

M

Modelo de Clasificación del TDAH con Redes Neuronales Convolucionales a partir de rs-fMRI

Catrina Quintero López^{1,2}, Víctor Daniel Gil Vera³, Juan Pablo Ospina Lopez⁴, Andrés Gallego^{5,2} y Yaira Chamorro Díaz^{6,7}

¹Grupo de Investigación en Neurociencias Básicas y Aplicadas (NBA), Universidad Católica Luis Amigó. Medellín, Colombia.

²Doctorado en Neurociencia Aplicada y Comportamiento, Universidad de San Buenaventura. Bogotá, Colombia.

³Grupo de Investigación en Sistemas de Información y Sociedad del Conocimiento (SISCO). Medellín, Colombia.

⁴Grupo de Investigación en Informática y Electrónica para el Beneficio de las Comunidades (SIKU), Universidad Sergio Arboleda. Bogotá, Colombia.

⁵Grupo de Investigación de Microelectrónica (GMUN), Universidad Nacional de Colombia. Bogotá, Colombia.

⁶Laboratorio de Neuropsicología y Neurolingüística, Instituto de Neurociencias (CUCBA), Universidad de Guadalajara. Guadalajara, Jalisco, México.

⁷Departamento de Estudios en Educación (CUCSH), Universidad de Guadalajara. Guadalajara, Jalisco, México.

Nota de Autor

Catrina Quintero López  <https://orcid.org/0000-0001-5532-3024>

Víctor Daniel Gil Vera  <https://orcid.org/0000-0003-3895-4822>

Juan Pablo Ospina Lopez  <https://orcid.org/0000-0002-6841-9778>

Juan Pablo Ospina Lopez  <https://orcid.org/0000-0002-5852-5788>

Yaira Chamorro Díaz  <https://orcid.org/0000-0003-0644-6452>

Correspondencia relacionada a este artículo deberá dirigirse a Catalina Quintero López.

Transversal 51A #67B 90. Medellín, Colombia. Correo electrónico:
catalina.quintero@amigo.edu.co

Resumen

Introducción. El Trastorno por Déficit de Atención-Hiperactividad (TDAH) afecta el desempeño académico, las relaciones sociales y la regulación emocional. Si bien tiene una prevalencia global estimada del 5%, el diagnóstico enfrenta limitaciones debido a dependencia de evaluaciones clínicas extensas, variabilidad de aplicación y escasez de profesionales especializados, lo que ha motivado el uso de enfoques complementarios basados en medidas neurobiológicas objetivas. La finalidad del estudio fue desarrollar un método automatizado para apoyar el diagnóstico del TDAH mediante resonancia magnética funcional en estado de reposo (rs-fMRI) y redes neuronales convolucionales (CNN). *Método.* Se utilizaron $n=177$ rs-fMRI de personas con TDAH ($n=90$) y controles con desarrollo típico ($n=87$) del sitio New York University Child Study Center, disponibles en el repositorio ADHD-200, con edades entre 7 y 18 años. Las imágenes fueron preprocesadas con el Pipeline ATHENA para la obtención de matrices de conectividad funcional a partir de la señal BOLD de 18 regiones de interés (ROIs). Estas matrices fueron la entrada de la CNN bidimensional (2D) diseñada para la clasificación binaria entre TDAH y controles. *Resultados.* El modelo fue entrenado durante 150 momentos alcanzó una precisión $=0.81$ y una pérdida de validación $=0.53$ en el momento 69, lo que indica un desempeño adecuado para entornos clínicos. Las principales alteraciones en conectividad se localizaron en la red del modo por defecto, la corteza prefrontal y el cíngulo anterior. *Conclusiones.* Los hallazgos respaldan el uso de CNN para el diagnóstico automatizado del TDAH, lo que reduce la dependencia exclusiva de pruebas psicométricas para la detección del trastorno. Se recomienda ampliar el tamaño muestral y explorar arquitecturas híbridas que integren CNN con otros enfoques de aprendizaje profundo, con el fin de mejorar la precisión y la generalización.

Palabras clave: TDAH, deep learning, diagnóstico, redes neuronales convolucionales, rs-fMRI

Diagnosis of ADHD with Convolutional Neural Networks based on rs-fMRI

Abstract

Introduction. Attention-Deficit/Hyperactivity Disorder (ADHD) affects academic performance, social relationships and emotional regulation. Although it has an estimated global prevalence of 5%, the diagnosis faces limitations due to reliance on extensive clinical evaluations, variability in application and a shortage of specialized professionals, which has motivated the use of complementary approaches based on objective neurobiological measures. The aim of the study was to develop an automated method to support the diagnosis of ADHD using resting-state functional magnetic resonance imaging (rs-fMRI) and convolutional neural networks (CNN). *Method.* $n=177$ rs-fMRI scans of subjects with ADHD ($n=90$) and typically developing controls ($n=87$) from the New York University Child Study Center, available in the ADHD-200 repository, were used. The subjects were aged 7 to 18 years. The images were preprocessed with the ATHENA Pipeline to obtain functional connectivity matrices from the BOLD signal of 18 regions of interest (ROIs). These matrices were the input for the two-dimensional (2D) CNN designed for

binary classification between ADHD and controls. *Results.* The model was trained for 150 epochs, reaching an accuracy of 0.81 and a validation loss of 0.53 at epoch 69, indicating satisfactory performance for clinical settings. The main changes in connectivity were observed in the default mode network, the prefrontal cortex, and the anterior cingulate. *Conclusions.* The findings support the use of CNN for the automated diagnosis of ADHD, reducing the exclusive reliance on psychometric tests for the detection of the disorder. It is recommended to expand the sample size and explore hybrid architectures to optimize the accuracy and generalization of the developed model.

Keywords: ADHD, deep learning, diagnosis, convolutional neural networks, rs-fMRI

Modelo de Clasificación del TDAH con Redes Neuronales Convolucionales a partir de rs-fMRI

El TDAH es una entidad clínica del neurodesarrollo caracterizada por inatención, hiperactividad e impulsividad, con una prevalencia global de 5% a 10% en niños y adolescentes (Popit et al., 2024). La sintomatología afecta el rendimiento académico, la integración social y la regulación emocional. Esta condición repercute negativamente en la calidad de vida de los pacientes y su entorno familiar (Peñuelas-Calvo et al., 2021). Aunque tiene una alta prevalencia, el diagnóstico del TDAH sigue siendo un problema debido a la heterogeneidad de la presentación clínica, la alta comorbilidad con otras psicopatologías y la ausencia de biomarcadores objetivos (Parlatini et al., 2024; Schleim, 2022). La valoración tradicional se sustenta en evaluaciones clínicas realizadas por especialistas, quienes emplean los criterios de los manuales diagnósticos, junto con la revisión de la historia prenatal, perinatal y familiar, el seguimiento de la evolución de las áreas del neurodesarrollo y la aplicación de pruebas cognitivas y conductuales (American Psychiatric Association [APA], 2024; Sadek, 2023). El uso de este enfoque para la detección del TDAH conlleva a diagnósticos inconsistentes y posibles errores, situación que se agrava por la limitada disponibilidad de profesionales capacitados para llevar a cabo una evaluación certera (Furzer et al., 2022; Quintero-López et al., 2024).

La neuroimagen emerge como una herramienta fundamental en la investigación del TDAH (Firouzabadi et al., 2022; Tao et al., 2017) ya que permite el estudio de la conectividad y la dinámica cerebral subyacente al trastorno (Grimm et al., 2021). La rs-fMRI ha demostrado ser un método efectivo para evaluar la actividad neuronal sin necesidad de tareas cognitivas específicas (Cortese et al., 2021); la medición de la fluctuación del nivel dependiente de oxígeno en la sangre, también conocida como *Blood Oxygen Level Dependent* (BOLD) refleja cambios en el consumo de oxígeno y el flujo sanguíneo cerebral, lo que permite identificar patrones de conectividad funcional alterados en personas con TDAH (Dinatolo et al., 2023).

En el TDAH, la investigación en neuroimagen ha revelado una divergencia entre los hallazgos clínicos tradicionales y los biomarcadores funcionales identificados mediante rs-fMRI (Chen et al., 2023). Cinco redes cerebrales (fronto-estriada-talámica, control ejecutivo, atención ventral, saliencia y modo por defecto), muestran patrones de conectividad alterados que explican parte de la sintomatología (Blomberg et al., 2022; Fu et al., 2021). La red fronto-estriada-talámica filtra la información del medio ambiente, realiza la selección de respuestas motoras y cognitivas, estos procesos se hiperactivan o hipoactivan en función de la presentación clínica del TDAH (Parlatini et al., 2023). La red de control ejecutivo que está implicada en la planificación, la memoria de trabajo y la atención sostenida, presenta hipo-conectividad en el TDAH (Jensen et al., 2022). La red de atención ventral, que permite reorientar rápidamente la atención hacia estímulos relevantes, presenta fallas asociadas con patrones de distracción en el TDAH (Alves et al., 2022). La hipoactividad de la red de saliencia presente en el TDAH limita la capacidad de priorizar información relevante, ya que esta red se encarga de mediar el cambio entre estados internos y externos (Damiani et al., 2021). La red del modo por defecto muestra desactivación insuficiente durante tareas cognitivas, lo que incrementa la variabilidad atencional y el pensamiento intrusivo en población con TDAH (Curtin et al., 2022). La interacción anómala entre estas redes sugiere un fallo en el equilibrio dinámico entre los estados de reposo y de actividad,

lo que genera impulsividad, inatención y desregulación emocional, características típicas de esta condición del neurodesarrollo (Harikumar et al., 2021; Saad et al., 2022).

La heterogeneidad clínica del TDAH se refleja de manera consistente en los estudios de neuroimagen funcional, no se observa un patrón único de alteraciones cerebrales, sino configuraciones variables de conectividad entre regiones, moduladas por la edad, presentación clínica, comorbilidad y contexto del desarrollo (Bu et al., 2025; Wang et al., 2023). En la rs-fMRI esta variabilidad se manifiesta en cambios dinámicos y distribuidos en múltiples redes, lo que dificulta la identificación de biomarcadores firmes mediante enfoques lineales o basados en características predefinidas (Xue et al., 2025). Los modelos de aprendizaje profundo resultan adecuados para capturar patrones complejos en datos de alta dimensionalidad, esto permite integrar la heterogeneidad neurofuncional del TDAH en esquemas de clasificación automatizada (Gülhan y Özmen, 2025).

La complejidad y alta dimensionalidad de los datos rs-fMRI dificultan la interpretación clínica, lo que ha impulsado la incorporación de modelos de inteligencia artificial (IA) para optimizar el análisis (Caraka et al., 2025; Taspinar y Ozkurt, 2024). Las CNN son un subcampo de la IA dentro del aprendizaje profundo (*deep learning*) que han mostrado un gran potencial en la clasificación y predicción de trastornos neurológicos a partir del análisis de imágenes cerebrales (Kulkarni et al., 2024; Zaheer y Akhtar, 2025). Las CNN son un tipo de red neuronal profunda diseñada específicamente para procesar datos espaciales/temporales y extraer de manera automática características relevantes, para minimizar la selección manual de parámetros en el proceso de ingeniería de características (Purwono et al., 2022).

Estas redes, ampliamente utilizadas en el análisis de imágenes médicas, han logrado una precisión superior a la de métodos tradicionales basados en machine learning (Chen et al., 2022). En el contexto del TDAH, investigaciones que emplearon CNN para analizar datos rs-fMRI, lograron tasas de clasificación superiores al 70%, lo que supera en precisión a evaluaciones realizadas por expertos humanos (Hu et al., 2024; Kim et al., 2023). Enfoques recientes han demostrado que la selección de regiones cerebrales específicas de interés mejora el rendimiento de los modelos y optimiza la detección del TDAH sin necesidad de procesar la totalidad de los datos neuroimagenológicos (Shoeibi et al., 2023).

Al considerar las limitaciones del diagnóstico clínico y el potencial de la neuroimagen para identificar biomarcadores funcionales, el objetivo de esta investigación fue desarrollar un método automatizado de apoyo al diagnóstico del TDAH mediante el análisis de la conectividad funcional derivada de rs-fMRI y el uso de una CNN 2D para la clasificación entre individuos con TDAH y controles con desarrollo típico. Este enfoque, que integra información neurofuncional de redes relevantes en la fisiopatología del TDAH con técnicas de *deep learning*, elude las restricciones de las evaluaciones clínicas tradicionales y genera modelos predictivos precisos. Con este estudio buscamos aportar evidencia empírica que respalde la viabilidad de las CNN como herramienta complementaria en la práctica clínica para obtener diagnósticos más objetivos y oportunos que los actuales.

Método

Participantes

Se emplearon 222 rs-fMRI del repositorio ADHD-200 (ADHD-200 Consortium, 2011), del sitio New York University Child Study Center (NYU), obtenidos a través de un escáner de 3T y se aplicó un control de calidad basado en el indicador QC_Rest_1. A cada una de las 222 imágenes (rs-fMRI) se les evaluó la validez de las adquisiciones en reposo, lo que llevó a descartar 45 registros por fallas en el escaneo, exceso de movimiento o información clínica incompleta. Este filtrado garantizó que el conjunto de datos incluido en el análisis estuviera compuesto por capturas confiables y comparables, lo que minimizó el impacto del ruido y la variabilidad técnica sobre las métricas de conectividad funcional extraídas del repositorio ADHD-200.

Dado lo anterior, la muestra se redujo a 177 participantes ($n = 90$ TDAH y $n = 87$ controles), con edades comprendidas entre los 7 y 18 años.

Programación Computacional

El desarrollo se realizó en el lenguaje de programación Python 3.13 (Van Rossum y Drake, 2009), se emplearon las librerías NumPy para el manejo de arreglos y operaciones vectorizadas (Harris et al., 2020), pandas para la organización de metadatos y particiones (Reback et al., 2020) y scikit-learn para normalización, división de datos y cálculo de métricas (Pedregosa et al., 2011). La visualización exploratoria se realizó con Matplotlib y Seaborn. La arquitectura de *deep learning* se implementó en PyTorch (Paszke et al., 2019), se usaron capas Conv2d para la extracción espacial de características, GroupNorm en la estabilización del entrenamiento con batches pequeños, ReLU como función de activación, Dropout2d para regularización, MaxPool2d en la reducción espacial, AdaptiveAvgPool2d(1) en la agregación global y Linear para la clasificación binaria TDAH/control. El flujo de trabajo se diseñó en Jupyter Notebook y se ejecutó en la nube con Google Colaboratory. En el entrenamiento se consideraron los siguientes hiperparámetros; epochs=150, lr= $1e^{-4}$ (Regularización L2), weight_decay= $1e^{-4}$ y es_patience=25 (ver Material Suplementario).

Preprocesamiento

Se realizó con el pipeline ATHENA (Bellec et al., 2017), el cual implica un preprocesamiento de imágenes anatómicas y rs-fMRI. Para las imágenes anatómicas (T1) se efectuó la segmentación tisular en sustancia gris, blanca y líquido cefalorraquídeo (LCR), la normalización espacial al espacio MNI152 mediante FSL, la extracción cerebral (skull-stripping) y el registro anatómico-funcional para garantizar la alineación precisa entre imágenes estructurales y funcionales. En las rs-fMRI se eliminaron los primeros cuatro volúmenes para evitar la inestabilidad del escáner, se aplicó corrección por movimiento y slice-timing, se registraron las imágenes funcionales al espacio anatómico y a MNI. Se realizó la regresión de señales no neuronales (materia blanca, LCR, seis parámetros de movimiento y señal global); se aplicó suavizado espacial con un kernel de 6 mm FWHM y filtrado temporal pasabanda entre 0.009-0.08 Hz para reducir el ruido fisiológico.

Atlas y Selección de ROIs

Para la extracción de la señal BOLD se empleó el Automated Anatomical Labeling Atlas (AAL-116), que segmenta el cerebro en 116 regiones anatómicas (Tzourio-Mazoyer et al., 2002). A partir de este, se seleccionaron 18 ROIs pertenecientes a redes funcionales vinculadas con la fisiopatología del TDAH. La Tabla 1 presenta las redes y regiones empleadas.


Tabla 1

ROIs Atlas 116

Red	Región	Lateralidad ROI (AAL116)	
Red fronto-estriada-talámica	Tálamo	Bilateral	Thalamus_L, Thalamus_R
	Putamen	Bilateral	Putamen_L, Putamen_R
	Núcleo caudado	Bilateral	Caudate_L, Caudate_R
Red de Control Ejecutivo	Corteza prefrontal dorsolateral	Bilateral	MiddleFrontal_L, MiddleFrontal_R
	Lóbulo parietal superior	Bilateral	Parietal_Sup_L, Parietal_Sup_R
Red de Atención Ventral	Corteza frontal inferior	Derecho	Frontal_Inf_Oper_R
	Circunvolución supramarginal	Derecho	SupraMarginal_R
Red de Saliencia	Cíngulo anterior	Bilateral	Cingulum_Ant_L, Cingulum_Ant_R
	Ínsula anterior	Derecho	Insula_R
Red del Modo por defecto	Cíngulo posterior	Bilateral	Cingulum_Post_L, Cingulum_Post_R
	Precúneo	Izquierdo	Precuneus_L

La Figura 1 muestra la localización de los 18 ROIs seleccionados del Atlas 116, representados en vistas axial, coronal y sagital en el espacio MNI152. Los ROIs se muestran en colores diferenciados y se agrupan por red funcional.

Luego de extraer la señal BOLD de los 18 ROIs seleccionados para cada uno de los 177 participantes, se obtuvo una matriz de tamaño 18×172 por participante (ROIs x Escaneos). El conjunto completo de datos se representó como un tensor de dimensiones 177×18×172 (muestra x ROIs x escaneos).


Figura 1*Redes y ROIs Fisiopatología del TDAH***Generación de Matrices de Conectividad**

Previo al cálculo de la conectividad, las series temporales de la señal BOLD de cada participante fueron normalizadas ($M=0$, $\sigma^2=1$) para garantizar comparabilidad entre los participantes y minimizar el efecto de diferencias de escala. Con el fin de mejorar la generalización del modelo y reducir el sobreajuste, se aplicó aumentación de datos sobre las señales normalizadas, consistente en la adición de ruido gaussiano ($M=0$, $D.E.=0.05$, $p=0.5$) y desplazamiento temporal aleatorio de hasta ± 2 TR ($p=0.3$). Este procedimiento permitió simular variabilidad fisiológica y de adquisición, para generar un conjunto de datos robusto. La Figura 2 presenta los mapas de calor de una matriz de conectividad funcional (18×18) obtenida a partir de las señales originales, la versión aumentada y la matriz de diferencias (aumentada-original), muestra los cambios introducidos por el proceso de aumentación.

En la Figura 2, el mapa original presenta la matriz de conectividad obtenida a partir de las señales sin modificar, donde cada celda representa el coeficiente de correlación de Pearson (r) entre un par de ROIs. Los colores siguen un gradiente de azul a amarillo, en el que los valores cercanos a azul indican correlaciones negativas o bajas (menor activación), mientras que los valores en tonos amarillos representan correlaciones positivas más altas (mayor activación). En el mapa aumentado se muestra la versión de la misma matriz, en la que se introdujeron perturbaciones controladas mediante ruido gaussiano $N(\mu, \sigma^2)$ y desplazamiento temporal aleatorio (Δt), se mantuvo la distribución general de conectividad con incremento de variabilidad del conjunto de datos. El mapa de diferencias (aumentada-original), presenta la matriz en donde los colores cálidos (rojo) indican un incremento en la conectividad y los colores fríos (azul) una disminución en la conectividad después de la aumentación. Esta representación permite verificar que los cambios inducidos son de pequeña magnitud y preservan el patrón global de conectividad funcional. La aumentación incrementa la variabilidad de la señal, mejora la generalización del modelo y simula condiciones realistas de ruido (Sanaat et al., 2022).

Figura 2

Mapas de Calor Señal BOLD




La segmentación de las series temporales permitió obtener un conjunto de matrices dinámicas de conectividad funcional para cada participante, a partir de las cuales calculamos cinco descriptores estadísticos que resumen la información de conectividad global y la variabilidad temporal. El promedio temporal de las correlaciones (Ecuación 1) indicó la fuerza media de la conectividad entre los ROIs, mientras que el promedio del valor absoluto (Ecuación 2) muestra la magnitud total de la conectividad independientemente. La densidad de conexiones moderadas ($|z| \geq 0.25$) y la densidad de conexiones fuertes ($|z| \geq 0.50$) permitieron cuantificar la proporción de enlaces funcionales que superan los umbrales, para suministrar un indicador de la integración funcional del cerebro en reposo. La varianza temporal (σ_t^2) ofreció una medida de la estabilidad de la conectividad a lo largo del tiempo, para evidenciar la dinámica de las redes implicadas.

$$\bar{r} = \frac{1}{T} \sum_{t=1}^T r(t) \quad (1)$$

$$|\bar{r}| = \frac{1}{N} \sum_{i=1}^N |r_i| \quad (2)$$

La combinación de estas cinco matrices estadísticas en un tensor multicanal de dimensiones $5 \times 18 \times 18$ suministró una representación compacta y de alta dimensionalidad, capaz de capturar de manera simultánea patrones espaciales y temporales. Este tensor fue la entrada al modelo CNN 2D, diseñado para aprender representaciones jerárquicas de las matrices de conectividad y optimizar la clasificación entre participantes con TDAH y controles. La Figura 3 muestra la arquitectura de la CNN 2D empleada, compuesta por capas convolucionales en qué color está, normalización por grupos, activaciones no lineales y pooling adaptativo, seguidas de una capa densa para la clasificación binaria. Cada cosa que señales decir cómo está representada en la Figura 3.

Figura 3*Arquitectura CNN 2D*

La red recibe como entrada un tensor multicanal de dimensiones $5 \times 18 \times 18$ y aplica dos bloques de convolución y GroupNorm con activación ReLU, seguidos de Dropout2D para regularización y MaxPooling para reducción espacial. Se aplicó Adaptive Average Pooling para comprimir la información en un vector latente, que alimenta una capa totalmente conectada con salida binaria.


Tras la generación de los cinco canales estadísticos derivados de la conectividad funcional, los tensores multicanal se emplearon como entrada en la CNN 2D para el entrenamiento y validación del modelo. La CNN utilizó capas de 32, 64 y 128 filtros en los bloques intermedios y una capa de salida con 96 canales, en la cual se integró normalización por grupos, activaciones ReLU, Dropout ($p=0.2$) y MaxPooling en cada bloque y Adaptive Average Pooling para la extracción de un vector latente antes de la clasificación. La partición del conjunto de datos se realizó de forma aleatoria mediante una semilla fija, con una proporción 80-20% para entrenamiento y validación, se consideraron los siguientes hiperparámetros; epochs=150, lr= $1e^{-4}$ (Regularización L2), weight_decay= $1e^{-4}$ y es_patience=25.

Resultados

En el escenario 1 (validación simple) el modelo completó 150 momentos, en el entrenamiento alcanzó en la última época un accuracy= 0.81 y en la validación un accuracy= 0.77. El mejor desempeño se obtuvo en la época 69, con un accuracy= 0.80 y loss= 0.53 en la validación, valores que se utilizaron para el análisis posterior. En el escenario 2 (experimentos de reproducibilidad), se realizaron 20 ejecuciones independientes con diferentes semillas aleatorias, se mantuvieron constantes la partición de datos y los hiperparámetros. Los resultados mostraron un accuracy= 0.73 (promedio) en validación ($\sigma=0.06$), con un rango entre 0.58 y 0.83, lo que confirma la estabilidad general del modelo y la capacidad de generalización bajo distintas inicializaciones. La Figura 4 presenta las curvas de aprendizaje de las CNN-2D.

Figura 4

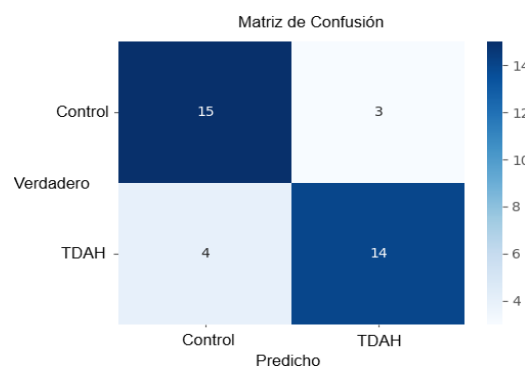
Curvas de Aprendizaje de las CNN-2D



En la Figura 4, a la izquierda, se muestra la evolución del accuracy en los conjuntos de entrenamiento y validación a lo largo de las épocas. A la derecha se observa la disminución progresiva de la función de pérdida (loss), con un punto de convergencia alrededor de la época 69, correspondiente al mejor modelo registrado. La evolución de las métricas durante el entrenamiento evidencia un incremento sostenido del accuracy (entrenamiento-validación). La función de pérdida mostró una disminución progresiva hasta estabilizarse, lo que indicó que el modelo logró una adecuada convergencia sin sobreajuste. La matriz de confusión para el conjunto de validación evidenció un buen equilibrio entre verdaderos positivos (VP) y negativos (VN), con una sensibilidad=77.8%, precisión=82.4%, especificidad=83.3% y F1-score=80.1%. La Figura 5 presenta la matriz de confusión.

Figura 5

Matriz de Confusión



La matriz de confusión muestra un buen desempeño en la clasificación de participantes con TDAH y controles. De los 18 controles, 15 fueron correctamente identificados (VN) y 3 fueron clasificados erróneamente como TDAH (falso positivo [FP]) error tipo I (α). De los 18 participantes con TDAH, 14 fueron clasificados correctamente (VP) y 4 fueron identificados como controles (falso negativo [FN]) error tipo II (β). El modelo CNN 2D clasificó correctamente el 81% del total de casos (accuracy), detectó el 78% de los participantes TDAH (sensibilidad), identificó el 83% de los controles (especificidad) y predijo el TDAH, correctamente el 82% de las veces (precisión).

Discusión

Las métricas obtenidas en esta investigación se interpretan en función del tamaño del conjunto de validación empleado. La muestra total estuvo compuesta por 177 participantes, se utilizó una partición 80-20% para entrenamiento y validación, el conjunto de validación resultante fue reducido. Pequeñas variaciones en el número de casos correcta o incorrectamente clasificados producen cambios apreciables en las métricas (accuracy, sensibilidad, especificidad), fenómeno documentado en estudios de aprendizaje profundo aplicados a neuroimagen con muestras moderadas (Avberšek et al., 2022; Tran et al., 2025). Esta característica es inherente a este tipo de diseños experimentales y no constituye un sesgo metodológico, es una limitación estructural asociada al tamaño muestral y a la partición de los datos (Vu et al., 2020). En la investigación este comportamiento se reflejó en los análisis de reproducibilidad, donde distintas inicializaciones del modelo generaron un rango amplio de desempeño en validación, tal como ha sido reportado previamente en trabajos basados en rs-fMRI y aprendizaje automático para el estudio del TDAH, las métricas reportadas son estimaciones del rendimiento del modelo bajo condiciones experimentales controladas (Chen et al., 2025; Li et al., 2025; Luo et al., 2025).

La estrategia de aprendizaje basada en matrices de conectividad funcional (18×18) y una arquitectura CNN 2D con bloques convolucionales y capa densa mostró un buen desempeño en la clasificación del TDAH. La ejecución del modelo fue similar tanto en los participantes TDAH como en los controles. Investigaciones previas han reportado precisiones de clasificación que alcanzan o superan el 90% (Ke et al., 2022; Zhou et al., 2024). Este rendimiento casi perfecto es atípico en el ámbito de rs-fMRI aplicada al diagnóstico clínico, excede los valores observados habitualmente en entornos reales, donde la variabilidad interindividual y las limitaciones técnicas reducen la exactitud alcanzable (Aggarwal et al., 2021; Pot et al., 2021).

Estudios han mostrado que la selección de ROIs específicos optimiza el desempeño de los modelos y favorece la detección del TDAH sin necesidad de procesar la totalidad de las regiones de un Atlas (Shoeibi et al., 2023; Tian et al., 2024). En esta investigación, la selección se hizo con base en la evidencia científica (Cortese et al., 2021; Saad et al., 2022), se emplearon las regiones más afectadas en la fisiopatología del TDAH (alteraciones de conectividad funcional y estructural), que hacen parte de cinco redes (fronto-estriada-talámica, control ejecutivo, atención ventral, saliencia y modo por defecto) que presentan déficit en esta condición clínica del TDAH (Cai et al., 2021; Hilger y Fiebach, 2019).

La elección de estas cinco redes no fue arbitraria, responde a la solidez de la evidencia disponible y al reconocimiento del TDAH como un trastorno heterogéneo, con manifestaciones

clínicas variables (Luo et al., 2019). Se consideraron las estructuras que han mostrado mayor alteración en los nodos críticos que explican la sintomatología del TDAH (Nejati y Ghayerin, 2024; Wang, Zuo, et al., 2021). En algunos casos se seleccionaron regiones bilaterales, cuando los hallazgos demuestran disfunciones simétricas, mientras que en otros se optó por una representación unilateral debido a que la afectación es lateralizada (Yu et al., 2023; Zou y Yang, 2021).

En la red fronto-estriada-talámica, las alteraciones bilaterales en caudado, putamen y tálamo están asociadas con la sintomatología de hiperactividad e impulsividad, estas estructuras modulan la iniciación e inhibición motora y la sensibilidad al refuerzo inmediato (Amen et al., 2021; Fu et al., 2021; Rowe et al., 2025). La red de control ejecutivo, representada por la corteza prefrontal izquierda y derecha, y el lóbulo parietal superior bilateral, se relaciona directamente con la inatención y las fallas en la memoria de trabajo (Friedman et al., 2024). La evidencia muestra una hipoactividad sostenida en estas áreas, lo que limita la capacidad de mantener la atención en tareas prolongadas, organizar información y regular la conducta dirigida a metas (Merzon et al., 2025). La selección de estos ROIs responde a que son los que han mostrado déficits en TDAH, mientras que otras regiones prefrontales presentan hallazgos divergentes dependiendo de la edad, subtipo clínico o comorbilidad (Isaac et al., 2024; Jensen et al., 2022).

En la red de atención ventral, se priorizaron la corteza frontal inferior derecha y la circunvolución supramarginal derecha, regiones con evidencia empírica en estudios de neuroimagen funcional (Gossé et al., 2022; Norman et al., 2024). En el TDAH se presenta primacía de afectación en el hemisferio derecho en estos ROIs (Hai et al., 2022). Esta disfunción se traduce en distractibilidad elevada y dificultades para filtrar estímulos irrelevantes (Alves et al., 2022; Salehinejad et al., 2022). En la red de saliencia, se incluyó la ínsula anterior derecha y el cíngulo anterior bilateral, estas estructuras median el cambio entre estados internos y externos (Bonath et al., 2016; Chiang et al., 2022). La disfunción genera variabilidad atencional y desregulación emocional, dificulta la priorización de información relevante y la transición adecuada entre la red del modo por defecto y la red ejecutiva (Wang, Lin, et al., 2021). La bilateralidad en el cíngulo anterior evidencia que la alteración en el TDAH compromete la integración global del sistema de saliencia, sin limitarse a un único hemisferio (Damiani et al., 2021).

En la red del modo por defecto, se seleccionaron el cíngulo posterior bilateral y el precúneo izquierdo; estructuras que participan en los procesos de autorreferencia, pensamiento espontáneo y monitoreo interno (Harikumar et al., 2021; Rafi et al., 2023). En el TDAH estas regiones presentan una desactivación insuficiente durante la ejecución de tareas cognitivas, lo que se traduce en lapsos atencionales, mente divagante y pensamientos intrusivos (Curtin et al., 2022; Metin et al., 2015).

Los hallazgos de este estudio adquieren un valor interpretativo relevante al ser contextualizados dentro de modelos teóricos sobre la interacción entre redes cerebrales. Una saliencia hipoactiva no logra regular el balance dinámico entre el modo por defecto (interno) y el control ejecutivo (externo), lo que explica la dificultad para mantener el foco atencional en tareas (Suk et al., 2021). La hiperactividad de los circuitos fronto-estriados potencia respuestas rápidas y conductas impulsivas, que se ven exacerbadas cuando la corteza prefrontal no logra modularlas de manera eficaz (Daviddi y Santangelo, 2025). La desregulación entre estas redes explica la presencia de síntomas específicos (inatención o impulsividad) y la variabilidad

interindividual que caracteriza al TDAH desde sus tres presentaciones clínicas (Koirala et al., 2024; Münger et al., 2021).

El uso de CNN en el ámbito clínico representa una ventaja frente a los métodos tradicionales, permite extraer de forma automática patrones espaciales y temporales de alta complejidad en datos de neuroimagen, lo que reduce la dependencia de ingeniería manual de características y minimiza sesgos derivados de la selección subjetiva de variables (Gao et al., 2019; Gülhan y Özmen, 2025; Ji et al., 2021). En esta investigación, la CNN 2D tuvo un desempeño estable, alcanzó un $\text{accuracy}=0.81$ en el conjunto de entrenamiento y 0.77 en el de validación, valores que muestran la capacidad de generalización en muestras clínicas desconocidas.

Limitaciones y Conclusiones

El modelo propuesto se basa en la identificación de patrones multivariados complejos aprendidos a partir de matrices de conectividad funcional, por lo que no se realizan análisis inferenciales grupo a grupo ni mapas diferenciales de conectividad.

El uso de rs-fMRI permitió que la arquitectura basada en CNN identificara patrones de conectividad funcional sin requerir la ejecución de tareas cognitivas, lo que reduce sesgos asociados a la cooperación, comprensión de instrucciones o fatiga en población infantil con TDAH. Esta característica amplía la aplicabilidad metodológica en contextos con recursos clínicos especializados y favorece la obtención de modelos reproducibles y menos dependientes de la valoración subjetiva del evaluador. Sin embargo, los resultados deben interpretarse dentro del marco del repositorio ADHD-200, el cual corresponde a un conjunto de datos de investigación y no a un entorno clínico. Este repositorio no incluye historiales médicos completos ni seguimiento longitudinal, por lo que las conclusiones de la presente investigación muestran patrones neurofuncionales identificados con fines científicos y no sustituyen la evaluación clínica integral.

En este trabajo se emplearon exclusivamente datos del sitio NYU, lo que permitió controlar la variabilidad inter-sitio y reducir el riesgo de sobreajuste, pero limita la generalización de los hallazgos a poblaciones adquiridas bajo otras condiciones de escaneo o contextos clínicos reales. El modelo se centró en una clasificación binaria (TDAH vs control), lo que no captura la heterogeneidad clínica del trastorno ni las distintas presentaciones diagnósticas. Futuras investigaciones deberán incorporar muestras más amplias y heterogéneas, datos longitudinales y arquitecturas híbridas basadas en CNN capaces de integrar múltiples representaciones de conectividad, con el fin de avanzar hacia modelos que permitan la diferenciación entre las presentaciones inatenta, hiperactivo-impulsiva y combinada del TDAH, que faciliten una eventual traslación clínica responsable.

Referencias

- ADHD-200 Consortium. (2011). The ADHD-200 Sample: A Model to Advance the Translational Potential of Neuroimaging in Clinical Neuroscience. *The International Neuroimaging Data-Sharing Initiative*. http://fcon_1000.projects.nitrc.org/indi/adhd200/
- Aggarwal, R., Sounderajah, V., Martin, G., Ting, D. S. W., Karthikesalingam, A., King, D., Ashrafiyan, H., & Darzi, A. (2021). Diagnostic accuracy of deep learning in medical imaging: a systematic review and meta-analysis. *NPJ Digital Medicine*, 4(1), 65. <https://doi.org/10.1038/s41746-021-00438-z>
- Alves, P. N., Forkel, S. J., Corbetta, M., & Thiebaut de Schotten, M. (2022). The subcortical and neurochemical organization of the ventral and dorsal attention networks. *Communications Biology*, 5(1), 1343. <https://doi.org/10.1038/s42003-022-04281-0>
- Amen, D. G., Henderson, T. A., & Newberg, A. (2021). SPECT functional neuroimaging distinguishes adult attention deficit hyperactivity disorder from healthy controls in big data imaging cohorts. *Frontiers in Psychiatry*, 12, 725788. <https://doi.org/10.3389/fpsy.2021.725788>
- American Psychiatric Association. (2024). *DSM-5-TR Manual Diagnóstico y Estadístico de los Trastornos Mentales* (5a. ed., text rev.). Médica Panamericana. <https://doi.org/10.1176/appi.books.9780890425787>
- Avberšek, L. K., & Repovš, G. (2022). Deep learning in neuroimaging data analysis: Applications, challenges, and solutions. *Frontiers in Neuroimaging*, 1, 981642. <https://doi.org/10.3389/fnimg.2022.981642>
- Bellec, P., Chu, C., Chouinard-Decorte, F., Benhajali, Y., Margulies, D. S., & Craddock, R. C. (2017). The Neuro Bureau ADHD-200 Preprocessed Repository. *NeuroImage*, 144(Part. B), 275-286. <https://doi.org/10.1016/j.neuroimage.2016.06.034>
- Blomberg, R., Signoret, C., Danielsson, H., Perini, I., Rönnerberg, J., & Capusan, A. J. (2022). Aberrant resting-state connectivity of auditory, ventral attention/salience and default-mode networks in adults with attention deficit hyperactivity disorder. *Frontiers in Neuroscience*, 16, 972730. <https://doi.org/10.3389/fnins.2022.972730>
- Bonath, B., Tegelbeckers, J., Wilke, M., Flechtner, H.-H., & Krauel, K. (2016). regional gray matter volume differences between adolescents with ADHD and typically developing controls: Further evidence for anterior cingulate involvement. *Journal of Attention Disorders*, 22(7), 627-638. <https://doi.org/10.1177/1087054715619682>
- Bu, X., Xia, M., Cui, Z., & He, Y. (2025). Toward individual heterogeneity and neurobiological subtypes in attention-deficit/hyperactivity disorder. *Journal of Pacific Rim Psychology*, 19, 1-16. <https://doi.org/10.1177/18344909241308101>
- Cai, W., Griffiths, K., Korgaonkar, M. S., Williams, L. M., & Menon, V. (2021). Inhibition-related modulation of salience and frontoparietal networks predicts cognitive control ability and inattention symptoms in children with ADHD. *Molecular Psychiatry*, 26(8), 4016-4025. <https://doi.org/10.1038/s41380-019-0564-4>
- Caraka, R. E., Supardi, K., Gio, P. U., Isnaniawardhani, V., Chen, R. C., Djatmiko, B., & Pardamean, B. (2025). Big data analytics for uncovering voxel connectivity patterns in attention deficit hyperactivity disorder. *Journal of Multidisciplinary Healthcare*, 18, 4411-4430. <https://doi.org/10.2147/JMDH.S523137>

- Chen, H., Yang, Y., Odisho, D., Wu, S., Yi, C., & Oliver, B. G. (2023). Can biomarkers be used to diagnose attention deficit hyperactivity disorder? *Frontiers in Psychiatry*, *14*, 1026616. <https://doi.org/10.3389/fpsy.2023.1026616>
- Chen, L., Yang, Y., Yu, A., Guo, S., Ren, K., Liu, Q., & Qiao, C. (2025). An explainable spatio-temporal graph convolutional network for the biomarkers identification of ADHD. *Biomedical Signal Processing and Control*, *99*, 106913. <https://doi.org/10.1016/j.bspc.2024.106913>
- Chen, M., Li, H., Fan, H., Dillman, J. R., Wang, H., Altaye, M., Zhang, B., Parikh, N. A., & He, L. (2022). ConCeptCNN: A novel multi-filter convolutional neural network for the prediction of neurodevelopmental disorders using brain connectome. *Medical Physics*, *49*(5), 3171-3184. <https://doi.org/10.1002/mp.15545>
- Chiang, H. L., Lin, H. Y., Tseng, W. Y. I., Hwang-Gu, S. L., Shang, C. Y., & Gau, S. S. F. (2022). Neural substrates underpinning intra-individual variability in children with ADHD: A voxel-based morphometry study. *Journal of the Formosan Medical Association*, *121*(2), 546-556. <https://doi.org/10.1016/j.jfma.2021.06.003>
- Cortese, S., Aoki, Y. Y., Itahashi, T., Castellanos, F. X., & Eickhoff, S. B. (2021). Systematic review and meta-analysis: Resting-state functional magnetic resonance imaging studies of attention-deficit/hyperactivity disorder. *Journal of the American Academy of Child & Adolescent Psychiatry*, *60*(1), 61-75. <https://doi.org/10.1016/j.jaac.2020.08.014>
- Curtin, P., Neufeld, J., Curtin, A., Arora, M., & Bölte, S. (2022). Altered periodic dynamics in the default mode network in autism and attention-deficit/hyperactivity disorder. *Biological Psychiatry*, *91*(11), 956-966. <https://doi.org/10.1016/j.biopsych.2022.01.010>
- Damiani, S., Tarchi, L., Scalabrini, A., Marini, S., Provenzani, U., Rocchetti, M., Olivia, F., & Politi, P. (2021). Beneath the surface: Hyper-connectivity between caudate and salience regions in ADHD fMRI at rest. *European Child & Adolescent Psychiatry*, *30*(4), 619-631. <https://doi.org/10.1007/s00787-020-01545-0>
- Daviddi, S., & Santangelo, V. (2025). The neural correlates of response inhibition with and without conflict in ADHD: An activation likelihood estimation meta-analysis. *European Journal of Neuroscience*, *62*(5), e70244. <https://doi.org/10.1111/ejn.70244>
- Dinatolo, M. F., Pur, D. R., Eagleson, R., & de Ribaupierre, S. (2023). The role of blood oxygen level dependent signal variability in pediatric neuroscience: A systematic review. *Life*, *13*(7), 1587. <https://doi.org/10.3390/life13071587>
- Firouzabadi, F. D., Ramezanpour, S., Firouzabadi, M. D., Yousem, I. J., Puts, N. A., & Yousem, D. M. (2022). Neuroimaging in attention-deficit/hyperactivity disorder: Recent advances. *American Journal of Roentgenology*, *218*(2), 321-332. <https://doi.org/10.2214/AJR.21.26316>
- Friedman, L. M., Eckrich, S. J., Rapport, M. D., Bohil, C. J., & Calub, C. (2024). Working and short-term memory in children with ADHD: An examination of prefrontal cortical functioning using functional near-infrared spectroscopy (fNIRS). *Child Neuropsychology*, *30*(3), 462-485. <https://doi.org/10.1080/09297049.2023.2213463>
- Fu, C., Chen, S., Qian, A., Zhou, R., Zhou, J., Li, J., Cheng, J., Yang, C., Zhao, K., & Wang, M. (2021). Larger thalamus correlated with inattentive severity in the inattentive subtype of ADHD without comorbidity. *Psychiatry Research*, *304*, 114079. <https://doi.org/10.1016/j.psychres.2021.114079>

- Furzer, J., Dhuey, E., & Laporte, A. (2022). ADHD misdiagnosis: Causes and mitigators. *Health Economics*, 31(9), 1926-1953. <https://doi.org/10.1002/hec.4555>
- Gao, Y., Shuai, D., Bu, X., Hu, X., Tang, S., Zhang, L., Li, H., Hu, X., Lu, L., Gong, Q., & Huang, X. (2019). Impairments of large-scale functional networks in attention-deficit/hyperactivity disorder: A meta-analysis of resting-state functional connectivity. *Psychological Medicine*, 49(15), 2475-2485. <https://doi.org/10.1017/S003329171900237X>
- Gossé, L. K., Bell, S. W., & Hosseini, S. H. (2022). Functional near-infrared spectroscopy in developmental psychiatry: A review of attention deficit hyperactivity disorder. *European Archives of Psychiatry and Clinical Neuroscience*, 272(2), 273-290. <https://doi.org/10.1007/s00406-021-01288-2>
- Grimm, O., van Rooij, D., Hoogman, M., Klein, M., Buitelaar, J., Franke, B., Reif, A., & Plichta, M. M. (2021). Transdiagnostic neuroimaging of reward system phenotypes in ADHD and comorbid disorders. *Neuroscience & Biobehavioral Reviews*, 128, 165-181. <https://doi.org/10.1016/j.neubiorev.2021.06.025>
- Gülhan, P. G., & Özmen, G. (2025). The Use of fMRI regional analysis to automatically detect ADHD through a 3D CNN-based approach. *Journal of Imaging Informatics in Medicine*, 38(1), 203-216. <https://doi.org/10.1007/s10278-024-01189-5>
- Hai, T., Swansburg, R., Kahl, C. K., Frank, H., Stone, K., Lemay, J.-F., & MacMaster, F. P. (2022). Right superior frontal gyrus cortical thickness in pediatric ADHD. *Journal of Attention Disorders*, 26(14), 1895-1906. <https://doi.org/10.1177/10870547221110918>
- Harikumar, A., Evans, D. W., Dougherty, C. C., Carpenter, K. L., & Michael, A. M. (2021). A review of the default mode network in autism spectrum disorders and attention deficit hyperactivity disorder. *Brain Connectivity*, 11(4), 253-263. <https://doi.org/10.1089/brain.2020.0865>
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H., Brett, M., Haldane, A., Del Río, J. F., Wiebe, M., Peterson, P., Gérard-Marchant, P., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585, 357-362. <https://doi.org/10.1038/s41586-020-2649-2>
- Hilger, K., & Fiebach, C. J. (2019). ADHD symptoms are associated with the modular structure of intrinsic brain networks in a representative sample of healthy adults. *Network Neuroscience*, 3(2), 567-588. https://doi.org/10.1162/netn_a_00083
- Hu, Y., Ran, J., Qiao, R., Xu, J., Tan, C., Hu, L., & Tian, Y. (2024). Identifying ADHD-related abnormal functional connectivity with a graph convolutional neural network. *Neural Plasticity*, 2024(1), 8862647. <https://doi.org/10.1155/2024/8862647>
- Isaac, V., Lopez, V., & Escobar, M. J. (2024). Arousal dysregulation and executive dysfunction in attention deficit hyperactivity disorder (ADHD). *Frontiers in Psychiatry*, 14, 1336040. <https://doi.org/10.3389/fpsy.2023.1336040>
- Jensen, D. A., Lundervold, A. J., Stubberud, J., Halmøy, A., Haavik, J., & Sørensen, L. (2022). Goal management training improves executive control in adults with ADHD: An open trial employing attention network theory to examine effects on attention. *BMC Psychology*, 10(1), 207. <https://doi.org/10.1186/s40359-022-00902-9>

- Ji, J., Xing, X., Yao, Y., Li, J., & Zhang, X. (2021). Convolutional kernels with an element-wise weighting mechanism for identifying abnormal brain connectivity patterns. *Pattern Recognition*, *109*, 107570. <https://doi.org/10.1016/j.patcog.2020.107570>
- Ke, H., Wang, F., Ma, H., & He, Z. (2022). ADHD identification and its interpretation of functional connectivity using deep self-attention factorization. *Knowledge-Based Systems*, *250*, 109082. <https://doi.org/10.1016/j.knosys.2022.109082>
- Kim, B., Park, J., Kim, T., & Kwon, Y. (2023). Finding essential parts of the brain in rs-fMRI can improve ADHD diagnosis using deep learning. *IEEE Access*, *11*, 116065-116075. <https://doi.org/10.1109/ACCESS.2023.3324670>
- Koirala, S., Grimsrud, G., Mooney, M. A., Larsen, B., Feczko, E., Elison, J. T., Nelson, S. M., Nigg, J. T., Tervo-Clemmens, B., & Fair, D. A. (2024). Neurobiology of attention-deficit hyperactivity disorder: Historical challenges and emerging frontiers. *Nature Reviews Neuroscience*, *25*(12), 759-775. <https://doi.org/10.1038/s41583-024-00869-z>
- Kulkarni, V., Nemade, B., Patel, S., Patel, K., & Velpula, S. (2024). A short report on ADHD detection using convolutional neural networks. *Frontiers in Psychiatry*, *15*, 1426155. <https://doi.org/10.3389/fpsy.2024.1426155>
- Li, Y., Zeng, W., Dong, W., Cai, L., Wang, L., Chen, H., Yan, H., Bian, L., & Wang, N. (2025). MHNet: Multi-view high-order network for diagnosing neurodevelopmental disorders using resting-state fMRI. *Journal of Imaging Informatics in Medicine*, *38*, 2494-3014. <https://doi.org/10.1007/s10278-025-01399-5>
- Luo, Y., Chen, Q., Li, F., Yi, L., Xu, P., & Zhang, Y. (2025). Hierarchical feature extraction on functional brain networks for autism spectrum disorder identification with resting-state fMRI data. *Neural Networks*, *188*, 107450. <https://doi.org/10.1016/j.neunet.2025.107450>
- Luo, Y., Weibman, D., Halperin, J. M., & Li, X. (2019). A Review of heterogeneity in attention deficit/hyperactivity disorder (ADHD). *Frontiers in Human Neuroscience*, *13*, 1-12. <https://doi.org/10.3389/fnhum.2019.00042>
- Merzon, L., Tauriainen, S., Triana, A., Nurmi, T., Huhdanpää, H., Mannerkoski, M., Aronen, E. T., Kantonistov, M., Henriksson, L., Macaluso, E., & Salmi, J. (2025). Real-world goal-directed behavior reveals aberrant functional brain connectivity in children with ADHD. *PLOS ONE*, *20*(3), e0319746. <https://doi.org/10.1371/journal.pone.0319746>
- Metin, B., Krebs, R. M., Wiersma, J. R., Verguts, T., Gasthuys, R., van der Meere, J. J., Achten, E., Roeyers, H., & Sonuga-Barke, E. (2015). Dysfunctional modulation of default mode network activity in attention-deficit/hyperactivity disorder. *Journal of Abnormal Psychology*, *124*(1), 208-214. <https://doi.org/10.1037/abn0000013>
- Münger, M., Candrian, G., Kasper, J., Abdel-Rehim, H., Eich, D., Müller, A., & Jäncke, L. (2021). Behavioral and neurophysiological markers of ADHD in children, adolescents, and adults: A large-scale clinical study. *Clinical EEG and Neuroscience*, *52*(5), 311-320. <https://doi.org/10.1177/1550059421993340>
- Nejati, V., & Ghayerin, E. (2024). Abnormal structure and function of parietal lobe in individuals with attention deficit hyperactivity disorder (ADHD): A systematic review study. *Basic and Clinical Neuroscience*, *15*(2), 147. <https://doi.org/10.32598/bcn.2022.2843.1>
- Norman, L. J., Sudre, G., Price, J., & Shaw, P. (2024). Subcortico-cortical dysconnectivity in ADHD: A voxel-wise mega-analysis across multiple cohorts. *American Journal of Psychiatry*, *181*(6), 553-562. <https://doi.org/10.1176/appi.ajp.20230026>

- Parlatini, V., Bellato, A., Gabellone, A., Margari, L., Marzulli, L., Matera, E., Petruzzelli, M. G., Solmi, M., Correll, C. U., & Cortese, S. (2024). A state-of-the-art overview of candidate diagnostic biomarkers for Attention-deficit/hyperactivity disorder (ADHD). *Expert Review of Molecular Diagnostics*, 24(4), 259-271. <https://doi.org/10.1080/14737159.2024.2333277>
- Parlatini, V., Itahashi, T., Lee, Y., Liu, S., Nguyen, T. T., Aoki, Y. Y., Forkel, S. J., Catani, M., Rubia, K., Zhou, J. H., Murphy, D. G., & Cortese, S. (2023). White matter alterations in attention-deficit/hyperactivity disorder (ADHD): A systematic review of 129 diffusion imaging studies with meta-analysis. *Molecular Psychiatry*, 28(10), 4098-4123. <https://doi.org/10.1038/s41380-023-02173-1>
- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., Killeen, T., Lin, Z., Gimelshein, N., Antiga, L., Desmaison, A., Köpf, A., Yang, E., De Vito, Z., Raison, M., Tejani, A., Chilamkurthy, S., Steiner, B., Fang, L., Bai, J., & Chintala, S. (2019). PyTorch: An imperative style, high-performance deep learning library. In H. Wallach, H. Larochelle, A. Beygelzimer, F. d'Alché-Buc, E. Fox, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 32, pp. 8026–8037). Curran Associates, Inc. <https://papers.nips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830. <http://jmlr.org/papers/v12/pedregosa11a.html>
- Peñuelas-Calvo, I., Palomar-Ciria, N., Porrás-Segovia, A., Miguélez-Fernández, C., Baltasar-Tello, I., Pérez-Colmenero, S., Delgado-Gómez, D., Carballo, J.J., & Baca-García, E. (2021). Impact of ADHD symptoms on family functioning, family burden and parents' quality of life in a hospital area in Spain. *The European Journal of Psychiatry*, 35(3), 166-172. <https://doi.org/10.1016/j.ejpsy.2020.10.003>
- Popit, S., Serod, K., Locatelli, I., & Stuhec, M. (2024). Prevalence of attention-deficit hyperactivity disorder (ADHD): systematic review and meta-analysis. *European Psychiatry*, 67(1), e68. <https://doi.org/10.1192/j.eurpsy.2024.1786>
- Pot, M., Kieusseyan, N., & Prainsack, B. (2021). Not all biases are bad: equitable and inequitable biases in machine learning and radiology. *Insights Into Imaging*, 12(1), 13. <https://doi.org/10.1186/s13244-020-00955-7>
- Purwono, P., Ma'arif, A., Rahmaniar, W., Fathurrahman, H. I. K., Frisky, A. Z. K., & ul Haq, Q. M. (2022). Understanding of Convolutional Neural Network (CNN): A review. *International Journal of Robotics and Control Systems*, 2(4), 739-748. <https://doi.org/10.31763/ijrcs.v2i4.888>
- Quintero-López, C., Vera, V. D. G., Bernal, R. M. C., & Martínez, M. H. (2024). Predicción del TDAH con aprendizaje de máquinas: Revisión sistemática de literatura. *Revista Argentina de Ciencias del Comportamiento*, 16(3), 14-32. <https://doi.org/10.32348/1852.4206.v16.n3.42221>

- Rafi, H., Murray, R., Delavari, F., Perroud, N., Vuilleumier, P., Debbané, M., & Piguet, C. (2023). Neural basis of internal attention in adults with pure and comorbid ADHD. *Journal of Attention Disorders*, 27(4), 423-436. <https://doi.org/10.1177/10870547221147546>
- Reback, J., McKinney, W., jbrockmendel., Van den Bossche, J., Augspurger, T., Cloud, P., gfyong, Sinhrks, Klein, A., Hawkins, S., Roeschke, M., Tratner, J., She, C., Ayd, W., Petersen, T., MolsBestFriend, Garcia, M., Schendel, J. Hayden, A., Jancauskas, V. ... & Winkel, M. (2020). *pandas-dev/pandas: Pandas 1.0.5*. [software]. Zenodo. <https://doi.org/10.5281/zenodo.3898987>
- Rowe, M. A., Leopold, D. R., Hegarty, A. K., Cutting, L. E., Petrill, S. A., Thompson, L. A., Willcutt, E. G., & Banich, M. T. (2025). Investigating the shared and divergent neuroanatomical features of attentional deficits in adolescents. *Journal of the American Academy of Child and Adolescent Psychiatry*, 65, 818-827. Advance online publication. <https://doi.org/10.1016/j.jaac.2025.05.006>
- Saad, J. F., Griffiths, K. R., Kohn, M. R., Braund, T. A., Clarke, S., Williams, L. M., & Korgaonkar, M. S. (2022). Intrinsic functional connectivity in the default mode network differentiates the combined and inattentive attention deficit hyperactivity disorder types. *Frontiers in Human Neuroscience*, 16, 859538. <https://doi.org/10.3389/fnhum.2022.859538>
- Sadek, J. (2023). Attention deficit hyperactivity disorder misdiagnosis: Why medical evaluation should be a part of ADHD assessment. *Brain Sciences*, 13(11), 1522. <https://doi.org/10.3390/brainsci13111522>
- Salehinejad, M. A., Ghanavati, E., Glinski, B., Hallajian, A. H., & Azarkolah, A. (2022). A systematic review of randomized controlled trials on efficacy and safety of transcranial direct current stimulation in major neurodevelopmental disorders: ADHD, autism, and dyslexia. *Brain and Behavior*, 12(9), e2724. <https://doi.org/10.1002/brb3.2724>
- Sanaat, A., Shiri, I., Ferdowsi, S., Arabi, H., & Zaidi, H. (2022). Robust-Deep: A method for increasing brain imaging datasets to improve deep learning models' performance and robustness. *Journal of Digital Imaging*, 35(3), 469-481. <https://doi.org/10.1007/s10278-021-00536-0>
- Schleim, S. (2022). Why mental disorders are brain disorders. And why they are not: ADHD and the challenges of heterogeneity and reification. *Frontiers in Psychiatry*, 13, 943049. <https://doi.org/10.3389/fpsy.2022.943049>
- Shoeibi, A., Ghassemi, N., Khodatars, M., Moridian, P., Khosravi, A., Zare, A., Gorriz, J. M., Chale-Chale, A. H., Khadem, A., & Acharya, U. R. (2023). Automatic diagnosis of schizophrenia and attention deficit hyperactivity disorder in rs-fMRI modality using convolutional autoencoder model and interval type-2 fuzzy regression. *Cognitive Neurodynamics*, 17, 1501-1523. <https://doi.org/10.1007/s11571-022-09897-w>
- Suk, J. W., Hwang, S., & Cheong, C. (2021). Functional and structural alteration of default mode, executive control, and salience networks in alcohol use disorder. *Frontiers in Psychiatry*, 12, 742228. <https://doi.org/10.3389/fpsy.2021.742228>
- Taspinar, G., & Ozkurt, N. (2024). A review of ADHD detection studies with machine learning methods using rsfMRI data. *NMR in Biomedicine*, 37(8), e5138. <https://doi.org/10.1002/nbm.5138>
- Tao, J., Jiang, X., Wang, X., Liu, H., Qian, A., Yang, C., Chen, H., Li, J., Ye, Q., Wang, J., & Wang, M. (2017). Disrupted control-related functional brain networks in drug-naive

- children with attention-deficit/hyperactivity disorder. *Frontiers in Psychiatry*, 8, 246. <https://doi.org/10.3389/fpsy.2017.00246>
- Tian, L., Zheng, H., Zhang, K., Qiu, J., Song, X., Li, S., Zeng, Z., Ran, B., Deng, X., & Cai, J. (2024). Structural or/and functional MRI-based machine learning techniques for attention-deficit/hyperactivity disorder diagnosis: A systematic review and meta-analysis. *Journal of Affective Disorders*, 355, 459-469. <https://doi.org/10.1016/j.jad.2024.03.111>
- Tran, A. T., Zeevi, T., & Payabvash, S. (2025). Strategies to improve the robustness and generalizability of deep learning segmentation and classification in neuroimaging. *BioMedInformatics*, 5(2), 20. <https://doi.org/10.3390/biomedinformatics5020020>
- Tzourio-Mazoyer, N., Landeau, B., Papathanassiou, D., Crivello, F., Etard, O., Delcroix, N., Mazoyer, B., & Joliot, M. (2002). Automated anatomical labeling of activations in SPM using a macroscopic anatomical parcellation of the MNI MRI single-subject brain. *NeuroImage*, 15(1), 273-289. <https://doi.org/10.1006/nimg.2001.0978>
- Van Rossum, G., & Drake, F. L. (2009). *Python 3 Reference Manual*. CreateSpace.
- Vu, T., Belussi, A., Migliorini, S., & Eldway, A. (2020). Using deep learning for big spatial data partitioning. *ACM Transactions on Spatial Algorithms and Systems (TSAS)*, 7(1), 1-37. <https://doi.org/10.1145/3402126>
- Wang, L.J., Lin, L.C., Lee, S.Y., Wu, C.C., Chou, W.J., Hsu, C.F., Tseng, H. H., & Lin, W.C. (2021). L-Cystine is associated with the dysconnectivity of the default-mode network and salience network in attention-deficit/hyperactivity disorder. *Psychoneuroendocrinology*, 125, 105105. <https://doi.org/10.1016/j.psyneuen.2020.105105>
- Wang, Q., Zhao, C., Qiu, J., & Lu, W. (2023). Two neurosubtypes of ADHD different from the clinical phenotypes. *Psychiatry Research*, 328, 115453. <https://doi.org/10.1016/j.psychres.2023.115453>
- Wang, Y., Zuo, C., Xu, Q., Hao, L., & Zhang, Y. (2021). Attention-deficit/hyperactivity disorder is characterized by a delay in subcortical maturation. *Progress in Neuro-Psychopharmacology and Biological Psychiatry*, 104, 110044. <https://doi.org/10.1016/j.pnpbp.2020.110044>
- Xue, Y., Zhou, Y., Na, X., Ou, X., & Liu, Y. (2025). ADHD diagnostics and severity assessment using topological manifold learning of resting-state functional magnetic resonance imaging (rs-fMRI). *Neuroimage: Reports*, 5(3), 100283. <https://doi.org/10.1016/j.ynirp.2025.100283>
- Yu, M., Gao, X., Niu, X., Zhang, M., Yang, Z., Han, S., Cheng, J., & Zhang, Y. (2023). Meta-analysis of structural and functional alterations of brain in patients with attention-deficit/hyperactivity disorder. *Frontiers in Psychiatry*, 13, 1070142. <https://doi.org/10.3389/fpsy.2022.1070142>
- Zaheer, A., & Akhtar, A. (2025). Artificial intelligence as a support to diagnose ADHD: An insight of unorthodox approaches: A scoping review. *Child Neuropsychology*, 31(8), 1324–1358. <https://doi.org/10.1080/09297049.2025.2468411>
- Zhou, J., Jie, B., Wang, Z., Zhang, Z., Du, T., Bian, W., Yang, Y., & Jia, J. (2024). LCGNet: Local sequential feature coupling global representation learning for functional connectivity network analysis with fMRI. *IEEE Transactions on Medical Imaging*, 43(12), 4319-4330. <https://doi.org/10.1109/TMI.2024.3421360>

Zou, H., & Yang, J. (2021). Temporal variability–based functional brain lateralization study in ADHD. *Journal of Attention Disorders*, 25(6), 839-847.
<https://doi.org/10.1177/1087054719859074>

Material suplementario: Código de Python en Google Colaboratory
<https://colab.research.google.com/drive/16DQJkYHiEufjcosN-JoVIFRxbov5zxw3?usp=sharing>