



**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE GUAYAQUIL
CARRERA DE COMPUTACIÓN**

**Aplicación de Machine Learning para la detección de patrones conductuales en Niños
de 6 a 12 Años con TDAH**

Trabajo de titulación previo a la obtención del
Título de Ingeniero en ciencias de la computación

AUTOR: María Fernanda Sáenz Yerovi

TUTOR: Msc. Joffre Luis León Veas

Guayaquil – Ecuador

2025

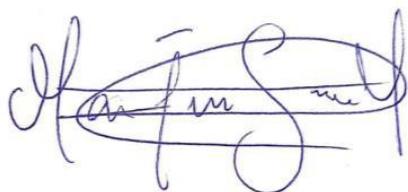
CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE TITULACIÓN

Yo, María Fernanda Sáenz Yerovi con documento de identificación N° 0955043542 manifiesto que:

Soy el autor y responsable del presente trabajo; y, autorizo a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Guayaquil, 27 de enero del año 2025

Atentamente,



María Fernanda Sáenz Yerovi
0955043542

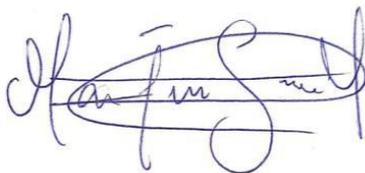
**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Yo, María Fernanda Sáenz Yerovi con documento de identificación No. 0955043542, expreso mi voluntad y por medio del presente documento cedo a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que soy autor(a) del Artículo Académico: “Aplicación de Machine Learning para la detección de patrones conductuales en Niños de 6 a 12 Años con TDAH”, el cual ha sido desarrollado para optar por el título de: Ingeniero en ciencias de la computación, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribo este documento en el momento que hago la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Guayaquil, 27 de enero del año 2025

Atentamente,



María Fernanda Sáenz Yerovi
0955043542

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Joffre Luis León Veas con documento de identificación N° 0911047058, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación: Aplicación de Machine Learning para la detección de patrones conductuales en Niños de 6 a 12 Años con TDAH, realizado por María Fernanda Sáenz Yerovi con documento de identificación N° 0955043542, obteniendo como resultado final el trabajo de titulación bajo la opción Artículo Académico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Guayaquil, 27 de enero del año 2025

Atentamente,

A handwritten signature in blue ink, appearing to read 'Joffre Luis León Veas', is written over a horizontal line.

Joffre Luis León Veas

0911047058

DEDICATORIA

A todas las personas que se sienten diferentes, que piensan, sienten o ven el mundo de una manera única, por quienes fue posible la investigación de este documento.

A mi familia y mascotas, quienes me acompañaron a pesar de todo, brindándome su cariño, sabiduría y sacrificios, aquello por lo que este trabajo ha sido posible.

Dedicado a mi mayor fuente de inspiración y fortaleza; mi abuelo, que en paz descansa, quien me guió a través de todo, enseñándome paciencia y demás valores a lo largo de mi carrera académica y personal.

AGRADECIMIENTO

Quiero expresar mi más sincero agradecimiento a mi familia, por su amor, apoyo incondicional y confianza en cada paso que doy, por la compañía que me ofrecieron mi hermana, padres, gatos y mi perro mientras este trabajo tan importante se hacía difícil de completar, a través de su amabilidad y consejos. A mis amigos, por estar siempre ahí, celebrando los logros y ofreciendo su ánimo en los momentos difíciles. Y, por supuesto, a todas las personas que, de una u otra manera, han contribuido a que este proyecto sea una realidad, incluidos mis profesores y tutores. Este trabajo no habría sido posible sin ustedes.

RESUMEN

El Trastorno por Déficit de Atención e Hiperactividad (TDAH) afecta profundamente a niños de 6 a 12 años, generando desafíos en su desarrollo académico, social y emocional. Los métodos tradicionales de diagnóstico, como los cuestionarios estandarizados y las entrevistas clínicas, han sido herramientas esenciales. Sin embargo, enfrentan limitaciones al abordar volúmenes grandes de datos y al proporcionar un análisis completamente objetivo de los patrones de comportamiento.

En este contexto, el aprendizaje automático (Machine Learning, ML) ha surgido como una alternativa que complementa los enfoques convencionales. Esta tecnología permite analizar datos de manera más eficiente, detectando patrones complejos que podrían pasar desapercibidos en métodos tradicionales. Este artículo explora cómo los algoritmos de ML pueden contribuir a mejorar el diagnóstico del TDAH, ofreciendo soluciones más rápidas y precisas que apoyen a los especialistas en sus evaluaciones.

El principal objetivo de este estudio es evaluar y comparar modelos de Machine Learning para identificar patrones conductuales y característicos en niños de 6 a 12 años con TDAH, contribuyendo a la precisión del diagnóstico. Al integrar estos avances tecnológicos, se busca no solo optimizar los procedimientos diagnósticos, sino también ofrecer beneficios tangibles tanto para los pacientes como para sus familias. Este enfoque interdisciplinario conecta los campos de la tecnología y la salud, estableciendo un camino claro hacia investigaciones futuras que puedan revolucionar el diagnóstico y manejo del TDAH.

Palabras claves: TDAH, Machine learning, diagnóstico clínico, modelos predictivos

ABSTRACT

Attention Deficit Hyperactivity Disorder (ADHD) profoundly affects children from 6 to 12 years old, generating challenges in their academic, social and emotional development. Traditional diagnostic methods, such as standardized questionnaires and clinical interviews, have been essential tools. However, they face limitations in dealing with large volumes of data and in providing a completely objective analysis of behavioral patterns.

In this context, Machine Learning (ML) has emerged as an alternative that complements conventional approaches. This technology makes it possible to analyze data more efficiently, detecting complex patterns that might go unnoticed in traditional methods. This article explores how ML algorithms can contribute to improve the diagnosis of ADHD, offering faster and more accurate solutions that support specialists in their evaluations.

The main objective of this study is to analyze how ML models can identify behaviors associated with ADHD, while addressing the challenges related to their implementation in clinical settings. By integrating these technological advances, we seek not only to optimize diagnostic procedures, but also to offer tangible benefits for both patients and their families. This interdisciplinary approach connects the fields of technology and health, setting a clear path toward future research that may revolutionize the diagnosis and management of ADHD.

Keywords: ADHD, Machine learning, clinical diagnosis, predictive modeling

ÍNDICE DE CONTENIDO

1. INTRODUCCIÓN	10
2. REVISIÓN DE LITERATURA.....	11
2.1. Introducción al Diagnóstico del TDAH	11
2.2. Métodos de diagnóstico tradicionales	11
2.3. Investigación sobre trabajos referentes previos	11
3. METODOLOGÍA	13
3.1. Métodos y técnicas de Recopilación de datos empleadas	13
3.2. Preprocesamiento del set de datos.....	14
3.3. Construcción del Modelo de Aprendizaje Automático	15
3.4. Comparación con conjunto de pruebas	15
3.5. Evaluación de los modelos	16
4. RESULTADOS	17
5. DISCUSIÓN	20
6. CONCLUSIÓN.....	22
REFERENCIAS	24

1. INTRODUCCIÓN

El Trastorno por Déficit de Atención e Hiperactividad (TDAH) es una condición neuropsiquiátrica con un índice de casos que llega aproximadamente a un 4% de la población mundial, siendo uno de los trastornos infantiles más comunes (Hutt Vater et al., 2024).

Detectarlo a tiempo es esencial para poder intervenir con un tratamiento que contribuya a prevenir los potenciales efectos negativos en los ámbitos académicos y relaciones interpersonales a largo plazo, priorizando mejorar la calidad de vida de los jóvenes afectados (Jangmo et al., 2019).

El diagnóstico tradicional se basa en cuestionarios estandarizados en conjunto con entrevistas realizadas por un profesional especializado que pueda evaluar los síntomas que son más notorios dentro del rango de edad de seis a doce años (Alonso, 2020). Estas herramientas representan un pilar fundamental en su identificación.

A pesar de la gran utilidad de los métodos tradicionales establecidos, estos pueden complementarse con tecnologías que permitan un análisis eficiente de datos recolectados. Dentro de este contexto los algoritmos de Machine Learning (ML) ofrecen un enfoque que busca apoyar el diagnóstico de TDAH. Actuando como un sistema de alerta temprana para identificar patrones en los datos recibidos, proporcionando a los especialistas un apoyo con estas señales de aviso.

La incorporación de tecnologías como el Aprendizaje Automático facilita la optimización del uso de los datos obtenidos mediante cuestionarios, debido a que los algoritmos permiten examinar información al detectar patrones. Esto potenciando la labor de especialistas al facilitar la identificación, funcionando como un filtro inicial para optimizar el proceso de diagnóstico. De forma que se aplica el ML como un recurso de apoyo que incrementa la eficiencia de las evaluaciones tradicionales.

Como objetivo principal de la investigación es comparar y evaluar modelos de Machine Learning para identificar patrones que llevan a la identificación del TDAH, evaluando sus respectivos desempeños. Buscando identificar el modelo más ideal para que funcione como un complemento a los métodos tradicionales de identificación.

2. REVISIÓN DE LITERATURA

A continuación, se hará una revisión de una base de datos de artículos de acuerdo con el tema de TDAH y Machine Learning, además de las áreas en que se destacaron y probaron resultados prometedores dentro de los campos psicológicos y psiquiátricos.

2.1. Introducción al Diagnóstico del TDAH

El diagnóstico del Trastorno por Déficit de Atención e Hiperactividad es un área de interés dentro de los campos de la psicología debido a su prevalencia entre la población infantil a nivel mundial, afectando directamente a su calidad de vida (Chan & Langberg, 2024). En Ecuador, los registros y los estudios sobre el padecimiento aún son escasos (Orozco et al., 2021). Sin embargo, a nivel mundial los estudios indican que con un tratamiento adecuado en conjunto con una detección temprana pueden llevar a una vida plena y satisfactoria para las personas que lo padecen (Jiménez-Muñoz et al., 2025).

2.2. Métodos de diagnóstico tradicionales

Los métodos de diagnóstico tradicionales se enfocan en cuestionarios clínicos establecidos en manuales como el DSM-5 (Chromik et al., 2025). Al existir la necesidad de examinar una gran cantidad de datos, surge la oportunidad de complementar estos métodos modernos, incitando el uso de tecnologías como el aprendizaje automático. Las herramientas que proporciona el Machine Learning permite examinar extensas cantidades de información de manera eficiente, mejorando la precisión al poder detectar síntomas optimizando el proceso de diagnóstico dentro de una población amplia y diversa (Ahire et al., 2023).

2.3. Investigación sobre trabajos referentes previos

Dentro de los trabajos referentes a los últimos cinco años se puede evidenciar los avances en ML que han permitido el análisis de datos conductuales, neurofisiológicos y genéticos, identificando patrones que serían complicados de percibir manualmente (Ghasemi et al., 2022). Diversos proyectos con distintos enfoques se han desarrollado, como en el caso de Altun et al. (2022) desarrollaron un modelo basado en Transformada Wavelet Continua y Redes Neuronales Convolucionales (CNN) logrando altos porcentajes dentro de los resultados de sus estudios para diagnosticar el trastorno. Resultados similares con estudios realizados en la universidad de Delhi se han enfocado en la exploración de resonancias magnéticas estructurales

en conjunto con datos personales de los que padecen del trastorno (Lohani & Rana, 2023). Enfoques priorizando la interpretabilidad mediante algoritmos de ML para clasificar las clases de TDAH presentados por Mohan & Padmashree (2023) presentaron resultados prometedores.

Aplicaciones de ML a través de datos conductuales provenientes de cuestionarios estandarizados como el Test de Variación de Atención (TOVA). Aparicio-Juárez et al. (2024) desarrollaron un modelo a partir de árboles de decisión logrando reducción de falsos positivos. Los modelos de ML se pueden ajustar considerando diversos factores contextuales y demográficos, llegando a diagnósticos personalizables (Mulraney et al., 2019). Este progreso tecnológico inaugura un nuevo escenario en la evaluación del TDAH, demostrando cómo la tecnología puede enriquecer los métodos convencionales.

Los modelos de ML han evidenciado un gran potencial, aunque de la misma forma también enfrentan una serie de limitaciones, las cuales recaen en la recolección de datos en entornos controlados, generalizando resultados a poblaciones más amplias (Hutt Vater et al., 2024). Son necesarias herramientas que permitan a profesionales de la salud comprender decisiones tomadas por modelos entrenados, complementando su implementación en entornos clínicos.

La inclusión de ML en el diagnóstico del TDAH constituye un progreso hacia técnicas más imparciales, precisos y eficaces. La implementación exitosa de los modelos dependerá de la presencia de *datasets* confiables, la capacidad de interpretación de los modelos y la incorporación de estas herramientas dentro de la práctica clínica cotidiana (Maniruzzaman et al., 2022)

“El diagnóstico del TDAH mediante Machine Learning no solo mejora la precisión y objetividad, sino que proporciona una herramienta robusta para los profesionales de la salud, ayudándolos a abordar los desafíos relacionados con la variabilidad de métodos tradicionales” (Das & Khanna, 2021). El enfoque busca la optimización de procesos de diagnóstico, para poder permitir intervenciones de expertos y desarrollar intervenciones tempranas.

3. METODOLOGÍA

En este trabajo se sigue un enfoque experimental orientado a evaluar diferentes modelos de Machine Learning (ML) aplicados al diagnóstico del Trastorno por Déficit de Atención e Hiperactividad en niños entre seis y doce años. Para ello, se utilizan modelos entrenados desde cero en los cuales se evalúa el rendimiento de cada uno en términos de *accuracy*, sensibilidad, especificidad y del área bajo la curva. Los modelos analizados incluyen: Random Forest, Árboles de Decisión y Perceptrón Multicapa (MLP). Estos modelos se aplicaron en el *dataset* National Survey of Children's Health o NSCH de los Estados Unidos, el cual recopila información sobre salud tanto física como mental, contexto socioeconómico, situación familiar entre otros factores que afectan el desarrollo del niño.

Los pasos que se realizan en la investigación se desglosan en:

- Recopilación de datos: Se revisa literatura de los últimos cinco años, en las que se puedan identificar las tendencias al momento de diagnosticar el trastorno.
- Selección de base de datos y preprocesamiento de datos: Se identifica un *dataset* que contenga datos relevantes para el estudio, se normalizan las variables necesarias, se equilibran las clases y se realiza una limpieza de valores atípicos.
- Construcción de modelos: Se realiza el entrenamiento de Random Forest, Árboles de Decisión y Perceptrón Multicapa.
- Evaluación de modelos: Utilizando métricas como precisión, sensibilidad, especificidad y área bajo la curva se busca comparar el rendimiento de cada uno.
- Validación en un dataset de prueba: Se prueban los modelos en un conjunto de datos diferente para evaluar posibles limitaciones.

3.1. Métodos y técnicas de Recopilación de datos empleadas

A partir de un *dataset* de acceso público con registros detallados de un cuestionario acerca de la salud, situación demográfica y comportamiento infantil. Al tener el acceso a los datos se selecciona una muestra de acuerdo con la investigación presente, segmentando y filtrando los datos de acuerdo con el rango de edad recomendado por especialistas (Lee et al., 2024). En conjunto con la selección de campos relevantes para el análisis.

3.2. Preprocesamiento del set de datos

Para abordar la tarea de diagnóstico del TDAH en niños, se realiza un preprocesamiento de datos que consiste en una fase elemental para los estudios en conjunto a técnicas de Machine Learning, debido a que aseguran la consistencia de datos utilizados, dentro de este proyecto se preparó el *dataset* antes de entrenar individualmente los modelos establecidos para poder garantizar registros confiables para continuar el entrenamiento. Según (Karami & Attallah, 2024) un correcto manejo del procesamiento incluye una normalización en conjunto con un manejo adecuado de datos faltantes, así disminuyendo el sesgo y priorizar el eficiente rendimiento de los modelos en espacios clínicos.

Se llevaron a cabo los experimentos con la *data* en el entorno virtual de la plataforma de acceso público Google Colab, debido a su capacidad de procesamiento y capacidad de almacenamiento de datos en la nube, en adición incluye su integración nativa con Google Drive, la cual permite la integración cómoda al gestionar el acceso a datos de manera eficiente (Jayachandran & Shyamala, 2024). En el experimento en particular se utiliza el Tensor Processing Unit (TPU) disponible de forma gratuita en la plataforma, siendo una unidad capaz de tomar la tarea del entrenamiento.

Al iniciar se realizó una limpieza de datos tomando base la limpieza de datos, eliminando registros incompletos. Consecuentemente se toman en cuenta variables determinantes como lo son las variables de la edad y la del diagnóstico confirmado de TDAH, con el propósito de evitar un sesgo dentro del análisis (García-Ponsoda et al., 2024). Además de la categorización de las variables de sexo y etnia, utilizando *one-hot encoding* para poder procesar los modelos correctamente.

Un desafío encontrado fue el tratamiento del desbalance de las clases de la variable objetivo (diagnóstico de TDAH), lo cual suele ser un inconveniente que se repite a lo largo de la literatura previamente revisada y que generalmente lleva a un sobreajuste de los modelos (Huynh et al., 2024). Para resolver este común problema se utiliza la técnica de SMOTE (Técnica de Muestreo Superior Synthetic Minority), la cual tiene como propósito el producir muestras sintéticas de la clase minoritaria con el fin de balancear las proporciones. La aplicación del método de balanceo de registros ha demostrado ser capaz de solventar el problema en estudios previos (Shao et al., 2020) incrementando la sensibilidad de los modelos.

Luego del balance, se verifica que ambas clases cuenten con una misma cantidad registros para facilitar el aprendizaje automático.

Se aplica la normalización sobre las variables numéricas utilizando el escalador *StandardScaler*, un paso para asegurar que todas las variables contribuyan de forma uniforme al proceso, como se lo utiliza con la razón de evitar que valores anormales afecten la capacidad predictiva del modelo (Chen et al., 2021).

3.3. Construcción del Modelo de Aprendizaje Automático

Se realizó la selección de los modelos de ML en base a las tendencias observadas en la literatura analizada. Random Forest y Árboles de Decisión basándose en árboles jerárquicos demostrando su eficiencia en cuanto a su capacidad de manejar variables categóricas y numéricas (Rostami et al., 2020). “Los árboles de decisión y Random Forest, ha ganado atención significativa debido a su capacidad para capturar patrones más complejos en los datos. DT y RF a menudo superan a la regresión logística (LR).”(Grazioli et al., 2024)Mientras que se escogió el modelo MLP por ser basado en redes neuronales, en adición de su capacidad de identificar relaciones complejas entre los registros. Estudios recientes han evidenciado que el modelo MLP pueden ser llegar a ser de gran utilidad en escenarios de datos diversos y multidimensionales, como lo señala Alsharif et al. (2024) quienes resaltan su capacidad de generalización y precisión dentro de un contexto de diagnóstico médico.

Para Random Forest y Árboles se optó por un ajuste utilizando *GridSearch* permitiendo explorar diversas combinaciones de hiperparámetros para poder encontrar los que permitan obtener los mejores resultados posibles y de acuerdo con (Pedrollo et al., 2024) logren mejorar las métricas objetivo. Por otro lado, en el caso de MLP se configuró una red neuronal con una capa oculta de 100 neuronas, con la función de activación ReLU, con una limitante de 300 iteraciones.

3.4. Comparación con conjunto de pruebas

Posteriormente se implementó un segundo *dataset* extraído del portal público de conjunto de datos DANS Data Station Life Sciences, titulado “Impact of Nutrition on Children with Attention-deficit Hyperactivity Disorder” (INCA)para poder utilizarlo como un conjunto de prueba, con el objetivo de evaluar el desempeño de los modelos en un contexto diferente al de entrenamiento, tomándolo como un enfoque necesario para poder determinar posibles

limitaciones en cuanto a las adaptaciones de los modelos. El conjunto de datos contiene datos de 100 niños observados dentro de un ensayo controlado que incluye factores nutricionales y conductuales recopilados entre los niños con diagnóstico confirmado bajo los criterios del DSM-5.

Los modelos entrenados inicialmente con el conjunto de datos NSCH se probaron utilizando el conjunto de datos INCA como conjunto de pruebas. Los resultados se medirían bajo las mismas métricas que el conjunto de entrenamiento original, tomando en cuenta que el *dataset* de pruebas corresponde a un enfoque clínico distintivo, que lo ubica como un caso ideal para evaluar de qué manera los modelos reaccionan ante cambios en las propiedades y contextos de los datos.

3.5. Evaluación de los modelos

Se utilizan las métricas para la evaluación de clasificaciones supervisadas para poder determinar el nivel de desempeño de los modelos al poder verificar diversos aspectos.

ROC (AUC-ROC) por Clase: Se calcula el AUC-ROC para cada modelo, la métrica mide la capacidad de diferenciar entre clases negativas y positivas del diagnóstico de TDAH. Cuan más cercano el valor de AUC-ROC sea a 1 mejor es la capacidad de discriminación del modelo. (Alves et al., 2024)

Visualización de Curvas ROC: Se muestra la visualización grafica de las Curvas ROC. representando su sensibilidad frente a 1-especificidad en diferentes umbrales de probabilidad. Permite identificar umbrales óptimos en cuanto a la sensibilidad y facilitar la comprensión de los modelos (Kasim, 2023).

Matriz de confusión: En complemento a las métricas de Curvas ROC, se genera la matriz de confusión para comprender la forma en que el modelo clasifica de forma correcta o incorrectamente. La matriz descompone las predicciones en verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos (Namasse et al., 2024).

4. RESULTADOS

El entrenamiento de los modelos mencionados se realizó empleando la técnica de SMOTE, lo que permitió ayudar a manejar el desequilibrio en el cual se encontraban los datos. El modelo Random Forest se realizó la configuración de 100 árboles de decisión como una base para la creación del bosque aleatorio, ajustando los hiperparámetros utilizando GrindSearchCV, logrando así incrementar la precisión del modelo.

- Con 20 estimadores y profundidad 5, se obtuvo una precisión del 81.98% y un F1-Score del 80.95%.
- Con 50 estimadores y profundidad 10, la precisión mejoró hasta 86.05% y el F1-Score alcanzó 84.98%.
- Finalmente, con 100 estimadores y profundidad 15, se alcanzó la mejor configuración con 87.71% de precisión y 87.50% en F1-Score.

Mientras que en el caso del Perceptrón Multicapa se entrenó utilizando diversas configuraciones:

- El modelo con 100 neuronas, activación ReLU, solver Adam y 300 iteraciones tuvo un desempeño similar con 84.94% de accuracy.
- La configuración con 50 neuronas, activación Tanh, solver SGD y 100 iteraciones tuvo el peor desempeño con 75.01% de accuracy.
- La arquitectura con tres capas de 20 neuronas, activación Logistic, solver LBFGS y 150 iteraciones obtuvo un desempeño intermedio con 81.16% de accuracy.

La red neuronal de cien neuronas ocultas en una capa, aplicando la función de activación ReLU. Delimitando 300 iteraciones, asegurando un entrenamiento constante. Por último, el modelo Decision Tree, permitió una clasificación con resultados consistentes. Los modelos se evaluaron con métricas para comprender su rendimiento.

A continuación, se presenta una comparación de las métricas obtenidas, incluyendo los valores de precisión, sensibilidad, especificidad y AUC de cada uno de los modelos:

Tabla 1.

Modelos evaluados con métricas

Modelo	Accuracy	Sensitivity	Specificity	AUC
Random Forest	87.472366	91.056511	83.889980	0.949550
Decision Tree	83.812331	83.587224	84.037328	0.926342
MLP	84.942275	88.206388	81.679764	0.934547

El modelo Random Forest destaca como el más robusto basándose en las métricas analizadas con un AUC de 0.95 y una alta sensibilidad del 91.06%, lo cual significa que tiene un número reducido de falsos negativo, un aspecto fundamental al momento de aplicarlo en entornos clínicos. En segundo lugar el modelo MLP logra un AUC de 0.93 con una sensibilidad de 88.21%, pero se encuentra delimitado por su especificidad inferior con una tendencia más alta a detectar falsos positivos. En tercer lugar el modelo de Decision Tree con una precisión del 83.81% y especificidad de 84.03% convirtiéndolo en una alternativa en contextos donde se priorice la interpretabilidad.

El modelo con un desempeño sobresaliente entre los tres algoritmos evaluados es el de Random Forest dentro del conjunto de prueba:

- Precisión: 87.47%
- Sensibilidad: 91.06%
- Especificidad: 83.89%
- Área bajo la curva ROC: 0.95

El gráfico anexo corresponde a las curvas de ROC, cada curva del gráfico generado corresponde al desempeño de un modelo destino en la clasificación de los patrones conductuales relacionados con el diagnóstico del TDAH. Reflejan las variaciones de la Tasa de Falsos Positivos (FPR) en conjunto con la tasa de Verdaderos Positivos (TPR) en el transcurso en el que la curva se acerca a la esquina superior derecha que como respuesta indica altos niveles dentro del TPR.

En la comparación con el segundo dataset, en el cual se prube una muestra de cien niños dentro del rango de edad.

Tabla 2.

Modelos evaluados a partir del Segundo conjunto de datos

Modelo	Accuracy	Sensitivity	Specificity	AUC
Random Forest	55.0	63.6	44.4	0.59
Decision Tree	50.0	63.6	33.3	0.56
MLP	60.0	72.7	44.4	0.53

El área bajo la curva (AUC) evalúa la capacidad de distinguir entre clases positivas (casos con diagnóstico de TDAH) en contraste con las clases negativas (sin diagnóstico). En el caso de Árboles de Decisión y MLP se alcanzó un AUC de 0.93, en cambio el modelo Random Forest demuestra un alcance de AUC de 0.95. Demostrando que los tres modelos poseen una alta capacidad de clasificación.

Modelos evaluados a partir del Segundo conjunto de datos

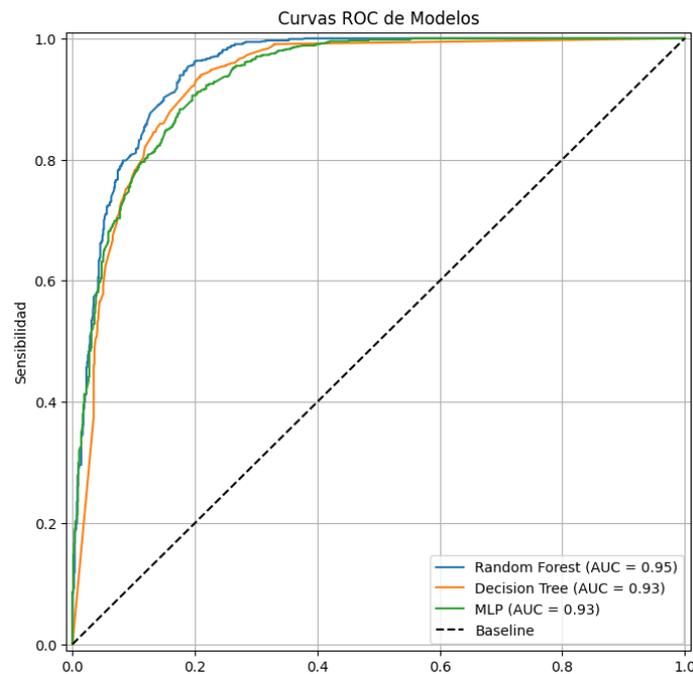


Figura 1 Curvas ROC de los 3 modelos de Machine Learning

El valor del área bajo la curva (AUC) se muestra en la etiqueta de cada una de las curvas. El porcentaje de AUC en el conjunto de entrenamiento es alto, lo que indica que el modelo posee un rendimiento bueno durante la clasificación de datos de entrenamiento. Las Curvas ROC confirman visualmente el equilibrio entre recall y especificidad del modelo Random Forest por sobre los otros modelos evaluados.

5. DISCUSIÓN

El presente análisis aborda diversos enfoques para tratar el diagnóstico del TDAH en niños con base en métodos de aprendizaje automático. Resultante en un desafío complejo de abordar debido a la superposición de síntomas y la amplia gama de métodos tradicionales de evaluación. Mediante modelos como Random Forest, Decision Tree y MLP se evidenció que estas herramientas presentan una gran capacidad de dar un soporte al diagnóstico aportando altos niveles de precisión. El notorio alto rendimiento de Random Forest con una precisión del 87.47% y una sensibilidad del 91.06%, demuestra ser el modelo más robusto de acuerdo con las métricas evaluadas. Los indicadores destacan la habilidad del modelo para detectar los casos de TDAH de forma correcta con un alto nivel de confiabilidad y con una notoria baja de falsos negativos.

Un crítico aspecto detectado fue el desequilibrio inicial del *dataset* entre casos positivos y negativos, el cual suele ser un problema en investigaciones vinculadas al TDAH. Se trató el problema con el método de SMOTE, permitiendo crear un conjunto de datos equilibrados. Se destaca la importancia de disponer de datos reales que sean representativos y diversos en base a una amplia muestra, algo a tomar en cuenta en investigaciones futuras.

Además, se hizo un entrenamiento de 2 *dataset* en el cual los 2 nos dan distintos tipos de precisión y las razones son varias ya que al ser entrenado con los 3 tipos de modelos de machine learning, también afecta la cantidad de datos que se encuentra en la data, ya que en una encontramos una data con escasos recursos a continuación visualizaremos los 3 tipos de entrenamiento con distintos *dataset*:

En este dataset se hizo un análisis de 100 datos donde solo se tomaron aquellas personas dentro del rango de edad establecido, seis a doce años, que tengan TDAH

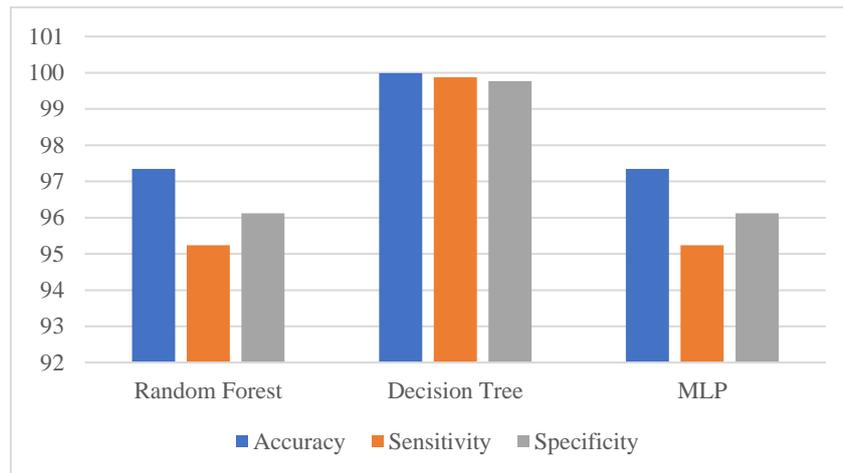


Figura 2. Comparación de métricas en modelos

El mayor nivel de desempeño lo obtuvo el modelo de Decision Tree, lo cual se explica por las características del conjunto de datos de prueba, el cual consiste en datos binarios en todas sus columnas, lo que permite al árbol de decisión dividir correctamente las clases objetivo. Incluyendo el hecho de ser una muestra de datos pequeña.

A pesar de los resultados favorables sobre las restricciones de los modelos evaluados dentro del conjunto de entrenamiento. El modelo MLP indicó una inclinación mayor a generar falsos positivos, indicando un posible vínculo con la complejidad del modelo y su alta sensibilidad frente a la configuración de hiperparámetros. Proponiendo emplear métodos de regularización como dropout o regularización L2, entre otros, para regular el sobreajuste.

Los resultados alcanzados son significativos desde el punto de vista práctico, debido a que respaldan la afirmación de que los modelos de aprendizaje automático pueden ser una estrategia viable para habilitar el diagnóstico del TDAH. La implementación de estas herramientas en el entorno clínico puede aumentar en gran medida la identificación temprana del trastorno. Aunque sea necesario mejorar la calidad de los conjuntos de datos disponibles y proporcionar a los médicos un acceso más fácil a los resultados generados por los modelos. Demostrando a partir de los resultados obtenidos que los modelos de ML pueden ser herramientas de gran utilidad para la identificación del trastorno, pero se debe de destacar que la del modelo varía según la calidad de los datos, por ello se debe continuar explorando estrategias que permitan mejorar estos modelos dentro del ámbito clínico.

6. CONCLUSIÓN

A través de una rigurosa revisión bibliográfica se identificaron las tendencias en cuanto a métodos de aprendizaje automático para la identificación de patrones de comportamiento y características relacionadas con el TDAH en niños de seis a doce años de los últimos cinco años. La investigación resaltó la relevancia de factores como la edad, el género y las comorbilidades (ansiedad, depresión, entre otros) como predictores fundamentales. Corroborando que el conjunto de datos clínicos y conductuales, junto al aprendizaje automático permite la colaboración eficiente entre tecnología y métodos convencionales para realizar un diagnóstico.

Dentro del estudio comparativo de los modelos de ML, el Random Forest demostró lograr un equilibrio notable entre la identificación de casos positivos y negativos. Por otro lado, los modelos Decision Tree y Perceptrón Multicapa mostraron un rendimiento competitivo, aunque presentaron algunas limitaciones en aspectos específicos de sensibilidad y especificidad. Estos resultados resaltan la importancia de seleccionar el modelo más adecuado según las necesidades clínicas y la calidad del conjunto de datos disponible.

El análisis de los resultados evidenció que cada modelo posee tanto beneficios como sectores que pueden ser optimizados. Random Forest se distinguió por su robustez, sin embargo, todavía podría aprovechar un mayor volumen de datos variados que representen de manera más efectiva la realidad del diagnóstico del TDAH. Otros algoritmos, como los empleados en este estudio, necesitan una modificación meticulosa de sus parámetros para alcanzar el máximo equilibrio entre precisión y generalización. Además, instrumentos como las curvas ROC y las matrices de confusión han probado ser beneficiosos para comprender el rendimiento de cada modelo en contextos prácticos, un aspecto que resultaría provechoso profundizar en investigaciones futuras.

Este estudio subraya la manera en que las herramientas de aprendizaje automático pueden transformarse en un soporte relevante para el diagnóstico del TDAH. Estos procedimientos poseen la capacidad de acelerar procesos, dejando atrás enfoques convencionales que, a veces, pueden resultar más subjetivos. En el futuro, resultaría factible investigar sobre modelos que fusionen diversas tecnologías, como los árboles de decisión y las redes neuronales, con el objetivo de explotar las mejores características de ambas tecnologías. Se plantea incorporar estas soluciones en sistemas más útiles, como plataformas de vigilancia a distancia, podría

representar un avance significativo. No obstante, para que estas tecnologías sean verdaderamente beneficiosas, resultará esencial desarrollar interfaces más sencillas de utilizar y accesibles, especialmente en situaciones donde los recursos son escasos.

Se evidencia el potencial aprendizaje automático como un instrumento esencial para optimizar el diagnóstico del TDAH, demostrando como estos pueden ayudar a la detección temprana del trastorno. En contraposición a los procedimientos convencionales, proporciona una perspectiva más directa e imparcial, simplificando el estudio de patrones complejos. No obstante, todavía existe margen para perfeccionar, como realizar una investigación que abarque más modelos de ML. Es crucial tener en cuenta que estas herramientas deben ser de fácil interpretación y uso, garantizando su utilidad real en contextos educativos y clínicos.

REFERENCIAS

- Ahire, N., Awale, R. N., & Wagh, A. (2023). Classification of attention deficit hyperactivity disorder using machine learning on an EEG dataset. *Applied Neuropsychology: Child*. <https://doi.org/10.1080/21622965.2023.2300078>
- Alonso, S. L. (2020). Análisis de las principales variables de diagnóstico del TDAH en niños entre 6 y 12 años de edad. *Revista INFAD de Psicología. International Journal of Developmental and Educational Psychology*, 1(2), 13–22. <https://doi.org/10.17060/IJODAEP.2020.N2.V1.1932>
- Alsharif, N., Al-Adhaileh, M. H., & Al-Yaari, M. (2024). Accurate Identification of Attention-deficit/Hyperactivity Disorder Using Machine Learning Approaches. *Journal of Disability Research*, 3(1), 20230053. <https://doi.org/10.57197/JDR-2023-0053>
- Altun, S., Alkan, A., & Altun, H. (2022). Automatic Diagnosis of Attention Deficit Hyperactivity Disorder with Continuous Wavelet Transform and Convolutional Neural Network. *Clinical Psychopharmacology and Neuroscience*, 20(4), 715–724. <https://doi.org/10.9758/CPN.2022.20.4.715>
- Alves, C. L., Martinelli, T., Sallum, L. F., Rodrigues, F. A., Toutain, T. G. L. de O., Porto, J. A. M., Thielemann, C., Aguiar, P. M. de C., & Moeckel, M. (2024). Multiclass classification of Autism Spectrum Disorder, attention deficit hyperactivity disorder, and typically developed individuals using fMRI functional connectivity analysis. *PLOS ONE*, 19(10), e0305630. <https://doi.org/10.1371/JOURNAL.PONE.0305630>
- Aparicio-Juárez, J., Domínguez-Ramírez, O. A., & Escotto-Córdova, E. A. (2024). Tecnologías Emergentes en el Diagnóstico y Tratamiento del TDAH. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías Del ICBI*, 12(23), 9–19. <https://doi.org/10.29057/ICBI.V12I23.12081>
- Chan, E. S. M., & Langberg, J. M. (2024). Predicting Occupational Outcomes for Individuals with ADHD: The Role of Hyperactivity/Impulsivity and Executive Functioning. *Journal of Occupational Rehabilitation*, 1–11. <https://doi.org/10.1007/S10926-024-10259-Y/FIGURES/2>
- Chen, T., Antoniou, G., Adamou, M., Tachmazidis, I., & Su, P. (2021). Automatic Diagnosis of Attention Deficit Hyperactivity Disorder Using Machine Learning. *Applied Artificial Intelligence*, 35(9), 657–669. <https://doi.org/10.1080/08839514.2021.1933761>
- Chromik, L. C., Friedman, L. M., Fabrikant-Abzug, G., Davis, M. C., Doane, L. D., & Lemery-Chalfant, K. (2025). The utility of multiple assessments in infancy and toddlerhood to predict middle childhood ADHD symptoms: Temperamental, behavioral, and genetic contributions. *Infant Behavior and Development*, 78, 102025. <https://doi.org/10.1016/J.INFBEH.2024.102025>
- Das, W., & Khanna, S. (2021). A Robust Machine Learning Based Framework for the Automated Detection of ADHD Using Pupillometric Biomarkers and Time Series Analysis. *Scientific Reports 2021 11:1*, 11(1), 1–12. <https://doi.org/10.1038/s41598-021-95673-5>
- García-Ponsoda, S., Maté, A., & Trujillo, J. (2024). Refining ADHD diagnosis with EEG: The impact of preprocessing and temporal segmentation on classification accuracy. *Computers in Biology and Medicine*, 183, 109305. <https://doi.org/10.1016/J.COMPBIOMED.2024.109305>
- Ghasemi, E., Ebrahimi, M., & Ebrahimie, E. (2022). Machine learning models effectively distinguish attention-deficit/hyperactivity disorder using event-related potentials. *Cognitive Neurodynamics*, 16(6), 1335–1349. <https://doi.org/10.1007/S11571-021-09746-2/FIGURES/3>

- Grazioli, S., Crippa, A., Buo, N., Busti Ceccarelli, S., Molteni, M., Nobile, M., Salandi, A., Trabattoni, S., Caselli, G., & Colombo, P. (2024). Use of Machine Learning Models to Differentiate Neurodevelopment Conditions Through Digitally Collected Data: Cross-Sectional Questionnaire Study. *JMIR Formative Research*, 8(1), e54577. <https://doi.org/10.2196/54577>
- Hutt Vater, C., DiSalvo, M., Ehrlich, A., Parker, H., O'Connor, H., Faraone, S. V., & Biederman, J. (2024). ADHD in Adults: Does Age at Diagnosis Matter? *Journal of Attention Disorders*, 28(5), 614–624. <https://doi.org/10.1177/10870547231218450>
- Huynh, N., Yan, D., Ma, Y., Wu, S., Long, C., Sami, M. T., Almudaifer, A., Jiang, Z., Chen, H., Dretsch, M. N., Denney, T. S., Deshpande, R., & Deshpande, G. (2024). The Use of Generative Adversarial Network and Graph Convolution Network for Neuroimaging-Based Diagnostic Classification. *Brain Sciences* 2024, Vol. 14, Page 456, 14(5), 456. <https://doi.org/10.3390/BRAINSCI14050456>
- Jangmo, A., Stålhandske, A., Chang, Z., Chen, Q., Almqvist, C., Feldman, I., Bulik, C. M., Lichtenstein, P., D'Onofrio, B., Kuja-Halkola, R., & Larsson, H. (2019). Attention-Deficit/Hyperactivity Disorder, School Performance and Effect of Medication. *Journal of the American Academy of Child and Adolescent Psychiatry*, 58(4), 423. <https://doi.org/10.1016/J.JAAC.2018.11.014>
- Jayachandran, C. M., & Shyamala, K. (2024). Diagnosing ADHD and Personality Disorders as Per DSM-5 Using Novel APK, PDPK, and DDPK Machine Learning Algorithms. *Lecture Notes in Networks and Systems*, 869 LNNS, 81–101. https://doi.org/10.1007/978-981-99-9040-5_6
- Jiménez-Muñoz, L., Lopez-Fernandez, O., Peñuelas-Calvo, I., Delgado-Gómez, D., Miguélez-Fernández, C., López-González, S., González-Garrido, C., Baca-García, E., Carballo, J. J., & Porras-Segovia, A. (2025). Persistence of ADHD into adulthood and associated factors: A prospective study. *Psiquiatría Biológica*, 32(2), 100529. <https://doi.org/10.1016/J.PSIQ.2024.100529>
- Karami, E., & Attallah, O. (2024). ADHD-AID: Aiding Tool for Detecting Children's Attention Deficit Hyperactivity Disorder via EEG-Based Multi-Resolution Analysis and Feature Selection. *Biomimetics* 2024, Vol. 9, Page 188, 9(3), 188. <https://doi.org/10.3390/BIOMIMETICS9030188>
- Kasim, Ö. (2023). Identification of attention deficit hyperactivity disorder with deep learning model. *Physical and Engineering Sciences in Medicine*, 46(3), 1081–1090. <https://doi.org/10.1007/S13246-023-01275-Y/METRICS>
- Lee, Y.-S., Sprong, M. E., Shrestha, J., Smeltzer, M. P., & Hollender, H. (2024). Trajectory Analysis for Identifying Classes of Attention Deficit Hyperactivity Disorder (ADHD) in Children of the United States. *Clinical Practice & Epidemiology in Mental Health*, 20(1). <https://doi.org/10.2174/0117450179298863240516070510>
- Lohani, D. C., & Rana, B. (2023). ADHD diagnosis using structural brain MRI and personal characteristic data with machine learning framework. *Psychiatry Research: Neuroimaging*, 334, 111689. <https://doi.org/10.1016/J.PSYCHRESNS.2023.111689>
- Maniruzzaman, M., Shin, J., & Hasan, M. A. M. (2022). Predicting Children with ADHD Using Behavioral Activity: A Machine Learning Analysis. *Applied Sciences* 2022, Vol. 12, Page 2737, 12(5), 2737. <https://doi.org/10.3390/APP12052737>

- Mohan, S., & Padmashree, T. (2023). An Innovative Framework for Classification of ADHD using Machine Learning Algorithm. *2nd International Conference on Automation, Computing and Renewable Systems, ICACRS 2023 - Proceedings*, 1016–1019. <https://doi.org/10.1109/ICACRS58579.2023.10405029>
- Mulraney, M., Giallo, R., Sciberras, E., Lycett, K., Mensah, F., & Coghill, D. (2019). ADHD Symptoms and Quality of Life Across a 12-Month Period in Children With ADHD: A Longitudinal Study. *Journal of Attention Disorders*, *23*(13), 1675–1685. <https://doi.org/10.1177/1087054717707046>
- Namasse, Z., Tabaa, M., & Mouchawrab, S. (2024). Predict ADHD in Children and Adults with Machine Learning Techniques. *Procedia Computer Science*, *251*, 124–131. <https://doi.org/10.1016/J.PROCS.2024.11.092>
- Orozco, E. I. L., Márquez, G. A. P., & Morillo, J. del R. J. (2021). Principales dificultades para el diagnóstico del TDAH en niños en Ecuador. *Revista Científica*, *6*(22), 96–116. <https://doi.org/10.29394/SCIENTIFIC.ISSN.2542-2987.2021.6.22.5.96-116>
- Pedrollo, G. R., Bagesteiro, L. B., Franco, A. R., & Balbinot, A. (2024). ADHD Diagnosis through Resting-State EEG Frequency Analysis with Random Forest. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*. <https://doi.org/10.1109/EMBC53108.2024.10782906>
- Pelsser, L. M., Frankena, K., Toorman, J., Savelkoul, H. F., Dubois, A. E., Pereira, R. R., Haagen, T. A., Rommelse, N. N., & Buitelaar, J. K. (2011). Effects of a restricted elimination diet on the behaviour of children with attention-deficit hyperactivity disorder (INCA study): A randomised controlled trial. *The Lancet*, *377*(9764), 494–503. [https://doi.org/10.1016/S0140-6736\(10\)62227-1](https://doi.org/10.1016/S0140-6736(10)62227-1)
- Rostami, M., Farashi, S., Khosrowabadi, R., & Pouretamad, H. (2020). Discrimination of ADHD Subtypes Using Decision Tree on Behavioral, Neuropsychological, and Neural Markers. *Basic and Clinical Neuroscience*, *11*(3), 359–368. <https://doi.org/10.32598/BCN.9.10.115>
- Shao, L., You, Y., Du, H., & Fu, D. (2020). Classification of ADHD with fMRI data and multi-objective optimization. *Computer Methods and Programs in Biomedicine*, *196*, 105676. <https://doi.org/10.1016/J.CMPB.2020.105676>