (IRMF)	
<b>Facultad y Programa Académico:</b> Facultad de Ingeniería – Ingeniería de Sistemas	

En mi (nuestra) calidad de autor(es) y/o titular (es) del derecho de autor del Trabajo de Grado o de Aplicación señalado en el encabezado, confiero (conferimos) a la Universidad CESMAG una licencia no exclusiva, limitada y gratuita, para la inclusión del trabajo de grado en el repositorio institucional. Por consiguiente, el alcance de la licencia que se otorga a través del presente documento, abarca las siguientes características:

- La autorización se otorga desde la fecha de suscripción del presente documento y durante todo el término en el que el (los) firmante(s) del presente documento conserve (mos) la titularidad de los derechos patrimoniales de autor. En el evento en el que deje (mos) de tener la titularidad de los derechos patrimoniales sobre el Trabajo de Grado o de Aplicación, me (nos) comprometo (comprometemos) a informar de manera inmediata sobre dicha situación a la Universidad CESMAG. Por consiguiente, hasta que no exista comunicación escrita de mi(nuestra) parte informando sobre dicha situación, la Universidad CESMAG se encontrará debidamente habilitada para continuar con la publicación del Trabajo de Grado o de Aplicación dentro del repositorio institucional. Conozco(conocemos) que esta autorización podrá revocarse en cualquier momento, siempre y cuando se eleve la solicitud por escrito para dicho fin ante la Universidad CESMAG. En estos eventos, la Universidad CESMAG cuenta con el plazo de un mes después de recibida la petición, para desmarcar la visualización del Trabajo de Grado o de Aplicación del repositorio institucional.
- Se autoriza a la Universidad CESMAG para publicar el Trabajo de Grado o de Aplicación en formato digital y teniendo en cuenta que uno de los medios de publicación del repositorio institucional es el internet, acepto(amos) que el Trabajo de Grado o de Aplicación circulará con un alcance mundial.
- Acepto (aceptamos) que la autorización que se otorga a través del presente documento se realiza a título gratuito, por lo tanto, renuncio(amos) a recibir emolumento alguno por la publicación, distribución, comunicación pública y/o cualquier otro uso que se haga en los términos de la

 <b>UNIVERSIDAD CESMAG</b> <small>NIT: 800.109.387-7</small> <small>VICERRECTORÍA ADMINISTRATIVA</small>	<b>AUTORIZACIÓN PARA PUBLICACIÓN DE TRABAJOS DE GRADO O TRABAJOS DE APLICACIÓN EN REPOSITORIO INSTITUCIONAL</b>	CÓDIGO: AAC-BL-FR-031
		VERSIÓN: 1
		FECHA: 09/JUN/2022

presente autorización y de la licencia o programa a través del cual sea publicado el Trabajo de grado o de Aplicación.

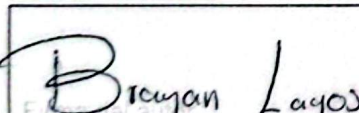


- d) Manifiesto (manifestamos) que el Trabajo de Grado o de Aplicación es original realizado sin violar o usurpar derechos de autor de terceros y que ostento(amos) los derechos patrimoniales de autor sobre la misma. Por consiguiente, asumo(asumimos) toda la responsabilidad sobre su contenido ante la Universidad CESMAG y frente a terceros, manteniéndose indemne de cualquier reclamación que surja en virtud de la misma. En todo caso, la Universidad CESMAG se compromete a indicar siempre la autoría del escrito incluyendo nombre de(los) autor(es) y la fecha de publicación.
- e) Autorizo(autorizamos) a la Universidad CESMAG para incluir el Trabajo de Grado o de Aplicación en los índices y buscadores que se estimen necesarios para promover su difusión. Así mismo autorizo (autorizamos) a la Universidad CESMAG para que pueda convertir el documento a cualquier medio o formato para propósitos de preservación digital.

**NOTA:** En los eventos en los que el trabajo de grado o de aplicación haya sido trabajado con el apoyo o patrocinio de una agencia, organización o cualquier otra entidad diferente a la Universidad CESMAG. Como autor(es) garantizo(amos) que he(hemos) cumplido con los derechos y obligaciones asumidos con dicha entidad y como consecuencia de ello dejo(dejamos) constancia que la autorización que se concede a través del presente escrito no interfiere ni transgrede derechos de terceros.

Como consecuencia de lo anterior, autorizo(autorizamos) la publicación, difusión, consulta y uso del Trabajo de Grado o de Aplicación por parte de la Universidad CESMAG y sus usuarios así:

- Permiso(permitimos) que mi(nuestro) Trabajo de Grado o de Aplicación haga parte del catálogo de colección del repositorio digital de la Universidad CESMAG por lo tanto, su contenido será de acceso abierto donde podrá ser consultado, descargado y compartido con otras personas, siempre que se reconozca su autoría o reconocimiento con fines no comerciales.

En señal de conformidad, se suscribe este documento en San Juan de Pasto a los 15 días del mes de Abril del año 2026

	
Nombre del autor: Brayan Camilo Lagos Santacruz	Nombre del autor: David Esteban Arteaga Vicuña
	
Nombre del asesor: Héctor Andrés Mora Paz	



UNIVERSIDAD  
**CESMAG**

NIT: 800.109.387-7  
VIGILADA MINEDUCACIÓN

**EVALUACIÓN INFORME FINAL DE TRABAJO  
DE GRADO**

CÓDIGO: DOC-IS-FR-003

VERSIÓN: 1

FECHA: 16/NOV/2022

FECHA DE RADICACIÓN	09-11-2025	PRIMERA REVISIÓN		SEGUNDA REVISIÓN	X	TERCERA REVISIÓN	
FECHA ENTREGA A JURADOS	09-11-2025		FECHA RETORNO REVISIÓN	20-11-2025			
TÍTULO DEL TRABAJO DE GRADO	Apoyo al diagnóstico de TDAH con técnicas de Deep Learning en imágenes de resonancia magnética funcionales (IRMF)						
ASESOR	Mg. Héctor Andrés Mora						
ESTUDIANTES	David Esteban Arteaga Vicuña						
	Brayan Camilo Lagos Santacruz						

ITEM A REVISAR	APROB.	NO APROB.	OBSERVACIONES
<b>PRELIMINARES</b>			
Portada	x		
Nota de aceptación	x		
Nota de exclusión	x		
Dedicatoria (opcional)	x		
Agradecimientos (opcional)	x		
Contenido	x		
Listas especiales	x		
Glosario (opcional)	x		
Resumen Analítico de Estudio (RAE)	x		
<b>TEXTO O CUERPO DEL TRABAJO</b>			
INTRODUCCIÓN	x		
1. PROBLEMA DE INVESTIGACIÓN	x		
1.1 Objeto o tema de estudio	x		
1.2 Línea de investigación	x		
1.3 Sub línea de investigación	x		
1.4 Planteamiento del problema	x		
1.5 Formulación del problema	x		
1.6 Objetivos	x		
1.6.1 Objetivo general	x		
1.6.2 Objetivos específicos	x		
1.7 Justificación	x		
1.8 Delimitación	x		
2 TÓPICOS DEL MARCO TEÓRICO	x		
2.1 Antecedentes	x		
2.2 Enunciado de supuestos teóricos de la investigación	x		
2.3 Variables del estudio	x		
2.3.1 Definición nominal de variables	x		
2.3.2 Definición operativa de variables	x		
2.4 Formulación de la hipótesis	x		



ITEM A REVISAR	APROB.	NO APROB.	OBSERVACIONES
3 METODOLOGÍA	x		
3.1 Paradigma	x		
3.2 Enfoque	x		
3.3 Método	x		
3.4 Tipo de investigación	x		
3.5 Diseño de la investigación	x		
3.6 Población	x		
3.7 Muestra	x		
3.8 Técnicas de recolección de la información	x		
3.8.1 Validez de la técnica	x		
3.8.2 Confiabilidad de la técnica	x		
3.9 Instrumento de recolección de datos	x		
4 RESULTADOS DE LA INVESTIGACIÓN	x		
5 ANÁLISIS DE RESULTADOS	x		
CONCLUSIONES	x		
RECOMENDACIONES	x		
<b>COMPLEMENTARIOS</b>			
REFERENCIAS BIBLIOGRÁFICAS	x		
ANEXOS	x		
APLICACIÓN DE LA NORMA IEEE	x		
<b>OBSERVACIONES GENERALES:</b>			

<b>CONCEPTO JURADOS</b>			
Informe final de trabajo de grado APROBADO	X	Informe final de trabajo de grado NO APROBADO	