

**Predicción del TDAH con Aprendizaje de Máquinas:
Revisión Sistemática de Literatura**

Agosto 2024, Vol. 16,
N°3, 14-32

revistas.unc.edu.ar/index.php/racc

Quintero López, Catalina^a; Gil Vera, Víctor Daniel^b; Cerpa Bernal, Rafael Mauricio^c; Herrera Martínez, Marcelo^d

Artículo de Revisión

Resumen	Abstract	Tabla de Contenido
<p>El Trastorno por Déficit de Atención e Hiperactividad (TDAH) tiene una prevalencia estimada del 5.3% en la población mundial; su diagnóstico se basa en evaluaciones clínicas, conductuales y resultados de pruebas psicométricas. Recientemente el Aprendizaje de Máquinas (AM) se ha empleado para detectar diversas condiciones neuropsiquiátricas, brindando una mayor precisión diagnóstica. El objetivo de este estudio fue realizar una revisión sistemática de la literatura (RSL) sobre la detección del TDAH en infantes con AM. Con base en la metodología PRISMA, se seleccionaron 30 publicaciones de Web of Science (WoS) y Scopus, que cumplieron los criterios de elegibilidad. Se concluye que la técnica más empleada para detectar el TDAH fue Máquinas de Vectores de Soporte, el modelo con el mejor desempeño se obtuvo de pruebas psicométricas. Un diagnóstico certero y temprano del TDAH previene complicaciones a largo plazo, problemas emocionales, académicos y sociales, así como el desarrollo de una estructura antisocial.</p> <p><i>Palabras clave:</i> aprendizaje de máquinas, diagnóstico, modelado predictivo, TDAH</p>	<p>Prediction of ADHD with Machine Learning: A Systematic Literature Review. Attention Deficit Hyperactivity Disorder (ADHD) has an estimated prevalence of 5.3% in the world population; its diagnosis is based on clinical and behavioral assessments and psychometric test results. Recently, Machine Learning (ML) has been used to detect various neuropsychiatric conditions, providing greater diagnostic accuracy. This work aimed to conduct a systematic literature review (SLR) on detecting ADHD in infants with MA. Based on the PRISMA methodology, 30 publications were selected from Web of Science (WoS) and Scopus, which met the eligibility criteria. This paper concludes that the most used technique to detect ADHD was Support Vector Machines, the model with the best performance was obtained from psychometric tests. An accurate and early diagnosis of ADHD prevents long-term complications, emotional, academic, and social problems, as well as the development of an antisocial structure.</p> <p><i>Keywords:</i> Palabras separadas por comas machine learning, diagnosis, predictive modeling, ADHD</p>	<p>Introducción 14 Método 17 Resultados 22 Discusión 23 Financiamiento 27 Referencias 27</p>

Recibido el: 10 de agosto de 2023; Aceptado el 19 de diciembre 2023
 Editaron este artículo: Ana García Coni, Debora Mola, Emilia Musso y Leandro Morales

El Trastorno por Déficit de Atención e Hiperactividad (TDAH) pertenece a las nosologías del desarrollo neurológico, se evidencia desde la edad preescolar y persiste en la adultez; esta condición clínica impacta de manera negativa en la funcionalidad de las habilidades adaptativas en el contexto familiar, académico y social; se asocia con dificultades atencionales y comportamientos hiperactivos-impulsivos (Parke et al., 2021; Scandurra et al., 2019). Las dificultades atencionales generan incapacidad para seguir instrucciones, ejecutar y culminar tareas cotidianas; los niños con esta condición clínica presentan inconvenientes para

^aUniversidad Católica Luis Amigó, Facultad de Ciencias Sociales Salud y Bienestar, Grupo de Investigación en Neurociencias Básicas y Aplicadas (NBA), Medellín, Colombia.
^bUniversidad Católica Luis Amigó, Facultad de Ingenierías y Arquitectura, Medellín, Colombia.
^cUniversidad San Buenaventura, Facultad de Ingeniería, Bogotá, Colombia.
^dUniversidad San Buenaventura, Doctorado en Neurociencia Aplicada y Comportamiento, Grupo de Investigación Acústica Aplicada, Bogotá, Colombia.
 *Enviar correspondencia a: Quintero López, C. E-mail: catalina.quintero@amigo.edu.com

Citar este artículo como: Quintero López, C., & Gil Vera, V., & Cerpa Bernal, R., & Herrera Martínez, M. (2023). Predicción del TDAH con Aprendizaje de Máquinas: Revisión Sistemática de Literatura. *Revista Argentina de Ciencias del Comportamiento*, 16(3), 14-32.

escuchar, pierden objetos frecuentemente, se dispersan con facilidad y muestran poca capacidad de organización (Martella et al., 2020); los comportamientos hiperactivos-impulsivos implican síntomas como: excesiva actividad, ineptitud para mantener la quietud o esperar por determinado tiempo, intromisión inoportuna en actividades sin que llegue su turno; las manifestaciones clínicas tienen la tendencia a exacerbase ante tareas, actividades o situaciones que sean valoradas como displacenteras e impliquen un esfuerzo mental (American Psychiatric Association [APA], 2021; González & Depaula, 2023).

El Manual Diagnóstico y Estadístico de los Trastornos Mentales [DSM-VTR] (APA, 2021), plantea tres presentaciones del TDAH: predominancia inatento (se caracteriza por problemas para focalizar/mantener la concentración y pérdida del enfoque para la ejecución de labores específicas; los niños con esta predominancia son distraídos, olvidadizos y tienen dificultades para seguir instrucciones); predominancia hiperactiva-impulsiva (presentan exacerbación de la energía física y mental, inquietud e impulsividad, dificultad para esperar turnos, tendencia a interrumpir a los demás y no controlar su comportamiento); predominancia combinada (se caracteriza por presentar manifestaciones clínicas de desatención, exacerbación motora e impulsividad; pueden aparecer conflictos para el mantenimiento atencional y vigilancia comportamental).

Aunque el TDAH tiene un origen biológico esencial, se debe considerar la influencia de los componentes socioambientales en la exacerbación o atenuación sintomática (Dawson et al., 2019). Se ha indicado que es una condición multicausal y heterogénea (Weiss et al., 2023); la evidencia empírica señala cierto grado de heredabilidad con una variabilidad del 50% al 78%. Dentro de los predisponentes relacionados con agentes químicos se encuentran la exposición al tabaco o al alcohol durante la gestación, y el tratamiento farmacológico (benzodiazepinas o anticonvulsivantes); otra causa es el peso deficiente al nacer y prematuridad (Baker et al., 2023; Brikell et al., 2019). Se ha planteado un tributo genético fundamental en su etiología; al parecer los contrastes de moléculas en los receptores y transportadores dopaminérgicos (D2-D4-D5), la duplicación en el alelo 7 del gen que

produce el receptor dopaminérgico D4, que regula las respuestas intracelulares a dopamina y la duplicación del alelo 10 del transportador DA1, se han relacionado con un aumento en la recaptación neuronal de dopamina, considerados los principales factores genéticos implicados en el TDAH (Mariggió et al., 2021). La neurobiología de este trastorno plantea alteraciones estructurales del cerebro en regiones corticales y subcorticales (Hermosillo et al., 2020). Estudios neurofisiológicos han demostrado un retraso significativo en la maduración cerebral, con un volumen total del 3% al 5% menor que niños con desarrollo típico (Greven et al., 2015).

La prevalencia global estimada del TDAH es del 5.3% (Rae et al., 2015). La frecuencia de esta condición clínica en niños y adolescentes se sitúa entre el 5.9% y el 7.1%, esta variabilidad en las cifras no obedece a diferencias geográficas, temporales o modelos de evaluación, sino a disparidades metodológicas entre los estudios epidemiológicos (Polanczyk et al., 2014).

Teniendo en cuenta este panorama, las tasas de detección del TDAH en comunidades afroamericanas y latinas por lo general son más bajas que en poblaciones caucásicas de Estados Unidos de América, debido a que se etiquetan de manera errónea los síntomas, confundiendo con oposicionismo, perturbación, psicopatía u otros síntomas disruptivos y conductuales (APA, 2021; Fayyad et al., 2017); en cuanto al género se ha planteado que es más frecuente en hombres, la sintomatología de las mujeres se ajusta a una predominancia de inatención (Young et al., 2020).

El TDAH tiene un potencial riesgo de inducir conductas suicidas, especialmente cuando se presenta de manera comórbida con otras condiciones psicológicas, comportamentales o el uso de sustancias psicoactivas (Conejero et al., 2019; Lugoboni & Tinghino, 2022). Según Sordo et al. (2021), es común que infantes que padecen TDAH presenten síntomas de ansiedad, depresión y síndrome de disfunción ejecutiva. El diagnóstico diferencial o doble requiere del cumplimiento de los criterios establecidos, que pueden tener similitud con diversos trastornos del neurodesarrollo, razón que implica que el ejercicio de evaluación sea riguroso; debe considerar el inicio, desarrollo y curso (Hoelzle et al., 2019).

El diagnóstico del TDAH se establece principalmente con evaluaciones clínicas, conductuales y neuropsicológicas; los

especialistas de la salud determinan la presentación del TDAH predominante a partir de los síntomas presentes en el sujeto evaluado. Cada evaluación tiene una duración promedio de dos horas, que suelen estar distribuidas en varias sesiones; sin embargo, este proceso conlleva un desafío debido al desequilibrio existente entre la cantidad de profesionales especializados y el número de niños que requieren evaluación. Esta disparidad, ocasionada por la escasez de expertos capacitados, conduce con frecuencia a demoras en la emisión de diagnósticos (Loh et al., 2022; Whitney & Peterson, 2019).

Además, existe controversia acerca de la posibilidad de diagnósticos erróneos en el TDAH, ya que las manifestaciones clínicas se confunden con otros trastornos del neurodesarrollo o problemas de conducta. El suministro de fármacos estimulantes, como el metilfenidato, también ha generado polémica respecto de que la medicación podría ser innecesaria en algunos niños, e incluso dar lugar a consecuencias negativas en su desarrollo (Furzer et al., 2022; Harrison & Edwards, 2023).

Recientemente, las técnicas basadas en Aprendizaje de Máquinas (AM) se han vuelto populares al detectar diversas condiciones del neurodesarrollo, brindan una mayor precisión en el diagnóstico temprano (Kim et al., 2021; Silva & Graña, 2022; Sundaresan et al., 2021). El AM es un subcampo de la inteligencia artificial que permite identificar automáticamente patrones o tendencias que facilitan la clasificación de datos desconocidos a partir de un conjunto grande de información (Jothi Prabha & Bhargavi, 2019). Los modelos predictivos construidos con técnicas de AM ofrecen la ventaja de no hacer presunciones previas sobre la fuente de los datos, eliminan el sesgo natural asociado al procesamiento realizado por los humanos; brindan mayor especificidad y sensibilidad. Estos modelos tienen la capacidad de clasificar casos en diferentes categorías (sujetos con y sin condiciones clínicas; tipología; nivel de gravedad, etc.), a partir de amplias cantidades de datos que pueden resultar de información cualitativa y cuantitativa; las técnicas de AM identifican en cada categoría patrones o estándares comunes, los cuales constituyen la base de los sistemas de clasificación para predecir el grupo al que pertenecerá un individuo (Burgos & Colliot, 2020).

Son reducidas las revisiones sistemáticas

de la literatura (RSL) que se han orientado específicamente hacia el estudio de la efectividad de los modelos predictivos de AM para el diagnóstico del TDAH. Estas investigaciones han resaltado la utilidad de ciertos biomarcadores, como las anomalías en la actividad cerebral evaluadas mediante métodos de neuroimagen (Cao et al., 2023; Pereira-Sanchez & Catellanos, 2021; Zhang-James et al., 2023). Otros trabajos se han enfocado en evaluar el desempeño de pruebas neurocognitivas en la predicción del TDAH en poblaciones infantiles y adultas (Arpaia et al., 2022; Periyasamy et al., 2021); se destaca entre estas publicaciones una RSL que empleó la integración de múltiples fuentes de datos, como información clínica, genética y ambiental (Loh et al., 2022). Aunque estas revisiones proporcionan conocimiento valioso sobre la eficacia de los modelos predictivos del TDAH y contribuyen al progreso de la investigación en este ámbito, se identificaron ciertas limitaciones, como la imposibilidad de acceder o consultar las bases de datos utilizadas en la construcción y validación de los modelos, que no se especifican las diferentes presentaciones del TDAH para establecer un diagnóstico preciso, y que ningún estudio reporta la validación en diferentes cohortes de pacientes. Estas consideraciones resaltan la necesidad de abordar estos aspectos para fortalecer la robustez y generalización de los modelos predictivos en el contexto del TDAH.

El objetivo de nuestra investigación fue realizar una RSL sobre la detección del TDAH en población infantil usando técnicas de AM. En cada estudio incluido se identificó el tamaño muestral, el rango de edad de las unidades de investigación, la presentación del TDAH, la fuente de los datos, el/los modelos empleados: Máquinas de Vectores de Soporte (MVS), Función de Base Radial de Máquinas de Vectores de Soporte (RBMVS), Aprendizaje Profundo (AP), Redes Neuronales Artificiales (RNA), Árboles de Decisión (AD), Redes Neuronales Convolucionales (RNC), K-Vecinos más cercanos (K-NN), Red de creencias profundas (DBN), Bosques Aleatorios (BA), Análisis Discriminante Lineal (LDA) y Máquina potenciadora de luz Gradiente (LGBM); las métricas de desempeño (*accuracy*, *precisión*, *recall*, *sensibilidad*, *especificidad*, *F1-Score* y *ROC / AUC*) y la forma de validación. Se realizó un análisis de las investigaciones seleccionadas, se identificaron tendencias y vacíos en esta área de

conocimiento. La pregunta de investigación considerada fue: P1. ¿Cómo se ha empleado el AM para predecir TDAH en población infantil? En definitiva, se identificaron investigaciones que señalan la efectividad del AM en la detección temprana del TDAH, entrenaron y validaron modelos de clasificación a partir de datos de diversas fuentes: técnicas de neuroimagen de hiperescaneo

[electroencefalogramas(EEG), resonancias magnéticas (fMRI), espectrograma], actigrafía, acelerómetro, sistemas de realidad virtual, resultados de pruebas psicométricas estandarizadas y datos genéticos (Yeh et al., 2020; Yasumura et al., 2020; Yoo et al., 2020); estos trabajos se han ejecutado en Norteamérica, Europa, Asia y Medio Oriente (Amado-Caballero et al., 2020; Lin et al., 2023; Öztekin et al., 2021). El AM es una herramienta que se ha empleado para el diagnóstico del TDAH, la detección temprana de esta condición clínica posibilita la atención especializada de manera oportuna.

Método

Estrategia de Búsqueda

Con la finalidad de identificar publicaciones científicas sobre modelos de AM para el diagnóstico del TDAH, se hizo una RSL de acuerdo con el protocolo PRISMA (Page et al., 2021). Los repositorios WoS y Scopus fueron empleados para el rastreo de publicaciones; se consideraron artículos desde enero de 2014 hasta junio de 2023; no hubo restricción de idiomas ni de áreas de conocimiento, se incluyeron: medicina, neurociencia, informática, ingeniería, psicología, genética y ciencias sociales. Se hizo uso de los Tesoros: a) APA PsycINFO (2021) de la Asociación Americana de Psicología y b) Tesoro IEEE (IEEE Advancing Technology for Humanity, 2020) de ingeniería y tecnología, para identificar los términos de búsqueda (*keywords*) adecuados. Se presenta la ecuación usada en Scopus (TITLE-ABS-KEY) y WoS (AllFields):

TITLE-ABS-KEY / All Fields (("predictive modelling" OR "machine learning") AND ("ADHD")) AND (LIMIT-TO (PUBSTAGE, "final")) AND (LIMIT-TO (PUBYEAR, 2023) OR LIMIT-TO (PUBYEAR, 2022) OR LIMIT-TO (PUBYEAR, 2021) OR LIMIT-TO (PUBYEAR, 2020) OR LIMIT-TO (PUBYEAR, 2019) OR LIMIT-TO (PUBYEAR, 2018) OR LIMIT-TO (PUBYEAR,

2017) OR LIMIT-TO (PUBYEAR, 2016) OR LIMIT-TO (PUBYEAR, 2015) OR LIMIT-TO (PUBYEAR, 2014)) AND (LIMIT-TO (DOCTYPE , "ar")) AND (LIMIT-TO (SRCTYPE , "j"))

Criterios de Elegibilidad

Para reducir el sesgo en las publicaciones incluidas en la RSL, los siguientes criterios de inclusión se definieron con precisión y rigurosidad: (1) investigaciones estructuradas y empíricas, (2) que se enfocaran en la variable objetivo de estudio (predicción del TDAH con AM en población infantil), (3) que emplearan resultados de pruebas psicométricas, espectrogramas, datos genéticos, fMRI, EEG, actigrafía, acelerómetro o sistema de realidad virtual para entrenar los modelos predictivos, (4) que usaran muestras de entrenamiento/validación, (5) que utilizaran métricas específicas de AM para evaluar el desempeño de los modelos. Se concretaron los sucesivos criterios de exclusión: (1) investigaciones que se enfocaran en la predicción del TDAH con AM en adultos, (2) estudios que no normalizaron la base de datos empleada, (3) investigaciones que se trataran de revisiones de literatura, estudios únicos de caso, memorias de congresos, monografías o manuales técnicos, (4) publicaciones cuya fuente de datos fuera de redes sociales (Twitter / Facebook), (5) investigaciones que no reportaran la edad de los grupos muestrales, (6) investigaciones que reportaran un *Accuracy* < 0.65.

Proceso de Extracción de Datos

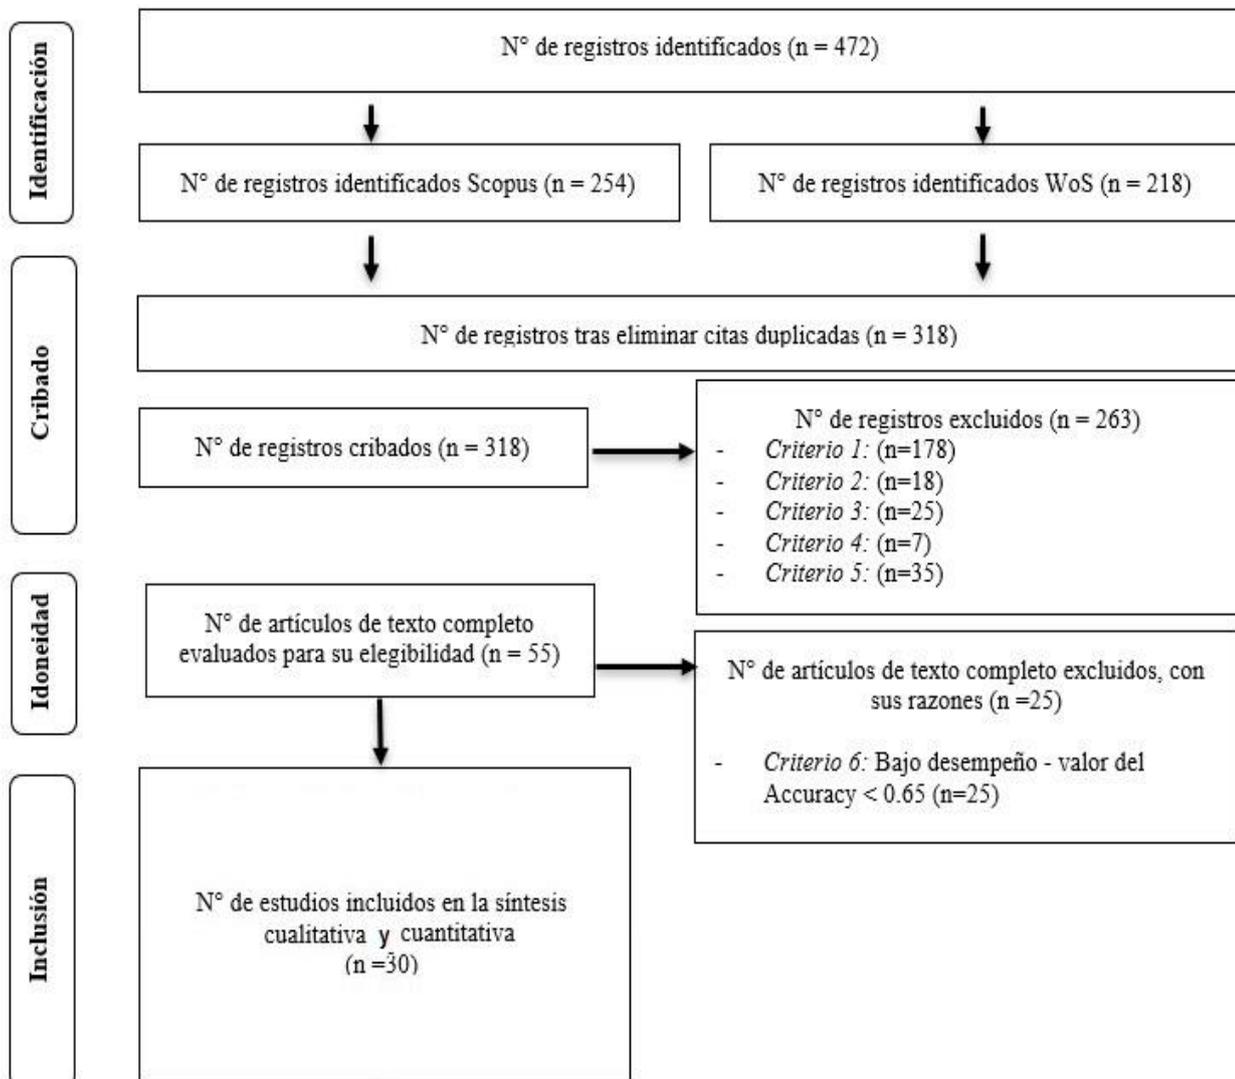
Cuatro revisores se encargaron de seleccionar y recopilar la información de las publicaciones que satisficieron los criterios de elegibilidad; cada uno hizo uso de la lista de chequeo adaptada y construida para garantizar que las publicaciones seleccionadas estuvieran acordes al objeto de estudio de esta RSL (Artrith et al., 2021; Bosch & Guardiola, 2003). Lista de chequeo: (a) diseño del estudio con descripción del planteamiento del problema y criterios de inclusión de los participantes, (b) construcción de los modelos predictivos teniendo en cuenta la variable objetivo, (c) análisis de resultados, centrándose en el desempeño de los modelos, descripción de estadísticos, conclusiones, y (d) interpretación con la generalización de hallazgos, limitaciones y formulación de nuevas hipótesis.

Selección de Estudios

Se identificaron inicialmente 254 publicaciones en Scopus y 218 en WoS, para un total de 472. Se eliminaron 154 duplicados entre las dos bases de datos, y quedaron 318 publicaciones; los cuatro revisores valoraron la pertinencia a partir del objeto de estudio de la RSL con base en: título/resumen/keywords. Consideraron adecuados 55 artículos que cumplieron los criterios de inclusión; descartaron 263 por los criterios de exclusión: criterio 1 = 178 (investigaciones que se enfocaran en la predicción del TDAH con AM en adultos), criterio 2 = 18 (estudios que no normalizaron la base de datos empleada), criterio 3 = 25 (investigaciones que se

trataran de revisiones de literatura, estudios únicos de caso, memorias de congresos, monografías o manuales técnicos), criterio 4 = 7 (publicaciones cuya fuente de datos fuera de redes sociales), criterio 5 = 35 (investigaciones que no reportaran la edad de los grupos muestrales). Posteriormente, se continuó con la lectura de las publicaciones completas y se empleó la lista de chequeo, excluyendo mediante consenso grupal 25 artículos (criterio 6) por tener bajos niveles de precisión (Accuracy < .65). Finalmente, 30 artículos fueron seleccionados para el análisis. La Figura 1 presenta el flujograma PRISMA (Page et al., 2021).

Figura 1.
Flujograma PRISMA



Organización de las Publicaciones

Seleccionadas

La **Tabla 1** presenta las 30 publicaciones seleccionadas; la organización se realizó de acuerdo a la fuente de los datos empleada en cada investigación. La denominación "fuente de datos" hace referencia a la procedencia de la información utilizada en la construcción y validación de los modelos predictivos de AM (Kelleher et al., 2020; Yang et al., 2019). En primer lugar, se presentan 9 estudios que tomaron como fuente de datos pruebas psicométricas cognitivas o clínicas, dirigidas a evaluar funciones ejecutivas, atención, estados emocionales, aspectos conductuales o sintomatología del TDAH. En segundo lugar, se reporta 1 investigación que empleó como fuente de datos

espectrogramas. En tercer lugar, 3 investigaciones que usaron datos genéticos. En cuarto lugar, 9 publicaciones que utilizaron fMRI. En quinto lugar, 1 estudio que utilizó un sistema de realidad virtual. En sexto lugar, 1 publicación que empleó como fuente de datos la actigrafía. En séptimo lugar, 1 investigación que usó acelerómetro y, por último, 5 publicaciones que emplearon EEG. De cada investigación seleccionada, se reportan los autores, el año de publicación, el tamaño muestral, el rango de edad de las unidades de investigación, la presentación del TDAH, la fuente de datos, el/los modelos empleados, las métricas de desempeño y la forma de validación (prueba/entrenamiento)

Tabla 1.
Investigaciones seleccionadas

Autores	Muestra	Rango de Edad (Años)	Presentación del TDAH	Fuente de Datos	Modelo	Métricas	Validación
(Öztekin et al., 2021)	87 TDAH 75 Control	"4-7	SC	BRIEF	MVS	Accuracy=92.6% Precision=94% Recall=91.9% F1-Score=92.9% AUC=0.98	Validación cruzada de 5 veces (CV)
(Slobodin et al., 2020)	213 TDAH 245 Control	"6-12	SC	CPT MOXO	BA	Accuracy=87% Sensibilidad=89% Especificidad=84%	Validación cruzada de 100 capas
(Yasumura et al., 2020)	108 TDAH 108 Control	"8-12	SC	STROOP	MVS	Accuracy=86.3% Sensibilidad=88.71% Especificidad=83.78%	NR
(Bledsoe et al., 2020)	23 TDAH 12 Control	"6-18	Combinado	Conners BASC-2 d2 Atención	MVS AD	Primer Modelo Accuracy = 100% Sensibilidad = 100% Especificidad = 100% Segundo Modelo Accuracy = 97.14% Sensibilidad = 100% Especificidad = 95.65%	LOOCV
(Lin et al., 2023)	328 TDAH- Inatento 239 TDAH- Combinado	"6-17	Inatento Combinado	SNAP-IV Conners	RNA	Accuracy=86,74% Recall=82,00% Precision=80.26%	Validación cruzada de k capas

Continuación...

(Mikolas et al., 2022)	153 TDAH 139 Control	"8-13	Hiperactivo/Impulsivo o Inatento	Conners-3 CBCL TRF SDQ	MVS	Accuracy=66.1% Sensibilidad=66.9% Especificidad=65.4% AUC=0.66	Validación cruzada de 30 veces (CV)
(Duda et al., 2017)	174 TDAH 248 TEA	"2-17	SC	SRS	LDA	Accuracy=82 % AUC=0.96	Validación cruzada de 3 veces (CV)
(Goh et al., 2023)	399 TDAH 399 Control	"7-13	SC	K-SADS ADHD-RS	BA	Accuracy=92% Sensibilidad=97% Especificidad=86%	LOOCV
(Kim et al., 2023)	79 TDAH 1011 Control	"9-11	SC	K-SADS	LGB M	Accuracy=97.3% Sensibilidad=75.6% Especificidad=71.6% AUC=0.79	Entrenamiento 70% Prueba 10% Retención 20%
(Amado-Caballero et al., 2020)	73 TDAH 75 Control	"6-15	Combinado	Espectrograma	RNC	Accuracy=98.6% Sensibilidad=97.62% Especificidad=99.52 % AUC=0.99	Validación cruzada de 10 veces (CV)
(Cervantes-Henríquez et al., 2022)	408 TDAH	"6-18	SC	Datos Genéticos	BA	Accuracy=94.0% Sensibilidad=88.0% Especificidad=98.6% AUC=0.93	Entrenamiento 70% Prueba 30%
(Jung, Mizuno, et al., 2019)	39 TDAH 34 Control	"7-15	SC	Datos Genéticos	MVS	Espesor cortical (mm) Accuracy = 79.4% Sensibilidad = 88.2% Especificidad = 74.3% Superficie (mm²) Accuracy = 73.9% Sensibilidad = 64.7% Especificidad = 69.2% Volumen de materia gris (mm³) Accuracy = 65.7% Sensibilidad = 52.9% Especificidad = 56.4%	Validación cruzada de 10 veces (CV)

Continuación...

(Yoo et al., 2020)	191 TDAH 78 Control	"6-17	Inatento Combinado	Datos Genéticos fMRI	BA	Accuracy=85.1% Sensibilidad=80.9%	Validación cruzada de 10 veces (CV)
(Vaidya et al., 2020)	307 TDAH 240 TEA 465 Control	"8-14	SC	fMRI	MVS	Accuracy=88.9%	Entrenamiento 50% Prueba 50%
(Jung, Tu, et al., 2019)	83 TDAH 86 TEA 125 Control	"7-15	SC	fMRI	MVS	Accuracy=84.1% Sensibilidad=88.8% Especificidad=76.1%	Validación cruzada de 10 veces (CV)
(Deshpande et al., 2015)	433 TDAH 311 Control	"7-17	Inatento Combinado	fMRI	DBN	Accuracy=90.0%	NR
(Du et al., 2016)	118 TDAH 98 Control	"8-14	SC	fMRI	MVS	Accuracy=94.91% Sensibilidad=93.22% Especificidad=96.94% AUC=0.96	LOOCV
(Ghiassian et al., 2016)	769 TDAH 171 Control	"8-15	SC	fMRI	MVS	Accuracy=69.6% Sensibilidad=79.8% Especificidad=57.1%	LOOCV
(Lohani & Rana, 2023)	316 TDAH 316 TDC	"8-15	SC	fMRI	RBMVS	Accuracy=75%	Validación cruzada de 10 veces (CV)
(Zhang et al., 2020)	422 TDAH 597 Control	"7-17	SC	fMRI	RNC	Accuracy=68.6%	LOOCV
(Qureshi et al., 2017)	53 TDAH Inatento 53 TDAH Combinado 53 Control	"7-14	Inatento Combinado	fMRI	MVS	Accuracy=82.14% Sensibilidad=92.85% Especificidad=71.42% AUC=0.83	LOOCV
(Kuang & He, 2014)	349 TDAH 100 Control	"7-15	Inatento Combinado Hiperactivo/Impulsivo	fMRI	MVS	Accuracy=65.37%	NR
(Yeh et al., 2020)	37 TDAH 31 Control	"6-12	SC	Sistema de realidad Virtual	MVS	Accuracy=83.2 %	Validación cruzada de 5 veces (CV)
(Faedda et al., 2016)	44 TDAH 21 TDAH y Depresión 48 TB 42 Control	"5-18	SC	Actigrafía	MVS	Accuracy=83.1% Sensibilidad=64.4% Especificidad=91.7%	Validación cruzada de 4 veces (CV)
(O'Mahony et al., 2014)	24 TDAH 19 Control	"6-11	Combinado	Acelerómetro	MVS	Accuracy = 95.1% Sensibilidad = 94.44% Especificidad = 95.65%	LOOCV

Continuación...

(Tor et al., 2021)	45 TDAH 62 TDAH con TDC 16 TDC	"7-16	SC	EEG	k-NN	Accuracy=97.88% Sensibilidad=96.68% Especificidad=100%	Validación cruzada 10 veces (CV)
(Chang et al., 2022)	30 TDAH 30 Control	"5-12	Inatento Combinado	EEG	AP	Accuracy=90.50%	NR
(Boroujeni et al., 2019)	50 TDAH 26 Control	"4-15	SC	EEG	MVS	Accuracy = 98% Sensibilidad= 88.8% Especificidad=92.31%	Validación cruzada 5 veces (CV)
(Mohammadi et al., 2016)	30 TDAH 30 Control	"7-14	SC	EEG	RNA	Pacientes Clínicos Accuracy=88 % Pacientes No Clínicos Accuracy=96 %	Validación cruzada 10 veces (CV)
(Koh et al., 2022)	45 TDAH 62 TDAH con TDC 16 TDC	"7-16	SC	EEG	AD	Accuracy=87.2% Sensibilidad= 87.71% Especificidad=86.29%	Anidado de 10 veces (CV)

Nota. TEA=Trastorno del Espectro Autista, TDC=Trastorno de Conducta, TB=Trastorno Bipolar, SC=Sin Clasificación, BRIEF=Evaluación Conductual de la Función Ejecutiva, SNAP-IV=Escala para la Detección del TDAH, Conners=Cuestionario de Conducta TDAH, CPT=Prueba continua de rendimiento, MOXO=Prueba de desempeño sostenido, STROOP=Test de colores y palabras, SRS=Escala de receptividad social, K-SADS=Escala para la evaluación de la depresión en niños, ADHD-RS=Escala de posición del TDAH, CBCL=Lista de verificación de comportamiento infantil, TRF=Formulario de informe del profesor, SDQ=Cuestionario de Capacidades y Dificultades en la Infancia, BASC-2= Sistema de evaluación de la conducta de niños y adolescentes, d2 Atención=Test de atención, fMRI= Resonancia Magnética, EEG= Electroencefalograma, MVS=Máquinas de vectores de soporte, RNA=Redes Neuronales Artificiales, BA=Bosques Aleatorios, LDA= Análisis Discriminante Lineal, LGBM=Máquina potenciadora de luz Gradiente, AD=Árboles de Decisión, RNC=Redes Neuronales Convolucionales, DBN=Red de creencias profundas, RBMVS=Función de Base Radial de Máquinas de Vectores de Soporte, K-NN=K- Vecinos más cercanos, AP=Aprendizaje Profundo, CV=Validación Cruzada, NR= No Reporta, LOOCV=Validación cruzada sin exclusión.

Resultados

Los estudios comprendidos en la RSL incluyen características agrupadas en las siguientes categorías: variables de los participantes (tamaño de la muestra, rango de edad, presentación del TDAH), variables metodológicas (fuente de datos, modelo de AM, métricas de desempeño, validación) y variables extrínsecas (autores, año de publicación y país).

Con relación a las variables de los participantes, el 80% de los estudios emplearon muestras de infantes con TDAH y con desarrollo típico, 7 investigaciones contemplaron muestras con otro tipo de nosologías (TEA, TB, TDC) y 3 publicaciones incluyeron muestras con comorbilidad (depresión, TDC). El uso de muestras control y experimental ayuda a

garantizar que los modelos de AM aprendan características generales presentes en la población y capturen las peculiaridades relacionadas con el TDAH (Koppe et al., 2021); al evaluar el modelo con ambos tipos de muestras, se puede determinar su capacidad para generalizar y diagnosticar correctamente casos nuevos, lo que contribuye a su validación y fiabilidad en entornos clínicos (Chekroud et al., 2021). En los estudios seleccionados, la media (\bar{x}) de las marcas de clase de los intervalos de oscilación de las edades fue de 10.5 años; es importante señalar que el diagnóstico del TDAH generalmente se realiza a partir de los 6 años; a esta edad, los patrones de comportamiento y las dificultades de atención o impulsividad se identifican con más claridad; previo a los 6 años, se considera una predisposición diagnóstica

(Holland & Sayal, 2019; Vimalajeewa et al., 2022). De acuerdo con el DSM-VTR, se establece que antes de los 12 años se evidencia la condición clínica (APA, 2021); este marco temporal resalta la importancia de considerar el desarrollo evolutivo al evaluar y diagnosticar.

El TDAH se manifiesta de manera diversa; existen diferentes presentaciones y niveles de gravedad, pues es una condición heterogénea (Mu et al., 2022). Determinar el predominio y gravedad permite a los profesionales de la salud adaptar el plan de tratamiento y la intervención de acuerdo a los síntomas y necesidades específicas (Cortese, 2022; Quintero-López et al., 2023). Solo el 44.44% de los artículos seleccionados reportaron la presentación del TDAH en las muestras que emplearon para la construcción de los modelos predictivos: inatento-6, combinado-9, hiperactivo/impulsivo-2 (Chang et al., 2022; Kuang & He, 2014; Qureshi et al., 2017).

De las variables metodológicas, la fuente de datos del 33.33% de los estudios fue fMRI; la técnica de AM utilizada en el 50% de los artículos seleccionados fue MVS; en estos, los datos empleados para la construcción de los modelos fueron de diversas fuentes (pruebas psicométricas estandarizadas=4, sistema de realidad virtual=1, actigrafía=1, acelerómetro=1, datos genéticos=1, EEG=1, fMRI=6); los modelos con MVS manejan eficazmente conjuntos de datos complejos, identifican patrones de condiciones clínicas, son menos propensos al sobreajuste (adaptación excesiva de un modelo a los datos de entrenamiento ocasiona un rendimiento deficiente en datos no vistos) (Wang & Chen, 2020). Catorce investigaciones usaron la validación cruzada (46.66%), esta evalúa de manera confiable la eficacia de los modelos de AM para predecir el TDAH, condición clínica que presenta síntomas heterogéneos y alta variabilidad entre los individuos que la padecen; además, proporciona una evaluación certera, evita el sobreajuste y permite generalizar a datos no utilizados durante el entrenamiento (Amado-Caballero et al., 2020; Boroujeni et al., 2019; Tor et al., 2021). El estudio realizado por Bledsoe et al. (2020) obtuvo un Accuracy, una especificidad y una sensibilidad del 100%, hizo uso de instrumentos psicométricos ampliamente utilizados en el ámbito clínico/científico, con adecuada validez y confiabilidad: Conners - Alfa de Cronbach [.77-.94], validez factorial con un índice de ajuste

comparativo superior a .90; BASC- Alfa de Cronbach [.81-.88]; d2 - Alfa de Cronbach [.80-.96] (Baghaei et al., 2019; Izzo et al., 2019; Song et al., 2017).

En cuanto a las variables extrínsecas, 30 publicaciones incluidas en la RSL fueron el resultado de colaboraciones entre múltiples autores; de este conjunto, se destaca que tres artículos especifican Harvard Medical School como su afiliación institucional (Faedda et al., 2016; Jung, Mizuno, et al., 2019; Jung, Tu, et al., 2019). Con respecto a la distribución temporal, se encontró que, de los 30 artículos, 8 fueron publicados en el año 2020; al explorar la ubicación geográfica, se constató que Estados Unidos de América lidera con un total de 14 artículos, seguido por Taiwán con 5 y China con 4. Estos hallazgos subrayan la diversidad y el alcance internacional de las contribuciones reportadas en esta revisión.

Discusión

El diagnóstico del TDAH por lo general implica un extenso proceso clínico que incluye entrevistas, aplicación, calificación e interpretación de pruebas psicométricas, psicológicas, comportamentales y neurocognitivas (Ging-Jehli et al., 2021; Martel et al., 2015). Este proceso se ve afectado a nivel mundial por una escasez de especialistas calificados en relación con la demanda de evaluaciones infantiles (Mengi & Malhotra, 2022; Song et al., 2022; Whitney & Peterson, 2019). La presente RSL se enfocó en analizar la efectividad de los modelos de clasificación de AM para predecir el TDAH; la inteligencia artificial en esta categoría podría ofrecer diagnósticos tempranos más precisos, rápidos y eficientes, por lo que representa una solución prometedora para la evaluación infantil.

Dentro del contexto de la salud mental infantil, es importante la definición precisa de la predominancia del TDAH (Inatento, Hiperactivo-Impulsivo o Combinado), así como la identificación de posibles comorbilidades en el proceso diagnóstico; esto permite abordar con eficacia los desafíos particulares que cada paciente enfrenta (Luo et al., 2023). Se ha informado que sólo el 30% de los casos se exhiben de manera pura, en cualquiera de sus presentaciones (Aggensteiner et al., 2019; Harkins et al., 2022); es decir, el TDAH tiene comorbilidad con otras condiciones psicopatológicas (neurodesarrollo/conducta/emocio

nales). Al respecto, el 23.33% de los artículos emplearon muestras de niños con TDAH y otras comorbilidades (TEA, TDC y depresión) (Faedda et al., 2016; Lohani & Rana, 2023; Vaidya et al., 2020).

Los niños que presentan TDAH y TEA exhiben dificultades notorias para estar atentos y concentrados, así como también problemas para regular su comportamiento y emociones; tienen déficits en el establecimiento y mantenimiento de la interacción e interpretación de las señales sociales; les cuesta comprender las respuestas emotivas de los demás y realizar una expresión pertinente de sus emociones; son características las conductas repetitivas o estereotipadas y la sensibilidad a estímulos sensoriales. Son dos entidades del neurodesarrollo con alta heredabilidad, que comparten factores genéticos subyacentes que explican las deficiencias en la funcionalidad ejecutiva y social (Duda et al., 2017; Jung, Mizuno, et al., 2019). El TDC ocasiona patrones conductuales desafiantes, oposicionistas y hostiles con las figuras de autoridad; esta condición clínica genera estados de irritabilidad y malhumor. El doble diagnóstico (TDAH-TDC) se vincula con un mayor detrimento en la funcionalidad social y familiar, los mecanismos subyacentes a la concomitancia de estas nosologías no están completamente comprendidos, se cree que ambos trastornos pueden compartir factores de riesgo genéticos y ambientales (Koh et al., 2022; Tor et al., 2021). Algunos infantes con TDAH experimentan trastornos depresivos debido a deficiencias de madurez cerebral en los procesos de información emocional; se ha propuesto que la sintomatología de depresión en el TDAH afecta negativamente la capacidad para funcionar adecuadamente en los diversos contextos, genera déficits en las respuestas motoras y altera la calidad del sueño (Faedda et al., 2016).

De acuerdo a los 30 artículos seleccionados, el AM empieza a constituirse en una eficaz herramienta de uso diagnóstico. Referente a las variables metodológicas incluidas en la RSL, la detección del TDAH en infantes con técnicas de AM se ha ejecutado mediante variadas fuentes de datos: pruebas psicométricas, técnicas de neuroimagen, actigrafía, acelerómetro, sistemas de realidad virtual y datos genéticos. Existen diferentes pruebas, escalas y tests psicométricos que han empleado los profesionales para

diagnosticar el TDAH. En esta RSL se seleccionaron nueve publicaciones cuyas fuentes de datos fueron pruebas psicométricas; estas investigaciones consideraron múltiples variables e indicadores para mejorar la precisión de los modelos predictivos del TDAH, incorporaron medidas objetivas (pruebas cognitivas) y medidas subjetivas (calificaciones de padres y maestros) para tener una visión integral de los síntomas (Mikolas et al., 2022; Slobodin et al., 2020; Yasumura et al., 2020). Los estudios señalaron la utilidad de los modelos predictivos del TDAH para un diagnóstico temprano y confiable, exploraron la capacidad de generalización de sus hallazgos al considerar diferentes regiones geográficas o poblaciones (Duda et al., 2017; Yasumura et al., 2020). El análisis de AM con indicadores de pruebas cognitivas puede ser útil para diagnosticar y evaluar la gravedad del TDAH en niños, con una tasa de discriminación general de al menos 85% (Goh et al., 2023; Kim et al., 2023; Lin et al., 2023). La inclusión de medidas subjetivas y objetivas mejora la precisión de los modelos del TDAH; la evaluación BRIEF (padres/maestros) contribuye a predecir la categoría diagnóstica con mayor precisión (Öztekin et al., 2021). La combinación de múltiples síntomas en diferentes dominios puede indicar un eventual diagnóstico de TDAH, en lugar de depender únicamente de los principales síntomas informados por maestros y padres (Bledsoe et al., 2020; Lin et al., 2023).

Otro estudio agregado en la RSL fue el de Amado-Caballero et al. (2020), quienes entrenaron una RNC para diagnosticar TDAH de presentación combinada, haciendo uso de espectrogramas, que son una representación visual/auditiva de frecuencias de señales que varían con el tiempo; es una medida no invasiva y asequible. Ejecutaron el estudio en un entorno controlado, obtuvieron un alto desempeño en el despliegue del modelo en comparación con métodos tradicionales (pruebas psicométricas); las ventanas de actividad a mediano plazo fueron más versátiles para encontrar patrones discriminatorios para el diagnóstico del TDAH en actividades diurnas.

En la RSL se incluyeron dos artículos cuya fuente de datos fue información genética (Cervantes-Henríquez et al., 2022; Jung, Mizuno et al., 2019), y una publicación que realizó el entrenamiento con datos genéticos y fMRI (Yoo et

al., 2020). Los hallazgos de estas investigaciones contribuyen a comprender los factores genéticos y neurobiológicos subyacentes al TDAH; brindan información sobre la gravedad de los síntomas y la estructura cerebral de los infantes con este trastorno. Jung, Mizuno, et al. (2019), se centraron en la identificación de síntomas del TDAH a partir de los criterios del DSM-IV (APA, 1994); identificaron la asociación entre los genes ADGRL3-SNAP25 y la gravedad de las manifestaciones clínicas; encontraron que el gen ADGRL3 exacerbaba la sintomatología de hiperactividad e impulsividad, y que la variante del gen SNAP25 (rs362990) se asociaba con la severidad de la impulsividad y la falta de atención. Cervantes-Henríquez et al. (2022) utilizaron el agrupamiento jerárquico y el análisis de covarianza estructural para evaluar la gravedad sintomática del TDAH, encontraron diferencias en la anatomía y organización cerebral de la muestra con TDAH comparada con la de control. La publicación de Yoo et al. (2020) plantea que el TDAH genera deficiencias en las regiones cerebrales sensoriales/motoras e inhibitorias; el modelo de AM que desarrollaron predijo la variación en la severidad clínica del TDAH y tuvo un rendimiento sólido en el conjunto de datos de validación. La fusión de la fuente de los datos de entrenamiento (genéticos/fMRI) no aumentó significativamente la precisión; identificaron variantes genéticas, especialmente polimorfismos, en niños con TDAH de ascendencia europea, marcando contrastes que no se hallaron en la población de asiáticos orientales.

En la RSL se incluyeron 9 artículos cuya fuente de datos era exclusivamente de fMRI; en estos se encontró que la conectividad distribuida en las redes cerebrales en estado de reposo es sensible a las alteraciones de base en el TDAH (Du et al., 2016; Ghiassian et al., 2016; Jung, Tu, et al., 2019). En las fMRI se observó una reducción significativa en la conectividad entre las regiones pulvinar bilateral y las regiones prefrontales derechas, así como un aumento significativo en la conectividad entre el pulvinar derecho y las regiones occipitales bilaterales en las imágenes analizadas de niños con TDAH en comparación con infantes sin este trastorno (Ghiassian et al., 2016). Se identificaron diferencias en la estructura cortical en regiones como el surco superior frontal, la circunvolución precentral y postcentral, el giro temporal medio y

el área fusiforme (Deshpande et al., 2015). De los estudios seleccionados que emplearon fMRI para la construcción de los modelos predictivos, 6 hicieron uso de MVS (Du et al., 2016; Ghiassian et al., 2016; Jung, Tu, et al., 2019; Kuang & He, 2014; Qureshi et al., 2017; Vaidya et al., 2020), uno empleó la técnica de RBMVS (Lohani & Rana, 2023), derivación de la técnica de MVS, uno empleó RNC (Zhang-James et al., 2020) y uno DBN (Deshpande et al., 2015). La técnica de MVS tiene la capacidad de manejar relaciones no lineales entre las frecuencias de activación cerebral y la sintomatología del TDAH; los datos de fMRI generan espacios de características de alta dimensión, cada una de estas representa la actividad cerebral en regiones específicas o vóxeles. En los estudios se identificaron diferencias en el control de algunas variables como la edad, el coeficiente intelectual y el movimiento de la cabeza; esto afectó el desempeño de los modelos diagnósticos (Qureshi et al., 2017; Vaidya et al., 2020; Zhang-James et al., 2020).

El trabajo publicado por Lohani y Rana (2023) identificó posibles biomarcadores de imágenes para el diagnóstico del TDAH. Crearon un conjunto de datos equilibrado de TDAH y niños con desarrollo típico; reportaron características volumétricas basadas en el grosor cortical de las regiones del cerebro; observaron zonas con mayor volumen de materia grisácea y menor engrosamiento. Du et al. (2016) establecieron perfiles de las funciones ejecutivas (flexibilidad emocional, inhibición y metacognición) del TDAH, a partir de fMRI, e indicaron diferencias en la gravedad de los síntomas.

En este estudio se analizó un artículo que empleó un sistema de realidad virtual para la construcción del modelo predictivo (Yeh et al., 2020); encontraron diferencias significativas ($p < .01$) entre la muestra experimental (TDAH) y control en el rendimiento de todas las tareas cognitivas que se ejecutaron por medio de sistemas de realidad virtual; identificaron errores de omisión y comisión en tareas de atención. El modelo que entrenaron tuvo un buen desempeño para evaluar el TDAH, con una alta precisión de clasificación.

En la RSL se incluyó un artículo que empleó actigrafía para la construcción del modelo de AM (Faedda et al., 2016); esta herramienta es un método no invasivo que se utiliza para monitorear

y estudiar los patrones de vigilia/sueño y los rangos de activación física de un individuo durante un período prolongado. Implica usar un pequeño dispositivo que se lleva en la muñeca, conocido como actígrafo, que mide el movimiento y registra datos relacionados con la intensidad y frecuencia de la actividad física. Faedda et al. (2016) reportaron discrepancias significativas en las medidas de actividad entre los infantes: TDAH, TDAH-Depresión, TB y controles; los parámetros de medición mostraron que la mayor diferencia estadística entre los cuatro grupos muestrales fue en la asimetría diurna y en las cinco horas de menor actividad.

Uno de los artículos analizados empleó acelerómetro para la construcción del modelo predictivo (O'Mahony et al., 2014); los investigadores consideraron el comportamiento de los infantes en múltiples contextos (prueba de rendimiento continuo), lo que les permitió aumentar la precisión de la clasificación. A partir de análisis comparativos, este estudio reportó un mejor desempeño por considerar una amplia gama de categorías de funciones (estadísticas básicas, características de dominio de frecuencia y medidas de correlación entre sensores), a diferencia de modelos entrenados con una sola categoría. Los resultados indican que el uso de acelerómetros puede brindar sensibilidad diagnóstica en el TDAH; sin embargo, se necesitan más investigaciones sobre el tema que incluyan muestras de mayor tamaño.

Cinco de los artículos seleccionados en la RSL emplearon EEG para la construcción de los modelos predictivos. Tor et al. (2021) informaron que las señales de EEG se han utilizado ampliamente para la detección automatizada del TDAH, con tasas de precisión de clasificación superiores al 90%; identificaron la presencia de disfunción autonómica en diagnósticos de TDAH. En las publicaciones de Koh et al. (2022) y Boroujeni et al. (2019) utilizaron características no lineales extraídas de señales de EEG para el diagnóstico del TDAH; estas incluyeron las dimensiones de correlación, exponentes de Lyapunov, dimensiones fractales, entropías de muestra/aproximada/difusa; los resultados indicaron diferencias en la actividad cerebral entre TDAH, TDC y grupos controles (sincronización en diferentes regiones y conectividad neuronal). La dimensión de correlación en los canales Fz y FP2 (lóbulo frontal) muestran el mayor porcentaje de

sensibilidad, especificidad y precisión en el diagnóstico y la clasificación del TDAH (Boroujeni et al., 2019). Mohammadi et al. (2016) encontraron que las características no lineales, como la dimensión fractal y la entropía aproximada, son apropiadas para analizar y caracterizar las señales de EEG en el TDAH; señalaron que el sistema cerebral de los diagnósticos de TDAH es más complejo e irregular en comparación con infantes con desarrollo típico. El análisis de características no lineales en el EEG para la predicción del TDAH es un campo de investigación en desarrollo, aún no se han establecido características específicas que sean consideradas como biomarcadores definitivos para su diagnóstico. Chang et al., (2022) mostraron que la actividad de potencia beta de los sitios O1 y O2 contribuye a la clasificación del TDAH, los casos exhibieron una disminución de la potencia beta y tuvieron menor rendimiento en el estado de activación tarea cognitiva.

A partir del análisis se identificó que los modelos de AM superan la subjetividad de los métodos tradicionales de diagnóstico, proporcionan evaluaciones objetivas del TDAH, ofrecen ventajas como mayor eficiencia y facilidad de administración. Algunos de los estudios seleccionados presentan limitaciones como: pequeños tamaños muestrales, no haber reportado la presentación del TDAH ni el software empleado para la construcción de los modelos. Los estudios de fMRI y EEG han proporcionado valiosas contribuciones para comprender la base neurobiológica del TDAH; no obstante, la heterogeneidad del trastorno y las restricciones de las técnicas de neuroimagen hacen que los resultados no sean completamente consistentes en todas las investigaciones. Además, la variabilidad del TDAH representa un desafío significativo, todos los estudios de AM que se enfocan en el diagnóstico deberían considerar las diversas manifestaciones clínicas y cognitivas de esta nosología, así como sus diferentes presentaciones; esto permitiría la generalización de los resultados a toda la población de pacientes con TDAH. Otro limitante identificado en los estudios es la no validación de los modelos de AM en diferentes cohortes de pacientes, lo que impide evaluar su robustez y capacidad diagnóstica; la replicación de los hallazgos en diferentes poblaciones es esencial para determinar su utilidad clínica.

Sería deseable que futuros trabajos se enfoquen en construir modelos de AM para diagnosticar TDAH integrando datos de diversas fuentes (actigrafía, espectrograma, pruebas psicométricas, fMRI, EEG, datos genéticos y sistemas de realidad virtual). Es necesaria más investigación científica para validar y expandir el uso del AM en el campo clínico neuropsiquiátrico.

Fuentes de financiamiento

Este trabajo ha sido realizado con el aporte de Subsidios de la Universidad Católica Luis Amigó. Centro de Costos N° 05020299152.

Referencias

- Aggensteiner, P. M., Brandeis, D., Millenet, S., Hohmann, S., Ruckes, C., Beuth, S., Albrecht, B., Schmitt, G., Schermuly, S., Wörz, S., Gevensleben, H., Freitag, C. M., Banaschewski, T., Rothenberger, A., Strehl, U., & Holtmann, M. (2019). Slow cortical potentials neurofeedback in children with ADHD: comorbidity, self-regulation and clinical outcomes 6 months after treatment in a multicenter randomized controlled trial. *European Child & Adolescent Psychiatry*, 28, 1087-1095. <https://doi.org/10.1007/s00787-018-01271-8>
- *Amado-Caballero, P., Casaseca-De-La-Higuera, P., Alberola-Lopez, S., Andres-De-Llano, J. M., Villalobos, J. A. L., Garmendia-Leiza, J. R., & Alberola-Lopez, C. (2020). Objective ADHD Diagnosis Using Convolutional Neural Networks over Daily-Life Activity Records. *IEEE Journal of Biomedical and Health Informatics*, 24(9), 2690–2700. <https://doi.org/10.1109/JBHI.2020.2964072>
- American Psychiatric Association (2021). *Diagnostic and Statistical Manual of Mental Disorders DSM-5-TRTM (5th Ed., Text Revision)*. Editorial Médica Panamericana.
- American Psychiatric Association (1994). *Diagnostic and Statistical Manual of Mental Disorders DSM-4 (4th Ed.)*. American Psychiatric Publishing, Inc.
- APA PsycInfo (2021). Thesaurus of Psychological Index Terms. <https://www.apa.org/pubs/databases/training/thesaurus>
- Arpaia, P., Covino, A., Cristaldi, L., Frosolone, M., Gargiulo, L., Mancino, F., Mantile, F., & Moccaldi, N. (2022). A systematic review on feature extraction in electroencephalography-based diagnostics and therapy in attention deficit hyperactivity disorder. *Sensors*, 22(13), Artículo 4934. <https://doi.org/10.3390/s22134934>
- Artrith, N., Butler, K. T., Coudert, F. X., Han, S., Isayev, O., Jain, A., & Walsh, A. (2021). Best practices in machine learning for chemistry. *Nature Chemistry*, 13, 505-508. <https://doi.org/10.1038/s41557-021-00716-z>
- Baghaei, P., Ravand, H., & Nadri, M. (2019). Is the d2 test of attention Rasch scalable? Analysis with the Rasch Poisson counts model. *Perceptual and Motor Skills*, 126(1), 70-86. <https://doi.org/10.1177/0031512518812183>
- Baker, B. H., Joo, Y. Y., Park, J., Cha, J., Baccarelli, A. A., & Posner, J. (2023). Maternal age at birth and child attention-deficit hyperactivity disorder: causal association or familial confounding? *Journal of Child Psychology and Psychiatry*, 64(2), 299-310. <https://doi.org/10.1111/jcpp.13726>
- *Bledsoe, J. C., Xiao, C., Chaovallitwongse, A., Mehta, S., Grabowski, T. J., Semrud-Clikeman, M., Pliszka, S., & Breiger, D. (2020). Diagnostic Classification of ADHD Versus Control: Support Vector Machine Classification Using Brief Neuropsychological Assessment. *Journal of Attention Disorders*, 24(11), 1547–1556. <https://doi.org/10.1177/1087054716649666>
- *Boroujeni, Y. K., Rastegari, A. A., & Khodadadi, H. (2019). Diagnosis of attention deficit hyperactivity disorder using non-linear analysis of the EEG signal. *IET Systems Biology*, 13(5), 260–266. <https://doi.org/10.1049/iet-syb.2018.5130>
- Bosch, F., & Guardiola, E. (2003). Lista de comprobación (checklist) abreviada para la evaluación de artículos de investigación biomédica básica. *Medicina Clínica*, 121(6), 228–230. [https://doi.org/10.1016/s0025-7753\(03\)73913-x](https://doi.org/10.1016/s0025-7753(03)73913-x)
- Brikell, I., Kuja-Halkola, R., & Larsson, H. (2019). Heritability of attention-deficit hyperactivity disorder across the lifespan. *European Neuropsychopharmacology*, 29(3), S757-S758. <https://doi.org/10.1016/j.euroneuro.2017.06.106>
- Burgos, N., & Colliot, O. (2020). Machine learning for classification and prediction of brain diseases: recent advances and upcoming challenges. *Current Opinion in Neurology*, 33(4), 439-450. <https://doi.org/10.1097/WCO.0000000000000838>
- Cao, M., Martin, E., & Li, X. (2023). Machine learning in attention-deficit/hyperactivity disorder: new approaches toward understanding the neural mechanisms. *Translational Psychiatry*, 13, Artículo 236. <https://doi.org/10.1038/s41398-023-02536-w>
- *Cervantes-Henríquez, M. L., Acosta-López, J. E., Martínez, A. F., Arcos-Burgos, M., Puentes-Rozo, P. J., & Vélez, J. I. (2022). Machine Learning Prediction of ADHD Severity: Association and Linkage to ADGRL3, DRD4, and SNAP25. *Journal of Attention Disorders*, 26(4), 587–605. <https://doi.org/10.1177/10870547211015426>
- *Chang, Y., Stevenson, C., Chen, I. C., Lin, D. S., & Ko, L. W. (2022). Neurological state changes indicative of ADHD in children learned via EEG-based LSTM networks. *Journal of Neural Engineering*, 19,

- Artículo016021. <https://doi.org/10.1088/1741-2552/ac4f07>
- Chekroud, A. M., Bondar, J., Delgadillo, J., Doherty, G., Wasil, A., Fokkema, M., Cohen, Z., Belgrave, D., DeRubeis, R., Iniesta, R., Dwyer, D. & Choi, K. (2021). The promise of machine learning in predicting treatment outcomes in psychiatry. *World Psychiatry*, 20(2), 154-170. <https://doi.org/10.1002/wps.20882>
- Conejero, I., Jaussent, I., Lopez, R., Guillaume, S., Olié, E., Hebbache, C., Cohen, R.F., Kahn, J.P., Leboyer, M., Courtet, P., & Lopez-Castroman, J. (2019). Association of symptoms of attention deficit-hyperactivity disorder and impulsive-aggression with severity of suicidal behavior in adult attempters. *Scientific Reports*, 9, Artículo4593. <https://doi.org/10.1038/s41598-019-41046-y>
- Cortese, S. (2022). Treatment of ADHD in preschool children. *The Lancet Child & Adolescent Health*, 6(12), 830-831. [https://doi.org/10.1016/S2352-4642\(22\)00312-1](https://doi.org/10.1016/S2352-4642(22)00312-1)
- Dawson, A. E., Wymbs, B. T., Evans, S. W., & DuPaul, G. J. (2019). Exploring how adolescents with ADHD use and interact with technology. *Journal of Adolescence*, 71(1), 119-137. <https://doi.org/10.1016/j.adolescence.2019.01.004>
- *Deshpande, G., Wang, P., Rangaprakash, D., & Wilamowski, B. (2015). Fully connected cascade artificial neural network architecture for attention deficit hyperactivity disorder classification from functional magnetic resonance imaging data. *IEEE Transactions on Cybernetics*, 45(12), 2668–2679. <https://doi.org/10.1109/TCYB.2014.2379621>
- *Du, J., Wang, L., Jie, B., & Zhang, D. (2016). Network-based classification of ADHD patients using discriminative subnetwork selection and graph kernel PCA. *Computerized Medical Imaging and Graphics*, 52, 82–88. <https://doi.org/10.1016/j.compmedimag.2016.04.004>
- *Duda, M., Haber, N., Daniels, J., & Wall, D. P. (2017). Crowdsourced validation of a machine-learning classification system for autism and ADHD. *Translational Psychiatry*, 7, Artículo e1133. <https://doi.org/10.1038/tp.2017.86>
- *Faedda, G. L., Ohashi, K., Hernandez, M., McGreenery, C. E., Grant, M. C., Baroni, A., Polcari, A., & Teicher, M. H. (2016). Actigraph measures discriminate pediatric bipolar disorder from attention-deficit/hyperactivity disorder and typically developing controls. *The Journal of Child Psychology and Psychiatry*, 57(6), 706–716. <https://doi.org/10.1111/jcpp.12520>
- Fayyad, J., Sampson, N. A., Hwang, I., Adamowski, T., Aguilar-Gaxiola, S., Al-Hamzawi, A., Andrade, L. H.G., Borges, G., de Girolamo, G., Florescu, S., Gureje, O., Haro, J. M., Hu, C., Karam, E. G., Lee, S., Navarro-Mateu, F., O'Neill, S., Pennell, B.E., Piazza, M., ... Kessler, R. C. (2017). The descriptive epidemiology of DSM-IV adult ADHD in the world health organization world mental health surveys. *ADHD Attention Deficit and Hyperactivity Disorders*, 9, 47-65. <https://doi.org/10.1007/s12402-016-0208-3>
- 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>
- *Ghiassian, S., Greiner, R., Jin, P., & Brown, M. R. G. (2016). Using functional or structural magnetic resonance images and personal characteristic data to identify ADHD and autism. *PLoS ONE*, 11(12), Artículo e0166934. <https://doi.org/10.1371/journal.pone.0166934>
- Ging-Jehli, N. R., Ratcliff, R., & Arnold, L. E. (2021). Improving neurocognitive testing using computational psychiatry—A systematic review for ADHD. *Psychological Bulletin*, 147(2), 169–231. <https://doi.org/10.1037/bul0000319>
- *Goh, P. K., Elkins, A. R., Bansal, P. S., Eng, A. G., & Martel, M. M. (2023). Data-Driven Methods for Predicting ADHD Diagnosis and Related Impairment: The Potential of a Machine Learning Approach. *Research on Child and Adolescent Psychopathology*, 51, 679–691. <https://doi.org/10.1007/s10802-023-01022-7>
- González, M. N., & Depaula, P. D. (2023). Parenting stress and coping strategies in mothers of children with Attention Deficit Hyperactivity Disorder in Argentina. *Revista Argentina De Ciencias Del Comportamiento*, 15(1), 84–92. <https://doi.org/10.32348/1852.4206.v15.n1.33294>
- Greven, C.U., Bralten, J., Mennes, M., O'Dwyer, L., van Hulzen, K.J.E., Rommelse, N., Schweren, L.J.S., Hoekstra, P.J., Hartman, C.A., Heslenfeld, D., Oosterlaan, J., Faraone, S.V., Franke, B., Zwiers, M. P., Arias-Vasquez, A., & Buitelaar, J.K. (2015). Developmentally Stable Whole-Brain Volume Reductions and Developmentally Sensitive Caudate and Putamen Volume Alterations in Those with Attention-Deficit/Hyperactivity Disorder and Their Unaffected Siblings. *JAMA Psychiatry*, 72(5), 490-499. <https://doi.org/10.1001/jamapsychiatry.2014.3162>
- Harkins, C. M., Handen, B. L., & Mazurek, M. O. (2022). The impact of the comorbidity of ASD and ADHD on social impairment. *Journal of Autism and Developmental Disorders*, 52, 2512-2522. <https://doi.org/10.1007/s10803-021-05150-1>
- Harrison, A. G., & Edwards, M. J. (2023). The Ability of Self-Report Methods to Accurately Diagnose Attention Deficit Hyperactivity Disorder: A

- Systematic Review. *Journal of Attention Disorders*, 27(12), 1343-1359. <https://doi.org/10.1177/10870547231177470>
- Hermosillo, R.J.M., Mooney, M.A., Fezcko, E., Earl, E., Marr, M., Sturgeon, D., Perrone, A., Dominguez, O.M., Faraone, S.V., Wilmot, B., Nigg, J.T., & Fair, D.A. (2020). Polygenic Risk Score–Derived Subcortical Connectivity Mediates Attention-Deficit/Hyperactivity Disorder Diagnosis. *Biological Psychiatry: Cognitive Neuroscience and Neuroimaging*, 5(3), 330-341. <https://doi.org/10.1016/j.bpsc.2019.11.014>
- Hoelzle, J. B., Ritchie, K. A., Marshall, P. S., Vogt, E. M., & Marra, D. E. (2019). Erroneous conclusions: The impact of failing to identify invalid symptom presentation when conducting adult attention-deficit/hyperactivity disorder (ADHD) research. *Psychological Assessment*, 31(9), 1174-1179. <https://doi.org/10.1037/pas0000752>
- Holland, J., & Sayal, K. (2019). Relative age and ADHD symptoms, diagnosis and medication: a systematic review. *European Child & Adolescent Psychiatry*, 28, 1417-1429. <https://doi.org/10.1007/s00787-018-1229-6>
- IEEE Advancing Technology for Humanity. (2020). *IEEE Thesaurus*. <https://www.ieee.org/publications/services/thesaurus.html>
- Izzo, V. A., Donati, M. A., Novello, F., Maschietto, D., & Primi, C. (2019). The Conners 3–short forms: Evaluating the adequacy of brief versions to assess ADHD symptoms and related problems. *Clinical Child Psychology and Psychiatry*, 24(4), 791-808. <https://doi.org/10.1177/1359104519846602>
- *Jung, M., Mizuno, Y., Fujisawa, T. X., Takiguchi, S., Kong, J., Kosaka, H., & Tomoda, A. (2019). The Effects of COMT Polymorphism on Cortical Thickness and Surface Area Abnormalities in Children with ADHD. *Cerebral Cortex*, 29(9), 3902–3911. <https://doi.org/10.1093/cercor/bhy269>
- *Jung, M., Tu, Y., Park, J., Jorgenson, K., Lang, C., Song, W., & Kong, J. (2019). Surface-based shared and distinct resting functional connectivity in attention-deficit hyperactivity disorder and autism spectrum disorder. *The British Journal of Psychiatry*, 214(6), 339–344. <https://doi.org/10.1192/bjp.2018.248>
- Kelleher, J. D., Mac Namee, B., & D'arcy, A. (2020). *Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies*. MIT press.
- Kim, W. P., Kim, H. J., Pack, S. P., Lim, J. H., Cho, C. H., & Lee, H. J. (2023). Machine Learning-Based Prediction of Attention-Deficit/Hyperactivity Disorder and Sleep Problems with Wearable Data in Children. *JAMA Network Open*, 6(3), Artículo e233502. <https://doi.org/10.1001/jamanetworkopen.2023.350>
- 2
- *Kim, S., Lee, H.-K., & Lee, K. (2021). Screening of mood symptoms using MMPI-2-RF scales: An application of machine learning techniques. *Journal of Personalized Medicine*, 11(8), Artículo 812. <https://doi.org/10.3390/jpm11080812>
- *Koh, J. E. W., Ooi, C. P., Lim-Ashworth, N. S., Vicnesh, J., Tor, H. T., Lih, O. S., Tan, R. S., Acharya, U. R., & Fung, D. S. S. (2022). Automated classification of attention deficit hyperactivity disorder and conduct disorder using entropy features with ECG signals. *Computers in Biology and Medicine*, 140, Artículo 105120. <https://doi.org/10.1016/j.compbiomed.2021.105120>
- Koppe, G., Meyer-Lindenberg, A., & Durstewitz, D. (2021). Deep learning for small and big data in psychiatry. *Neuropsychopharmacology*, 46, 176-190. <https://doi.org/10.1038/s41386-020-0767-z>
- *Kuang, D., & He, L. (2014, November). Classification on ADHD with deep learning. En *2014 International Conference on Cloud Computing and Big Data* (pp. 27-32). IEEE. <https://doi.org/10.1109/CCBD.2014.42>
- *Lin, I. C., Chang, S. C., Huang, Y. J., Kuo, T. B. J., & Chiu, H. W. (2023). Distinguishing different types of attention deficit hyperactivity disorder in children using artificial neural network with clinical intelligent test. *Frontiers in Psychology*, 13, Artículo1067771. <https://doi.org/10.3389/fpsyg.2022.1067771>
- Loh, H. W., Ooi, C. P., Barua, P. D., Palmer, E. E., Molinari, F., & Acharya, U. R. (2022). Automated detection of ADHD: Current trends and future perspective. *Computers in Biology and Medicine*, 146, Artículo105525. <https://doi.org/10.1016/j.compbiomed.2022.105525>
- *Lohani, D. C., & Rana, B. (2023). ADHD Diagnosis using structural Brain MRI and Personal Characteristic Data with Machine Learning Framework. *Psychiatry Research: Neuroimaging*, 334, Artículo111689. <https://doi.org/10.1016/j.pscychresns.2023.111689>
- Lugoboni, F., & Tinghino, B. (2022). Combined prevention for substance use and mental health problems in youth: A glance at two conditions at high risk for addiction. En M. Colizzi & M. Ruggeri (Eds.), *Prevention in mental health: From risk management to early intervention* (pp. 189-201). Springer International Publishing. https://doi.org/10.1007/978-3-030-97906-5_11
- Luo, N., Luo, X., Zheng, S., Yao, D., Zhao, M., Cui, Y., Zhu, Y., Calhoun, V.D., Sun, L., & Sui, J. (2023). Aberrant brain dynamics and spectral power in children with ADHD and its subtypes. *European Child & Adolescent Psychiatry*, 32, 2223-2234. <https://doi.org/10.1007/s00787-022-02068-6>
- Mariggió, M. A., Palumbi, R., Vinella, A., Laterza, R.,

- Petruzzelli, M. G., Pescechera, A., Gabellone, A., Gentile, O., Vincenti, A., & Margari, L. (2021). DRD1 and DRD2 receptor polymorphisms: genetic neuromodulation of the dopaminergic system as a risk factor for ASD, ADHD and ASD/ADHD overlap. *Frontiers in Neuroscience*, 15, Artículo705890. <https://doi.org/10.3389/fnins.2021.705890>
- Martel, M. M., Schimmack, U., Nikolas, M., & Nigg, J. T. (2015). Integration of symptom ratings from multiple informants in ADHD diagnosis: a psychometric model with clinical utility. *Psychological Assessment*, 27(3), 1060-1071. <https://doi.org/10.1037/pas0000088>
- Martella, D., Aldunate, N., Fuentes, L.J., & Sánchez-Pérez, N. (2020). Arousal and Executive Alterations in Attention Deficit Hyperactivity Disorder (ADHD). *Frontiers in Psychology*, 11, Artículo1991. <https://doi.org/10.3389/psyg.2020.01991>
- Mengi, M., & Malhotra, D. (2022). Artificial Intelligence Based Techniques for the Detection of Socio-Behavioral Disorders: A Systematic Review. *Archives of Computational Methods in Engineering*, 29, 2811–2855. <https://doi.org/10.1007/s11831-021-09682-8>
- *Mikolas, P., Vahid, A., Bernardoni, F., Süß, M., Martini, J., Beste, C., & Bluschke, A. (2022). Training a machine learning classifier to identify ADHD based on real-world clinical data from medical records. *Scientific Reports*, 12, Artículo 12934. <https://doi.org/10.1038/s41598-022-17126-x>
- *Mohammadi, M. R., Khaleghi, A., Nasrabadi, A. M., Rafieivand, S., Begol, M., & Zarafshan, H. (2016). EEG classification of ADHD and normal children using non-linear features and neural network. *Biomedical Engineering Letters*, 6, 66–73. <https://doi.org/10.1007/s13534-016-0218-2>
- Mu, S., Wu, H., Zhang, J., & Chang, C. (2022). Structural brain changes and associated symptoms of ADHD subtypes in children. *Cerebral Cortex*, 32(6), 1152-1158. <https://doi.org/10.1093/cercor/bhab276>
- *O'Mahony, N., Florentino-Liano, B., Carballo, J. J., Baca-García, E., & Rodríguez, A. A. (2014). Objective diagnosis of ADHD using IMUs. *Medical Engineering and Physics*, 36(7), 922–926. <https://doi.org/10.1016/j.medengphy.2014.02.023>
- *Öztekin, I., Finlayson, M. A., Graziano, P. A., & Dick, A. S. (2021). Is there any incremental benefit to conducting neuroimaging and neurocognitive assessments in the diagnosis of ADHD in young children? A machine learning investigation. *Developmental Cognitive Neuroscience*, 49, Artículo100966. <https://doi.org/10.1016/j.dcn.2021.100966>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I. T., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S. ...Moher, D. (2021). Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. *Revista Española de Cardiología*, 74(9), 790–799. <https://doi.org/10.1016/j.recesp.2021.06.016>
- Parke, E. M., Becker, M. L., Graves, S. J., Baily, A. R., Paul, M. G., Freeman, A. J., & Allen, D. N. (2021). Social cognition in children with ADHD. *Journal of Attention Disorders*, 25(4), 519-529. <https://doi.org/10.1177/1087054718816157>
- Pereira-Sanchez, V., & Castellanos, F. X. (2021). Neuroimaging in attention-deficit/hyperactivity disorder. *Current Opinion in Psychiatry*, 34(2), 105-111. <https://doi.org/10.1097/YCO.0000000000000669>
- Periyasamy, R., Vibashan, V. S., Varghese, G. T., & Aleem, M. A. (2021). Machine learning techniques for the diagnosis of attention-deficit/hyperactivity disorder from magnetic resonance imaging: a concise review. *Neurology India*, 69(6), 1518-1523. <https://doi.org/10.4103/0028-3886.333520>
- Polanczyk, G. V., Willcutt, E. G., Salum, G. A., Kieling, C., & Rohde, L. A. (2014). ADHD prevalence estimates across three decades: an updated systematic review and meta-regression analysis. *International Journal of Epidemiology*, 43(2), 434-442. <https://doi.org/10.1093/ije/dyt261>
- Jothi Prabha, A., & Bhargavi, R. (2019). Prediction of dyslexia using machine learning—a research travelogue. En V. Nath & J. Mandal (Eds.), *Proceedings of the Third International Conference on Microelectronics, Computing and Communication Systems* (pp. 23-34). Springer, Singapore. https://doi.org/10.1007/978-981-13-7091-5_3
- Quintero-López, C., Gil-Vera, V. D., Landinez-Martínez, D. A., Vargas-Gaviria, J. P., & Gómez-Muñoz, N. (2023). Predictive Neurocognitive Model of Attention Deficit Hyperactivity Disorder Diagnosis. *Mediterranean Journal of Clinical Psychology*, 11(1), 1-25. <https://doi.org/10.13129/2282-1619/mjcp-3606>
- *Qureshi, M. N. I., Oh, J., Min, B., Jo, H. J., & Lee, B. (2017). Multi-modal, multi-measure, and multi-class discrimination of ADHD with hierarchical feature extraction and extreme learning machine using structural and functional brain MRI. *Frontiers in Human Neuroscience*, 11, Artículo 157. <https://doi.org/10.3389/fnhum.2017.00157>
- Scandurra, V., Emberti Gialloreti, L., Barbanera, F., Scordo, M. R., Pierini, A., & Canitano, R. (2019). Neurodevelopmental disorders and adaptive

- functions: a study of children with autism spectrum disorders (ASD) and/or attention deficit and hyperactivity disorder (ADHD). *Frontiers in Psychiatry*, 10, Artículo673. <https://doi.org/10.3389/fpsy.2019.00673>
- Silva, M., & Graña, M. (2022). On Machine Learning for Autism Prediction from Functional Connectivity. En M. Choraś, R. S. Choraś, M. Kurzyński, P. Trajdos, J. Pejaś, & T. Hyla, (Eds). *Progress in Image Processing, Pattern Recognition and Communication Systems* (pp. 163-172). Springer.https://doi.org/10.1007/978-3-030-81523-3_16
- *Slobodin, O., Yahav, I., & Berger, I. (2020). A Machine-Based Prediction Model of ADHD Using CPT Data. *Frontiers in Human Neuroscience*, 14, Artículo560021. <https://doi.org/10.3389/fnhum.2020.560021>
- Song, J., Leventhal, B. L., Koh, Y. J., Cheon, K. A., Hong, H. J., Kim, Y. K., Cho, K., Lim, E.C., Park, J., & Kim, Y. S. (2017). Cross-cultural aspect of behavior assessment system for children-2, parent rating scale-child: standardization in Korean children. *Yonsei Medical Journal*, 58(2), 439-448. <https://doi.org/10.3349/ymj.2017.58.2.439>
- Song, C., Jiang, Z. Q., Liu, D., & Wu, L. L. (2022). Application and research progress of machine learning in the diagnosis and treatment of neurodevelopmental disorders in children. *Frontiers in Psychiatry*, 13, Artículo 960672. <https://doi.org/10.3389/fpsy.2022.960672>
- Sordo, S. Á., Garrido Hernansaiz, H., Cantero García, M., Sánchez Iglesias, I., González Moreno, J., & Santacreu, J. (2021). Validez de las pruebas de atención para el diagnóstico diferencial de TDAH infantil y Trastornos del Aprendizaje. *Revista Electrónica de Investigación Psicoeducativa*, 19(54), 437-464. <https://doi.org/10.25115/ejrep.v19i54.3868>
- Sundaresan, A., Penchina, B., Cheong, S., Grace, V., Valero-Cabré, A., & Martel, A. (2021). Evaluating deep learning EEG-based mental stress classification in adolescents with autism for breathing entrainment BCI. *Brain Informatics*, 8(1), Artículo 13. <https://doi.org/10.1186/s40708-021-00133-5>
- Rae, T., Sanders, S., Doust, J., Beller, E., & Glasziou, P. (2015). Prevalence of attention-deficit/hyperactivity disorder: a systematic review and meta-analysis. *Pediatrics*, 135(4), e994-e1001.<https://doi.org/10.1542/peds.2014-3482>
- *Tor, H. T., Ooi, C. P., Lim-Ashworth, N. S., Wei, J. K. E. Jahmunah, V., Oh, S. L., Acharya, U. R., & Fung, D. S. S. (2021). Automated detection of conduct disorder and attention deficit hyperactivity disorder using decomposition and nonlinear techniques with EEG signals. *Computer Methods and Programs in Biomedicine*, 200, Artículo 105941. <https://doi.org/10.1016/j.cmpb.2021.105941>
- *Vaidya, C. J., You, X., Mostofsky, S., Pereira, F., Berl, M. M., & Kenworthy, L. (2020). Data-driven identification of subtypes of executive function across typical development, attention deficit hyperactivity disorder, and autism spectrum disorders. *The Journal of Child Psychology and Psychiatry*, 61(1), 51–61. <https://doi.org/10.1111/jcpp.13114>
- Vimalajeewa, D., McDonald, E., Bruce, S. A., & Vidakovic, B. (2022). Wavelet-based approach for diagnosing attention deficit hyperactivity disorder (ADHD). *Scientific Reports*, 12(1), Artículo 21928. <https://doi.org/10.1038/s41598-022-26077-2>
- Wang, M., & Chen, H. (2020). Chaotic multi-swarm whale optimizer boosted support vector machine for medical diagnosis. *Applied Soft Computing*, 88, Artículo105946. <https://doi.org/10.1016/j.asoc.2019.105946>
- Weiss, F., Tidona, S., Carli, M., Perugi, G., & Scarselli, M. (2023). Triple Diagnosis of Attention-Deficit/Hyperactivity Disorder with Coexisting Bipolar and Alcohol Use Disorders: Clinical Aspects and Pharmacological Treatments. *Current Neuropharmacology*, 21(7), 1467-1476.<https://doi.org/10.2174/1570159X20666220830154002>
- Whitney, D. G., & Peterson, M. D. (2019). US national and state-level prevalence of mental health disorders and disparities of mental health care use in children. *JAMA Pediatrics*, 173(4), 389-391. <https://doi.org/10.1001/jamapediatrics.2018.5399>
- Yang, S., Ma, W., Pi, X., & Qian, S. (2019). A deep learning approach to real-time parking occupancy prediction in transportation networks incorporating multiple spatio-temporal data sources. *Transportation Research Part C: Emerging Technologies*, 107, 248-265. <https://doi.org/10.1016/j.trc.2019.08.010>
- Yasumura, A., Omori, M., Fukuda, A., Takahashi, J., Yasumura, Y., Nakagawa, E., Koike, T., Yamashita, Y., Miyajima, T., Koeda, T., Aihara, M., Tachimori, H., & Inagaki, M. (2020). Applied Machine Learning Method to Predict Children with ADHD Using Prefrontal Cortex Activity: A Multicenter Study in Japan. *Journal of Attention Disorders*, 24(14), 2012–2020. <https://doi.org/10.1177/1087054717740632>
- *Yeh, S. C., Lin, S. Y., Wu, E. H. K., Zhang, K. F., Xiu, X., Rizzo, A., & Chung, C. R. (2020). A Virtual-Reality System Integrated with Neuro-Behavior Sensing for Attention-Deficit/Hyperactivity Disorder Intelligent Assessment. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(9), 1899–1907.

<https://doi.org/10.1109/TNSRE.2020.3004545>

- *Yoo, J. H., Kim, J. I., Kim, B. N., & Jeong, B. (2020). Exploring characteristic features of attention-deficit/hyperactivity disorder: findings from multi-modal MRI and candidate genetic data. *Brain Imaging and Behavior*, *14*, 2132–2147. <https://doi.org/10.1007/s11682-019-00164-x>
- Young, S., Adamo, N., Ásgeirsdóttir, B. B., Branney, P., Beckett, M., Colley, W., Cubbin, S., Deeley, Q., Farrag, E., Gudjonsson, G., Hill, P., Hollingdale, J., Kilic, O., Lloyd, T., Mason, P., Paliokosta, E., Perecherla, S., Sedgwick, J., Skirrow, C. ... Woodhouse, E. (2020). Females with ADHD: An expert consensus statement taking a lifespan approach providing guidance for the identification and treatment of attention-deficit/hyperactivity disorder in girls and women. *BMC Psychiatry*, *20*, Artículo 404. <https://doi.org/10.1186/s12888-020-02707-9>
- *Zhang-James, Y., Chen, Q., Kuja-Halkola, R., Lichtenstein, P., Larsson, H., & Faraone, S. V. (2020). Machine-Learning prediction of comorbid substance use disorders in ADHD youth using Swedish registry data. *The Journal of Child Psychology and Psychiatry*, *61*(12), 1370–1379. <https://doi.org/10.1111/jcpp.13226>
- Zhang-James, Y., Razavi, A. S., Hoogman, M., Franke, B., & Faraone, S. V. (2023). Machine learning and MRI-based diagnostic models for ADHD: Are we there yet? *Journal of Attention Disorders*, *27*(4), 335-353. <https://doi.org/10.1177/10870547221146256>