

Recibido 08 FEB. 2024

ReCIBE, Año 12 No.2, NOV. 2023

Aceptado 08 FEB. 2024

Diagnóstico de TDAH con Machine Learning y Sensores: Un Mapeo Sistemático

ADHD Diagnosis with Machine Learning and Sensors: A Mapping Study

Iván de Jesús Cetina Ucán¹
Antonio Armando Aguilera Güemez¹
aaguilet@correo.uady.mx
Raúl Antonio Aguilar Vera¹
Juan Pablo Ucán Pech¹

¹ Facultad de Matemáticas, Universidad Autónoma de Yucatán, Mérida, Yucatán, México.

Resumen

El trastorno de déficit de atención con hiperactividad (TDAH) es un trastorno del neurodesarrollo que tiene como características principales la hiperactividad y la falta de concentración en actividades cotidianas. Es un trastorno conocido por darse a tempranas edades y afectar a el desempeño escolar. El diagnóstico del TDAH ha sido un procedimiento complejo, al necesitar una gran recolección y análisis de datos de manera manual. Por esto mismo, se ha propuesto el uso de las herramientas de machine learning (ML) para mejorar la precisión y el tiempo del diagnóstico. Actualmente, existen una proliferación de las metodologías que reconocen diferentes tipos de datos de pacientes para el diagnóstico del TDAH. El objetivo de este estudio es revisar dentro del estado del arte las investigaciones previas sobre esta área y responder los cuestionamientos planteados. En el artículo se discutirán temas sobre los modelos de machine learning y los diferentes datos recolectados. Entre los resultados se ve como modelos de redes neuronales y Support Vector Machine (SVM) son los de mayor frecuencia. Además, que los datos de movimiento y aceleración tienen un mayor desempeño a comparación de las implementaciones por procesos neuronales a contra posición de lo esperado. Podemos concluir que los estudios relacionados a la adquisición de datos de movimiento tienen una gran promesa en su implementación y desarrollo en tiempos futuros para una mayor precisión en los resultados clínicos.

Palabras Clave

TDAH; Aprendizaje Máquina; Diagnóstico; Trastorno por déficit de atención con hiperactividad; Sensores.

Abstract

Attention deficit hyperactivity disorder (ADHD) is a neurodevelopmental disorder whose main characteristics are hyperactivity and lack of concentration in daily activities. It is a disorder known to occur early and affects school performance. The diagnosis of ADHD has been a complex procedure, requiring extensive manual data collection and analysis. For this reason, machine learning (ML) tools have been proposed to improve the accuracy and time of diagnosis. Currently, there is a proliferation of methodologies that recognize different types of patient data for diagnosing ADHD. This study aims to review previous research on this area within the state of the art and answer the questions raised. The article will discuss topics about machine learning models and the different data collected. The results show that neural network models and Support Vector Machine (SVM) are the most frequently used. Furthermore, movement and acceleration data have better performance compared to implementations by neural processes, contrary to what was expected. We can conclude that studies related to the acquisition of motion data have great promise in their implementation and development in future times for greater precision in clinical results.

Keywords

ADHD; Machine Learning; Diagnosis; Attention deficit hyperactivity disorder; Sensors.

1. Introducción

El trastorno por déficit de atención con hiperactividad (TDAH) es un trastorno del neurodesarrollo (Johnson, 2005) el cual es caracterizado por patrones de falta de atención, hiperactividad e impulsividad que interfieren con el funcionamiento y el desarrollo diario (NIMH, 2021). Algunos de sus síntomas son: malas habilidades de organización, olvidos, distracción y son más propensos a recibir estímulos fuertes.

Aunque el TDAH afecta a personas de todas las edades, los síntomas suelen aparecer desde edades muy tempranas y pueden persistir hasta la adultez. Se estima que afecta alrededor del 5 al 10 por ciento de los niños (Polanczyk et al., 2014). Estos niños deben de llevar un diagnóstico junto con un especialista en el área (normalmente un neurólogo y/o psicólogo) (AAP, 2019).

El diagnóstico de TDAH implica una evaluación integral que incluye un historial médico y psiquiátrico completo, observación constante de los síntomas presentados, testimonio de padres y la aplicación de actividades recreativas con su evaluación (NIMH, 2021).

El área que rodea el diagnóstico del TDAH tiene dificultades propias las cuales obstaculizan la realización exitosa de la misma, por lo cual ocasiona batallas en la ejecución, como por ejemplo: La falta de información sobre el paciente para que el especialista pueda realizar el diagnóstico (Rader et., 2009); y la falta de herramientas prácticas funcionales cuantitativas con gran precisión para usar en el análisis del proceso de diagnóstico del TDAH para facilitar los resultados y reducir el tiempo (Keper et al., 2008).

Para la obtención de los datos del paciente se han implementado sensores, los cuales traen muchas facilidades en el reconocimiento del TDAH. Estos sensores proporcionan mediciones objetivas y continuas de varios parámetros fisiológicos y conductuales, permitiendo una evaluación más precisa de los síntomas del TDAH (Muñoz et al., 2018).

A la par del manejo de sensores se han desarrollado modelos Aprendizaje maquina (ML, por sus siglas en inglés, machine learning) los cuales pueden predecir si una persona tiene o no TDAH. Estos han demostrado una precisión y velocidad prometedora, aunque se requiere una validación y refinamiento adicionales antes de su implementación clínica generalizada (Slobodin, 2020). Con la gran cantidad de experimentos realizados se han hecho varios mapeos al estado del arte para conocer el ambiente actual del fenómeno. Aun así, algunos de estos mapeos se centran en conocer la distribución de las configuraciones de los modelos de únicamente métodos de resonancia magnética por ML (Periyasamy et al., 2021), sin comparar la precisión de varios métodos. Por lo mismo los estudios referentes a otros métodos de diagnósticos son escasos, por ende, los estudios que comparan los métodos son nulos.

En este estudio, se tiene como objetivo explorar el estado del arte actual sobre el diagnóstico del TDAH con ML y sensores, para conocer la tendencia de las metodologías llevadas a cabo en los modelos ML y sus sensores, tomando en cuenta los tipos de diagnóstico. En la sección dos, se hablará más a detalle sobre la metodología de la investigación.

2. Método de investigación

Para este estudio se ha decidido utilizar el método de estudio de mapeo sistemático. El cual tiene como objetivo proporcionar una visión general y clasificación de la literatura existente sobre un tema específico mediante el uso de un proceso sistemático y transparente de búsqueda, selección y análisis (Kitchenham, 2004). Para el proceso de mapeo, se decidió utilizar un enfoque utilizado en otro estudio por Aguilera & Gómez (2016), propuesto por Kitchenham (2004). Este proceso se divide en ciertas actividades, las cuales son:

- Planificación: Se definen los objetivos, las preguntas de investigación y la cadena de búsqueda. Se establecen los medios de investigación y los criterios de inclusión/exclusión.
- Ejecución: Se lleva a cabo el plan previamente definido, se ejecuta la cadena de búsqueda y se recopilan los datos obtenidos.
- Resultados: Presentamos los resultados obtenidos con representación gráfica y generamos discusiones.

3. Planeación

3.1. Preguntas de investigación (PI)

- PI1: ¿Cuál es la distribución de las contribuciones relacionadas con los tipos de datos recolectados para el diagnóstico del TDAH con ML?
- PI2: ¿Cuál es la distribución de las contribuciones relacionado con los tipos de clasificadores usados en el diagnóstico del TDAH con ML?
- PI3: ¿Cuál es el desempeño promedio de los modelos ML para el diagnóstico de TDAH para cada tipo de dato?

3.2. Cadena de búsqueda

Se definió una lista de palabras y términos que se utilizaron para la búsqueda de información, estos fueron extraídos de las preguntas de investigación. Las palabras son las siguientes: Trastorno por déficit de atención con hiperactividad, TDAH, Sensores, Fusión de sensores, Aprendizaje automático, Hiperactividad.

Para la búsqueda de información se ha elegido la base de datos Scopus, debido a que en ella se almacenan numerosas publicaciones referentes al área de machine learning y engloba muchas respuestas de otras bases de datos. Con esto, se define la siguiente cadena de búsqueda, en la que se utilizaron las palabras clave que se definieron previamente junto con los operadores lógicos AND y OR, que nos permitirán obtener las publicaciones de cada base de datos.

TITLE-ABS-KEY((ADHD OR "Attention deficit hyperactivity disorder") AND ("Sensors" OR "Sensorfusion" OR "feature fusion" OR "Multiview") AND ("learning" OR "Machine learning") AND "Hyperactivity")

3.3. Criterios de inclusión y Exclusión

Los resultados obtenidos al realizar la búsqueda se dividirán según los criterios de inclusión (IC) y exclusión (EX) definidos en la Tabla 1, esto nos permitirá identificar qué publicaciones se considerarán relevantes en el área de diagnósticos del TDAH.

Tabla 1. Criterios de inclusión y exclusión

Criterio	Descripción
IC1	Incluye aquellas publicaciones que fueron publicadas antes de junio de 2023.
IC2	Incluye aquellas publicaciones escritas en idioma inglés.
IC3	Incluye aquellas publicaciones que están relacionadas con las palabras clave seleccionadas.
EX1	Excluye todas las publicaciones que no tengan estas características.

4. Ejecución

Los siguientes son los resultados de la búsqueda realizada en la base de datos de Scopus. La Tabla 2 muestra el número de resultados obtenidos además de las publicaciones que pasaron los criterios de inclusión. Se puede ver que hay 20 colaboraciones destacables, teniendo un poco menos del 50 por ciento de los resultados arrojados al principio.

Tabla 2. Numero de diferentes publicaciones encontradas en cada fuente

Fuentes	No. de resultados	No. de publicaciones después de criterios
Scopus	42	20

5. Resultados

5.1. P11: ¿Cuál es la distribución de las contribuciones relacionadas con los tipos de datos recolectados para el diagnóstico del TDAH con ML?

La motivación viene por los tipos de diagnósticos que se pueden realizar a los pacientes, ya que en la actualidad existen muchas variaciones y cada uno tiene diferentes datos a analizar. Para poder categorizar de mejor manera los datos tomaremos como foco principal los 2 diagnósticos más comunes que recolectan datos por medio de sensores. Por la misma razón, los tipos de datos se han clasificado en las siguientes categorías: Cerebral y de Movimiento

Cerebral: Estos pueden ser imágenes cerebrales o resonancia magnética, principalmente con datos RGB o datos EEG y MEG. El diagnóstico de TDAH puede complementarse con enfoques neurocientíficos, como técnicas de neuro-imagen que brindan información sobre la estructura y función del cerebro (Sáenz et al., 2018).

Movimiento: Son datos corporales con marcas de tiempo que miden comportamiento. El diagnóstico de TDAH generalmente se basa en los síntomas conductuales observados, que incluyen falta de atención, hiperactividad e impulsividad (AAP, 2019).

Con el siguiente gráfico de la Figura 1 podemos ver que el número de contribuciones que recolectan datos cerebrales son muy superiores al resto de categorías, teniendo un porcentaje superior a 50 por ciento (con 11 contribuciones) (Hamedi et al., 2022) (Kim et al., 2021) (Sanchez et al., 2021) (Khadem et al., 2021) (Song et al., 2019) (Chen et al., 2019) (Gu et al., 2022) (Dongwei, et al., 2021) (Shengbing, et al., 2023) (Zhou, et al., 2021) (Hailong et al., 2019). Por otro lado, el segundo lugar es para los datos que se centran en el movimiento y el comportamiento (8 contribuciones) (Lee et al., 2023) (Lindhiem et al., 2022) (Muñoz et al., 2018) (Jaiswal et al., 2017) (O'Mahony et al., 2014) (Deok et al., 2023) (Xin et al., 2022). Tan solo hay una contribución que no habla de ninguna de las 3 planteadas previamente (Dolón et al., 2020).

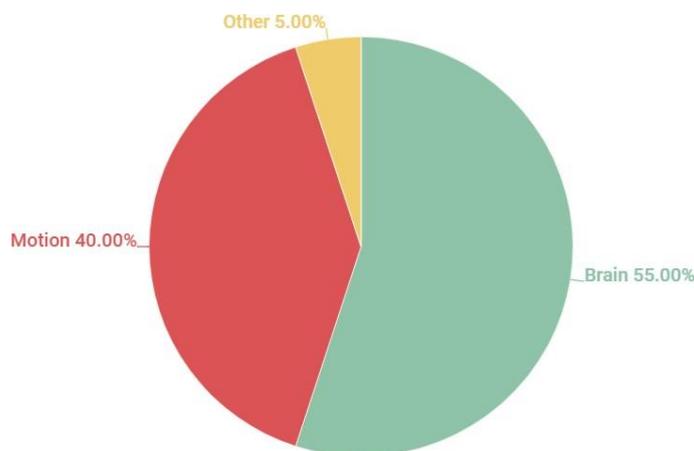


Figura 1. Distribución de tipos de datos detectados en cada publicación

5.2. PI2: ¿Cuál es la distribución de las contribuciones relacionado con los tipos de clasificadores usados en el diagnóstico del TDAH con ML?

El objetivo es tener una visión completa de los clasificadores más recurrentes en el fenómeno dentro del estado del arte. Los datos se representan en la Figura 2. Para la elaboración, se contabilizó cada clasificador usado en cada artículo, así que el número de clasificadores es mayor al de artículos.

Podemos observar que existe una tendencia a utilizar el SVM (usado por 9) (Kim et al., 2021) (Chen et al., 2019) (Song et al., 2019) (Jaiswal et al., 2017) (Faedda, et al., 2016) (O'Mahony et al., 2014) (Gu et al., 2022) (Dongwei, et al., 2021) (Zhou, et al., 2021) como algoritmo de clasificación. Otra frecuencia muy alta la tienen las redes neuronales, algunas de las destacadas son CNN (Muñoz et al., 2018) (Shengbing, et al., 2023), LSTM (Lee et al., 2023), GRU (Lee et al., 2023) y MLP (Song et al., 2019) (Deok et al., 2023) (GRU y LSTM con una sola contribución, MLP y CNN con 2), el resto no específica (Sanchez et al., 2021) (Faedda, et al., 2016) (Xin et al., 2022) (Hailong et al., 2019). Aun así, el K-NN (5 contribuciones) (Lee et al., 2023) (Hamedí et al., 2022) (Khadem et al., 2021) y Random Forest (2 contribuciones) (Lindhiem et al., 2022) (Faedda, et al., 2016) tienen frecuencias muy altas. En las lecturas, muchos clasificadores se mencionan solo una vez, por lo que es difícil comprender su relevancia para los datos, siendo

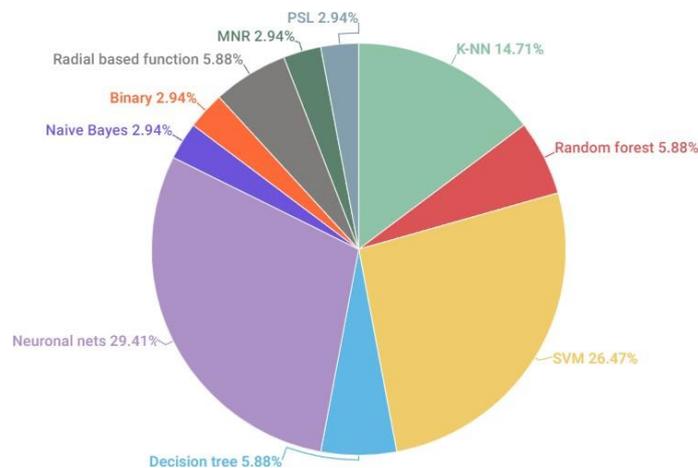


Figura 2. Distribución de los clasificadores usados en los modelos ML de las publicaciones

MNR (Faedda, et al., 2016), PSL (Faedda, et al., 2016), Native Bayes (Khadem et al., 2021) y un clasificador binario (Dolón et al., 2020) los mencionados. También se tienen a SVM con RBF (Khadem et al., 2021) (Hamedí et al., 2022) y Decision tree (Hamedí et al., 2022) (Khadem et al., 2021) con 2 aportaciones cada uno.

5.3. PI3: ¿Cuál es el desempeño promedio de los modelos ML para el diagnóstico de TDAH para cada tipo de dato?

Tomando en cuenta el tipo de dato recolectado de cada contribución se desea conocer el desempeño promedio en precisión de cada modelo y así tener un hecho concreto de cuál es el tipo de diagnóstico de TDAH usando ML más efectivo en la literatura actual.

En el caso del desempeño entre los clasificadores que usan datos de imágenes cerebrales y los que usan datos de movimiento, se representó en el gráfico de la Figura 3. En él se puede ver que la diferencia del desempeño entre ambas es bastante significativa, estando a favor de los diagnósticos por movimiento. Para la elaboración de la gráfica se promedió cada desempeño dado por cada clasificador usados en cada artículo.

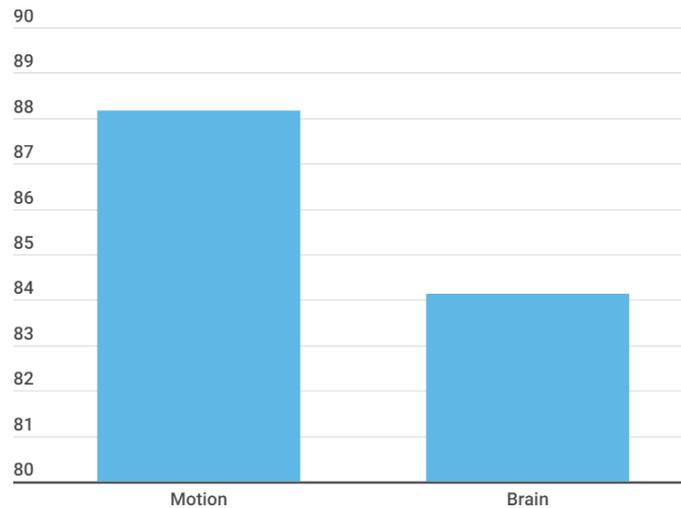


Figura 3. Distribución del desempeño en promedio dividido por el tipo de dato que reconocen de las publicaciones

6. Discusión

Entre los dos tipos de diagnósticos de TDAH que se investigaron (Mentales y Movimiento), se observa en los resultados de la PI1 que los diagnósticos por datos cerebrales son más frecuentes. Este tipo de prueba es conocido por reflejar datos neuronales por el cual se podría reflejar patrones de TDAH (Siendo este un trastorno del neurodesarrollo). Mientras, el movimiento tiene una mayor exclusividad en comportamientos hiperactivos. Esto toma una mayor relevancia con la existencia del trastorno por déficit de atención (TDA) (Henderson et al. 2010) sin hiperactividad, del cual los diagnósticos de movimiento les sería difícil detectar. Dando como enfoque central en las investigaciones al TDAH como un impacto dentro de un ámbito neuronal.

Se puede apreciar en los resultados de la PI2, el SVM es el clasificador más usado dentro de los algoritmos tradicionales. Pero las redes neuronales son los clasificadores más utilizados, lo que demuestra un interés mayor por desarrollar estos modelos. Algunas de estas redes más utilizadas son: GRU, LSTM, CNN y MLP.

Asimismo, se muestra en los resultados de la PI3 la comparación del desempeño de cada tipo de diagnóstico de todos los experimentos. Los resultados sorprenden a favor de los datos por movimiento, ya que los resultados presentados en la PI1 demuestran que los datos cerebrales son más frecuentes. También se puede destacar que el promedio del desempeño de los modelos de datos de movimiento no llega al 90 por ciento de efectividad en promedio, señalando que existe una gran área de oportunidad para mejorar el desempeño. Por lo tanto, el uso de sensores de movimiento puede generar un mayor beneficio a las investigaciones del fenómeno, dando un mayor aporte a comparación de los sensores cerebrales (como EEG), ya que presentan un desempeño más alto, además de la capacidad de poder recopilar datos de manera no invasiva. En contra posición, la frecuencia de estos tipos es menor, lo cual sugiere muy poco conocimiento y confianza en su implementación en este fenómeno.

Otra cosa que destacar es que, hasta donde sabemos, no se ha producido alguna aportación del cual se realice un diagnóstico de TDAH combinando los dos tipos de recolección de datos. Lo que encadena a un área de oportunidad del cual se pueda realizar esta combinación y mejore el desempeño presentado individualmente (mayor a 90 por ciento).

Finalmente, es importante resaltar que existen otros estudios secundarios que hacen uso de datos de movimiento y cerebrales. Uno de estos se enfoca en evaluar todos los modelos del diagnóstico de TDAH con machine learning que implementan CNN (Amado et al., 2023). El segundo es el más completo, ya que se enfoca en conocer la frecuencia de los sensores y clasificadores (clásicos y redes neuronales) (Zhou, 2021) de estudios que usan los datos mencionados (Wen et al., 2022). Análogamente a los anteriores, nosotros también estudiamos los algoritmos clásicos y redes neuronales, para conocer las frecuencias de los clasificadores y los sensores. Sin embargo, a diferencia de los demás, nosotros analizamos y comparamos el desempeño que han logrado, y no solo las frecuencias de ambos tipos de datos.

7. Conclusión

Uno de los puntos fuertes de esta investigación es la comparativa de los diferentes tipos de datos reconocidos por los sensores con relación al tipo de diagnóstico realizado. La diferencia de los datos del cerebro con el movimiento radica en el trato que se les da en los experimentos. Los estudios que realizan experimentos con datos cerebrales tienen un mayor desarrollo, frecuencia e importancia dentro del fenómeno. En cambio, los estudios que experimentan con datos de movimiento presentan menor motivación en su implementación, pero tienen un mayor rendimiento en promedio (al menos en los casos analizados). Esto da como resultado en una posible área de oportunidad en los diagnósticos por datos de movimiento, teniendo un mejor desempeño promedio sin presentar tanto interés en los experimentos. Estos tipos de datos pueden ser implementados por modelos con clasificadores SMV o redes neuronales, al ser estos los de mayor frecuencia.

Ha habido muchos aportes significativos para el diagnóstico de TDAH con ML, aun así, se destaca el hecho de que ningún experimento haya trabajado con los datos cerebrales y movimiento de manera combinada para tener un sistema más completo. Por tanto, se desconoce cuál podría ser el aporte al desarrollar este tipo de experimentos y los resultados obtenidos. Este podría ser el comienzo de un posible futuro proyecto de investigación.

En un futuro se espera generar datos más detallados en un artículo más específico en esta área de investigación, demostrando el gran aporte que el Machine Learning nos puede dar en el análisis de datos y el tiempo de respuesta. Se planea exponer mayores preguntas y tener una vista más completa del estado del arte.

Referencias

- Johnson, M. H. (2005). *Developmental cognitive neuroscience: An introduction*. Wiley-Blackwell.
- National Institute of Mental Health. (2021). Attention-Deficit/Hyperactivity Disorder (ADHD). Retrieved from <https://www.nimh.nih.gov/health/topics/attention-deficit-hyperactivity-disorder-adhd/index.shtml>
- Polanczyk G. V., Willcutt E. G., et. al. (2014). ADHD prevalence estimates across three decades: An updated systematic review and meta-regression analysis. *International Journal of Epidemiology*, 43(2), 434-442.
- American Academy of Pediatrics. (2019). Clinical practice guideline for the diagnosis, evaluation, and treatment of attention-deficit/hyperactivity disorder in children and adolescents. *Pediatrics*, 144(4), e20192528.
- Rader, R., McCauley, L., and Callen, E. C. (2009). Current strategies in the diagnosis and treatment of childhood attention-deficit/hyperactivity disorder. *American Family Physician*, 79(8), 657-665.
- Kemper AR, Maslow GR, et al. (2018). Attention Deficit Hyperactivity Disorder: Diagnosis and Treatment in Children and Adolescents. Agency for Healthcare Research and Quality (US). Comparative Effectiveness Reviews, No. 203
- Muñoz-Organero, M., Powell, L., Heller, B., Harpin, V., and Parker, J. (2018). Automatic Extraction and Detection of Characteristic Movement Patterns in Children with ADHD Based on a Convolutional Neural Network (CNN) and Acceleration Images. *Sensors (Basel)*. 18(11): 3924.
- Slobodin, O., Yahav, I., Berger, I. (2020). A Machine-Based Prediction Model of ADHD Using CPT Data. *Front Hum Neurosci*. 14:560021. eCollection.
- Periyasamy, R., Vibashan, V., Varghese, G., Aleem, M., (2021). Machine Learning Techniques for the Diagnosis of Attention-Deficit/Hyperactivity Disorder from Magnetic Resonance Imaging: A Concise Review. 69(6):1518-1523.
- Kitchenham, B. (2004). *Procedures for performing systematic reviews*. Keele University, Technical Report TR/SE-0401.
- Sáenz, A., Villemonteix, T., Massat, I., (2018). Structural and functional neuroimaging in attention-deficit/hyperactivity disorder. *Dev Med Child Neurol* 61(4):399-405. doi: 10.1111/dmcn.14050.
- Carr, L., Henderson, J., Nigg, J., (2010). Cognitive Control and Attentional Selection in Adolescents with ADHD Versus ADD. Pages 726-740.
- Lee W., Lee D., et. al. (2023). Deep-Learning-Based ADHD Classification Using Children's Skeleton Data Acquired through the ADHD Screening Game, 23(1), 246
- Lindhiem O., Goel M., et. al. (2022) Objective Measurement of Hyperactivity Using Mobile Sensing and Machine Learning: Pilot Study
- Hamedi N., Khadem A., et. al.(2022) Detecting ADHD Based on Brain Functional Connectivity Using Resting-State MEG Signals, Vol.9, No.2 110-118.
- Kim S., Baek J., et. al.(2021) Machine-learning-based diagnosis of drug-naive adult patients with attention-deficit hyperactivity disorder using mismatch negativity, 11:484 ;
- Sanchez A., Villanueva C., et. al. (2021) Classification of brain signals for RPAS control in the treatment of attention deficit hyperactivity disorder. vol.97 no.2.
- N. Hamedi, A. Khadem, et. al. (2021). An Effective Connectomics Approach for Diagnosing ADHD using Eyes-open Resting-state MEG, "11th International Conference on Computer Engineering and Knowledge (ICCKE), 110-114,
- Chen H., Song Y., Li X. (2019). A deep learning framework for identifying children with ADHD using an EEG-based brain network. *Neurocomputing*, 356, 83-96.

- Chen H., Chen W., et. al. (2019). EEG characteristics of children with attention-deficit/hyperactivity disorder. *Neuroscience*, 406, 444-456.
- Jaiswal S., Valstar M. F., et. al. (2017). Automatic Detection of ADHD and ASD from Expressive Behaviour in RGBD Data. 12th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2017), 762-769,
- Faedda G. L., Ohashi K., et. al. (2016). Actigraph measures discriminate pediatric bipolar disorder from attention-deficit/hyperactivity disorder and typically developing controls. *Journal of Child Psychology and Psychiatry*, 57(6), 706-716.
- O'Mahony N., Florentino-Liano B., et. al. (2014). Objective diagnosis of ADHD using IMUs. *Medical Engineering and Physics*, 36(7), 922-926.
- Dolón-Poza, M., Berrezueta-Guzman, J., Martín-Ruiz, M., (2020). Creation of an Intelligent System to Support the Therapy Process in Children with ADHD.: TICEC 2020, CCIS 1307, pp. 36–50, 2020.
- Gu, Y., Miao, S., et. al., (2022). ADHD Children Identification with Multiview Feature Fusion of fNIRS Signals. *IEEE Sensors Journal*, vol. 22, NO. 13,
- Deok-Won Lee, Sang-hyub Lee, et. al. (2023) Development of a Multiple RGB-D Sensor System for ADHD Screening and Improvement of Classification Performance Using Feature Selection Method. *Sci.* 2023, 13, 2798.
- Dongwei Li, Xiangsheng Luo, et. al. (2022). Yan Song Information-based multivariate decoding reveals imprecise neural encoding in children with attention deficit hyperactivity disorder during visual selective attention. 44:937–947
- Shengbing Pei, Chaoqun Wang, Shuai Cao, Member, IEEE, and Zhao Lv (2023). Data Augmentation for fMRI-Based Functional Connectivity and its Application to Cross-Site ADHD Classification. *IEEE transactions on instrumentation and measurement*, vol. 72
- Xin Qin, Jindong, Wang, Yiqiang Chen, et. al. (2022). Domain Generalization for Activity Recognition via Adaptive Feature Fusion. 2157-6904
- Xiaocheng Zhou, Qingmin Lin, et. al. (2021). Multimodal MR Images-Based Diagnosis of Early Adolescent Attention-Deficit/Hyperactivity Disorder Using Multiple Kernel Learning. *Front. Neurosci.* 15:710133.
- Ming Chen, BS, Hailong Li, et. al. (2019). A Multichannel Deep Neural Network Model Analyzing Multiscale Functional Brain Connectome Data for Attention Deficit Hyperactivity Disorder Detection. 2(1):e190012
- Amado-Caballero, P., Casaseca-de-la-Higuera, P., et. al. (2023). Insight into ADHD diagnosis with deep learning on Actimetry: Quantitative interpretation of occlusion maps in age and gender subgroups. *Artificial Intelligence In Medicine* 143 (2023) 102630.
- Wen Loh, H., Ping Ooi, C., et. al. (2022) Automated detection of ADHD: Current trends and future perspective. *Computers in Biology and Medicine* 146 (2022) 105525.
- Zhi-Hua Zhou (2021) *Machine Learning*. Springer Nature, 2021

NOTAS BIOGRÁFICAS



Iván de Jesús Cetina Ucán es actualmente un estudiante matriculado en la Facultad de Matemáticas, llevando la licenciatura de ingeniería de software. Se encuentra realizando su tesis relacionada a Machine Learning y TDAH. Tiene como principales gustos, el aprendizaje máquina, el reconocimiento de la actividad humana y análisis de datos.



Antonio Armando Aguilera Güemez es Licenciado en Ciencias de la Computación por la Facultad de Matemáticas de la Universidad Autónoma de Yucatán, Ph. D. y Maestría en Ciencias de la Computación por el Instituto Tecnológico y de Estudios Superiores de Monterrey. Actualmente es profesor de la Facultad de Matemáticas de la Universidad Autónoma de Yucatán. Es colaborador del Cuerpo Académico de Investigación de Ingeniería de Software para la Educación. Cuenta con el reconocimiento del Sistema Nacional de Investigadores como Investigador Candidato Nacional por el CONAHCYT y cuenta con el reconocimiento del Programa de Desarrollo Profesional Docente (PRODEP) desde 2022. Su labor investigadora comprende las áreas de Ingeniería de Software y Computación Educativa.



Raúl Antonio Aguilar Vera obtuvo el grado de Doctor por la Universidad Politécnica de Madrid, España (Mención de Doctor Europeo) y el de Máster en Ingeniería de Software por la misma Institución, posee también el grado de Maestro en Educación Superior por la Universidad Autónoma de Yucatán. Actualmente es profesor en la Facultad de Matemáticas de la Universidad Autónoma de Yucatán. Es responsable del Cuerpo académico de Ingeniería de Software para la Educación. Es miembro desde 2014 del Sistema Nacional de Investigadores del CONAHCYT (Nivel 1). Su trabajo de investigación incluye las áreas de Ingeniería de Software e Informática Educativa.



Juan Pablo Ucán Pech es Licenciado en Ciencias de la Computación por la Facultad de Matemáticas de la Universidad Autónoma de Yucatán, Magíster en Sistemas Computacionales por el Instituto Tecnológico de Mérida y Doctor en Sistemas Computacionales por la Dirección de Posgrado e Investigación de la Universidad del Sur, México. Actualmente es profesor de la Facultad de Matemáticas de la Universidad Autónoma de Yucatán. Es miembro del Cuerpo Académico de Investigación de Ingeniería de Software para la Educación. Cuenta con el reconocimiento del Sistema Nacional de Investigadores como Investigador Candidato Nacional por el CONAHCYT y cuenta con el reconocimiento del Programa de Desarrollo Profesional Docente (PRODEP) desde 2014. Su labor investigadora se centra en las áreas de Ingeniería del Software y Ciencias de la Computación Educativas.

