



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Instituto Tecnológico de Orizaba

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN I.- TESIS

TRABAJO PROFESIONAL

**"Identificación del nivel de diagnóstico
de TDAH mediante técnicas de
inteligencia artificial"**

QUE PARA OBTENER EL GRADO DE:
**MAESTRO EN SISTEMAS
COMPUTACIONALES**

PRESENTA:

I.S.C. Ismael Santarrosa López

DIRECTOR DE TESIS:

Dr. Giner Alor Hernández

CODIRECTOR DE TESIS:

Dra. Maritza Bustos López



ORIZABA, VERACRUZ, MÉXICO.

FEBRERO 2024

Orizaba, Veracruz, 16/febrero/2024
Dependencia: División de Estudios de
Posgrado e Investigación
Asunto: Autorización de Impresión
OPCION: I

**C. ISMAEL SANTARROSA LÓPEZ
CANDIDATO A GRADO DE MAESTRO EN:
SISTEMAS COMPUTACIONALES
P R E S E N T E.-**

De acuerdo con el Reglamento de Titulación vigente de los Centros de Enseñanza Técnica Superior, dependiente de la Dirección General de Institutos Tecnológicos de la Secretaría de Educación Pública y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

" Identificación del nivel de diagnóstico de TDAH mediante técnicas de inteligencia artificial"

comunico a Usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

ATENTAMENTE

Excelencia en Educación Tecnológica®
CIENCIA - TÉCNICA - CULTURA®



**DRA. OFELIA LANDETA ESCAMILLA
ENCARGADA DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN**





Orizaba, Veracruz, 09/febrero/2024
Asunto: Revisión de trabajo escrito

C. OFELIA LANDETA ESCAMILLA
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.

ISMAEL SANTARROSA LÓPEZ

La cual lleva el título de:

Identificación del nivel de diagnóstico de TDAH mediante técnicas de inteligencia artificial

Y concluyen que se acepta.

ATENTAMENTE
Excelencia en Educación Tecnológica®
CIENCIA - TÉCNICA - CULTURA®

PRESIDENTE: DR. GINER ALOR HERNÁNDEZ

FIRMA

SECRETARIO: DRA. MARITZA BUSTOS LÓPEZ

FIRMA

VOCAL: DR. JOSÉ LUIS SÁNCHEZ CERVANTES

FIRMA

VOCAL SUP.: DRA. LAURA NELY MORALES SÁNCHEZ

FIRMA


TA-09-18



CARTA DE CESIÓN DE DERECHOS

En la ciudad de Orizaba el día 26 del mes de febrero del año 20 24, el (la) que suscribe Ismael Santarrosa López alumno (a) del programa de Maestría en Sistemas Computacionales con número de control M16011220, manifiesta que es autor (a) intelectual del trabajo de tesis bajo la dirección del Dr. Giner Alor Hernández y ceden los derechos del trabajo intitulado "Identificación del nivel de diagnóstico de TDAH mediante técnicas de inteligencia artificial" al TecNM/Instituto Tecnológico de Orizaba para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y del director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección: msc@orizaba.tecnm.mx . Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.



Ismael Santarrosa López

Nombre y firma

CARTA DE ORIGINALIDAD

En la ciudad de Orizaba, Veracruz, el día 26 del mes de febrero del año 2024, el (la) que suscribe Ismael Santarrosa López, alumno (a) del programa de Maestría en Sistemas Computacionales con número de control M16011220, manifiesta que es autor (a) del trabajo de tesis titulado "Identificación del nivel de diagnóstico de TDAH mediante técnicas de inteligencia artificial" y declara que el trabajo es original, ya que su contenido es producto de su directa contribución intelectual. Todos los datos y las referencias a materiales ya publicados están debidamente identificados con su respectivo crédito e incluidos en las notas bibliográficas y en las citas que se destacan como tal y, en los casos que así lo requieran, se tienen las debidas autorizaciones de quienes poseen los derechos patrimoniales. Por lo tanto, se hace responsable de cualquier litigio o reclamación relacionada con derechos de propiedad intelectual, exonerando de toda responsabilidad al Tecnológico Nacional de México / Instituto Tecnológico de Orizaba.



Ismael Santarrosa López
Nombre y firma autógrafa

Agradecimientos

Culminar este trabajo de tesis ha sido un viaje largo y desafiante, lleno de momentos de incertidumbre y satisfacción. Sin embargo, este logro no habría sido posible sin el apoyo y la compañía de personas especiales que me acompañaron en el camino.

Primero, a mis padres, gracias por su amor incondicional, por su apoyo constante y por creer en mí desde el principio. Su aliento y confianza me impulsaron a seguir adelante incluso en los momentos más difíciles.

A mi querida pareja, Angela, tu motivación y entusiasmo fueron un faro que me guio durante todo el proceso. Tu paciencia y comprensión me permitieron encontrar el equilibrio entre mis estudios y nuestra vida personal. Gracias por ser mi compañera incondicional en este viaje.

A mis amigos y compañeros, agradezco su amistad y apoyo invaluable. Sus palabras de aliento, consejos y momentos de compañerismo me ayudaron a mantenerme motivado y enfocado en mi objetivo.

A mi director de tesis, Giner Alor Hernández, y a mi codirectora, Maritza Bustos López, su invaluable guía, paciencia y dedicación fueron fundamentales para el desarrollo de este trabajo. Sus comentarios, sugerencias y críticas constructivas me permitieron mejorar mi investigación y fortalecer mi tesis.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) y al Instituto Tecnológico Nacional de México Campus Orizaba; agradezco el apoyo económico y académico que me brindaron durante mi investigación. Su contribución fue fundamental para la realización de este trabajo.

Finalmente, a todas las personas que de una u otra forma me apoyaron en este camino: Gracias por su colaboración, paciencia y comprensión. Su presencia en mi vida ha sido un pilar fundamental para alcanzar este logro.

De corazón, gracias a todos.

Índice general

Índice general.....	VII
Índice de Figuras.....	XI
Índice de Tablas.....	XIII
Índice de Listados	XIV
Resumen	XV
Introducción.....	1
Capítulo 1. Antecedentes	3
1.1 Marco Teórico	3
1.1.1 Trastornos de Neurodesarrollo	3
1.1.2 TDAH	4
1.1.2.1 Tipos del TDAH	4
1.1.2.2 Diagnóstico y tratamiento del TDAH.....	5
1.1.3 Biomarcadores.....	6
1.1.4 Inteligencia Artificial	6
1.1.4.1 Aprendizaje Automático.....	8
1.1.4.2 Algoritmos de aprendizaje automático.....	9
1.1.4.3 Aprendizaje Profundo	10
1.1.4.4 Algoritmos de aprendizaje profundo	11
1.1.4.5 Redes Neuronales Artificiales.....	11
1.1.5 Aplicación Web	12
1.1.6 Lenguajes de programación	12
1.1.6.1 TypeScript	12
1.1.6.2 Python	13
1.1.7 Bibliotecas de desarrollo.....	13
1.1.7.1 Scikit-Learn.....	14
1.1.8 Dispositivos vestibles útiles para medir la actividad cerebral.....	14
1.1.8.1 Muse.....	15
1.1.8.2 Mendi.....	15
1.1.9 Minería de Datos.....	15

1.1.9.1 Técnicas de Minería de Datos	16
1.1.10 Instrucción Asistida por Computadora	17
1.2 Situación tecnológica, económica y operativa de la empresa	17
1.3 Planteamiento del problema	18
1.4 Objetivo general y específicos	19
1.4.1 Objetivo general.....	19
1.4.2 Objetivos específicos	19
1.5 Justificación	19
Capítulo 2. Estado de la práctica.....	22
2.1 Trabajos relacionados.....	22
2.2 Análisis comparativo	36
2.3 Solución propuesta	38
2.3.1 Tecnologías de desarrollo.....	39
2.3.1.1 HTML5.....	39
2.3.1.2 TypeScript	39
2.3.1.2 Python	40
2.3.2 Marcos de trabajo	40
2.3.2.1 Angular	40
2.3.2.2. FastAPI.....	40
2.3.3 Entornos de desarrollo.....	41
2.3.3.1. Visual Studio Code	41
2.3.4 Técnicas de Inteligencia Artificial	41
2.3.4.1 Aprendizaje Automático.....	42
2.3.4.2 Aprendizaje Profundo	42
2.3.5 Sistemas Gestores de Base de Datos	42
2.3.5.1 MYSQL	43
2.3.6 Metodologías de Desarrollo de Software	43
2.3.6.1 Extreme Programming.....	43
2.3.7 Justificación de la solución	44
Capítulo 3. Aplicación de la metodología	45
3.1 Análisis.....	45

3.1.1 Características del módulo	46
3.1.1.1 Identificación de variables biomédicas relacionadas al TDAH.....	46
3.1.1.2 Análisis de conjunto de datos	47
3.1.1.3 Selección de algoritmos de aprendizaje automático.....	49
3.1.1.4 Selección de algoritmos de aprendizaje profundo	51
3.1.2 Requerimientos funcionales del sistema.....	52
3.1.3 Casos de uso de la aplicación	53
3.2 Diseño.....	55
3.2.1 Esquema de almacenamiento de información	55
3.2.1.1 Diccionario de datos	56
3.2.2 Diseño de interfaces del módulo (Mockups)	59
3.2.2.1 Inicio de sesión.....	59
3.2.2.2 Vista principal (Dashboard)	60
3.2.2.3 Pacientes.....	61
3.2.2.4 Pruebas	62
3.2.2.5 Dispositivos	64
3.2.3 Diseño de arquitectura del módulo	65
3.2.4 Diseño de los servicios web (API).....	67
3.2.4.1 Diseño del servicio para iniciar de sesión.....	67
3.2.4.2 Diseño del servicio para obtener información de perfil del usuario..	67
3.2.4.3 Diseño del servicio para consultar la lista de pacientes.....	67
3.2.4.4 Diseño del servicio para obtener información de un paciente	68
3.2.4.5 Diseño del servicio para almacenar información de una prueba	68
3.2.4.6 Diseño del servicio para consultar la lista del historial de pruebas..	68
3.3 Desarrollo.....	68
3.3.1 Implementación de los algoritmos de aprendizaje automático.....	68
3.3.2 Desarrollo de los servicios	71
3.3.2.1 Servicio para identificar el nivel de atención.....	71
3.3.2.2 Servicio para iniciar de sesión	73
3.3.2.3 Servicio para obtener información del perfil de usuario.....	74
3.3.2.4 Servicio para consultar la lista de pacientes.....	75

3.3.2.5 Servicio para obtener información de un paciente.....	75
3.3.2.6 Servicio para almacenar información de una prueba	76
3.3.2.7 Servicio para consultar la lista del historial de pruebas	77
3.3.3 Desarrollo de las interfaces	78
Capítulo 4. Resultados	87
4.1 Proceso de identificación del TDAH.....	87
4.1.1 Diseño de la prueba.....	88
4.1.2 Caso de estudio 1: Sujeto con déficit de atención (positivo).....	89
4.1.3 Caso de estudio 2: Sujeto sin déficit de atención (negativo).....	89
4.1.4 Caso de estudio 3: Sujeto con posible déficit de atención	90
4.1.5 Datos iniciales.....	90
4.1.6 Proceso de identificación	91
4.1.7 Clasificación automática de los datos	96
4.1.8 Resultados.....	96
Capítulo 5. Conclusiones	98
5.1 Recomendaciones	99
Productos académicos	100
Derechos de autor	103
Bibliografía	105

Índice de Figuras

Figura 1.1. Tipos de aprendizaje automático.....	8
Figura 1.2. El aprendizaje profundo forma parte del aprendizaje automático, y a su vez, de la inteligencia artificial.	10
Figura 3.1. Metodología de investigación.	45
Figura 3.2. Comparación de las métricas obtenidas para el conjunto HYPERAKTIV.	50
Figura 3.3. Comparación de los resultados de la Tabla 3.2 para el conjunto de datos ADHD-200.....	51
Figura 3.4. Diagrama de casos de uso para el módulo desarrollado.	54
Figura 3.5. Es quema de almacenamiento para la base de datos.....	56
Figura 3.6. Diseño de la página de Iniciar Sesión.	59
Figura 3.7. Diseño de la página de Dashboard (vista principal).	60
Figura 3.8. Diseño de la página principal de Pacientes.....	61
Figura 3.9. Vista para exportar información de todos los pacientes.	61
Figura 3.10. Diseño de la página de Perfil del Paciente.....	62
Figura 3.11. Diseño de la página de Pruebas (selección de dispositivo).	63
Figura 3.12. Diseño de la página de Pruebas (prueba en tiempo real).	64
Figura 3.13. Diseño de la página principal de Dispositivos.	64
Figura 3.14. Arquitectura final del módulo.	65
Figura 3.15. Servicio para iniciar sesión.....	67
Figura 3.16. Servicio para obtener la información de perfil del usuario.....	67
Figura 3.17. Servicio para obtener la lista de pacientes.....	67
Figura 3.18. Servicio para obtener la información completa del paciente.	68
Figura 3.19. Servicio para almacenar la información de la prueba realizada.	68
Figura 3.20. Servicio para obtener la lista de pruebas realizadas.....	68
Figura 3.21. Pantalla de inicio de sesión.....	78
Figura 3.22. Pantalla principal después de iniciar sesión.....	79
Figura 3.23. Vista general de la sección de pacientes.	79
Figura 3.24. Modal para exportar la información de todos los pacientes.	80

Figura 3.25. Pantalla de perfil del paciente (previo a la realización de una prueba).	80
Figura 3.26. Pantalla de perfil del paciente (después de realizar una o más pruebas).....	81
Figura 3.27. Pantalla para la selección de dispositivo.....	82
Figura 3.28. Pantalla con información del dispositivo seleccionado.....	82
Figura 3.29. Lista de consejos previos a la prueba.	83
Figura 3.30. Búsqueda y sincronización entre el módulo y el dispositivo.	83
Figura 3.31. Pantalla de las pruebas en tiempo real.	84
Figura 3.32. Pantalla de la sección de dispositivos.	85
Figura 3.33. Vista general del reporte de la prueba.	86
Figura 3.34. Resultados del EEG para el nivel de atención.	86
Figura 4.1. Resultado obtenido para el primer caso de estudio (positivo en déficit de atención).....	90
Figura 4.2. Resultado obtenido para el segundo caso de estudio (negativo en déficit de atención).....	91
Figura 4.3. Resultado obtenido para el tercer caso de estudio (déficit de atención intermedio).....	91
Figura 4.4. Panel que muestra la información del paciente.....	92
Figura 4.5. Panel para la selección del dispositivo a utilizar en la prueba.....	92
Figura 4.6. Panel de la realización de la prueba en tiempo real.....	93
Figura 4.7. Panel que muestra la información del paciente (actualizado).	94
Figura 4.8. Panel del reporte de la prueba realizada.....	94
Figura 4.9. Panel del reporte realizado con los resultados del EEG realizado.	95

Índice de Tablas

Tabla 2.1 Análisis comparativo de los artículos relacionados.	36
Tabla 3.1. Resultados de la comparación obtenidos para el conjunto de datos HYPERAKTIV.	49
Tabla 3.2. Comparación de los resultados obtenidos en el conjunto de datos ADHD-200.	50
Tabla 3.3. Resultados obtenidos con los algoritmos de aprendizaje profundo para los conjuntos de datos EEG ADHD y WMRC ADHD.	51
Tabla 3.4. Descripción general del caso de uso de la Figura 3.2.	54
Tabla 3.5. Descripción de la tabla Tipos de Evaluación.	57
Tabla 3.6. Descripción de la tabla Tipos de Dispositivos.	57
Tabla 3.7. Descripción de la tabla Evaluaciones.	57
Tabla 3.8. Descripción de la tabla Proceso de Pruebas.	58
Tabla 3.9. Descripción de la tabla Proceso de Detalle de Pruebas.	58
Tabla 3.10. Descripción de la tabla Relación Paciente – Médico.	58
Tabla 3.11. Descripción de la tabla Relación Médico – Dispositivo.	59
Tabla 3.12. Reglas establecidas para identificar el nivel de atención.	73
Tabla 4.1. Características de los participantes.	87
Tabla 4.2. <i>Lista de actividades validadas para su aplicación para la identificación del TDAH.</i>	88
Tabla 4.3. Resultado obtenido para el primer caso de estudio.	89
Tabla 4.4. Resultado obtenido para el segundo caso de estudio.	89
Tabla 4.5. Resultado obtenido para el tercer caso de estudio.	90
Tabla 4.6. Valores de referencia para la identificación del déficit de atención dentro del TDAH.	96
Tabla 4.7. Matriz de confusión para la identificación de déficit de atención dentro del TDAH.	96

Índice de Listados

Listado 3.1. Configuración experimental para el conjunto de datos HYPERAKTIV con SVM.	69
Listado 3.2. Configuración experimental para el conjunto de datos con Regresión Lineal.	70
Listado 3.3. Configuración experimental para el conjunto de datos con CatBoost.	70
Listado 3.4 Método identificador del nivel de atención.	71
Listado 3.5. Código del servicio para iniciar sesión.	73
Listado 3.6. Código del servicio para obtener la información del usuario actual. ..	74
Listado 3.7. Código para el servicio de listar pacientes en el módulo.	75
Listado 3.8. Código para el servicio de obtener información de un paciente.	75
Listado 3.9. Código para el servicio que almacena la información de una prueba realizada.	76
Listado 3.10. Código para el servicio que obtiene el historial de pruebas de un paciente.	77

Resumen

El trastorno por déficit de atención e hiperactividad, también conocido como TDAH, es un trastorno que afecta principalmente a niños, generando problemas en los ámbitos de desarrollo de la persona, como lo son el ámbito escolar, social e incluso laboral. Las características principales de este trastorno son varios, como tener problemas para retener la atención, olvidar o perder cosas con frecuencia, una alta actividad motriz (correr, brincar, por mencionar algunos), cometer descuidos, entre otros. La detección de este trastorno es compleja, ya que los síntomas son muy parecidos al comportamiento habitual presentado durante la niñez. Si el trastorno no se detecta a tiempo, logra persistir con los síntomas hasta la edad adulta y afectar gravemente su estilo de vida.

Por lo antes mencionado, en este documento se propone el desarrollo de un módulo para la detección e identificación del nivel del TDAH en pacientes mediante técnicas de aprendizaje automático. El módulo se entrenó por un conjunto de datos de actividad y con el uso de un dispositivo inteligente, se monitorea la información del paciente. Con los datos obtenidos y con el uso de las técnicas de aprendizaje automático, se diagnosticó si un paciente padece o no de TDAH.

El principal beneficio de desarrollar este módulo es identificar de manera accesible y confiable, los síntomas asociados del TDAH para iniciar a tiempo el tratamiento de este trastorno y así evitar problemas o futuras secuelas para el estilo de vida del paciente. Además, la implementación de este módulo contribuyó significativamente a la personalización del proceso de diagnóstico. Al adaptarse a los patrones individuales de comportamiento y las respuestas cognitivas de cada paciente, lo que aumentó la precisión de los diagnósticos por parte de los profesionales de la salud. Otra ventaja clave fue la mejora en la eficiencia de los procesos de seguimiento y evaluación clínica. Al automatizar la recopilación y análisis de datos de comportamiento y cognitivos, el módulo redujo la carga de trabajo manual de los especialistas, optimizando el tiempo de los profesionales de la salud y acelerando el tiempo de respuesta de las decisiones clínicas.

Introducción

En la actualidad cada día son más los casos registrados de niños diagnosticados con TDAH, y aun que el TDAH se estudia desde hace muchos años, las técnicas actuales aún son deficientes para el correcto diagnóstico de este o en su caso, de difícil acceso por el tiempo y costo de implican. La falta de precisión en los diagnósticos son un problema ya que evitaría que las personas que padecen de este trastorno y no lo sabe, no reciban el tratamiento adecuado a tiempo, generando problemas en su entorno social, escolar o laboral.

Según la Organización Mundial de la Salud (OMS), se estima que en México hay aproximadamente 33 millones de niños y adolescentes, de los cuales 1.5 millones de ellos tiene la probabilidad de padecer este trastorno. Cerca de la mitad de los infantes que presentaron este trastorno continúan presentando los síntomas en la edad adulta, reflejándose en problemas emocionales y de relación con otros. El diagnóstico es de gran relevancia, pues su tratamiento permite disminuir los riesgos que conlleva, como sufrir maltrato infantil, rechazo escolar, aislamiento social, e incluso, el consumo de sustancias nocivas para la salud en los adolescentes.

Los investigadores aún no determinan las causas exactas que generan el desarrollo del TDAH, factores como antecedentes familiares de TDAH, el consumo de sustancias nocivas para la salud durante la gestación o una deficiencia de peso al nacer son los factores que más están relacionados el TDAH.

En la presente tesis se propone el desarrollo de un módulo para la detección del trastorno por déficit de atención e hiperactividad con el uso de técnicas del aprendizaje automático.

Este documento se divide en cinco capítulos, el primer capítulo se presenta el marco teórico, el planteamiento del problema, así como el objetivo principal y los objetivos específicos junto con la justificación; en el segundo capítulo se presenta el estado de la práctica junto con un análisis comparativo, se describe la solución y un análisis de las tecnologías a usar; en el tercer capítulo describe el desarrollo de la solución propuesta (diseño del módulo, diseño del esquema de la base de datos,

implementación de los algoritmos de inteligencia artificial, por mencionar algunos); en el cuarto capítulo se presenta los resultados obtenidos en el desarrollo y de las pruebas utilizadas para finalizar con el capítulo cinco correspondiente a las conclusiones y la referencias utilizadas.

Capítulo 1. Antecedentes

En este capítulo se presentan los conceptos más relevantes para el desarrollo de este proyecto. También se incluye la problemática a resolver, el objetivo general, los objetivos específicos y la justificación de este trabajo.

1.1 Marco Teórico

A continuación, se presenta un conjunto de términos relacionados con el tema de investigación.

1.1.1 Trastornos de Neurodesarrollo

Los trastornos de neurodesarrollo se manifiestan generalmente en la etapa temprana del desarrollo (durante la niñez) y a menudo antes de que el infante comience la etapa escolar, e involucran una alteración en el desarrollo del cerebro y del sistema nervioso [1]. Algunos de los trastornos de neurodesarrollo son:

- **Trastorno del Espectro Autista (TEA):** Implica desafíos en la comunicación social y la presencia de comportamientos repetitivos y/o intereses restringidos.
- **Trastorno por Déficit de Atención e Hiperactividad (TDAH):** Caracterizado por dificultades en mantener la atención, comportamiento hiperactivo y actuar impulsivamente.
- **Trastornos del Aprendizaje:** Como la dislexia (dificultad en la lectura), la dispraxia (problemas con el movimiento y la coordinación), la discalculia (dificultades en matemáticas), entre otros.
- **Trastorno de la Comunicación:** Incluye problemas en la comprensión del lenguaje hablado y escrito, y en la expresión verbal.
- **Trastornos del Movimiento:** Tales como la distonía (movimientos involuntarios y prolongados), la corea (movimientos repentinos y no controlados) y el temblor.
- **Discapacidad Intelectual:** Se refiere a limitaciones significativas en el funcionamiento intelectual y en las habilidades adaptativas.
- **Trastornos Motores:** Como la parálisis cerebral, que afecta la habilidad de movimiento y la postura.

Los trastornos de neurodesarrollo suelen estar relacionados con dificultades en el aprendizaje, el control de las emociones, la memoria, la atención, y las habilidades sociales y a menudo se diagnostican en la infancia o la adolescencia, aunque algunos no son identificados hasta la edad adulta. Cada uno presenta sus propios desafíos y necesidades específicas (el manejo y tratamiento varía considerablemente).

1.1.2 TDAH

El trastorno por déficit de atención e hiperactividad (TDAH) es uno de los problemas de neurodesarrollo más conocidos de la vida juvenil. Generalmente se diagnostica en la niñez y con frecuencia perdura en la edad adulta. Los niños con TDAH tienen problemas para concentrarse, para controlar las formas precipitadas de comportamiento o para ser excesivamente activos.

Los efectos secundarios se asemejan al comportamiento normal de los niños, los niños con TDAH no dejan atrás el comportamiento a medida que avanzan en años. Los síntomas continúan y causan problemas en la escuela, en casa o con personas cercanas [2]. Un paciente con TDAH muestra las siguientes formas de comportamiento:

- Hablar mucho.
- Descuidar o perder cosas de manera frecuente.
- Retorcerse con frecuencia.
- Cometer errores imprudentes.
- Enfrentarse a retos inútiles.
- Experimentar dificultades para oponerse a la distracción.
- Dificultad para alternar turnos.
- Experimentar problemas de convivencia con los demás.

1.1.2.1 Tipos del TDAH

Existen tres subtipos del TDAH [3] que van dependiendo de la intensidad con el que se presentan los síntomas en la persona:

- **TDAH en la que predomina la falta de atención:** El individuo se agita rápidamente o descuida las sutilezas de la rutina diaria, no cumple en su totalidad tareas o rutinas, no se concentra en las sutilezas o no se adhiere a las instrucciones o discusiones.
- **TDAH en la que predomina la hiperactividad/impulsividad:** El individuo se retuerce y divaga. Le resulta difícil permanecer de pie o sentado durante periodos de tiempo significativos (por ejemplo, para una fiesta o mientras realiza tareas escolares). Los niños más jóvenes están continuamente corriendo, saltando o trepando. El individuo se siente inquieto y desaprueba la impulsividad. Un individuo con impulsividad tiene un mayor número de percances y heridas que otros.
- **Presentación combinada:** Los efectos secundarios de los dos tipos anteriores están presentes de forma similar en el individuo.

Dado que los síntomas cambian después de algún tiempo, la presentación también cambia a largo plazo [3].

1.1.2.2 Diagnóstico y tratamiento del TDAH

No existe una prueba única para diagnosticar el TDAH; diferentes cuestiones, como el malestar, la tristeza y determinados tipos de trastornos de aprendizaje, tienen efectos secundarios comparables. Un hallazgo incluye una evaluación clínica, incluyendo pruebas de audición y visión, para descartar diferentes problemas con efectos secundarios como el TDAH. Una pieza más de la determinación incorpora una agenda para calificar los efectos secundarios del TDAH y la recopilación del conjunto de experiencias del joven de los tutores, instructores, y algunas veces el propio niño.

La mayoría de las veces, el TDAH se trata mejor utilizando una mezcla de tratamiento social y prescripción de medicamentos. Para los niños de edad preescolar (4-5 años) con TDAH, se sugiere el tratamiento social como línea principal de tratamiento. Ningún tratamiento único es la respuesta principal para todos los niños, y los grandes planes de tratamiento incorporan un control estrecho, un seguimiento y cualquier cambio vital en el camino [2].

1.1.3 Biomarcadores

El término biomarcador, un acrónimo de "marcador biológico", alude a una subcategoría general de signos clínicos, es decir, signos objetivos del estado clínico vistos desde fuera del paciente, estimados de forma precisa y reproducible. Los signos médicos difieren de los síntomas clínicos, que se limitan a los signos de bienestar o enfermedad vistos por el propio paciente. Hay algunos significados exactos adicionales de los biomarcadores en la literatura, y por suerte se cruzan significativamente. El *Biomarker Definition Working Group* (BDWG) estableció la definición de un biomarcador como "una característica que se mide y evalúa objetivamente como un indicador de procesos biológicos normales, procesos patógenos o respuestas farmacológicas a una intervención terapéutica" [4].

Los ejemplos de biomarcadores incluyen todo, desde el pulso y la presión arterial hasta las químicas básicas y las pruebas de laboratorio más complejas de sangre y otros tejidos. Los signos médicos tienen una larga historia de propósito en la práctica clínica, tan antigua como la medicina misma, y los biomarcadores son básicamente los signos clínicos más objetivos y cuantificables que la ciencia de los centros de investigación de vanguardia permite estimar de forma reproducible. La utilización de los biomarcadores, y específicamente de los biomarcadores estimados en el laboratorio, en el examen clínico es bastante más actual, y las mejores formas de tratar con esta formación todavía se están creando y refinando. El objetivo clave en cuestión es determinar la relación entre cualquier biomarcador medible dado y los criterios de valoración clínicos relevantes [4].

1.1.4 Inteligencia Artificial

No hay una definición única y definitiva para la IA (Inteligencia Artificial) es por eso que muchos autores al escribir del tema dan su propia definición, por ejemplo:

“La inteligencia Artificial es el estudio de las ideas que permiten ser inteligentes a los ordenadores” o también como *“Parte de la informática que estudia procesos simbólicos, razonamientos no algorítmicos y representaciones simbólicas del conocimiento”* [5].

En cualquier caso, una de las definiciones más fiables se refleja en la *Encyclopedia Of Artificial Intelligence*, definiéndola como como un área de la ciencia y el diseño que se ocupa de la comprensión, según una perspectiva computacional, de lo que ordinariamente se denomina conducta inteligente [5].

Así mismo, la idea o el significado de la IA está avanzando, muchos la consideran como la reproducción de los procesos de perspicacia humana por parte de máquinas o antigüedades hechas por personas, particularmente los sistemas informáticos. La inteligencia artificial se organiza a partir de varias materias como la ingeniería de software, la racionalidad, las matemáticas, el razonamiento y la información, para crear el desarrollo de modelos computacionales aptos para realizar ejercicios humanos, en vista de dos atributos cruciales: el pensamiento y la conducta. La IA aborda temas tales como:

- **Resolución de problemas y búsqueda:** Cómo formalizar y las formas de resolución de un problema.
- **Representación de la información y sistemas basados en este:** Sistemas expertos que integran la información al espacio de aplicación para solucionar problemas.
- **Aprendizaje automático:** Mejora de proyectos a partir del aprendizaje de la actividad realizada, de los propios errores y de la utilización de instrumentos que permiten extraer información de los conjuntos de datos.
- **Inteligencia artificial distribuida:** Arreglos distribuidos con independencia para decidir y conectar con otros.
- **Otros puntos** relacionados con el lenguaje natural, la visión artificial, la robótica, vehículos perspicaces, el reconocimiento del habla y diferentes resultados.

La inteligencia artificial, al igual que otras innovaciones problemáticas, desempeña sin duda un papel importante y un impacto en los marcos de datos de bienestar, la telemedicina, la imagen, el tratamiento del dolor, la recuperación, la excitación neurosensorial y diferentes campos de la medicación son hoy un espacio de desarrollo en la enseñanza clínica y la atención médica [6].

1.1.4.1 Aprendizaje Automático

El aprendizaje automático (en inglés, *Machine Learning*) es una de las principales formas de tratar el razonamiento del hombre. Básicamente, las computadoras o las máquinas aprenden sin ser modificadas para ello. Un resultado normal son las ideas o previsiones en una circunstancia concreta. La IA utiliza cálculos para obtener diseños de información, con el punto de que los cálculos se utilizan para aprender ejemplos y utilizar la información adquirida para la toma de decisiones independiente [5]. En la Figura 1.1 se aprecian los tres diferentes subtipos de aprendizaje automático.




Figura 1.1. Tipos de aprendizaje automático.

- En el aprendizaje supervisado, los algoritmos utilizan la información que se identifica de forma proactiva para demostrar cómo se organizan los nuevos datos. Con esta estrategia, se espera que la mediación humana dé lugar a la retroalimentación [7].
- En el aprendizaje no supervisado, los algoritmos no utilizan información recientemente nombrada o coordinada para demostrar cómo se ordenan los nuevos datos, sino que tienen que averiguar cómo ordenarlos ellos mismos. En consecuencia, esta estrategia no necesita la mediación humana [7].
- Por último, con el aprendizaje por refuerzo, el modelo recibe información en forma de recompensas o castigos por sus acciones, y utiliza esta retroalimentación para ajustar su comportamiento y maximizar la recompensa a largo plazo [7].

1.1.4.2 Algoritmos de aprendizaje automático

Los algoritmos de aprendizaje automático permiten a las computadoras aprender de los datos y hacer predicciones para tomar decisiones basadas en ellos. Hay tres tipos principales de aprendizaje automático: supervisado, no supervisado y de refuerzo. A continuación, se enlistan algunos de los algoritmos fundamentales en el campo del aprendizaje automático:

- La **Regresión Lineal** se utiliza para estimar valores reales (como el costo de las casas, número de llamadas, ventas totales, etc.) basados en una o varias variables continuas. Este algoritmo establece la relación entre las variables independientes y dependientes ajustando la mejor línea recta a los datos. Esta línea de mejor ajuste es conocida como la línea de regresión.
- El **Árbol de Decisión** es un algoritmo de aprendizaje supervisado que se utiliza principalmente para problemas de clasificación, aunque funciona para variables dependientes tanto categóricas como continuas. Este algoritmo divide la población en dos o más conjuntos homogéneos basados en los atributos o variables independientes más significativos, con el objetivo de hacer grupos lo más distintos posible [8].
- **SVM** (Máquina de Vectores de Soporte) es un algoritmo supervisado que discrimina entre dos clases generando un hiperplano que separa de manera óptima estas mismas clases después de que los datos de entrada se transformaron matemáticamente en un espacio de alta dimensión. Dado que el enfoque SVM está basado en datos y libre de modelos, tiene un importante poder discriminativo para la clasificación, especialmente en los casos en que los tamaños de la muestra son pequeños y un gran número de variables están involucradas. Esta técnica se utilizó recientemente para desarrollar la clasificación automatizada de enfermedades y para mejorar los métodos de detección de enfermedades en el entorno clínico [9].
- **KNN** (*k-Nearest Neighbors*) es utilizado tanto para problemas de clasificación como de regresión, aunque es más comúnmente utilizado en problemas de clasificación. El algoritmo KNN es simple: almacena todos los casos disponibles y clasifica nuevos casos mediante una votación mayoritaria de sus k vecinos

más cercanos. La clasificación de un caso se realiza asignándolo a la clase más común entre sus k vecinos más cercanos, medidos mediante una función de distancia [8].

1.1.4.3 Aprendizaje Profundo

El aprendizaje profundo (en inglés, *Deep Learning*). Se trata de un subcampo del aprendizaje automático que se utiliza para resolver problemas muy complejos y que normalmente implican grandes cantidades de datos.

El aprendizaje profundo se produce mediante el uso de redes neuronales (Figura 1.2), que se organizan en capas para reconocer relaciones y patrones complejos en los datos. Su aplicación requiere un enorme conjunto de información y una potente capacidad de procesamiento. Actualmente, se utiliza en el reconocimiento de voz, el procesamiento del lenguaje natural, la visión artificial y la identificación de vehículos en los sistemas de asistencia al conductor [7].




Figura 1.2. El aprendizaje profundo forma parte del aprendizaje automático, y a su vez, de la inteligencia artificial.

El aprendizaje profundo incorpora modelos computacionales y algoritmos que imitan la estructura de las redes neuronales biológicas en el cerebro, llamadas redes neuronales artificiales (ANN, *Artificial Neural Network*). Cada vez que el cerebro recibe información nueva, trata de compararla con información ya conocida para tratar de darle sentido. El cerebro descifra la información mediante el etiquetado y

la asignación de elementos a varias categorías, y el aprendizaje profundo emplea el mismo concepto [10].

1.1.4.4 Algoritmos de aprendizaje profundo

Los algoritmos de aprendizaje profundo son un subconjunto de aprendizaje automático enfocado a redes neuronales de muchas capas, conocidas como redes neuronales profundas. Estas redes tienen la capacidad de aprender jerarquías de características de los datos, lo que permite realizar tareas complejas como reconocimiento de imágenes, procesamiento de lenguaje natural, entre otros.

Las **Redes Neuronales Convolucionales** (CNN, por sus siglas en inglés) son una categoría de redes neuronales muy efectivas en tareas relacionadas con el procesamiento de imágenes, como reconocimiento de objetos, detección de rostros y clasificación de imágenes. Una CNN se compone de varias capas que transforman la entrada (una imagen) en una salida (una etiqueta de clase) [11]. Las capas clave de una CNN son:

- Capa de Convolución: donde se detectan las características de la imagen, como bordes, texturas o colores.
- Capa de Activación: introduce no linealidades en el modelo, permitiendo que la red aprenda patrones más complejos.
- Capa de Pooling: reduce la dimensionalidad de los mapas de características, lo que reduce el número de parámetros y el costo computacional.
- Capa Completamente Conectada: todas las neuronas están conectadas entre sí y se utilizan para producir la salida final, que suele ser una clasificación, una puntuación, entre otras.

La combinación de estas capas permite que las CNN sean efectivas para aprender jerarquías de características de las imágenes y realizar tareas de procesamiento de imágenes de manera eficiente.

1.1.4.5 Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN) son sistemas computacionales que consisten en muchos elementos de procesamiento simples conectados entre sí

para realizar tareas de manera análoga a los cerebros biológicos. ANN se utiliza de manera efectiva como una herramienta en la toma de decisiones médicas. El proceso de aprendizaje de las redes neuronales artificiales es similar al de la función de aprendizaje del cerebro. Durante el entrenamiento, se entregan muestras a la capa de entrada que produce cambios en el estado de activación de los elementos de procesamiento de salida. La red ajusta los pesos dependiendo de la diferencia entre los valores de salida requeridos y calculados [5].

1.1.5 Aplicación Web

Una aplicación web es un programa informático avanzado que se encuentra alojado en un servidor remoto, permitiendo su utilización y manipulación por medio de navegadores web desde diversos dispositivos. Estas aplicaciones, por su naturaleza de diseño, proponen un marco de interacción digital que se adapta a las peculiaridades de los navegadores, mostrando un manejo diferenciado con lenguajes web como HTML, XML, Flash, Perl, ASP, y PHP. A través de la interfaz navegador-servidor, las aplicaciones web facilitan la compatibilidad con una amplia gama de sistemas operativos y configuraciones de hardware, lo que las convierte en herramientas versátiles para la entrega de funcionalidades y servicios en línea. En un contexto contemporáneo, las aplicaciones web representan una convergencia entre la ingeniería web y el desarrollo de software, enfrentando desafíos específicos en su construcción y mantenimiento, pero proporcionando a su vez, una plataforma eficaz para la interacción usuario-servidor y la entrega de servicios en línea [12].

1.1.6 Lenguajes de programación

Los lenguajes de programación permiten diseñar y construir un conjunto de instrucciones que le indican a una computadora cómo realizar una tarea específica.

1.1.6.1 TypeScript

TypeScript es un lenguaje de programación desarrollado por Microsoft, que se basa en JavaScript y añade funcionalidades adicionales para mejorar el desarrollo de software grande y complejo. Una de las características más destacadas de TypeScript es su sistema de tipos estáticos, que permite a los desarrolladores especificar los tipos de variables, parámetros y valores de retorno en su código.

Esto facilita la detección de errores en tiempo de compilación, mejora la legibilidad del código y proporciona una experiencia de desarrollo más robusta y segura. Además del sistema de tipos, TypeScript también introduce otras características que no están presentes en JavaScript, como interfaces, tipos enumerados y decoradores, que brindan más flexibilidad y opciones para estructurar el código de manera eficiente [13].

TypeScript es completamente compatible con JavaScript, lo que significa que cualquier código JavaScript válido también es código TypeScript válido. Esto hace que sea relativamente fácil para los desarrolladores que ya están familiarizados con JavaScript adoptar TypeScript en sus proyectos.

1.1.6.2 Python

Python es un lenguaje descifrado, intuitivo y con objetos. Integra módulos, casos especiales, composición dinámica, tipos de información de nivel extremadamente significativo y clases. Python consolida una potencia notable con una estructura de sintaxis excepcionalmente clara. Tiene puntos de interacción con numerosas llamadas y bibliotecas, así como con diferentes sistemas de ventanas, y es extensible en C o C++. Asimismo, es utilizable como lenguaje de expansión para aplicaciones que necesitan un punto de conexión programable. Por último, Python se ejecuta en numerosas variaciones de Unix, Mac, Windows 2000 y posteriores.

Python es un lenguaje de programación de propósito general de alto nivel y ampliamente útil que se aplica a una amplia gama de tipos de cuestiones. El lenguaje se acompaña de una enorme biblioteca estándar que cubre regiones como el manejo de cadenas (articulaciones habituales, Unicode, cálculo de diferencia de registros), convenciones de Internet (HTTP, FTP, SMTP, XML-RPC, POP, IMAP, programación CGI), programación (pruebas unitarias, registro, perfiles, examen de código Python) e interfaces de marco de trabajo (llamadas de marco, marcos de documentos, anexos TCP/IP) [14].

1.1.7 Bibliotecas de desarrollo

Las bibliotecas de desarrollo son colecciones de funciones, clases, y otros recursos predefinidos que facilitan el proceso de desarrollo, ya que permite a los

programadores utilizar código ya escrito y probado para realizar tareas comunes. Estas bibliotecas incluyen funciones para manejar operaciones de entrada y salida, procesamiento de datos, interacción con sistemas de bases de datos, manipulación de gráficos, entre otros.

Además, las bibliotecas de desarrollo también ayudan a mejorar la calidad del software, ya que el código en una biblioteca suele escribirse y actualizarse por expertos en el área, ya probados y depurados en múltiples situaciones. Esto reduce la posibilidad de errores y problemas en el software final. Es común que las bibliotecas de desarrollo se enfoquen en un lenguaje de programación específico o en una plataforma de desarrollo particular, y de código abierto o comercial.

1.1.7.1 Scikit-Learn

Scikit-learn es una biblioteca de desarrollo de código abierto para Python que proporciona herramientas y algoritmos para aprendizaje automático y análisis de datos. Es una de las bibliotecas más utilizadas en la comunidad de ciencia de datos y de aprendizaje automático, y es conocida por su facilidad de uso, eficiencia y versatilidad.

Esta biblioteca incluye una amplia gama de algoritmos de aprendizaje automático, así como diversas herramientas para la preparación y limpieza de datos, evaluación de modelos, y selección de características. La biblioteca se integra de manera efectiva con otras bibliotecas de Python utilizadas en ciencia de datos, lo que facilita la realización de análisis y visualizaciones de datos [15].

El uso de Scikit-learn en proyectos de aprendizaje automático y análisis de datos permite a los desarrolladores y científicos de datos acceder a una amplia gama de algoritmos y herramientas probados y de alta calidad, lo que facilita el desarrollo de soluciones eficientes y efectivas.

1.1.8 Dispositivos vestibles útiles para medir la actividad cerebral

Existen dispositivos que son instrumentos tecnológicos diseñados para medir y analizar la actividad cerebral, cada uno con un enfoque y metodología particular. A

continuación, se describe brevemente cada uno de los dispositivos contemplados en la presente tesis en el contexto de detección de la actividad cerebral.

1.1.8.1 Muse

Muse es una diadema inteligente que funciona como un entrenador personal de meditación. Utiliza sensores EEG avanzados para detectar la actividad cerebral y proporcionar retroalimentación en tiempo real en forma de sonidos suaves a través de auriculares. La diadema Muse tiene siete sensores; dos ubicados en la frente, dos detrás de las orejas, y tres sensores de 'referencia' que miden la actividad en otras partes del cerebro, proporcionando así un contexto para la actividad en regiones clave. La información recopilada por el dispositivo se utiliza para proporcionar retroalimentación en tiempo real al usuario a través de una aplicación móvil, con el objetivo de ayudar a mejorar la meditación y la concentración. Los sensores de Muse detectan las ondas cerebrales y los patrones asociados con diferentes estados mentales, como la relajación y la concentración, y utilizan esta información para guiar al usuario en su práctica de meditación [16].

1.1.8.2 Mendi

Mendi es un dispositivo de *neurofeedback* que utiliza la tecnología de oxígeno funcional en el cerebro para medir la actividad cerebral para hacer accesible el entrenamiento cerebral en cualquier lugar. El dispositivo consta de una diadema que se coloca en la frente y que contiene sensores avanzados basados en la espectroscopia funcional del infrarrojo cercano (fNIRS) para medir la actividad cerebral, principalmente en la corteza prefrontal. Una aplicación móvil traduce esta actividad en una puntuación, y mediante el uso de un juego para controlar conscientemente la puntuación, los usuarios logran mejorar el control de la actividad cerebral en la corteza prefrontal. El objetivo de ayudar al usuario a mejorar su capacidad de concentración y relajación [17].

1.1.9 Minería de Datos

La minería de datos se define como “el proceso no trivial de identificar patrones válidos, novedosos, potencialmente útiles y, en última instancia, comprensibles en los datos”. Además, la minería de datos también se define como un procedimiento

en el descubrimiento de conocimiento que se compone de la aplicación de algoritmos de extracción y descubrimiento de datos. Ahora juega un gran papel en diferentes áreas como los negocios, la ciencia, la industria, entre otros. al proporcionar información como relaciones implícitas o tendencias potenciales para la gestión y la toma de decisiones [18].

1.1.9.1 Técnicas de Minería de Datos

La minería de datos es uno de los pasos en el descubrimiento de conocimiento en bases de datos, cuyo objetivo es identificar patrones comprensibles en los datos y extraer conocimiento de los datos. Existe una serie de técnicas de minería de datos (agrupación, clasificación, detección de valores atípicos, por mencionar algunas) para elegir [19].

- **Clasificación:** El algoritmo de clasificación es un método de aprendizaje supervisado. El enfoque central es clasificar los datos no etiquetados de acuerdo con los datos de entrada y sus etiquetas correspondientes mediante el proceso de mapeo de un conjunto de datos a diferentes categorías predeterminadas que no se superponen. La clasificación identifica un modelo que describe y distingue modelos de clases de datos o conceptos para predecir objetos de etiqueta de clase desconocidos. Los algoritmos de clasificación comúnmente utilizados incluyen la clasificación *Naïve Bayes*, las máquinas de vectores de soporte, el árbol de decisiones, entre otras. Cada algoritmo tiene sus propias ventajas y desventajas correspondientes y es adecuado para diferentes tipos de conjuntos de datos.
- **Agrupación:** Similar a la clasificación, el agrupamiento asigna un conjunto de datos a diferentes clases. Sin embargo, el agrupamiento pertenece al aprendizaje no supervisado. Sin un conocimiento previo de los criterios de clasificación, la computadora aprende el conjunto, descubre las reglas de clasificación y, de acuerdo con las reglas de clasificación, determina a qué categoría pertenecen los registros a clasificar. El enfoque central de la agrupación es agrupar datos con atributos iguales o similares para formar un

conjunto de datos. El método de agrupamiento principal temporal incluye el aprendizaje múltiple y el agrupamiento de *K-Means*.

- **Integración de datos:** La integración de datos se refiere al estudio de la fusión de fuentes de datos para descubrir correlaciones entre datos que se refieren al mismo significado y entidades de diferentes fuentes de datos. En aplicaciones prácticas, el trabajo de integración de datos es importante para los escenarios de gestión, consulta y análisis de *Big Data* [18].

1.1.10 Instrucción Asistida por Computadora

Una de las mejores estrategias en la intervención escolar para estudiantes con un trastorno que afecte el desarrollo escolar es la instrucción asistida por computadora (CAI, *Computer-assisted Instruction*), que incluye funciones de instrucción que permiten a los estudiantes con TDAH centrar su atención en estímulos educativos. CAI se diseñó principalmente para abordar objetivos de instrucción específicos, centrarse en material esencial, utilizar múltiples modalidades sensoriales (textos escritos, imágenes, narración, sonidos y animaciones); dividir el material de contenido en piezas de información más pequeñas y proporcionar comentarios inmediatos sobre la precisión de la respuesta. CAI ayuda a los estudiantes a mejorar el rendimiento académico dado a los contenidos bastante claramente diseñados, unidades de aprendizaje bien estructuradas que se proporcionan según secuencias planificadas de complejidad creciente y retroalimentación inmediata [20].

1.2 Situación tecnológica, económica y operativa de la empresa

El Instituto Tecnológico de Orizaba es una institución de educación superior dispuesta a la mejora de la ciencia y la innovación a través de la preparación de recursos humanos y la investigación en dichas áreas, para el fortalecimiento económico y social de la gran región montañosa en el punto focal del territorio de Veracruz. El instituto se encuentra ubicado en Avenida Oriente 9 Núm. 852, Colonia Emiliano Zapata, C.P. 94320, Orizaba, Veracruz. Brinda educación superior, orientada al desarrollo de la ciencia y la técnica. Actualmente, en el instituto se imparten carreras a nivel licenciatura y estudios de posgrado. A nivel licenciatura, cuenta con ocho programas educativos.

Dentro del instituto, se encuentra el área de la Maestría en Sistemas Computacionales de la División de Estudios de Posgrado e Investigación del Instituto Tecnológico de Orizaba que es un programa de estudios de posgrado que responde a las necesidades de los sectores de la sociedad y, asimismo, ofrece un Doctorado en Ciencias de la Ingeniería.

1.3 Planteamiento del problema

El trastorno por déficit de atención e hiperactividad (TDAH) es uno de los trastornos del neurodesarrollo más frecuentes de la niñez. Habitualmente su diagnóstico se realiza en la niñez y a menudo dura hasta la adultez.

Los profesionales de atención médica utilizan las pautas de la quinta edición del Manual Diagnóstico y Estadístico (DSM-5), de la Asociación Estadounidense de Siquiatría (*American Psychiatric Association*) para diagnosticar el TDAH. Este estándar de diagnóstico ayuda a garantizar que el diagnóstico y tratamiento de las personas con TDAH se realice de manera correcta. El uso del mismo estándar también ayuda a determinar cuántos niños tienen TDAH y qué impacto tiene esta afección en la salud pública. En la actualidad, no hay pruebas de laboratorio ni una sola causa genética identificada para determinar el TDAH; en cambio, los médicos observan el comportamiento del niño y realizan entrevistas estructuradas con los cuidadores del niño mediante cuestionarios. Pero estos cuestionarios son extensos, complicados y no infalibles. Como resultado, muchos niños no reciben los tratamientos que necesitan en un momento crítico.

Por lo anterior, se requiere desarrollar sistemas más rápidos, más confiables y más accesibles para ayudar a los médicos a evaluar a los niños para detectar trastornos del desarrollo como el TDAH. Un método basado en Inteligencia Artificial (IA) toma la forma de una prueba adaptativa por computadora, impulsada por el aprendizaje automático, que ayude a los profesionales clínicos a decidir qué preguntas hacer a continuación en tiempo real en función de las respuestas anteriores de los cuidadores. Este método basado en IA, actúa como un diagrama de flujo inteligente, adaptándose en función de las respuestas anteriores del encuestado y

recomendando qué elemento preguntar a continuación a medida que haya más datos disponibles sobre el niño.

Mediante la utilización de un método de entrenamiento de aprendizaje por refuerzo basado en recompensar los comportamientos deseados y castigar los no deseados, se sugiere qué elementos seguir para diferenciar entre trastornos y hacer un diagnóstico preciso.

1.4 Objetivo general y específicos

A continuación, se describe el objetivo general y los objetivos específicos de la propuesta del tema de tesis.

1.4.1 Objetivo general

Desarrollar un módulo de software para la identificación del nivel de diagnóstico de TDAH mediante técnicas de inteligencia artificial.

1.4.2 Objetivos específicos

- Analizar y estudiar los algoritmos de inteligencia artificial más usados en el estado de la práctica para la detección del trastorno por déficit de atención e hiperactividad.
- Identificar los principales biomarcadores relacionados con la detección del trastorno por déficit de atención e hiperactividad reportados en la literatura.
- Diseñar un conjunto de prestaciones de servicios para la detección del trastorno por déficit de atención e hiperactividad.
- Desarrollar un módulo de software para la identificación del nivel de diagnóstico de TDAH mediante técnicas de inteligencia artificial.
- Evaluar y validar el módulo desarrollado mediante un caso de estudio como prueba de concepto.

1.5 Justificación

El trastorno por déficit de atención e hiperactividad es cada vez más presente en niños, este trastorno afecta severamente la vida del paciente, afectando su entorno escolar, social e incluso laboral. Este trastorno neurológico afecta cerca del 5% a 11% de los niños y 2% a 5% de los adultos en todo el mundo, según la Organización

Mundial de la Salud (OMS) [21] y se estima que en México hay aproximadamente 1.5 millones de los 33 millones de niños y adolescentes en todo el país que tienen la probabilidad de padecer este trastorno según el CDC [22]. El TDAH se caracteriza por una actividad motora excesiva, poco interés por aprender, impulsividad y la dificultad de controlar impulsos. Si el paciente no se diagnostica y trata a tiempo, los síntomas llegan a persistir hasta la edad adulta. No obstante, la detección de este trastorno es compleja por la similitud de los síntomas con el comportamiento habitual de las personas durante la niñez e incluso de otros trastornos. Carecer de un diagnóstico certero afecta gravemente a la calidad de vida de los pacientes que sufren de este trastorno por no recibir la atención necesaria.

El desarrollo tecnológico en la actualidad se ve cada vez más relacionado en el sector de la salud, por lo que, por medio de este trabajo, al utilizar técnicas de inteligencia artificial y añadiendo el impulso del aprendizaje automático, se pretende obtener mejores resultados en la identificación del nivel de diagnóstico de TDAH. Consecuencia de esto, se realiza una contribución a la población y al estado del arte para la detección correcta y oportuna del TDAH e inclusive de otros trastornos con características similares.

El desarrollo de un módulo de software específicamente diseñado para abordar las necesidades de las personas con TDAH ofrece una variedad de herramientas y estrategias que promuevan la organización, la concentración, el entrenamiento cognitivo y la autorregulación emocional. Estas mejoras logran tener un impacto positivo en la vida diaria, el rendimiento académico, la productividad laboral y la calidad de vida en general de las personas con TDAH.

El desarrollo de un módulo de software para la detección del Trastorno por Déficit de Atención e Hiperactividad (TDAH) tiene un impacto significativo en varios aspectos sociales, económicos y científicos. Un módulo de software para la detección temprana del TDAH permite una intervención adecuada y una mejora en la calidad de vida de las personas con TDAH. También se garantiza un acceso equitativo a la evaluación y el diagnóstico, reduciendo las disparidades en el tratamiento. Además, ayuda a identificar a los estudiantes que necesitan ajustes

educativos, promoviendo una educación inclusiva. El uso del módulo reduce los costos asociados con diagnósticos erróneos y tratamientos inadecuados. También mejora la productividad de las personas con TDAH, lo que resulta en un impacto económico positivo. La recopilación de datos a través del módulo contribuye a la investigación científica y al avance en el campo del TDAH. Por último, el desarrollo del módulo fomenta la colaboración entre profesionales de la salud mental y expertos en tecnología, impulsando enfoques innovadores para la detección.

Capítulo 2. Estado de la práctica

El Trastorno por Déficit de Atención e Hiperactividad (TDAH), es un trastorno neuropsiquiátrico muy frecuente en niños, que suele presentarse antes de los 12 años y que influye de forma significativa en el desarrollo y rendimiento de quien lo presenta en uno o más ámbitos de su vida como en el ámbito escolar, laboral, familiar o social. Actualmente existen tecnologías que intentan proporcionar un diagnóstico confiable y acertado, lamentablemente por los síntomas del trastorno, es muy difícil de obtener un resultado cien por ciento seguro.

A continuación, se presenta un conjunto de resúmenes de trabajos relacionados al Trastorno por Déficit de Atención e Hiperactividad.

2.1 Trabajos relacionados

En [23], se buscó un método de diagnóstico que fuese preciso para la detección del TDAH en niños y adolescentes, si bien existen varios métodos para indicar si un paciente padece de este trastorno, estos tienen un amplio margen de error y un alto consumo de tiempo. La experiencia del médico y los criterios clínicos agregaron un valor adicional a la precisión del diagnóstico, pero esto no evitó que muchos niños no recibieran el tratamiento correcto. Para obtener la clasificación de pacientes con TDAH, se utilizó el proceso de Amplitud Fraccional Alterada de Fluctuación de Baja Frecuencia (FALFF, por sus siglas en inglés) y que sirvió para obtener la actividad cerebral en reposo, para obtener un subconjunto de características, después se complementó con el algoritmo *Relief* para obtener las características candidatas y así lograr la clasificación con la Máquina de Vectores de Soporte (SVM), dando como resultado una clasificación viable de pacientes con TDAH en función a los datos de las neuroimágenes y los métodos de aprendizaje automático.

Por otro lado, los autores de [24] desarrollaron una aplicación que reconocía gestos para detectar patrones de comportamiento del TDAH, pero claro que no sería una tarea fácil, el reconocimiento de estos patrones por una visión artificial estaba lejos de igualar al desempeño humano, aún en escenarios simples. Por medio de investigaciones realizadas, los autores se propusieron a usar una extensión del método Deformación Dinámica del Tiempo, por sus siglas en inglés DTW, para

medir la similitud entre dos secuencias temporales, dicha extensión se codificó utilizando clasificadores de una clase, como GMM y APE; y con la ayuda de un dispositivo *Kinect*® (de *Microsoft*) obtener los patrones de comportamiento con base a características como: el movimiento de cabeza, movimiento del torso sobre una mesa, comportamiento ante la invasión de su espacio de trabajo y de movimientos con o sin patrón de comportamiento, que serían los movimientos generales del sujeto. El modelo aplicado a un conjunto de datos multimodal (RGB más Profundidad) obtuvo mejoras estadísticamente significativas con respecto a las técnicas puras de DTW un punto de vista clínico.

En [25] se abordó uno de los problemas al trabajar con la detección automática de TDAH, y es que, los grandes conjuntos de datos recopilados generan bases de datos heterogéneas. Los mosaicos de subconjuntos de datos son desafiantes a falta de protocolos de recopilación de datos y esto influye gravemente en un diagnóstico al momento de tomar en cuenta varios de los estudios basados en datos de múltiples sitios. En este estudio, se intentó abordar el desarrollo de modelos de soporte de diagnóstico interpretables y legibles capaces de hacer frente a una base de datos médica de múltiples sitios. Primero se realizó la comprobación de presencia de un trastorno y luego, la detección del tipo de trastorno en caso de un diagnóstico positivo usando un enfoque multinivel para resolver el problema de clasificación jerárquica expuesta previamente. Con los modelos de caja blanca (compuestos por modelos como árboles de decisión, con el algoritmo C4.5 y reglas) el marco fue capaz de proporcionar a los médicos explicaciones sobre cómo se tomó la decisión. Al aplicar este marco en la colección pública ADHD-200 usando sus características junto con imágenes de Resonancias Magnética Funcional (fMRI), logró un desempeño justo entre el tamaño del modelo y su desempeño en el conjunto de entrenamiento, dando sujetos correctamente predichos como afectados por el TDAH.

Un factor importante a considerar es la accesibilidad de los diagnósticos por parte del paciente ya que el costo económico que estos tienen es elevado en los países que se encuentran en desarrollo [26] ya que el diagnóstico se basa únicamente en

el comportamiento observado y los síntomas informados, lo que crea un riesgo de diagnóstico excesivo o insuficiente. Los paradigmas oculomotores son expertos en el seguimiento de anomalías madurativas en cerebros afectados por trastornos del neurodesarrollo. Un biomarcador prometedor para el TDAH es la dinámica del tamaño de la pupila: la forma en que la pupila responde a ciertos estímulos visuales. Se demostró que la dinámica del tamaño de la pupila refleja el estado del sistema de norepinefrina (NE) del cerebro, que controla el funcionamiento ejecutivo (grupo de habilidades mentales) afectados por el TDAH. Los autores buscaron desarrollar un método basado en el aprendizaje automático para analizar la variación pupilo métrica en los sujetos, con la hipótesis de que reflejaría con precisión las diferencias de comportamiento entre los pacientes con TDAH positivo y los sujetos de control. La precisión de este nuevo método superó con creces las tasas de diagnóstico clínico del 80%: es mucho más preciso y los propios pacientes tienen la oportunidad de usar esta aplicación realizada en la web para detectar la presencia del TDAH.

Por su parte, en [27] los autores al contemplar los problemas típicos en la detección del TDAH decidieron enfocarse en la clasificación de los participantes que contaban con este síndrome y los que contaban con el Trastorno del Espectro Autista (TEA) en función de sus actuaciones durante un experimento de reconocimiento de emociones que desarrollaron. El experimento consistió en mostrar una serie de imágenes con rostros de personas mostrando emociones como de enojo, miedo, felicidad, por mencionar algunas. Con ello, se registró el tiempo de respuesta junto con la respuesta seleccionada y así usaron los datos como registros para los clasificadores de Árboles de decisión, SVM, KNN, *AdaBoost* y *RandomForest*. Los resultados indicaron que el TDAH y el TEA se clasificaron con un 90 % de precisión mediante el uso del algoritmo *AdaBoost* con los datos del tiempo de respuesta y con ello, lograr separar a los participantes con TDAH, TEA y grupos de control entre sí. La selección de características relevantes e informativas aumentó la precisión de la clasificación. También el rendimiento de la clasificación se benefició de la redefinición del grupo.

En [28] el diagnóstico de trastornos del neurodesarrollo en la etapa primitiva llevó a un aumento en el desarrollo de sistemas de diagnóstico automatizados ya que los diagnósticos aún son una tarea desafiante dado al espectro de condiciones asociadas al mismo y también por su alta comorbilidad. Motivados por estos hechos, realizaron una investigación de los sistemas de diagnóstico automatizado utilizando técnicas de inteligencia artificial con base en parámetros cuantitativos (biomarcadores y datos multimodales) para la detección temprana de TEA o TDAH. Los resultados de esta investigación mostraron que la IA en el dominio médico requiere la exploración de múltiples formas de datos. La utilización de los datos de múltiples modalidades en el campo biomédico mejoró la precisión diagnóstica de las enfermedades. Lamentablemente, la escasez de conjuntos de datos estandarizados y de referencia es uno de los problemas básicos en la mayoría de los sistemas de diagnóstico automatizados existentes, lo que conduce al sobreajuste y también limita su capacidad de uso en la práctica clínica. El estudio realizado en artículos publicados durante los años 2015 - 2020 sobre los trastornos mencionados anteriormente, señaló que aproximadamente el 80% de los artículos de investigación están dedicados a la detección automática de TEA o TDAH, el 20% de ellos considera la detección de TEA y TDAH, y cerca del 10% de ellos trabaja en la detección de TEA, TDAH y su comorbilidad.

Kuang D. y He L. [29] indicaron algunos de los principales síntomas de TDAH son la distracción, la falta de concentración, la actividad excesiva o el autocontrol débil. De acuerdo con el sesgo de los síntomas, la Asociación Estadounidense de Psiquiatría (APA) dividió el TDAH en tres subtipos: TDAH mixto, TDAH inatento y TDAH hiperactivo. Hasta el momento, el diagnóstico de TDAH es defectuoso, la sensibilidad del diagnóstico del Manual Diagnóstico y Estadístico de la Asociación Estadounidense de Psiquiatría sobre el TDAH alcanza entre el 70 y el 90 por ciento de asertividad. En esta investigación, se propuso el uso de una Red de Creencia Profunda (DBN), esta se compone por una pila de máquinas de Boltzmann (RBM); la entrada sin procesar se ve como las unidades visibles del primer RBM y, al entrenar el RBM, se derivan las unidades ocultas. Los resultados se conectaron a las unidades ocultas superiores para construir un nuevo RBM. Del mismo modo, la

DBN se construye apilando múltiples RBM. El preentrenamiento de DBN se realizó con el peso y los sesgos de cada RBM. DBN se aplicó para predecir los subtipos de TDAH, pero se necesitó un preprocesamiento para los datos específicos de fMRI. El método propuesto demostró ser eficaz para discriminar el TDAH del control y los subtipos. La precisión de la predicción mejoró en cierto grado en comparación con los resultados publicados en la competencia ADHD-200.

Shao L. *et al.* [30] mencionaron que el TDAH se caracteriza por falta de concentración, exceso de actividad o falta de autocontrol. Se informó que millones de personas se vieron afectadas y aproximadamente la mitad de los pacientes adultos todavía están afectados por la enfermedad diagnosticada en su infancia. Se utilizaron varias técnicas de aprendizaje automático, incluidas las redes neuronales profundas, para clasificar el TDAH. Como alternativa a las redes neuronales profundas, el bosque profundo o gcForest se propuso recientemente por Zhou y Feng en *“Deep Forest: Towards an Alternative to Deep Neural Networks”*. Se demostró que el enfoque del bosque profundo es altamente competitivo para las redes neuronales profundas. El bosque profundo utilizó una estructura de capas múltiples donde cada capa contiene muchos bosques aleatorios. En realidad, es un conjunto de conjuntos de árboles de decisión. A diferencia de las redes neuronales profundas que requieren datos de entrenamiento a gran escala y un gran esfuerzo en el ajuste de hiperparámetros, gcForest es más fácil de entrenar y funciona bien incluso con datos de entrenamiento a pequeña escala. Estas características hacen de gcForest un clasificador adecuado para el diagnóstico de TDAH. Los resultados experimentales en los conjuntos de datos mostraron que este método logró un rendimiento superior que los métodos informados en la literatura sobre los conjuntos de datos de prueba de retención. Este método también se aplica al diagnóstico de otras enfermedades con datos de fMRI, como la enfermedad de Alzheimer y el autismo, entre otras.

En [31] definió el TDAH como un Trastorno de Comportamiento Disruptivo caracterizado por la presencia de un conjunto de patrones de comportamiento crónicos y perjudiciales que muestran niveles anormales de falta de atención,

hiperactividad o su combinación. Dado que la mayoría de las personas, especialmente los niños, muestran estos comportamientos de vez en cuando, es difícil diferenciar los comportamientos que reflejan el TDAH de aquellos que son parte normal del crecimiento, lo que hace que el diagnóstico sea complicado y muy difícil de detectar. En [31], se aplicó una técnica de inteligencia artificial SVM; esta Máquina de Vectores de Soporte es un conjunto de métodos de aprendizaje supervisado relacionados que se utilizan para la clasificación y la regresión para el diagnóstico del trastorno. Para implementar este algoritmo se usó una herramienta llamada Clementine, este software es una interfaz gráfica que pone el poder de la minería de datos en manos del usuario. Para usar el modelo en la herramienta Clementine, se creó una secuencia para trabajar y crear un módulo de algoritmo SVM para el tipo de kernel de función de base radial. Después de ejecutar esta base de datos de acuerdo con la máquina de vectores de soporte, este proporcionó su propia interpretación de los resultados. Los resultados fueron muy alentadores, el diagnóstico del TDAH mediante el algoritmo SVM demostró un porcentaje de 88,674 % de éxito.

En [32] indicaron que los síntomas del trastorno están presentes en niveles superiores a los esperados para la etapa de desarrollo de una persona, lo que interfiere con la capacidad de la persona para funcionar en diferentes entornos (p. ej., en la escuela y en el hogar). Los criterios principales utilizados para hacer un diagnóstico de TDAH fueron los síntomas de atención y los síntomas de hiperactividad, los síntomas de falta de atención incluye no seguir las instrucciones y no terminar las tareas, dificultad para organizar tareas o actividades, facilidad de distracción, entre otras. Los síntomas asociados con la hiperactividad incluyen jugueteando con las manos o los pies, correr o trepar excesivamente, hablar en exceso o interrumpir a otros. Se propuso un modelo híbrido de red artificial llamado DIAGADHD para el diagnóstico del TDAH utilizando la técnica neuro difusa. Este modelo es una combinación de un algoritmo de entrenamiento no supervisado que utiliza mapas autoorganizados de Kohonen (KSOM) y un algoritmo de entrenamiento supervisado que utilizó una función de base radial (RBF, *Radial Basis Function*). El modelo híbrido de redes SOM y RBF tuvo una mejor precisión en

comparación con las redes neuronales de retro propagación. Incluso fueron menos vulnerables a problemas con entradas no estacionarias por el comportamiento de las unidades ocultas de la función de base radial.

En [33] señalaron con su investigación, que el aprendizaje automático dentro de la atención médica, con frecuencia carece de los datos públicos necesarios para ser completamente reproducible y comparable. Los conjuntos de datos a menudo están restringidos por problemas de privacidad y requisitos legales que vienen con los datos relacionados con el paciente. En consecuencia, muchos algoritmos y modelos se publican sobre el mismo tema sin un punto de referencia estándar para medir. Por lo tanto, en [33] presentó HYPERAKTIV, un conjunto de datos público que contiene datos de salud, actividad y frecuencia cardíaca de pacientes adultos diagnosticados con TDAH. El conjunto de datos se probó con cuatro algoritmos de aprendizaje automático además de una serie de reglas de predicción simples. Los cuatro métodos de aprendizaje automático incluyen regresión logística, bosque aleatorio, XGBoost y LightGBM. También se ejecutó una serie de reglas de predicción simples en el conjunto de datos de prueba para evaluar la eficacia de los modelos entrenados. Como resultado, se obtuvo un conjunto de datos abierto destinado a la investigación del TDAH. El conjunto contiene datos de actividad y frecuencia cardíaca recopilados de 103 participantes (pacientes con TDAH y controles clínicos) junto con un conjunto de atributos del paciente. Además, se sugieren una serie de métricas a usarse al evaluar los métodos de aprendizaje automático entrenados en HYPERAKTIV.

En [34] se estimó que la prevalencia del TDAH afecta aproximadamente al 5-7% de los niños en edad escolar en todo el mundo y al 6-12% en Taiwán. Algunos estudios de seguimiento a largo plazo indican que aproximadamente el 60-80% de los niños en edad escolar con TDAH persisten con síntomas hasta la adolescencia, y el 40-60% de ellos continúan hasta la edad adulta. Recientemente, varios estudios señalaron la relación entre el TDAH y el trastorno del sueño, alrededor del 25-55% de los niños y adolescentes con TDAH experimentaron problemas para dormir. Dado que el TDAH y la apnea obstructiva del sueño (AOS) tienen síntomas

similares, la asociación del sueño con el TDAH es múltiple y compleja. Con el objetivo de reducir acelerar el proceso de diagnóstico, se recogieron muestras mediante cuestionarios a padres y docentes. Usando modelos de aprendizaje automático de la siguiente manera: CART, CHAID y modelo de red neuronal para buscar la mejor manera de discriminar entre ADHD, OSA y ambos. Con lo anteriormente discutido, se encontró una asociación importante entre la calidad del sueño de los niños con TDAH y la atención a los patrones de impulso. El beneficio en la red neuronal construida del modelo de comparación también vio un excelente rendimiento para distinguir los tres subgrupos: niños con TDAH, AOS y TDAH+AOS.

En [20] se informó que la falta de biomarcadores para el TDAH es particularmente nefasta, esto por la superposición de los síntomas centrales con otros trastornos psiquiátricos frecuentes. El diagnóstico de TDAH en adultos se ve obstaculizado aún más por la evaluación retrospectiva de los síntomas en la infancia. Algunos estudios de genes candidatos asociaron variantes implicadas en la neurotransmisión monoaminérgica con el TDAH. Los datos de modelos animales, así como los estudios farmacológicos y genéticos apuntan la participación de la serotonina en el TDAH y se demostró que la atomoxetina, un fármaco para el tratamiento del TDAH, bloquea el transportador de serotonina además de sus propiedades noradrenérgicas. Se propuso un modelo de clasificación de imágenes multivariado, genético y de tomografía por emisión de positrones (PET) para TDAH y controles sanos (HC). Al evaluar las imágenes de PET y los predictores genéticos anclados dentro del sistema serotoninérgico, se logró una precisión moderada de 0,82 para la clasificación de TDAH y HC. Más allá de la utilidad como herramienta de diagnóstico, estos resultados abogan por propiedades serotoninérgicas diferentes y reconocibles para el TDAH y el HC. Los resultados del modelo de clasificación transdiagnóstica clínica, por uso de biomarcadores, es clínicamente significativa incluso con una precisión moderada.

En [35] mencionaron que la cantidad de niños en los EE. UU. diagnosticados con TDAH fluctuó de la siguiente manera: alrededor de 4.4 millones de niños entre las edades de 2 y 17 años se diagnosticaron con TDAH en 2003, 5,4 millones de niños

en 2007, 6,4 millones de niños en 2011 y 6,1 millones de niños en 2016. Se observa que el número de niños con TDAH aumentaron día a día. Los factores genéticos son responsables de casi el 75% del riesgo de TDAH en niños más pequeños. Además, hay otros factores de riesgo para el TDAH, como lesión cerebral, consumo de alcohol/tabaco durante el embarazo y parto prematuro. Por tanto, es necesario proponer un modelo para la identificación de los factores de riesgo del TDAH. En este sentido, los modelos basados en aprendizaje automático (ML) se usan para la predicción. Los modelos basados en ML también utilizaron para la identificación y predicción en el campo de las imágenes médicas, cuidado de la salud, y salud mental. Este estudio tuvo como objetivo predecir niños con TDAH utilizando ocho clasificadores basados en ML: bosque aleatorio (RF), Naïve Bayes (NB), árbol de decisión (DT), XGBoost, vecino más cercano (KNN), perceptrón multicapa (MLP), máquina de vectores de soporte (SVM), y red de convolución unidimensional (1D CNN). Se observó que el clasificador basado en RF proporcionó la precisión de clasificación más alta del 85,5 %, una sensibilidad del 84,4 % y una especificidad del 86,4 %, mientras que NB proporcionó la precisión de clasificación más baja del 69,8 %, una sensibilidad del 86,4 %.77,3% y especificidad de 65,3%.

En [36] indicaron que TDAH tiene muchos efectos negativos sobre la calidad de vida de los pacientes, para sus familias y la sociedad. Aproximadamente el 70% de los niños con TDAH persiste con los síntomas hasta la edad adulta. El TDAH en adultos tiende a asociarse con depresión, trastorno de ansiedad, abuso de sustancias, accidentes de tráfico y delitos, por lo tanto, el TDAH es un importante problema de salud pública en la actualidad. En este estudio, utilizaron la idea de la computación granular mediante el análisis de exploraciones de fMRI a través de perspectivas espaciales y temporales. Se utilizó CNN para conocer las características espaciales de cada cuadro de todo el escaneo. Para mantener la coherencia de los cuadros de fMRI, utilizaron núcleos de convolución 3-D. Después, estos núcleos se extendieron a la dimensión temporal, aprendiendo patrones espaciales y temporales simultáneamente con la operación de convolución 4-D (este encapsula varias imágenes a la vez y aprender el movimiento del cerebro), por lo que aprende mejor las características espacio-temporales. Los resultados arrojaron una precisión del

71,3 % y un AUC del 0,80. Por lo tanto, el método CNN 4-D se utilizó para crear una herramienta de diagnóstico automático más precisa del TDAH. El método CNN 4-D es más compacto, discriminativo y más rápido de calcular en comparación a los mejores métodos actuales.

En [37] mencionaron que el TDAH se compone de tres síntomas básicos: falta de atención, hiperactividad, impulsividad; estos aparecen antes de los 12 años, logrando persistir hasta la edad adulta. Los síntomas disminuyen con el tiempo; de lo contrario, la falta de atención llega a persistir durante toda la vida. Las escuelas y las aulas representan un entorno primario para el reconocimiento de los problemas del TDAH. Una estrategia en la intervención escolar para estudiantes con TDAH es la Instrucción Asistida por Computadora (CAI), que incluye funciones de instrucción que permite centrar su atención en estímulos educativos, dividiendo el material de contenido en pequeñas piezas de información. Se añadió también la ayuda de agentes pedagógicos (personajes virtuales que se utilizan en entornos de aprendizaje en línea) presentados en una pantalla de computadora que guían a los usuarios a través de entornos multimedia. Se diseñaron dos roles instruccionales para el agente pedagógico: Experto y Motivador. Luego desarrollaron un programa para una asignatura (matemáticas) con el software Unity 3D y usaron el agente pedagógico. Este agente se diseñó para brindar apoyo cognitivo y emocional a los estudiantes con TDAH ayudando a los estudiantes a superar su déficit de atención mediante el uso de señales sociales y un carácter humano para atraer y dirigir su atención al componente de instrucción previsto. El estudio demostró que los agentes pedagógicos generan importantes beneficios educativos en el aprendizaje de las matemáticas para los estudiantes con TDAH.

En [38] indicaron que existe una prevalencia aproximada del 2,8% para el TDAH en adultos. Según la Declaración de Consenso Europeo sobre el diagnóstico y tratamiento del TDAH en adultos, el diagnóstico tiene cuatro componentes: una entrevista clínica con base en el DSM, cuestionarios estandarizados para evaluar los síntomas, evaluación de la comorbilidad y la evaluación de certificados escolares o laborales. Este elaborado procedimiento no es fácilmente traducible en la práctica

clínica por factores como las restricciones económicas, límites de tiempo con respecto al proceso de diagnóstico. Sin embargo, surgen problemas cuando el objetivo es distinguir a los pacientes adultos con TDAH de otros pacientes que presentan síntomas similares, por ejemplo, ansiedad. Las Escalas de Calificación del TDAH para Adultos de Conners (CAARS) están bien establecidas y evalúan los síntomas específicos del TDAH en adultos. Por lo tanto, el objetivo del estudio fue establecer si el CAARS logró discriminar entre diferentes grupos de pacientes que presentaban síntomas similares y/o que acompañaban frecuentemente al TDAH en adultos. Al aplicar el algoritmo LightGBM en el aprendizaje automático, logró diferenciar sujetos con TDAH, obesidad, ludopatía y un grupo de control utilizando los 26 elementos de las escalas de calificación de TDAH en adultos de Conners (CAARS-S: S) con una precisión global del 80%. CAARS-S: self-rating (la versión corta) parece ser un instrumento prometedor para aplicar en la práctica clínica y también para otros trastornos que muestran síntomas similares a los del TDAH.

Para el trabajo [39], los autores se centraron en la clasificación de imágenes de resonancia magnética funcional en estado de reposo (rs-fMRI) de pacientes con TDAH y pacientes de control sanos utilizando técnicas de aprendizaje profundo y el conjunto de datos ADHD-200. Se aplicaron técnicas basadas en aprendizaje profundo como el algoritmo de red neuronal convolucional bidimensional (CNN) y la red neuronal convolucional híbrida bidimensional con memoria a corto plazo (2D CNN-LSTM) para clasificar el TDAH. El sistema híbrido propuesto se evaluó en función de parámetros como la precisión, la especificidad, la sensibilidad, la puntuación F1 y el AUC. El método propuesto logró una mejora significativa en el análisis y la detección de parámetros. Al incorporar técnicas de aprendizaje profundo con rs-fMRI, los resultados construyeron un modelo adecuado e inteligente para diagnosticar comparativamente el TDAH a partir de pacientes de control sanos.

El objetivo principal de este estudio [40] fue revelar el canal y el estado de grabación más eficaces para el diagnóstico del TDAH. De este modo, los datos provenientes de un EEG necesiten de menos canales para la clasificación del TDAH con una mayor precisión. El conjunto de datos utilizado en los experimentos de este estudio,

se obtuvieron utilizando densidades espectrales de potencia y valores de entropía espectral de individuos con y sin TDAH. Cuando estos datos se aplicaron a clasificadores de memoria a largo plazo (LSTM), máquina de vectores de soporte (SVM) y red neuronal artificial, la mayor precisión se obtuvo con LSTM. La precisión de la LSTM se calculó en un 88,88% en el canal "Fp1, F7" y en un 92,15% en el estado de reposo con los ojos cerrados. Como resultado, en el estado de reposo con los ojos cerrados demostró ser eficaz para diagnosticar el TDAH.

En [41], se presentó un método de detección inteligente de SZ y TDAH de la modalidad fMRI en estado de reposo (rs-fMRI) utilizando un nuevo método de aprendizaje profundo. Para los experimentos se utilizó el conjunto de datos de la Universidad de California en Los Ángeles, que contiene las modalidades rs-fMRI de pacientes con SZ y TDAH. La caja de herramientas de la biblioteca de software FMRIB realizó primero el preprocesamiento de los datos rs-fMRI. Después, se utilizó un modelo *autoencoder* convolucional para extraer características de los datos de rs-fMRI. En el paso de clasificación, se introdujo un nuevo método difuso llamado Regresión Difusa de Intervalo Tipo 2 (IT2FR) junto con la optimización de enjambre de partículas. Los resultados de los métodos IT2FR se compararon con los métodos perceptrón multicapa, KNN, SVM, *Random Forest* y Decision Tree, y Sistema de Inferencia Neuro-fuzzy adaptativo. Los resultados del experimento mostraron que el método IT2FR logró resultados satisfactorios en comparación con otros métodos de clasificación. Finalmente, la técnica de clasificación propuesta fue capaz de proporcionar una precisión del 72,71%.

En [42], se desarrolló una nueva separación del ritmo EEG basada en el modo variacional y la transformada de Hilbert (HT) (VHERS). Las envolventes de frecuencia instantánea (IFE) y la amplitud instantánea (IA) se extrajeron mediante descomposición modal variacional (VMD) y HT. Los ritmos delta, theta, alfa, beta y gamma se construyeron a partir de las correspondientes IFE e IA. A partir de los ritmos se evaluaron diferentes características basadas en la entropía, se seleccionaron mediante análisis estadísticos [media y desviación estándar (STD)] y se clasificaron mediante múltiples técnicas. El VHERS propuesto obtuvo el máximo

rendimiento con una precisión del 99.95%, utilizando un *kernel* sigmoide de un clasificador de máquina de aprendizaje extremo (ELM). El rendimiento mostró que el ritmo delta proporcionó más información sobre las señales EEG de TDAH y NC. El rendimiento degradado para el ritmo gamma es debido a la naturaleza solapada de las características del TDAH y el EEG NC. El modelo VHERS propuesto ayudó a los expertos a detectar el TDAH en escenarios en tiempo real.

Los autores de [43], revisaron la literatura actual sobre estudios de aprendizaje automático y aprendizaje profundo sobre el diagnóstico del TDAH e identificaron las diversas herramientas de diagnóstico utilizadas. Posteriormente, clasificaron estos estudios según su herramienta de diagnóstico como imágenes de resonancia magnética cerebral (IRM), señales fisiológicas, cuestionarios, simulador de juego y prueba de rendimiento, y datos de movimiento. Las lagunas en la investigación identificadas incluyeron la escasez de bases de datos disponibles públicamente para todas las modalidades de evaluación del TDAH distintas de la IRM, así como la falta de enfoque en el uso de datos de dispositivos portátiles para el diagnóstico del TDAH, como ECG, PPG y datos de movimiento. Esta revisión se realizó con el objetivo de inspirar futuros trabajos para crear más conjuntos de datos disponibles al público y la realización de investigaciones para otras modalidades de diagnóstico y monitoreo del TDAH.

En [44], se procesaron datos de actividad motora de adultos que padecen TDAH y de controles clínicos para obtener 788 características estadísticas relacionadas con la actividad. Posteriormente, se llevó a cabo un análisis de componentes principales para obtener características significativas para una clasificación precisa. Después, estas características se introdujeron en seis algoritmos diferentes de aprendizaje automático para la clasificación, que incluyen C4.5, KNN, Random Forest, LogitBoost, SVM y Naive Bayes. La evaluación detallada de los resultados mediante validación cruzada de 10 veces reveló que SVM supera a otros clasificadores con una precisión del 98,43%, una medida F del 98,42%, una sensibilidad del 98,33%, una especificidad del 98,56% y un AUC de 0,983. Por lo tanto, un enfoque SVM basado en PCA fue una opción eficaz para la identificación precisa de los pacientes

con TDAH entre otros controles clínicos utilizando el análisis en tiempo real de los datos de actividad.

Los autores de [45] investigaron el uso de datos de actividad física derivados de sensores portátiles y el aprendizaje automático para identificar objetivamente los incidentes de agresión física en los niños. Los participantes de entre 7 y 16 años, con y sin TDAH, llevaron un monitor de actividad en la cintura (ActiGraph, GT3X+) durante una semana, tres veces a lo largo de 12 meses, mientras se recogían datos demográficos, antropométricos y clínicos. Se utilizaron técnicas de aprendizaje automático, concretamente bosques aleatorios, para analizar patrones que identificaran incidentes físico-agresivos derivados del TDAH con una resolución temporal de 1 minuto. Se recogió un total de 119 episodios de agresión, con una duración de $7,3 \pm 13,1$ min para un total de 872 épocas de 1 min, incluidas 132 épocas de agresión física. El modelo logró una alta precisión (80,2%), exactitud (82,0%), recuperación (85,0%), puntuación F1 (82,4%) y área bajo la curva (89,3%) para distinguir las épocas de agresión física. La característica derivada del sensor de la magnitud del vector (aceleración triaxial más rápida) fue la segunda característica que contribuyó al modelo, y distinguió significativamente las épocas de agresión de las de no agresión.

Finalmente, en [46] seleccionaron diferentes parámetros de salud del usuario, a través de sus variables fisiológicas como: número de pasos, frecuencia cardiaca, nivel de oxigenación en la sangre y otras. Y una de las condiciones intelectuales más solicitadas, es el nivel de atención alcanzado cuando el usuario ejecuta una tarea. El trabajo describió una metodología y la experimentación para conocer el nivel de atención de las personas a través de una prueba para identificar colores; también se mostró el desarrollo y la aplicación de un sistema (hardware y software) para medir el nivel de atención de las personas utilizando dos señales de entrada: postura corporal y ondas cerebrales. El trabajo expuso el análisis matemático para encontrar la correlación entre la postura corporal y el nivel de atención. Los resultados obtenidos indicaron que la postura corporal influye directamente en el nivel de atención de las personas.

2.2 Análisis comparativo

En la siguiente tabla (Tabla 2.1) se comparan diez de los artículos más relacionados con el TDAH con el fin de observar sus similitudes y diferencias más importantes.

Tabla 2.1 Análisis comparativo de los artículos relacionados.

Artículo	Problema	Contribución	Tecnología	Resultados	Estado
Miao y Zhang [23]	Falta de un método preciso para la detección de TDAH en niños y adolescentes.	Un proceso de Amplitud Fraccional Alterada de Fluctuación de Baja Frecuencia (FALFF).	Relief, SVM	Buena clasificación de pacientes con TDAH en función a neuroimágenes y métodos de aprendizaje automático.	Terminado
Bautista <i>et al.</i> [24]	Dificultad de reconocimiento de patrones de comportamiento del TDAH	Extensión del método Deformación Dinámica del Tiempo para medir la similitud entre dos secuencias temporales.	GMM, APE, RGB + Profundidad	Mejoras estadísticamente significativas con respecto a las técnicas puras de DTW un punto de vista clínico.	Terminado
Khanna Y Das [26]	Accesibilidad y costo económico de los diagnósticos de TDAH en países en desarrollo.	Desarrollo método basado en el aprendizaje automático para analizar la variación pupilo métrica en los sujetos en una aplicación realizada en web.	<i>Logistic regression</i> , KNN, Random Forest, Decision tree, SVM, AdaBoost, Naive Bayes	La precisión supera las tasas de diagnóstico clínico del 80% y los propios pacientes usarían esta aplicación para detectar la presencia del TDAH.	Terminado
Uluyagmur - Ozturk <i>et al.</i> [27]	Dificultad para diferencias los síntomas del TDAH de los de Trastornos del Espectro Autista.	Clasificador mediante el reconocimiento de emociones, midiendo tiempo y precisión de la respuesta.	SVM, KNN, AdaBoost, <i>Decision tree</i> , <i>Random Forest</i>	El TDAH y el TEA se clasificaron mejor con un 90 % de precisión con el uso de AdaBoost.	Terminado
Kuang y He [29]	Dificultad para identificar los subtipos del TDAH: mixto, inatento e hiperactivo, dado al sesgo de síntomas.	En esta investigación, se propuso el uso de una Red de Creencia Profunda (DBN),	DBN, RBM	La precisión de la predicción ha mejorado en comparación con los resultados publicados en la competencia ADHD-200.	Terminado
Anuradha <i>et al.</i> [31]	Dificultad de diferenciar los comportamientos que reflejan el TDAH de aquellos que son parte normal del crecimiento en niños.	En este artículo, se aplica la técnica de inteligencia artificial SVM que utiliza para la clasificación y la regresión para el diagnóstico del trastorno.	SVM, Clementine	Los resultados son muy alentadores, el diagnóstico del TDAH mediante el algoritmo SVM demostró un porcentaje de 88,674 % de éxito.	Terminado

Artículo	Problema	Contribución	Tecnología	Resultados	Estado
Arthi y Tamilarasi [32]	Los síntomas del TDAH están presentes en niveles superiores a los esperados en una persona, lo que interfiere en sus diferentes entornos.	Se propone un modelo híbrido de red artificial llamado DIAGADHD para el diagnóstico del TDAH utilizando la técnica neuro difusa.	DIAGADHD, KSOM, SOM, RBF	Se observa que el modelo híbrido de redes SOM y RBF tiene una mejor precisión en comparación con las redes neuronales de retropropagación.	Terminado
Hicks et al. [33]	La investigación de aprendizaje automático dentro de la atención médica carece de datos públicos necesarios para ser reproducible y comparable.	Un conjunto de datos público que contiene datos de salud, actividad y frecuencia cardíaca de pacientes adultos con TDAH llamado HYPERAKTIV.	<i>Logistic regression</i> , <i>Random Forest</i> , XGBoost, LightGBM, Reglas simples de predicción.	Un conjunto de datos abierto destinado a la investigación del TDAH conteniendo datos de actividad y frecuencia cardíaca recopilados de participantes con TDAH.	Terminado
Mao et al. [36]	El TDAH en adultos se asocia con depresión, trastorno de ansiedad, y otros, por lo tanto, el TDAH es un problema de salud pública en la actualidad.	Utilizar la idea de la computación granular mediante el análisis de exploraciones de fMRI a través de perspectivas espaciales y temporales.	CNN 4-D	Los resultados arrojaron una precisión del 71,3 % y un AUC del 0,80. Por lo tanto, el método CNN 4-D se utiliza para crear una herramienta de diagnóstico del TDAH.	Terminado
Hatami et al. [37]	El tratamiento del TDAH no sólo pertenece al ámbito clínico, las aulas son un entorno para el reconocimiento de los problemas del TDAH.	Desarrollo de un agente pedagógico virtual para ayudar a alumnos con TDAH para dar apoyo cognitivo y emocional.	Instrucción Asistida por Computadora, Unity 3D	El estudio encontró que los agentes pedagógicos mejora significativamente el aprendizaje de las matemáticas en estudiantes con TDAH.	Terminado

De acuerdo con la tabla anterior, se observa que existen múltiples y distintos enfoques que ofrecen una solución parcial al problema ya mencionado, la mayoría de estos enfoques comparten el uso de alguna rama de la inteligencia artificial (como el aprendizaje automático o redes de creencia profunda) para procesar y dar forma a la información recibida por parte del paciente; pero en lo que se diferencian, es la forma en la que obtienen los datos, como por ejemplo, el uso de imágenes por resonancia magnética propuesto por los autores Kuang y He [29] y Mao et al. [36] o el uso de biomarcadores externos como la detección del movimiento ocular

realizado por Khanna y Das [26]. Si bien estos son algunos ejemplos, la solución que se ofrece en este proyecto, es facilitar la detección de este mismo trastorno con el uso combinado de distintos biomarcadores fáciles de medir de forma externa complementando con el uso de una subrama de la inteligencia artificial sobre distintos bancos de datos para ofrecer una mayor confiabilidad de los resultados.

2.3 Solución propuesta

Se propone desarrollar un módulo que realice un proceso inteligente de identificación del Trastorno por Déficit de Atención e Hiperactividad mediante dispositivos vestibles y aprendizaje automático. El módulo propuesto aplicó algoritmos de clasificación de aprendizaje automático, los cuales permitirán detectar la presencia del TDAH y su nivel, basándose en otros atributos de un conjunto de datos.

La arquitectura del módulo comienza con la extracción de información importante mediante un dispositivo como una pulsera o diadema inteligente y así almacenar los datos de ondas cerebrales, frecuencia cardíaca y el registro del movimiento, dicha información se extrae mediante un módulo que realiza la monitorización. Una vez obtenida la información, mediante el uso de un SDK compatible con el dispositivo a seleccionar, se obtuvieron un conjunto de datos que se validaron mediante un algoritmo de aprendizaje automático para su clasificación. Los resultados son visibles en cualquier momento desde una aplicación web que contiene el módulo para la detección del nivel del TDAH.

El flujo de trabajo para la propuesta de solución consistió en:

- **Monitorización:** Al usuario, mediante dispositivos vestibles, se le permitió medir sus variables biomédicas (biomarcadores), las cuales son: ondas cerebrales, frecuencia cardíaca y un registro de su actividad física. Estos biomarcadores se consideran como parámetros para detectar si una persona tiene o no la prevalencia del TDAH, mediante técnicas de inteligencia artificial.
- **Detección:** Mediante el uso de un SDK o biblioteca de desarrollo compatible con el dispositivo seleccionado, y con el uso de técnicas de inteligencia artificial, los datos de los biomarcadores obtenidos por el dispositivo vestible se usaron para

detectar si una persona padece del TDAH o no, estos resultados están disponibles para ser consultados en el módulo a desarrollar.

A continuación, se analizan y describen las tecnologías y metodologías disponibles para el desarrollo de la solución de la propuesta.

2.3.1 Tecnologías de desarrollo

El uso de un lenguaje u otro varía en función a las necesidades de la solución a resolver, es por eso que se propusieron los siguientes lenguajes de programación que, por sus características, son altamente compatibles con el desarrollo de la solución propuesta.

2.3.1.1 HTML5

HTML es el lenguaje de marcado de hipertexto que se planificó para realizar páginas web. Desde su creación, HTML avanzó por diferentes exigencias, en su mayor parte orientadas a desarrollar aún más el manejo de datos, y en consecuencia han aparecido algunas correcciones que ampliaron e investigaron este lenguaje.

Se seleccionó HTML5 como piedra angular para la creación de la estructura web, considerando que su uso es esencial para desarrollar una interfaz de usuario clara, accesible y que se ajuste a las necesidades específicas del módulo web. La versatilidad y amplia aceptación de HTML5 en la comunidad de desarrolladores facilitó su integración con otras tecnologías utilizadas en la presente tesis.

Además, HTML5 incorpora el *Document Object Model* (DOM), que es la construcción de un registro según el paradigma de la POO, caracterizada por la disposición de los componentes que están disponibles en un documento HTML y las actividades que se realizan en ellos [47], una característica muy útil para el manejo de elementos en la interfaz.

2.3.1.2 TypeScript

Se optó por TypeScript en lugar de JavaScript por su capacidad para ofrecer un entorno de programación más sólido y estructurado, gracias a su sistema de tipos estático. Esto permitió minimizar los errores en tiempo de ejecución y mejorar la calidad del código, resultando en un software más confiable y fácil de mantener,

además de su estrecha relación con el marco de trabajo seleccionado para el desarrollo del módulo.

2.3.1.2 Python

Se eligió Python como el lenguaje de programación principal para el desarrollo backend, dada su popularidad y robustez en el ámbito de la inteligencia artificial. Python proporcionó una base sólida para integrar algoritmos y técnicas de aprendizaje automático (junto con el uso de otras bibliotecas de desarrollo), que son cruciales para el procesamiento y análisis de datos en la detección del nivel de TDAH.

2.3.2 Marcos de trabajo

Un marco de trabajo es una herramienta que otorga los elementos necesarios para llevar a cabo el desarrollo de un proyecto de principio a fin, con el objetivo de reducir costos y tiempo invertido; a continuación, se presentan los marcos de trabajo elegidos para el desarrollo del proyecto.

2.3.2.1 Angular

Angular es un marco de desarrollo para aplicaciones web dinámicas. Le permite involucrar a HTML como un lenguaje de plantillas y le permite extender los componentes HTML para comunicar las partes de su aplicación de forma clara y breve. La vinculación de datos y la inyección de dependencias de Angular eliminan gran parte del código que tendría que escribirse de otro modo. Además, todo ocurre dentro del programa, lo que lo convierte en un socio ideal con cualquier innovación del lado del servidor [48].

Angular se seleccionó como el marco de trabajo para el desarrollo frontend del módulo, aprovechando su capacidad para crear interfaces de usuario dinámicas y reactivas. La integración natural de Angular con TypeScript fue otro factor decisivo, ya que permitió un desarrollo más fluido y coherente en el lado del cliente.

2.3.2.2. FastAPI

Se eligió FastAPI para el desarrollo backend, este es un marco de trabajo moderno y rápido de Python para construir APIs con Python basado en estándares del mismo

lenguaje. El nombre de este marco proviene de la velocidad con la que se crea y ejecuta una API, así como de la alta velocidad de operación del framework en sí mismo [49].

FastAPI proporciona una manera sencilla y eficiente de construir APIs seguras y robustas, facilitando la validación y serialización de datos, la gestión de errores, la autenticación y autorización, y más. Gracias a la documentación clara y fácil de entender, agilizó el desarrollo y el consumo de la API.

Además, FastAPI se integra fácilmente con otras herramientas y frameworks de Python, lo que permite utilizar las herramientas ya conocidas. Esto, combinado con su velocidad y facilidad de uso, hizo de FastAPI una excelente opción para construir APIs modernas y eficientes en Python.

2.3.3 Entornos de desarrollo

Un entorno de desarrollo integrado (IDE) es un sistema de software que ayuda a desarrollar aplicaciones combinando herramientas para desarrolladores en una única interfaz de usuario gráfica (GUI).

2.3.3.1. Visual Studio Code

Visual Studio Code se eligió como el entorno de desarrollo principal por su flexibilidad, amplio catálogo de extensiones y compatibilidad con los lenguajes de programación y marcos de trabajo seleccionados. Su interfaz intuitiva y su conjunto de características lo convirtieron en una herramienta indispensable para agilizar el proceso de desarrollo. Visual Studio Code es un gestor de código fuente ligero, pero fuerte, que se eleva repentinamente en la demanda del área de trabajo y es accesible para Windows, macOS y Linux. Viene con soporte incorporado para JavaScript, TypeScript y Node.js y tiene un rico entorno de expansiones para diferentes dialectos y tiempos de ejecución (como C++, C#, Java, Python, PHP, Go, .NET) [50].

2.3.4 Técnicas de Inteligencia Artificial

Las técnicas de inteligencia artificial hacen referencia a las diferentes maneras con las que se desarrolla una aplicación con base en inteligencia artificial.

2.3.4.1 Aprendizaje Automático

Se implementaron técnicas de aprendizaje automático para analizar y procesar de forma eficiente los datos recopilados de los usuarios. Esta tecnología resultó fundamental para identificar patrones y correlaciones que permitieron detectar el nivel de TDAH en los participantes del estudio.

El aprendizaje automático se implementa en muchos casos de uso. Mientras haya datos importantes para analizar, el aprendizaje automático ayuda a darle sentido. Esto es útil en cualquier lugar en el que quiera reconocer patrones y prever formas de comportamiento en vista de la información auténtica. El reconocimiento de patrones va desde el reconocimiento de caracteres hasta el mantenimiento predictivo y la recomendación, por ejemplo, de productos a los clientes en vista de compras anteriores.

Hay muchos algoritmos de aprendizaje automático bien establecidos en este momento. Muchos de estos vienen precargados en bibliotecas populares de codificación de ciencia de datos. Crear un modelo básico de aprendizaje automático es tan simple como probar múltiples algoritmos pre creados para ver cuál se ajusta mejor a los datos. Cada modelo tiene sus propias fortalezas, debilidades, arquitectura y un enfoque único para ponderar los resultados [51].

2.3.4.2 Aprendizaje Profundo

El aprendizaje profundo se incorporó con el objetivo de validar si ofrece una mejor precisión del modelo desarrollado, permitiendo así identificar patrones más complejos y sutiles en los datos. Esta técnica resultó clave para refinar los resultados obtenidos y asegurar una detección más precisa del TDAH. El aprendizaje profundo se produce utilizando redes neuronales, que se coordinan en capas para percibir conexiones y ejemplos complejos en la información. Su aplicación requiere un conjunto de datos gigantesco y una gran capacidad de manejo [6].

2.3.5 Sistemas Gestores de Base de Datos

Los sistemas gestores de bases de datos (SGBD) son una herramienta de software que permite a los desarrolladores administrar un conjunto de datos, resolviendo

tareas como la caracterización de conjuntos de datos, la elección de las estructuras de información fundamentales para el almacenamiento y la búsqueda a través de la información; ya sea de forma inteligente o a través de un lenguaje de programación.

2.3.5.1 MYSQL

Se escogió MySQL como sistema gestor de base de datos por su confiabilidad, rendimiento y sencillez de uso. Su estructura permitió almacenar y gestionar eficientemente los datos de los usuarios, garantizando la integridad y seguridad de la información. MySQL es la base de datos de código abierto más popular del mundo. Según DB-Engines, MySQL se clasifica como la segunda base de datos más popular, detrás de Oracle Database. MySQL impulsa muchas de las aplicaciones más visitadas, incluidas Facebook, Twitter, Netflix, Uber, Airbnb, Shopify y Booking.com.

Dado que MySQL es de código abierto, incluye numerosas características desarrolladas en estrecha cooperación con los usuarios durante más de 25 años. La base de datos MySQL es un marco cliente/servidor que consta de un servidor SQL de varios niveles que mantiene diferentes back-ends, algunos proyectos y bibliotecas de clientes diferentes, instrumentos de regulación y una amplia variedad de puntos de interfaces programación de aplicaciones (API). También se proporciona MySQL como una biblioteca multiproceso integrada que se vincula a su aplicación para obtener un producto independiente más pequeño, más rápido y más fácil de administrar [52]

2.3.6 Metodologías de Desarrollo de Software

son un conjunto de estrategias y técnicas jerárquicas que se aplican para planificar acuerdos de programación. El objetivo de los distintos procedimientos es intentar ordenar los grupos de trabajo para fomentar los elementos de un programa de la manera más idónea.

2.3.6.1 Extreme Programming

Se adoptó la metodología XP para el desarrollo del proyecto, con el fin de mejorar la calidad del software. Las prácticas de programación, integración continua y pruebas frecuentes promovieron un enfoque iterativo y ágil, adaptándose a los

cambios y requerimientos del proyecto de forma efectiva. Este enfoque permitió responder con certeza a los cambiantes requisitos de los clientes, incluso hacia el final del ciclo de vida.

La programación extrema (XP) es uno de varios procesos ágiles populares. Demostrando que tiene mucho éxito en muchas empresas de todos los tamaños e industrias en todo el mundo [53]. Esta metodología subraya la cooperación entre directores, clientes e ingenieros para abordar con la mayor eficacia posible los cambios que surgieron.

2.3.7 Justificación de la solución

Considerando las características, ventajas y desventajas de las tecnologías y herramientas analizadas, se determina como solución propuesta el uso de HTML y Python como lenguajes de programación, Netbeans como IDE, PostgreSQL como sistema gestor de base de datos, AngularJS como marco de trabajo, Aprendizaje Automático como técnica de IA y XP como metodología de desarrollo.

Las tecnologías seleccionadas satisfacen las necesidades para el desarrollo de la solución del proyecto planteado; HTML5 y Python logran una excelente compatibilidad, potenciados por el marco de trabajo AngularJS que aseguran el funcionamiento óptimo con otras tecnologías y módulos previamente desarrollados.

Como entorno de desarrollo se seleccionó el software NetBeans por su soporte multilenguaje. Se seleccionó a PostgreSQL como sistema gestor de bases de datos por su atomicidad y facilidad de conexión con los lenguajes de programación seleccionados, dando mayor facilidad de desarrollo.

La técnica de inteligencia artificial seleccionadas es la técnica del *Machine Learning* (aprendizaje automático), según la literatura, esta técnica es una de las más utilizadas, adaptables y precisas para el desarrollo de módulos cuya finalidad radica en la predicción de trastornos en pacientes humanos. Por último, el desarrollo de la solución de este proyecto es bajo la metodología *Extreme Programming* (XP) porque es muy eficiente en el proceso de pruebas y planificación, pero, sobre todo, facilita cambios y origina una programación muy organizada.

Capítulo 3. Aplicación de la metodología

A continuación, en este capítulo, se presenta el desarrollo del proyecto mediante las tecnologías seleccionadas en el capítulo anterior, divididos en las siguientes secciones (Figura 3.1):

- La primera fase es el **Análisis**, que establece los requisitos y casos de uso del módulo.
- La segunda fase es el **Diseño**, que incluye la propuesta de la interfaz gráfica, el diseño arquitectónico y la base de datos.
- La tercera fase es el **Desarrollo**, que presenta el modelo de interfaces y el módulo de clasificación implementado.
- La cuarta fase es la de **Pruebas**, que muestra los resultados de la funcionalidad y el rendimiento del módulo mediante casos de estudio.



Figura 3.1. Metodología de investigación.

El proceso de desarrollo para este trabajo fue bajo el cumplimiento de cada una de las fases anteriormente señaladas, siendo un proceso secuencial e iterativo hasta llegar al objetivo establecido.

3.1 Análisis

En esta sección, se establecen los requerimientos y casos de uso necesarios para el correcto funcionamiento del proyecto. Aquí se definen las necesidades del usuario, las limitaciones técnicas y las posibles soluciones. En este sentido, el análisis se enfoca en la identificación y definición de los problemas que se abordaron en el proyecto y en la búsqueda de soluciones que permitan alcanzar los objetivos propuestos.

En esta sección se hace una descripción general del módulo, describiendo las tecnologías seleccionadas (lenguaje de programación, marcos de trabajo, herramientas de desarrollo, por mencionar algunas) y una breve descripción de los

conjuntos de datos y algoritmos de inteligencia artificial contemplados. Luego se hizo una recolección de los requerimientos funcionales del sistema para tener una idea general del flujo de trabajo del módulo. Y finalmente, un diagrama de caso de uso para detallar la funcionalidad de este.

3.1.1 Características del módulo

El módulo desarrollado utiliza Angular, FastAPI (marco de trabajo de Python), Scikit-Learn (biblioteca que ofrece algoritmos de aprendizaje automático) y MySQL; es una combinación de tecnologías para crear una solución escalable y eficiente para procesar datos y presentar resultados en una interfaz de usuario atractiva y fácil de usar. Angular es un marco de desarrollo de aplicaciones web de código abierto que utiliza HTML, CSS y TypeScript para crear aplicaciones ricas en funcionalidades y con una excelente experiencia de usuario. Python es un lenguaje de programación versátil que se utilizó para desarrollar microservicios con Flask, que es un micro marco web para Python que se utiliza para desarrollar aplicaciones web rápidas y ligeras.

Scikit-Learn es una biblioteca de aprendizaje automático de Python que se utiliza para procesar datos, crear modelos predictivos y una variedad de algoritmos de aprendizaje automático. Esta biblioteca se utiliza para la clasificación de pacientes con TDAH mediante algoritmos de aprendizaje automático.

MySQL es un sistema de gestión de bases de datos relacionales de código abierto que se utiliza para almacenar y recuperar datos. MySQL es escalable, fiable y fácil de usar, lo que lo hace ideal para aplicaciones web que manejan grandes cantidades de datos.

3.1.1.1 Identificación de variables biomédicas relacionadas al TDAH

En el proceso de análisis y selección de las variables biomédicas para la detección del Trastorno por Déficit de Atención e Hiperactividad (TDAH), primero se identificaron las variables más relevantes mediante una revisión exhaustiva de la literatura y la consulta con expertos en el campo. Las variables seleccionadas incluyeron marcadores neurofisiológicos, genéticos y de neuroimagen, que demostraron una asociación significativa con el TDAH en estudios previos.

Una vez identificadas las variables biomédicas clave, se evaluó su disponibilidad, validez y fiabilidad de cada uno en el contexto de este estudio. Para garantizar la calidad de los datos, se seleccionaron aquellas variables que contaban con métodos de medición estandarizados y validados. Posteriormente, se analizó la correlación entre las variables seleccionadas y el diagnóstico de TDAH. Este análisis permitió determinar el grado de asociación entre cada una de las variables biomédicas y el TDAH.

Finalmente, se optó por la selección de las variables biomédicas asociadas con la actividad eléctrica del cerebro para medir el nivel de atención y así evaluar de manera precisa y objetiva las fluctuaciones en la atención, que son características del TDAH. La actividad eléctrica cerebral, registrada mediante técnicas como el electroencefalograma (EEG), proporciona información valiosa sobre los patrones de activación cerebral asociados con los procesos de atención. Además, también se consideró utilizar nivel de actividad física como un indicador del grado de hiperactividad. Para esto, implementó el uso de acelerómetros y otros sensores de movimiento que cuantifican de manera objetiva la actividad física del individuo.

3.1.1.2 Análisis de conjunto de datos

Este módulo trabaja con servicios de clasificación, dichos servicios utilizan un conjunto de datos que proporcionan entrenamiento y pruebas de clasificación para las pruebas de detección de TDAH. Para ello, se realizó un análisis de 5 conjuntos de datos diferentes entre sí, con diferentes enfoques, diferentes características y distintos orígenes de datos; estos conjuntos se seleccionaron por ser de acceso libre al público y gratuitos. Los conjuntos de datos analizados fueron:

- **HYPERAKTIV:** HYPERAKTIV [54] es un conjunto de datos público con datos relacionados con la frecuencia cardíaca y de datos de movimiento de 51 pacientes adultos sin TDAH y 52 pacientes clínicos con TDAH. HYPERAKTIV incluye datos salud, atributos como la edad y el sexo, datos de salida de una prueba neuropsicológica informatizada e información sobre el estado mental del paciente. El conjunto de datos se utilizó en [44] para el diagnóstico del TDAH en adultos utilizando algoritmos de aprendizaje automático.

- **ADHD200:** Por su parte, ADHD200 [55] ofrece un conjunto de datos preprocesados procedentes del Concurso Mundial ADHD-200. ADHD200 consiste en 776 conjuntos de datos anatómicos y de RMf en estado de reposo, incluyendo 285 de niños y adolescentes con TDAH. ADHD200 incluye datos sobre edad, sexo, estado de diagnóstico, estado de medicación, medidas dimensionales de los síntomas del TDAH, puntuación de algunos de los cuestionarios más comunes para la detección del TDAH y cociente intelectual. El conjunto de datos ADHD200 se utilizó en [56] para el desarrollo de métodos de clasificación del TDAH basados en CNN 3D.
- **Working Memory and Reward in Children with and without ADHD:** este conjunto de datos (disponible en OpenNeuro.org [57]) fue el resultado de datos registrados por resonancia magnética funcional (fMRI) y puntajes longitudinales de medidas estandarizadas para la capacidad cognitiva, síntomas de TDAH y habilidades de lectura. El objetivo era explorar la memoria de trabajo y el procesamiento de la retroalimentación en niños con desarrollo típico y con diagnóstico de TDAH. Se recogieron datos de 79 niños entre los 8, 6 y 12 años; y 35 niños tenían un diagnóstico formal de TDAH [58].
- **Working Memory and Reward in Adults:** En un estudio posterior, se creó un conjunto de datos titulado "Working Memory and Reward in Adults" [59] (disponible en OpenNeuro.org) con las mismas características que su predecesor y que incluye datos de 24 individuos adultos que realizaron las mismas tareas. El conjunto de datos anteriormente mencionado tiene antecedentes en el estudio presentado por [60] y [61].
- **EEG DATA FOR ADHD:** Por su parte, EEG DATA FOR ADHD [62] es un conjunto de datos que contiene información de 61 niños con TDAH y 60 pacientes sanos. El registro EEG se realizó durante tareas de atención visual, se pedía a los niños que contaran el número de personajes de cada imagen; cada imagen se mostraba inmediatamente después de la respuesta del niño. El registro EEG se basó en registros EEG estándar de 19 canales (Fz, Cz, Pz, C3, T3, C4, T4, Fp1, Fp2, F3, F4, F7, F8, P3, P4, T5, T6, O1, O2) a una frecuencia de muestreo de 128 Hz, y se colocaron electrodos A1 y A2 en los lóbulos de las

orejías. El conjunto de datos EEG DATA FOR ADHD se utilizó en otros estudios para la detección del TDAH a partir de las características del EEG ([63]).

El conjunto de datos seleccionado para una primera aplicación fue HYPERAKTIV, dado que los biomarcadores que necesita para realizar una clasificación se encuentran al alcance de dispositivos inteligentes de acceso considerable y no como los dispositivos de propósito clínico (máquinas de resonancia magnética).

3.1.1.3 Selección de algoritmos de aprendizaje automático

Se realizó un análisis comparativo (utilizando Python y la biblioteca Scikit-Learn) de 10 algoritmos de aprendizaje automático; se eligieron los que, según la literatura, presentaron los mejores resultados en investigaciones previas.

Los resultados arrojaron que los algoritmos Regresión Lineal, CatBoost y SVM obtuvieron más del 85% de exactitud en el conjunto de datos HYPERAKTIV y más del 97% para el conjunto ADHD200; además se tomaron en cuenta las métricas *recall*, F1-score y la curva ROC. En la siguiente tabla (Tabla 3.1 y Tabla 3.2) se detallan los valores obtenidos en cada uno de los algoritmos analizados y, en las posteriores, se presenta una gráfica con los resultados obtenidos.

Tabla 3.1. Resultados de la comparación obtenidos para el conjunto de datos HYPERAKTIV.

Algoritmos AA	Accuracy	Precision	Recall	F1-Score	ROC-AUC
Linear Regression	0.9047	0.9090	0.9166	0.9000	0.9166
CatBoost	0.9047	0.9047	0.9047	0.9047	0.9047
SVM	0.8571	0.8750	0.8750	0.8571	0.8750
Gradient Boosting	0.8571	0.8545	0.8611	0.8421	0.8611
AdaBoost	0.8571	0.8545	0.8611	0.8421	0.8611
Random Forest	0.8095	0.8136	0.8194	0.8000	0.8194
Decision Tree	0.7619	0.7777	0.7777	0.7619	0.7777
LightGBM	0.7619	0.7777	0.7777	0.7619	0.7777
XGBoost	0.7619	0.7777	0.7777	0.7619	0.7777
KNN	0.6666	0.6636	0.6666	0.6315	0.6666

Tabla 3.2. Comparación de los resultados obtenidos en el conjunto de datos ADHD-200.

Algoritmo AA	Accuracy	Precision	Recall	F1-Score	ROC-AUC
KNN	0.9750	0.9705	0.9791	0.9787	0.9791
CatBoost	0.9750	0.9736	0.9772	0.9767	0.9772
Decision Tree	0.9750	0.9800	0.9687	0.9795	0.9687
Gradient Boosting	0.9750	0.9800	0.9687	0.9795	0.9687
LightGBM	0.9750	0.9800	0.9687	0.9795	0.9687
XGBoost	0.9750	0.9800	0.9687	0.9795	0.9687
Random Forest	0.9750	0.9800	0.9687	0.9795	0.9687
AdaBoost	0.9750	0.9800	0.9687	0.9795	0.9687
Linear Regression	0.9500	0.9479	0.9479	0.9583	0.9479
SVM	0.9250	0.9194	0.9270	0.9361	0.9270

En las Figura 3.2 y Figura 3.3, se presenta una gráfica de barrar que representa la comparación entre las métricas obtenidas para cada uno de los algoritmos utilizados para el conjunto de datos HYPERAKTIV y ADHD-200 respectivamente.




Figura 3.2. Comparación de las métricas obtenidas para el conjunto HYPERAKTIV.




Figura 3.3. Comparación de los resultados de la Tabla 3.2 para el conjunto de datos ADHD-200.

En resumen, los algoritmos con mayor puntaje obtenido para esta métrica fueron SVM, Regresión Lineal y CatBoost, donde los resultados arrojaron un rango entre un 85% y 97% de exactitud. El desafío de la detección del TDAH con técnicas de aprendizaje automático requiere la colaboración de especialistas médicos y técnicos en aprendizaje automático para desarrollar algoritmos precisos y eficientes. Este análisis arrojó resultados prometedores, demostrando que las técnicas de aprendizaje automático son útiles en la detección del TDAH, pero que necesitan de un conjunto de datos con suficiente información y características específicas para realizar una correcta identificación.

3.1.1.4 Selección de algoritmos de aprendizaje profundo

Los conjuntos de datos evaluados (*EEG DATA FOR ADHD* y *Working Memory and Reward in Children with and without ADHD*) con algoritmos de aprendizaje profundo se realizaron con Matlab. Se obtuvieron las cinco métricas ya mencionadas. En la Tabla 3.3 se muestra los resultados obtenidos para el resto de los conjuntos de datos.

Tabla 3.3. Resultados obtenidos con los algoritmos de aprendizaje profundo para los conjuntos de datos EEG ADHD y WMRC ADHD.

Conjunto	Algoritmo AP	Accuracy	Precision	Recall	F1-Score	ROC-AUC
EEG ADHD	CNN	0.5833	0.5833	0.5533	0.5833	0.5533
WMRC ADHD	Multimodality 3D CNN	0.6833	0.6833	0.6833	0.6538	0.6833

Para el resto de los conjuntos de datos *EEG data for ADHD* y *Working Memory and Reward in Children with and without ADHD* fueron los menos precisos, arrojando resultados de entre el 58% y 68% respectivamente. No obstante, los conjuntos relacionados con fMRI no se encuentran descartados, se espera en un futuro, con la obtención de un mayor número de datos, obtener un mayor grado de precisión.

3.1.2 Requerimientos funcionales del sistema

En esta sección se describen los requisitos funcionales necesarios para el desarrollo del módulo.

- **Acceso**

- Para acceder al módulo, el usuario ingresa las credenciales correspondientes (usuario y contraseña) a través de una pantalla de inicio de sesión.
- Para finalizar la sesión, el usuario cuenta con un botón de salir dentro de la barra de navegación.

- **Panel médico**

- Después de realizar las validaciones correspondientes para el acceso del usuario médico, el módulo muestra un panel *dashboard*, donde se resume la información importante como: nombre y especialidad del médico, número de pacientes asignados y número de pacientes positivos con TDAH. También se muestra una gráfica de la prevalencia histórica de todos los pacientes diagnosticados como positivo en TDAH o sus derivados.
- El panel médico cuenta con un menú lateral donde se enlistan los accesos a las distintas secciones del módulo.

- **Pacientes**

- El usuario cuenta con una sección para visualizar la lista de pacientes asignados.
- El usuario cuenta con el acceso al perfil de cada usuario, donde visualiza información personal, antecedentes personales, información médica y el historial de las pruebas realizadas en orden cronológico del más reciente al más antiguo, así como un resumen del estado de prevalencia del paciente.

- El usuario tiene acceso a los reportes de cada una de las pruebas realizadas al paciente, donde se muestran las métricas y los resultados obtenidos.
- Dentro del perfil de cada paciente, se cuenta con un botón que da comienzo a una nueva prueba.
- **Pruebas**
 - Para realizar una prueba, el usuario selecciona un dispositivo (previamente registrado) con el que realiza la prueba.
 - El módulo realiza la sincronización del dispositivo seleccionado por medio de *Bluetooth*.
 - El módulo muestra los datos obtenidos en tiempo real por el dispositivo para su monitorización.
 - El módulo es capaz de pausar, detener y finalizar la prueba, donde esta última opción, guarda todos los datos obtenidos por el dispositivo en una base de datos relacionada al paciente.
 - El módulo permite exportar los reportes de las pruebas en formato PDF.
- **Dispositivos**
 - El módulo permite al usuario realizar la gestión de dispositivos: altas, bajas y modificaciones.
 - Sincronizar el dispositivo por primera vez para obtener información relevante.

3.1.3 Casos de uso de la aplicación

Tomando en cuenta los requisitos funcionales del módulo, se muestra el siguiente diagrama de casos de uso donde se observa la interacción del usuario con el sistema (Figura 3.4).




Figura 3.4. Diagrama de casos de uso para el módulo desarrollado.

A continuación, en la siguiente tabla (Tabla 3.4) se describe la interacción del usuario con el módulo.

Tabla 3.4. Descripción general del caso de uso de la Figura 3.2.

Caso de Uso	Descripción	Precondiciones
Iniciar Sesión	Acceder al módulo con las credenciales del usuario.	Tener un registro previo en el sistema.
Cerrar Sesión	Finalizar la sesión del usuario.	Contar con una sesión activa.
Visualizar Dashboard	Visualizar un resumen de información relevante para el usuario (incluye número de pacientes, números de casos positivos con TDAH y un historial de la prevalencia del trastorno en todos los pacientes).	Tener acceso al sistema.
Exportar Información	Permite al usuario exportar la información de todos los pacientes en distintos formatos.	Tener al menos un paciente asignado.
Ver Pacientes	Visualizar los pacientes asignados.	Tener al menos un paciente asignado.

Caso de Uso	Descripción	Precondiciones
Ver Perfil de Paciente	Visualizar información personal, médica y otros. Resumen general de prevalencia del trastorno.	Contar con la información completa del paciente.
Ver Historial de Pruebas	Visualizar la lista de pruebas realizadas, ordenadas del más reciente al más antiguo.	Contar con al menos una prueba realizada.
Ver Resultados de Prueba	Visualizar los resultados obtenidos de la prueba realizada.	Realizar una prueba previamente.
Realizar Prueba	Preparar el dispositivo y el entorno para realizar la prueba.	Seleccionar un paciente.
Seleccionar Dispositivo	Seleccionar el dispositivo con el que realiza la prueba.	Contar con al menos un dispositivo registrado.
Sincronizar Dispositivo	Sincronizar mediante <i>Bluetooth</i> el equipo actual con el dispositivo correspondiente.	Contar con al menos un dispositivo registrado y acceso a <i>Bluetooth</i> .
Monitorizar Prueba	Visualizar la información obtenida en tiempo real por el dispositivo.	Contar con una prueba en curso.
Añadir Dispositivo	Agregar un dispositivo para realizar pruebas.	Contar con acceso a <i>Bluetooth</i> .
Eliminar Dispositivo	Eliminar un dispositivo de la lista de dispositivos.	Seleccionar el dispositivo a eliminar.

3.2 Diseño

A continuación, se presenta el diseño de la arquitectura, el diseño del esquema de almacenamiento y los diseños (mockups) de interfaces gráficas para el desarrollo del módulo teniendo en cuenta el propósito del módulo. Se realizó el esquema de almacenamiento de la información para el módulo, con una descripción de los datos; también se realizaron los primeros diseños para el módulo, interfaces que van desde la pantalla de inicio de sesión hasta la pantalla de realización de pruebas y, por último, el diseño de la arquitectura para el módulo.

3.2.1 Esquema de almacenamiento de información

Una parte fundamental en el desarrollo del módulo web para la detección del nivel de TDAH mediante técnicas de inteligencia artificial es el diseño e implementación de un esquema de almacenamiento de información eficiente y estructurado. Un

sistema de base de datos adecuadamente organizado es crucial para asegurar la integridad, seguridad y accesibilidad de los datos recopilados. En este apartado, se presenta en detalle el esquema de almacenamiento de información (Figura 3.5) utilizado en el proyecto.




Figura 3.5. Esquema de almacenamiento para la base de datos.

3.2.1.1 Diccionario de datos

Para complementar y ofrecer una comprensión más profunda del esquema de almacenamiento de información descrito anteriormente, se proporciona a continuación un diccionario de datos para dar una descripción clara y detallada de los elementos que conforman la base de datos (Tabla 3.5 – Tabla 3.11). Proporcionar esta información, facilita la interpretación y comprensión del esquema de almacenamiento.

Tabla 3.5. Descripción de la tabla Tipos de Evaluación.

Entidad	TDAH.TIPOS.EVALUACION				
Resumen	Tabla que almacena el conjunto de datos para los distintos tipos de evaluaciones para la detección del TDAH				
Propiedad	Descripción	Tipo	Longitud	Clave	Valor
idTipoEvaluacion	Identificador del registro	INTEGER	default	Primaria	-
Nombre	Nombre de la evaluación	VARCHAR	25	-	-
Descripcion	Detalles generales de la evaluación	VARCHAR	255	-	-
Estado	Establece si el registro se encuentra activo (1) o inactivo (0)	TINYINT	default	-	1

Tabla 3.6. Descripción de la tabla Tipos de Dispositivos.

Entidad	TDAH.TIPOS.DISPOSITIVOS				
Resumen	Tabla que almacena el conjunto de datos para los distintos dispositivos que extraen información de diferentes biomarcadores para la detección del TDAH				
Propiedad	Descripción	Tipo	Longitud	Clave	Valor
idTipoDispositivo	Identificador del registro	INTEGER	default	Primaria	-
Nombre	Nombre del dispositivo	VARCHAR	25	-	-
Marca	Nombre de la marca a la que pertenece el dispositivo	VARCHAR	25	-	-
Modelo	Modelo de referencia del dispositivo	VARCHAR	100	-	-
Tipo	Tipo de dispositivo en función a sus características	VARCHAR	100	-	-
Estado	Establece si el dispositivo se encuentra activo (1) o inactivo (0)	TINYINT	default	-	1

Tabla 3.7. Descripción de la tabla Evaluaciones.

Entidad	TDAH.EVA.EVALUACIONES				
Resumen	Tabla que almacena el conjunto de evaluaciones disponibles para su ejecución				
Propiedad	Descripción	Tipo	Longitud	Clave	Valor
idEvaluacion	Identificador del registro	INTEGER	default	Primaria	-
idTipoEvaluacion	Identificador de referencia al tipo de evaluación que pertenece	INTEGER	default	Foránea	-
idTipoDispositivo	Identificador de referencia al tipo de dispositivo que pertenece	INTEGER	default	Foránea	-
Estado	Establece si el registro se encuentra activo (1) o no (0)	TINYINT	default	-	1

Tabla 3.8. Descripción de la tabla Proceso de Pruebas.

Entidad	TDAH.PROC.Pruebas				
Resumen	Tabla que almacena las pruebas realizadas por los doctores				
Propiedad	Descripción	Tipo	Longitud	Clave	Valor
idPrueba	Identificador del registro	INTEGER	default	Primaria	-
idPaciente	Identificador de referencia del paciente que realizó la prueba	INTEGER	default	Foránea	-
idTipoDispositivo	Identificador de referencia del dispositivo con el que se realizó la prueba	INTEGER	default	Foránea	-
idDetallePrueba	Identificador de referencia al detalle de la prueba	INTEGER	default	Foránea	-
Fecha	Fecha en la que se realizó la prueba	DATETIME	default	-	-
Probabilidad	Porcentaje de probabilidad global de prevalencia del TDAH arrojado por la prueba	DECIMAL	3,2	-	-
SubTipo	Especifica el subtipo de TDAH de mayor prevalencia	TINYINT	default	-	1

Tabla 3.9. Descripción de la tabla Proceso de Detalle de Pruebas.

Entidad	TDAH.PROC.DETALLE_PRUEBAS				
Resumen	Tabla que almacena los detalles de las pruebas realizadas por los doctores				
Propiedad	Descripción	Tipo	Longitud	Clave	Valor
idPruebas	Identificador del registro	INTEGER	default	Primaria	-
idEvaluacion	Identificador de referencia a la evaluación realizada	INTEGER	default	Foránea	-
FreCardiaca	Valor de la frecuencia cardiaca obtenida durante la prueba	DECIMAL	3,2	-	-
Concentracion	Valor del nivel de concentración obtenida durante la prueba	DECIMAL	3,2	-	-
Actividad	Valor de la actividad motriz obtenida durante la prueba	DECIMAL	3,2	-	-
esPositivo	Especifica si el resultado de la prueba es positivo	BOOLEAN	-	-	False

Tabla 3.10. Descripción de la tabla Relación Paciente – Médico.

Entidad	USUARIOS.REL.PACIENTE_MEDICO				
Resumen	Tabla que almacena las relaciones entre pacientes y médicos				
Propiedad	Descripción	Tipo	Longitud	Clave	Valor
idPaciente	Identificador de referencia del usuario paciente	INTEGER	default	Primaria, Foránea	-
idMedico	Identificador de referencia del usuario médico	INTEGER	default	Primaria, Foránea	-

Tabla 3.11. Descripción de la tabla Relación Médico – Dispositivo.

Entidad	USUARIOS.REL.MEDICO_DISPOSITIVO				
Resumen	Tabla que almacena las relaciones entre médicos y los dispositivos con los que cuenta				
Propiedad	Descripción	Tipo	Longitud	Clave	Valor
idMedico	Identificador de referencia del usuario médico	INTEGER	default	Primaria, Foránea	-
idDispositivo	Identificador de referencia del dispositivo registrado por el médico	INTEGER	default	Primaria, Foránea	-

3.2.2 Diseño de interfaces del módulo (Mockups)

En esta sección se muestran los modelos gráficos de las interfaces del módulo con el fin de determinar los aspectos fundamentales del mismo.

3.2.2.1 Inicio de sesión

La Figura 3.6 se presenta el diseño de la sección de inicio de sesión que necesita de un usuario y una contraseña, también se presentan otras opciones como reestablecer la contraseña y mantener la sesión abierta.



The mockup shows a white rounded rectangle centered on a light gray background. At the top is a black silhouette of a head with a brain. Below it is the label 'Usuario' followed by a text input field. Then the label 'Contraseña' followed by a password input field. Below the password field is a checkbox labeled 'Recordarme' and a blue link 'Olvidé mi clave'. At the bottom is a blue button with the text 'ENTRAR' in white.

Figura 3.6. Diseño de la página de Iniciar Sesión.

3.2.2.2 Vista principal (Dashboard)

Para esta sección (Figura 3.7), después de iniciar sesión, se presenta una pantalla con los siguientes elementos en ella:

- **Tarjeta de perfil:** Muestra el nombre completo y la especialidad del usuario (médico) junto con su foto de perfil.
- **Tarjeta de pacientes:** Muestra el número de pacientes asignados al médico.
- **Tarjeta de casos positivos:** Muestra el número de pacientes correctamente diagnosticados con TDAH de todos los pacientes asignados al médico.
- **Gráfico histórico:** Muestra el seguimiento histórico de todos los pacientes positivos en TDAH en periodos de tiempo establecidos, donde se encuentran los filtros por subtipo de TDAH, periodo y sexo.
- **Lista de pacientes recientes:** Muestra una pequeña lista de los últimos pacientes atendidos del más reciente al más antiguo.




Figura 3.7. Diseño de la página de Dashboard (vista principal).

3.2.2.3 Pacientes

Esta es una sección dedicada a los pacientes asignados al médico (Figura 3.8); se muestra una tabla con información esencial de los pacientes, como: nombre completo, edad, sexo, correo de contacto, fecha de la última cita y además se añade un botón para acceder al perfil del paciente. En esta vista (Figura 3.9) también permite exportar la información de todos los pacientes en distintos formatos y también la posibilidad de añadir a un nuevo paciente.





Figura 3.8. Diseño de la página principal de Pacientes.



La información del paciente es mostrada en otra ventana (Figura 3.10), donde se visualiza la información personal, información médica, antecedentes médicos, un historial de pruebas en forma de gráfica y una tabla como historial de reportes (de cada prueba realizada) con información relevante: ID de la prueba, fecha de la aplicación de la prueba, diagnóstico preliminar, probabilidad de prevalencia del trastorno y un botón para visualizar el reporte completo; por último, un botón donde da inicio a una prueba para el paciente que visualiza en su momento.



Figura 3.10. Diseño de la página de Perfil del Paciente.

3.2.2.4 Pruebas

Para esta interfaz (Figura 3.11), se plantea el desarrollo de una ventana “paso a paso”, donde en primera instancia, se selecciona el dispositivo a utilizar, se muestra una imagen de este y una pequeña descripción. Luego el módulo se encarga de buscar y sincronizar el dispositivo mediante la tecnología *bluetooth*; por último, se muestra una lista de consejos para el dispositivo con la opción de iniciar la prueba o cancelar el proceso.




Figura 3.11. Diseño de la página de Pruebas (selección de dispositivo).

Cuando la prueba esté en curso, se visualiza toda la información recabada por el dispositivo que el paciente esté utilizando, para eso se diseñó la siguiente interfaz (Figura 3.12) donde se muestran todos los biomarcadores (ritmo cardíaco, datos del acelerómetro, oxigenación en sangre, ondas cerebrales, por mencionar algunos) a los que tiene acceso el dispositivo con el fin de dar un monitoreo en tiempo real al paciente. El diseño incluye funciones como pausar, detener o finalizar la prueba.




Figura 3.12. Diseño de la página de Pruebas (prueba en tiempo real).

3.2.2.5 Dispositivos

En esta interfaz, se tiene como objetivo listar los dispositivos compatibles con el módulo (Figura 3.13) y obtener más información sobre los mismos. Esta interfaz contiene tarjetas que muestra una imagen previa del dispositivo, el nombre y una breve descripción.




Figura 3.13. Diseño de la página principal de Dispositivos.

3.2.3 Diseño de arquitectura del módulo

A continuación, se expone una vista general de la arquitectura del módulo para la detección del TDAH (Figura 3.14), se detalla la interacción entre el usuario y el módulo web junto con todos los parámetros necesarios.




Figura 3.14. Arquitectura final del módulo.

El flujo de trabajo es el siguiente: el módulo en cuestión se encuentra alojado en un cliente web, donde el módulo comienza con el ingreso al sitio para la realización de detección de TDAH, contando con apartados como la aplicación de nuevas pruebas, y el seguimiento evolutivo del paciente con respecto al historial de pruebas realizadas al paciente. En el proceso de las pruebas se recopilan los datos obtenidos por uno o varios dispositivos, se recopila y procesa dicha información para después interpretar y obtener los resultados esperados para realizar su monitorización y continuar con su seguimiento.

El proceso de obtención de datos para el módulo es realizado por uno o más dispositivos inteligentes con capacidad para recolectar información de biomarcadores como las señales de onda cerebrales, saturación de oxígeno, ritmo cardíaco, entre otros. Los datos obtenidos se envían a un servidor externo donde uno o varios clasificadores se encarga de realizar las operaciones de procesamiento e interpretación para finalmente, guardar los resultados para su consulta y seguimiento.

La arquitectura seleccionada para este módulo es una arquitectura basada en capas, esta proporciona una solución escalable que organiza el módulo en varias capas o niveles, cada uno con una funcionalidad específica. Cada capa se construye encima de la capa anterior y proporciona servicios a la capa superior.

A continuación, se describe cada una de las capas que compone al módulo presentado en la anterior:

- **Capa de presentación:** es la capa que interactúa con el usuario final, y se encarga de la presentación de la información y la interacción con el usuario, como mostrar información de los pacientes, del perfil médico, la realización de pruebas con su respectivo seguimiento, entre otros.
- **Capa de integración:** La capa de integración se encarga de procesar las solicitudes de la capa de presentación y enviarlas a la capa de servicios correspondiente. También se encarga de recuperar los datos de la capa de acceso a datos y enviarlos a la capa de presentación. Los módulos que lo integran son los módulos de pruebas, donde se realizan las pruebas a los pacientes con los dispositivos inteligentes; el módulo de monitorización se encarga de recibir en tiempo real los datos obtenidos en por el dispositivo, dicha información se procesa e interpreta por la capa de servicios; y finalmente, el módulo de resultados, que permite visualizar de forma clara y concisa los resultados obtenidos.
- **Capa de servicios:** es una capa adicional que expone la funcionalidad de la capa de lógica de negocio a través de una interfaz de programación de aplicaciones. La capa de servicios web proporciona una forma estandarizada y segura de acceder a los servicios del sistema desde cualquier aplicación o dispositivo con acceso a Internet. Esta capa utiliza protocolos de comunicación como HTTP o HTTPS para recibir solicitudes y enviar respuestas en formato de intercambio de datos estándar como JSON o XML. Esta capa se conforma de los módulos de comunicación (conexión con una API), el módulo de modelos de aprendizaje automático que contiene diferentes algoritmos de aprendizaje para

luego realizar la clasificación de los datos; y dichos datos se envían al módulo de acceso a datos que conecta con la capa de datos.

- **Capa de datos o almacenamiento:** esta capa se encarga del almacenamiento y la recuperación de datos del sistema, ya sea en una base de datos o en otro tipo de almacenamiento. Esta información se muestra en la capa de presentación lista para su interpretación por el usuario final.

3.2.4 Diseño de los servicios web (API)

Con el fin de ofrecer una comunicación limpia y estructurada entre el cliente y el servidor, se diseñaron los siguientes servicios para el funcionamiento del módulo (Figura 3.15 – Figura 3.20).

3.2.4.1 Diseño del servicio para iniciar de sesión




Figura 3.15. Servicio para iniciar sesión.

3.2.4.2 Diseño del servicio para obtener información de perfil del usuario

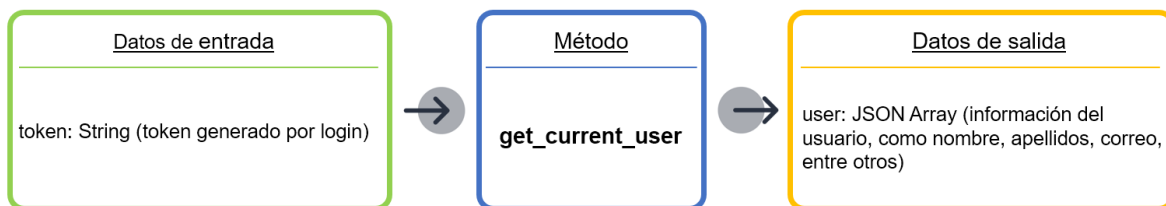


Figura 3.16. Servicio para obtener la información de perfil del usuario.

3.2.4.3 Diseño del servicio para consultar la lista de pacientes

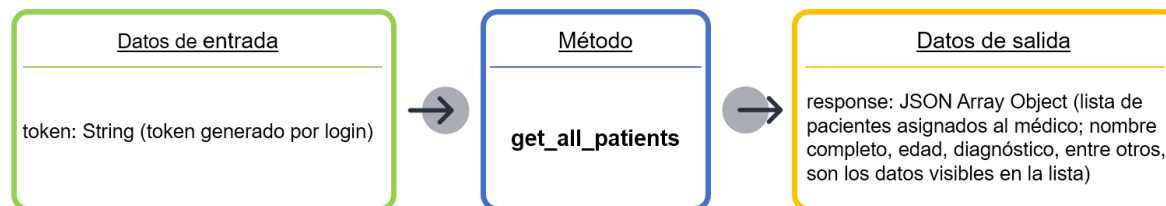


Figura 3.17. Servicio para obtener la lista de pacientes.

3.2.4.4 Diseño del servicio para obtener información de un paciente

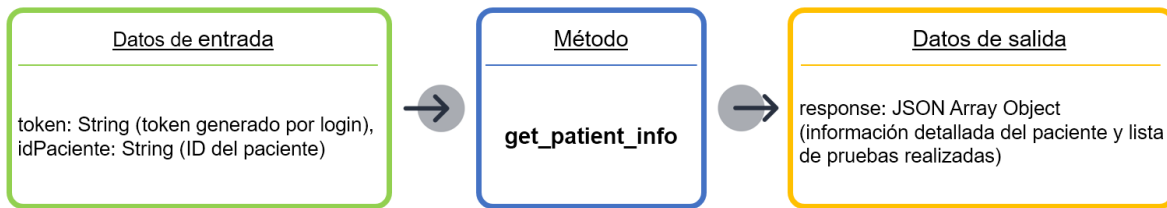


Figura 3.18. Servicio para obtener la información completa del paciente.

3.2.4.5 Diseño del servicio para almacenar información de una prueba

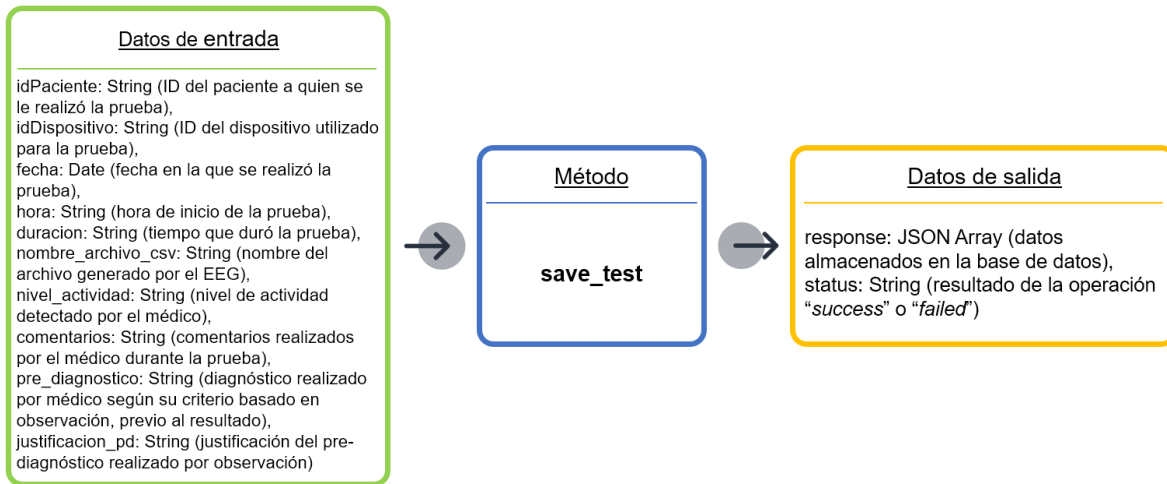


Figura 3.19. Servicio para almacenar la información de la prueba realizada.

3.2.4.6 Diseño del servicio para consultar la lista del historial de pruebas

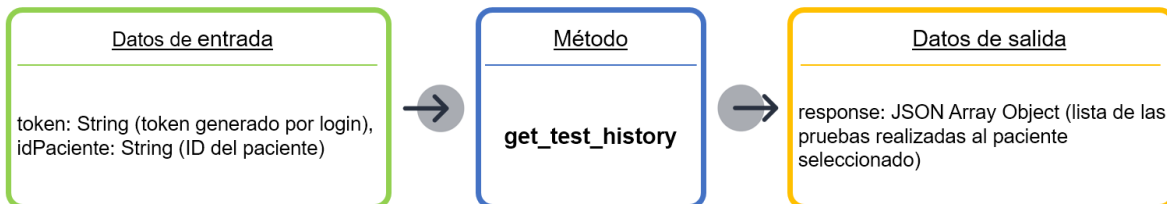


Figura 3.20. Servicio para obtener la lista de pruebas realizadas.

3.3 Desarrollo

En esta sección, se detalla el proceso de desarrollo para el módulo.

3.3.1 Implementación de los algoritmos de aprendizaje automático

En esta sección se describe el proceso de implementación de los algoritmos de clasificación basados en aprendizaje automático a través de las tecnologías propuestas.

En un principio, la implementación de estos algoritmos se realizó en el lenguaje *Python* y se realizó la configuración experimental para entrenar y probar cada uno

de los algoritmos seleccionados utilizando la biblioteca *Sckit-Learn*. Dependiendo del conjunto de datos seleccionado para evaluar, se estableció una configuración diferente de los parámetros de entrada, filtrando principalmente aquellos que se consideraron elementales para la clasificación y después sustituyendo los valores faltantes por valores aleatorios (de acuerdo con el contexto y al tipo de dato); se dividió el tamaño de los datos siendo un 80% para entrenamiento y un 20% para pruebas. Después se aplicó la clasificación y se obtuvieron diferentes métricas para evaluar su precisión (Listado 3.1). Los algoritmos seleccionados (que obtuvieron los mejores resultados) fueron Regresión Lineal, CatBoost y SVM.

Listado 3.1. Configuración experimental para el conjunto de datos HYPERAKTIV con SVM.

```

1. import pandas as pd
2. from sklearn.model_selection import train_test_split, GridSearchCV
3. from sklearn.svm import SVC
4. from sklearn.metrics import precision_score, recall_score, accuracy_score,
   f1_score, roc_auc_score
5. # Importar la data
6. df = pd.read_csv("./data/HYPERAKTIV.csv")
7. df.fillna(0, inplace=True)
8. # Filtrar características
9. df_filter = df[df.columns[:-1]]
10. df_train = df_filter.drop(['ADHD'], axis=1)
11. X = df_train.values
12. y = df['ADHD'].values
13. # Preparar los segmentos de entrenamiento y prueba
14. X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
   random_state=404)
15. # Preparando los algoritmos
16. svm = SVC()
17. params_svm = {
18.     'C': [1, 2, 4, 8, 16, 32],
19.     'gamma': ['scale', 'auto'],
20.     'kernel': ['linear', 'rbf'],
21.     'random_state': [1, 5, 10],
22. }
23. # Validación cruzada
24. svm_cv = GridSearchCV(
25.     svm,
26.     params_svm,
27.     scoring='accuracy'
28. )
29. # Aplicar clasificación
30. svm_cv.fit(X_train, y_train)

```

```

31. # Buscar los mejores parámetros
32. svm_y_pred = svm_cv.best_estimator_.predict(X_test)
33. # Resultados
34. print('==> SVM <==')
35. print('Accuracy:\t%f' % accuracy_score(y_test, svm_y_pred))
36. print('Precision:\t%f' % precision_score(y_test, svm_y_pred, average="macro"))
37. print('Recall:\t\t%f' % recall_score(y_test, svm_y_pred, average="macro"))
38. print('F1-Score:\t%f' % f1_score(y_test, svm_y_pred))
39. print('ROC_AUC:\t%f' % roc_auc_score(y_test, svm_y_pred))
40. print('-----')
41. print('Mejores params: ', svm_cv.best_params_)
42. print('- Fin del entrenamiento -')

```

Conservando la estructura del código anterior, en el Listado 3.2 se muestra el código realizado para el algoritmo de Regresión Lineal y en el Listado 3.3 el código realizado con *CatBoost*, donde únicamente cambia la preparación del algoritmo.

Listado 3.2. Configuración experimental para el conjunto de datos con Regresión Lineal.

```

1. # Parámetros iniciales
2. params_lnr = {
3.     'C' : [1, 2, 4, 8, 16, 32],
4.     'max_iter' : [1000, 3000, 5000],
5.     'penalty' : ['l2'],
6.     'random_state': [5, 10, 20, 50]
7. }
8. # Validación cruzada
9. lnr_cv = GridSearchCV(
10.     lnr,
11.     params_lnr,
12.     scoring='accuracy'
13. )
14. # Entrenamiento
15. lnr_cv.fit(X_train, y_train)
16. # Realizar predicciones con el modelo “mejor encontrado”
17. lnr_y_pred = lnr_cv.x(X_test)

```

Listado 3.3. Configuración experimental para el conjunto de datos con CatBoost.

```

1. # Estancia del clasificador
2. ctb = CatBoostClassifier()
3. # Parámetros iniciales
4. params_ctb = {
5.     'learning_rate': [0.01, 0.1, 0.25, 0.5, 1.0],
6.     'n_estimators': [10, 25, 50, 75, 100],
7.     'random_state': [0, 1, 10, 100, None]
8. }
9. # Validación cruzada
10. ctb_cv = GridSearchCV(

```

```

11.     ctb,
12.     params_ctb,
13.     scoring='accuracy'
14. )
15. # Entrenamiento
16. ctb_cv.fit(X_train, y_train)
17. # Realizar predicciones con el modelo "mejor encontrado"
18. adb_y_pred = ctb_cv.best_estimator_.predict(X_test)

```

3.3.2 Desarrollo de los servicios

Para el desarrollo de los *end-points* se realizó una arquitectura REST para crear un servicio *RESTful API* utilizando el marco de trabajo FastAPI de Python. Dentro de la lista de los servicios desarrollados, se incluye la detección del nivel de atención (Listado 3.4) donde después de analizar los datos obtenidos en bruto del EEG realizado, se devuelve un prediagnóstico del nivel de atención. El resto de los servicios se listan a continuación.

3.3.2.1 Servicio para identificar el nivel de atención.

Listado 3.4 Método identificador del nivel de atención.

```

1. from fastapi import FastAPI, HTTPException, UploadFile, File
2. # Otras bibliotecas...
3. # Instancia de FastAPI
4. app = FastAPI()
5. # Configura CORS
6. origins = [
7.     "http://localhost:4200",
8. ]
9. app.add_middleware(
10.     # ...
11. )
12. @app.post("/process-eeg/")
13. async def process_eeg(file: UploadFile = File(...)):
14.     if file and file.filename.endswith('.csv'):
15.         try:
16.             df = pd.read_csv(file.file)
17.             def bandpass_filter(data, lowcut=0.5, highcut=50.0, fs=256, o=5):
18.                 # Aplicación de filtros...
19.                 return filtfilt(b, a, data)
20.             # Promedio de las potencias de las bandas
21.             def average_power(psd, freqs, start, end):
22.                 return psd[(freqs >= start) & (freqs <= end)].mean()
23.             # Cálculo de ventanas existentes
24.             def sw_alay (data, fs=256, nperseg=256*4):
25.                 window_length = fs * 60 # 1 minuto

```

```

26.         num_windows = len(data) // window_length
27.         theta_avgs, beta_avgs, beta_theta_ratios = [], [], []
28.         # ...
29.         # Cálculo avg por ventana temporal...
30.         # ...
31.         return theta_avgs, beta_avgs, beta_theta_ratios
32.     # Filtrado de las bandas AF7 y AF8
33.     filtered_af7 = bandpass_filter(df['AF7'].to_numpy())
34.     filtered_af8 = bandpass_filter(df['AF8'].to_numpy())
35.     # Límite de Hz para cada tipo de onda
36.     theta = (4, 8)
37.     beta = (13, 30)
38.     # Filtrado de las bandas por promedio y ratio
39.     theta_avgs_af7, beta_avgs_af7, ratios_af7 = sw_aly(filtered_af7)
40.     theta_avgs_af8, beta_avgs_af8, ratios_af8 = sw_aly(filtered_af8)
41.     # Más código que evalúa y promedia el estado de atención...
42.     avg_ratio_af7 = sum(ratios_af7) / len(ratios_af7)
43.     avg_ratio_af8 = sum(ratios_af8) / len(ratios_af8)
44.     # Calcular el promedio general para ambos canales
45.     average_ratio = (avg_ratio_af7 + avg_ratio_af8) / 2
46.     # Calcular el estado de atención general
47.     if average_ratio > 1.2:
48.         final_state = "Atento"
49.     elif average_ratio < 0.8:
50.         final_state = "Distracción"
51.     else:
52.         final_state = "Medianamente atento"
53.     # Regresa el objeto resultante para el front-end
54.     return {
55.         "attention_state_AF7": attention_state_AF7,
56.         "attention_state_AF8": attention_state_AF8,
57.         "beta_theta_ratio_af7": ratios_af7,
58.         "beta_theta_ratio_af8": ratios_af8,
59.         "final_state": final_state
60.     }
61. except Exception as e:
62.     raise HTTPException(status_code=400, detail=str(e))
63. else:
64.     raise HTTPException(status_code=400, detail="Invalid file format!")

```

El extracto de código listado anteriormente muestra el proceso de identificación del nivel de atención. El proceso inicia con la validación del archivo recibido de tipo CSV para luego leerlo y convertirlo en un *DataFrame*. Se define una función que filtra los datos del EEG para eliminar ruido y mantener solo las frecuencias de interés (entre 0.5 y 50 Hz) en los canales AF7 y AF8 del EEG. Luego se hace un análisis de la

potencia en las bandas de frecuencia a las ondas Theta (4 – 8 Hz) y Beta (13 – 30 Hz). La frecuencia de las ondas se divide en ventanas deslizantes sobre los datos filtrados del EEG. En cada ventana, se calcula la densidad espectral de potencia (PSD) y, a partir de ella, el poder medio en las bandas Theta y Beta. Además, se calcula el cociente entre el poder Beta y el poder Theta. Después, se hace un cálculo del estado de atención de los canales AF7 y AF8 (hemisferio izquierdo y derecho respectivamente), en la siguiente tabla (Tabla 3.12) se establecen las reglas para determinar el estado de atención del sujeto.

Tabla 3.12. Reglas establecidas para identificar el nivel de atención.

Regla	Rango (μV)	Resultado
$\beta > \theta$	1.2 – 2.0	“Atento”
$\beta < \theta$	0.0 – 0.8	“Distracción”
$\beta \approx \theta$	0.9 – 1.1	“Medianamente atento”

Las reglas consisten en: si el poder Beta es mayor que el Theta, se considera que el estado es "Atento"; de lo contrario, se considera "Distracción"; y si son aproximadamente iguales, se considera "Medianamente atento". Finalmente, se calcula un "estado final" promediando los cocientes de ambos canales y categorizándolos en "Atento", "Distracción" o "Medianamente atento". El código devuelve un objeto con los estados de atención calculados, los cocientes beta/theta de ambos canales y el estado de atención final.

3.3.2.2 Servicio para iniciar de sesión

Para el desarrollo de este servicio (Listado 3.5), necesita recibir los datos del formulario de “inicio de sesión” (que es el correo y la contraseña) para acceder al módulo. Dicho acceso devuelve un token de acceso que es utilizado para validar futuras solicitudes a los distintos servicios disponibles, esto con el fin de ofrecer un alto nivel de seguridad al módulo.

Listado 3.5. Código del servicio para iniciar sesión.

```

1. @router.post("/login")
2. async def login(form_data: OAuth2PasswordRequestForm = Depends(), db: Session
3. = Depends(get_db)):
4.     # Autentica el usuario

```

```

5.     user=authenticate_user(db,form_data.username,form_data.password)
6.     if not user:
7.         raise HTTPException(
8.             status_code=status.HTTP_401_UNAUTHORIZED,
9.             detail="Correo o contraseña incorrectos.",
10.            headers={"WWW-Authenticate": "Bearer"},
11.        )
12.     # Verifica si el rol del usuario es 'Médico'
13.     if user.rol != "Médico":
14.         raise HTTPException(
15.             status_code=status.HTTP_401_UNAUTHORIZED,
16.             detail="No tienes permiso para iniciar sesión.",
17.             headers={"WWW-Authenticate": "Bearer"},
18.        )
19.     # Crea el token de acceso
20.     access_token_exp=timedelta(minutes=ACCESS_TOKEN_EXPIRE_MINUTES)
21.     access_token=create_access_token(
22.         data={"sub": user.correo}, expires_delta=access_token_exp
23.     )
24.     Return {
25.         "access_token": access_token,
26.         "token_type": "bearer"
27.     }

```

3.3.2.3 Servicio para obtener información del perfil de usuario

Después de obtener el token, se recolecta la información de perfil del usuario que inició sesión, la información que devuelve este servicio (Listado 3.6) es información básica del usuario (nombre, apellidos, correo, entre otros) y excluyendo la información sensible (contraseña).

Listado 3.6. Código del servicio para obtener la información del usuario actual.

```

1. async def get_current_active_user(db: Session = Depends(get_db), token: str
= Depends(oauth2_scheme)):
2.     credentials_exception = HTTPException(
3.         status_code=status.HTTP_401_UNAUTHORIZED,
4.         detail="Las credenciales no existen o no son válidas.",
5.         headers={"WWW-Authenticate": "Bearer"},
6.     )
7.     try:
8.         payload=jwt.decode(token,SECRET_KEY, algorithms=[ALGORITHM])
9.         correo: str = payload.get("sub")
10.        if correo is None:
11.            raise credentials_exception
12.        token_data = schemas.TokenData(correo=correo)
13.    except JWTError:

```

```

14.         raise credentials_exception
15.         user = db.query(models.Usuario)
16.             .filter(models.Usuario.correo == token_data.correo).first()
17.         if user is None:
18.             raise credentials_exception
19.         return user
20. # Método para obtener el usuario actual
21. @router.get("/get-current-user", response_model=UserPublic)
22. async def get_current_user(
23.     current_user: UserPublic = Depends(get_current_active_user)
24. ):
25.     return current_user

```

3.3.2.4 Servicio para consultar la lista de pacientes

En el Listado 3.7 se muestra el código del servicio utilizado para la visualización de todos los pacientes. Dicha información se muestra en forma de tabla en la interfaz del módulo.

Listado 3.7. Código para el servicio de listar pacientes en el módulo.

```

1. @router.get("/get-patients", response_model=List[UserPublic])
2. def get_patients(
3.     current_user: models.Usuario = Depends(get_current_active_user),
4.     db: Session = Depends(get_db)
5. ):
6.     pacientes=db.query(models.Usuario)
7.         .filter(models.Usuario.rol=="Paciente")
8.         .all()
9.     return pacientes

```

3.3.2.5 Servicio para obtener información de un paciente

En el funcionamiento establecido para el módulo, después de mostrar la lista de pacientes, se encuentra la opción de visualizar la información de cada uno de los pacientes. Para ello sólo es necesario enviar la información del identificador del paciente al servicio (Listado 3.8) para devolver toda la información relacionada con el paciente.

Listado 3.8. Código para el servicio de obtener información de un paciente.

```

1. @router.get("/get-patient-info/{paciente_id}", response_model=UserPublic)
2. def get_paciente(
3.     paciente_id: int,
4.     current_user: models.Usuario = Depends(get_current_active_user),
5.     db: Session = Depends(get_db)
6. ):

```

```

7.      # Verificar si el usuario actual tiene permiso para ver la información
8.      if current_user.rol != "Médico":
9.          raise HTTPException(
10.             status_code=status.HTTP_403_FORBIDDEN,
11.             detail="No tiene permiso para acceder a esta información."
12.         )
13.     paciente = db.query(models.Usuario)
14.         .filter(
15.             models.Usuario.idUsuario==paciente_id,
16.             models.Usuario.rol == "Paciente")
17.         .first()
18.     # Si el paciente no existe...
19.     if not paciente:
20.         raise HTTPException(
21.             status_code=404,
22.             detail="Paciente no encontrado"
23.         )
24.     return paciente

```

3.3.2.6 Servicio para almacenar información de una prueba

Este servicio guarda la información obtenida durante la realización de la prueba y sus detalles. En el Listado 3.9 se describe parte del desarrollo realizado para almacenar dicha información.

Listado 3.9. Código para el servicio que almacena la información de una prueba realizada.

```

1. # Guardar la información del detalle de la prueba
2. def create_detalle_prueba(
3.     db: Session,
4.     detalle_data: schemas.DetallePruebaCreate
5. ):
6.     detalle_prueba = models.DetallePrueba(**detalle_data.dict())
7.     db.add(detalle_prueba)
8.     db.commit()
9.     db.refresh(detalle_prueba)
10.    return detalle_prueba
11. # Guardar la información de la prueba
12. def create_prueba(
13.     db: Session,
14.     prueba_data: schemas.PruebaCreate,
15.     id_detalle_prueba: int
16. ):
17.     # Asignar el ID del detalle de la prueba
18.     prueba_data.idDetallePrueba = id_detalle_prueba
19.     prueba = models.Prueba(**prueba_data.dict())
20.     db.add(prueba)
21.     db.commit()

```

```

22.     db.refresh(prueba)
23.     return prueba
24. # Método para guardar la información de la prueba
25. @router.post("/sabe-test/", response_model=schemas.Prueba)
26. def create_prueba_endpoint(
27.     prueba: schemas.PruebaCreate,
28.     detalle: schemas.DetallePruebaCreate,
29.     db: Session = Depends(get_db),
30.     current_user: models.Usuario = Depends(get_current_active_user)
31. ):
32.     # Primero, crear el detalle de la prueba y obtener el ID
33.     detalle_prueba = crud.create_detalle_prueba(db=db,detalle_data=detalle)
34.     # Luego, crear la prueba con el ID del detalle incluido
35.     prueba.idDetallePrueba = detalle_prueba.idDetallePrueba
36.     return crud.create_prueba(db=db, prueba_data=prueba)

```

3.3.2.7 Servicio para consultar la lista del historial de pruebas

Finalmente, se muestra el código desarrollado (Listado 3.10) para obtener las pruebas realizadas a un mismo paciente. Estas se ordenan de forma ascendente del más antiguo al más reciente.

Listado 3.10. Código para el servicio que obtiene el historial de pruebas de un paciente.

```

1. def get_pruebas_by_paciente_id(db: Session, paciente_id: int):
2.     return db.query(models.Prueba)
3.         .filter(models.Prueba.idPaciente == paciente_id)
4.         .all()
5. # Método para guardar la información de la prueba
6. @router.get(
7.     "/patient/{paciente_id}/test",
8.     response_model=List[schemas.Prueba]
9. )
10. def list_pruebas_for_paciente(
11.     paciente_id: int,
12.     db: Session = Depends(get_db),
13.     current_user: models.Usuario = Depends(get_current_active_user)
14. ):
15.     # Verifica si el usuario actual tiene permiso para ver las pruebas
16.     if current_user.rol != "Médico" and current_user.id != paciente_id:
17.         raise HTTPException(
18.             status_code=status.HTTP_403_FORBIDDEN,
19.             detail="No autorizado a ver estas pruebas"
20.         )
21.     # Llama el método para obtener la lista de pruebas
22.     pruebas = get_pruebas_by_paciente_id(db, paciente_id=paciente_id)
23.     return pruebas

```

3.3.3 Desarrollo de las interfaces

En esta sección se muestran las interfaces finales implementadas como parte de la aplicación web. El módulo proporciona diversas características, como la ejecución de pruebas, la exhibición de los resultados de la categorización y el monitoreo del historial del usuario. También se emplearon estrategias de verificación de elementos para asegurar que los datos recibidos y tratados en el servidor sean confiables y completos.

En la Figura 3.21 presenta la ventana de acceso principal al módulo, en este se encuentra el formulario de inicio de sesión para las credenciales correspondientes (usuario y contraseña), además de contar con un enlace para recuperar la contraseña y la posibilidad de mantener la sesión activa.




Figura 3.21. Pantalla de inicio de sesión.

Después de validar las credenciales correspondientes, se redirige a la ventana principal del usuario dentro del módulo (Figura 3.22) donde se muestra la información del usuario, el número de pacientes asignados al mismo y el número de pacientes diagnosticadas positivamente con TDAH. También se incluye una gráfica histórica de la prevalencia de TDAH en todos los pacientes y una lista de pacientes recientemente atendidos.



Figura 3.22. Pantalla principal después de iniciar sesión.

El usuario tiene a su disposición una sección de “Pacientes” donde se consultan los pacientes asignados, dichos pacientes se muestran en una tabla (paginada) con información relevante (Figura 3.23); también se dispone de funcionalidades como: exportar datos en diferentes formatos (Figura 3.24), registrar paciente y ver el perfil del paciente.

Lista de Pacientes

ID	Nombre	Contacto	Diagnóstico	Última cita	Estado
123456	Adolfo Meza Romero	fake_email@gmail.com	Mixto	01/03/2023	Activo
234567	Brandon Azael Muciño Santiesteban	fake_email@gmail.com	Hiperactivo	01/03/2023	Activo
345678	Ismael Santarrosa López	fake_email@gmail.com	Inatento	01/03/2023	Activo
456789	Óscar Crecencio Rico	fake_email@gmail.com	Normal	01/03/2023	Activo

Figura 3.23. Vista general de la sección de pacientes.




Figura 3.24. Modal para exportar la información de todos los pacientes.

El usuario tiene acceso a toda la información del paciente haciendo clic sobre el botón “Ver Perfil” en cual lo redirige a una interfaz (Figura 3.25) con los detalles personales del paciente, información médica, antecedentes familiares, entre otros. La vista de la ventana cambia después de realizar la primera prueba (Figura 3.26), donde ahora se incluye una gráfica lineal con información histórica de todas las pruebas realizadas, además de una tabla que lista los mismos reportes de cada prueba para su monitorización.




Figura 3.25. Pantalla de perfil del paciente (previo a la realización de una prueba).




Figura 3.26. Pantalla de perfil del paciente (después de realizar una o más pruebas).

En esta misma sección y después de realizar la primera prueba, se habilita un botón llamado “Recalcular” que sirve para recalcular el porcentaje de probabilidad de la prevalencia del TDAH. Además, el usuario es capaz de realizar las pruebas necesarias pulsando el botón “Iniciar prueba”, comenzando por la selección del dispositivo de todos los dispositivos admitidos por el módulo (Figura 3.27); luego de seleccionarlo, aparece en pantalla una descripción completa del dispositivo (Figura 3.28), que incluye información importante como el nombre, modelo, descripción y características disponibles; después, se muestra una lista de consejos para el usuario previos a iniciar la prueba (Figura 3.29) y finalmente se realiza la sincronización del dispositivo por *bluetooth* (Figura 3.30).




Figura 3.27. Pantalla para la selección de dispositivo.




Figura 3.28. Pantalla con información del dispositivo seleccionado.



Figura 3.29. Lista de consejos previos a la prueba.




Figura 3.30. Búsqueda y sincronización entre el módulo y el dispositivo.

Una vez comenzada la prueba, se redirige a una interfaz (Figura 3.31) que muestra la información obtenida en tiempo real del dispositivo en uso; dependiendo del tipo de dispositivo se presentan diferentes datos (biomarcadores) en pantalla, siendo los más comunes el ritmo cardíaco, oxigenación en sangre, datos de acelerómetro, datos EEG, por mencionar. Esta vista sirve para monitorizar al paciente durante la prueba y tener un reconocimiento mejor del estado del paciente. Dentro de las funcionalidades de esta sección, se encuentra “pausar” la prueba, “detener” la prueba (que elimina la información registrada al momento) y “finalizar” la prueba, que envía la información a un servicio para clasificar con los algoritmos de aprendizaje automático y obtener un resultado de prevalencia en el individuo.




Figura 3.31. Pantalla de las pruebas en tiempo real.

Otra sección importante es la de “Dispositivos”, donde se administra todos los dispositivos registrados por el médico (usuario); en esta sección se muestra en forma de galería los dispositivos con una imagen previa, un nombre y una breve descripción, como se observa en la Figura 3.32; aquí se agrega y elimina los dispositivos necesarios.




Figura 3.32. Pantalla de la sección de dispositivos.

Por último, se muestra el diseño resultante del desarrollo de la ventana de “Reporte”, en esta ventana (Figura 3.33) se visualiza la información obtenida de cada prueba realizada, como la fecha, el tiempo que duró la prueba, el dispositivo utilizado, una gráfica que muestra el cociente de la concentración medida durante la prueba y un prediagnóstico de esa misma prueba (Figura 3.34), comentarios realizados por el especialista, entre otros. Esta información es importante para realizar un promedio general de todas las pruebas y otorgar un diagnóstico final al médico en base al perfil del paciente.




Figura 3.33. Vista general del reporte de la prueba.



Figura 3.34. Resultados del EEG para el nivel de atención.

Capítulo 4. Resultados

En este capítulo, se presentan los resultados obtenidos a partir del desarrollo y aplicación de casos de estudio específicos para la detección del Trastorno por Déficit de Atención e Hiperactividad (TDAH). Los casos de estudio se diseñaron con el objetivo de evaluar la efectividad de la herramienta y de las metodologías propuestas en este trabajo de investigación para identificar la presencia de TDAH en los individuos evaluados. A continuación, se detalla el proceso de desarrollo, implementación y resultados de cada uno de los casos de estudio, destacando los hallazgos más relevantes y su implicación en el ámbito de la detección del TDAH.

4.1 Proceso de identificación del TDAH

En esta sección se expone el resultado de los casos realizados para comprobar la eficiencia del módulo y validar su uso como una herramienta de apoyo para los profesionales de la salud y que contribuya en el proceso de la identificación oportuna y precisa de la prevalencia del TDAH.

El caso de estudio se aplicó en un grupo de diez personas de las cuales cinco funcionaron como sujetos de control y el resto funcionaron como sujetos con TDAH clínicamente diagnosticado y/o con fuerte sospecha de prevalencia de este trastorno (Tabla 4.1). El proceso de validación del módulo se realizó durante el lapso de una semana, comprendido del 9 al 13 de octubre de 2023.

Tabla 4.1. Características de los participantes.

Sexo	Edad	Prediagnóstico (sospecha)
Femenino	22	Trastorno Depresivo (TD)
Masculino	25	Ninguno
Masculino	21	Trastorno de Ansiedad Generalizada (TAG)
Femenino	32	Ninguno
Femenino	25	Trastorno Déficit de Atención (TDA)
Masculino	24	Ninguno
Masculino	25	Trastorno Déficit de Atención e Hiperactividad (TDAH)
Femenino	25	Ninguno

Sexo	Edad	Prediagnóstico (sospecha)
Masculino	23	Trastorno Déficit de Atención (TDA)
Femenino	27	Trastorno Déficit de Atención (TDA)

Cada uno de los participantes tuvo una sesión (aproximadamente de una hora) dedicada a la realización de ejercicios para la evaluación de su estado de concentración y relajación. A continuación, se detalla el contexto estudiado para cada tipo de paciente resultante.

4.1.1 Diseño de la prueba

Esta sección tiene como objetivo presentar el método y criterios utilizados para poner a prueba el sistema, asegurando que cumpla con los requisitos y expectativas establecidos. Para llevar a cabo el estudio, se solicitó a los participantes realizar una lista de actividades; dichas actividades se evaluaron y validaron por una especialista en el área de neuropediatría. Estas actividades (Tabla 4.2) se realizaron con el fin de fomentar la estimulación de ondas Beta y Theta para medir el nivel de concentración y de relajación en los participantes.

Tabla 4.2. Lista de actividades validadas para su aplicación para la identificación del TDAH.

Onda (Bloque)	Tipo de actividad	Actividad	Tiempo (aprox)	Material
<u>Theta</u> (1)	Auditiva	Escuchar un audio (música o sonidos relajantes) con el propósito de alcanzar un estado de relajación.	4 – 8 min	- "Track_1.mp3" (4 min). - "Track_2.mp3" (5 min). - "Track_3.mp3" (7 min).
	Meditación	Realizar ejercicios de respiración profunda.	6 – 8 min	- "Medi_1.mp3" (8 min). - "Medi_2.mp4" (6 min).
<u>Beta</u> (2)	Resolución de problemas	Resolver un rompecabezas (de acuerdo a la edad del sujeto).	5 – 15 min	- "Rmcbz_1" (15 pzas). - "Rmcbz_2" (24 pzas). - "Rmcbz_3" (48 pzas).
		Resolver un cubo de Rubik.	10 min	- "Cubo_1" (2x2). - "Cubo_2" (3x3).
		Resolver un juego de "Sopa de letras".	5 – 10 min	- "Sopa_1" (10 palabras) - "Sopa_2" (20 palabras) - "Sopa_3" (30 palabras)
	Aprendizaje activo	Leer un texto y con base en lo aprendido, contestar un formulario.	15 min	- "texto_1" (1 cuartilla). - "texto_2" (2 cuartillas).
		Visualizar un video educativo y con base en lo aprendido, contestar un formulario.	20 min	- "Video_1.mp3" (5 min) - "Video_2.mp3" (7 min) - "Video_3.mp3" (9 min)

Después de presentar la lista de las actividades posibles para su aplicación, se diseñó la prueba de la siguiente forma:

1. Realizar una tarea de tipo auditiva que estimule la actividad de las ondas Theta.
2. Realizar una segunda tarea de tipo meditativa que estimula la actividad de las ondas Theta.
3. Realizar dos tareas de tipo de resolución de problemas para estimular las ondas Beta.
4. Realizar una tercera tarea de tipo de aprendizaje activo para estimular las ondas Beta.
5. Realizar cada actividad respetando su tiempo establecido.
6. Tomar descanso de 1 a 2 minutos entre cada tarea.

4.1.2 Caso de estudio 1: Sujeto con déficit de atención (positivo)

Sujeto masculino de 25 años diagnosticado clínicamente con TDAH, presentó un alto nivel de déficit de atención en tareas cognitivas de tiempo prolongado y con una actividad física moderada – alta al intentar permanecer quieto por largos periodos de tiempo (Figura 4.1). En Tabla 4.3, se compara el prediagnóstico realizado previo a iniciar la prueba del diagnóstico final obtenido después de realizar la prueba.

Tabla 4.3. Resultado obtenido para el primer caso de estudio.

Sexo	Edad	Prediagnóstico	Diagnóstico Final
Masculino	25	TDAH	TDAH

4.1.3 Caso de estudio 2: Sujeto sin déficit de atención (negativo)

Sujeto masculino de 26 años sin TDAH diagnosticado clínicamente, tampoco presenta síntomas o sospechas de la prevalencia de este trastorno. El sujeto presentó un alto nivel de concentración al momento de realizar tareas cognitivas (resolución de problemas y aprendizaje activo) además de permanecer quieto por largos periodos de tiempo (Figura 4.2). En la siguiente tabla (Tabla 4.4), se compara el prediagnóstico esperado del diagnóstico final realizado.

Tabla 4.4. Resultado obtenido para el segundo caso de estudio.

Sexo	Edad	Prediagnóstico	Diagnóstico Final
Masculino	26	Ninguno	Sin TDAH

4.1.4 Caso de estudio 3: Sujeto con posible déficit de atención

Sujeto femenino de 25 con la presencia de algunos síntomas y sospechas de la prevalencia de TDA. El sujeto presentó ligeros lapsos de tiempo en el que perdía total atención hacia la tarea realizada además de una actividad física baja – moderada durante la realización de la prueba (Figura 4.3). En Tabla 4.5, se compara el prediagnóstico realizado antes de la prueba y el diagnóstico obtenido.

Tabla 4.5. Resultado obtenido para el tercer caso de estudio.

Sexo	Edad	Prediagnóstico	Diagnóstico Final
Femenino	25	Ninguno	TDA

4.1.5 Datos iniciales

Para la realización de la prueba, se seleccionó una actividad por cada tipo de actividades correspondiente a la edad de cada participante, cada sesión tuvo una duración aproximada de una hora; durante el desarrollo de la prueba, cada participante utilizó un dispositivo inteligente vestible (diadema inteligente) que midió la actividad eléctrica del cerebro en canales específicos, es decir, un electroencefalograma en tiempo real para después ser analizar los datos obtenidos y ofrecer un prediagnóstico. Para representar el nivel de atención durante las pruebas, se utilizó una gráfica lineal para presentar una línea del tiempo donde muestra el grado de atención (relación Beta/Theta) de cada hemisferio (izquierdo y derecho). A continuación, se presentan las imágenes correspondientes a las gráficas obtenidas con base a los resultados obtenidos conforme a cada caso de estudio:




Figura 4.1. Resultado obtenido para el primer caso de estudio (positivo en déficit de atención).




Figura 4.2. Resultado obtenido para el segundo caso de estudio (negativo en déficit de atención).




Figura 4.3. Resultado obtenido para el tercer caso de estudio (déficit de atención intermedio).

4.1.6 Proceso de identificación

A continuación, se presenta el proceso realizado para la identificación del nivel de diagnóstico del TDAH utilizando el módulo desarrollado; el proceso describe los pasos relevantes para su identificación.

Inicialmente, en la Figura 4.4, se muestra el panel de uno de los sujetos que participaron en el caso de estudio. Dentro de este panel, se encuentra la información médica del paciente y un historial de pruebas realizadas (en el caso de que no fuera la primera prueba por realizarse); también se encuentra una opción para recalcular el estado de prevalencia del paciente y la opción iniciar una prueba nueva, esto último comienza pulsando sobre el botón “Iniciar prueba”.




Figura 4.4. Panel que muestra la información del paciente.

Después, se preparó la prueba iniciando con la selección de un dispositivo del catálogo de dispositivos compatibles con el módulo para la realización de esta (Figura 4.5), esta sección muestra una imagen previa del dispositivo (para identificarlo de manera más fácil), el nombre y una breve descripción del mismo. Después de seleccionar el dispositivo, se muestra información más detallada del mismo y, por último, una lista de recomendaciones previas a iniciar la prueba.




Figura 4.5. Panel para la selección del dispositivo a utilizar en la prueba.

Después de conectar el dispositivo por vía *Bluetooth*, comenzó la prueba donde se registró la actividad cerebral del paciente en tiempo real junto con otros datos durante todo el proceso de la prueba (Figura 4.6).




Figura 4.6. Panel de la realización de la prueba en tiempo real.

Después de finalizada la prueba, se contestó un breve formulario para completar la prueba. Finalmente se regresó al panel principal donde se muestra la información del usuario, y donde ahora, aparece la prueba que se realizó por última vez (Figura 4.7). También se muestra una gráfica que resume los resultados obtenidos de cada prueba realizada o por realizar.




Figura 4.7. Panel que muestra la información del paciente (actualizado).

Una vez seleccionado el reporte de interés, se visualiza la información detallada de la prueba realizada (Figura 4.8).




Figura 4.8. Panel del reporte de la prueba realizada.

Para identificar el nivel de diagnóstico del TDAH, se necesitó pulsar sobre la opción “Resultado del EEG” para que el módulo analizara el estado de atención en el EEG realizado (Figura 4.9).




Figura 4.9. Panel del reporte realizado con los resultados del EEG realizado.

Mediante este enfoque, se cumple de manera efectiva la clasificación para la identificación del TDAH utilizando dispositivos inteligentes junto con la realización de tareas que estimulan los estados de concentración y relajación de un individuo, para así informar al profesional de la salud sobre la prevalencia existente de este trastorno en el individuo y para una posterior toma de decisiones.

Es importante mencionar que el resultado obtenido por el módulo desarrollado es meramente informativo, es decir, no es definitivo; el resultado sirve como apoyo en la toma de decisiones de los profesionales de la salud, quienes son los que tienen la última palabra. El valor del resultado obtenido representa una probabilidad de la prevalencia del trastorno basado en los resultados obtenidos durante los estudios realizados, por lo que es muy importante que el profesional de la salud realice un diagnóstico completo para un mejor seguimiento. En resumen, los resultados presentados por el módulo, tienen como propósito brindar una identificación oportuna para mejorar la calidad de vida de los pacientes que padecen del TDAH.

4.1.7 Clasificación automática de los datos

La clasificación automática de los datos se basa en los resultados obtenidos por cada prueba realizada por el módulo de identificación del TDAH. Esta clasificación individual se obtiene promediando la relación al respecto entre las ondas Theta y las ondas Beta, donde dicho promedio sigue unas reglas previamente diseñadas para la detección del déficit de atención, estas reglas se presentan en la Tabla 4.6.

Atributo: “Estado de nivel de atención”

Tabla 4.6. Valores de referencia para la identificación del déficit de atención dentro del TDAH.

Tipo de dato	Rango	Resultado	Descripción
Numérico	< 0.8	Inatento	Sugiere que las ondas theta son más dominantes, lo que indica un estado de relajación o distracción.
Numérico	0.8 – 1.2	Medianamente Atento	Indica que las potencias de las ondas beta y theta son similares.
Numérico	> 1.2	Atento	Indica que la potencia de las ondas beta es dominante en comparación con las ondas theta. Esto se asocia con un estado de alerta o concentración.

Luego, para obtener una clasificación general de prevalencia del TDAH, se promedian todos los prediagnósticos obtenidos de las pruebas previamente realizadas.

4.1.8 Resultados

En la sección de resultados, presentamos el análisis de los datos obtenidos mediante una matriz de confusión (Tabla 4.7), que nos permitió evaluar el rendimiento del módulo web desarrollado para la detección del nivel de TDAH.

Tabla 4.7. Matriz de confusión para la identificación de déficit de atención dentro del TDAH.

Déficit de atención		Predicho		
		Atento	Medianamente Atento	Distraído
Real	Real Atento	3	3	0
	Real Medianamente atento	0	1	0
	Real Distraído	0	1	2

Para comprender mejor los resultados, desglosemos los elementos de la matriz:

- Los participantes que se encontraban en realidad atentos fueron clasificados correctamente como atentos en 3 ocasiones, pero también se clasificaron incorrectamente como medianamente atentos en 3 ocasiones.
- En cuanto a los participantes medianamente atentos, se clasificaron correctamente en 1 ocasión, y no se observaron clasificaciones incorrectas.
- Para los participantes distraídos, 2 de ellos se clasificaron correctamente, mientras que 1 fue clasificado incorrectamente como medianamente atento.

Cabe resaltar que en nuestro estudio participaron 10 personas, 5 con TDAH o fuerte sospecha de él y 5 sujetos de control. La matriz de confusión nos proporciona una visión clara del comportamiento del modelo y nos permite identificar áreas de mejora para incrementar la precisión de la detección del nivel de TDAH.

La evaluación del modelo para la detección de déficit de atención arrojó los siguientes resultados: una precisión (*Accuracy*) del 73%. Esto indica que el modelo fue capaz de identificar correctamente tanto casos de déficit de atención como casos sin déficit el 66% del tiempo. El valor de *Recall*, o sensibilidad, fue del 76%, en otras palabras, de todos los sujetos que realmente presentaban déficit de atención, el modelo detectó correctamente 3 de cada 4 aproximadamente. El resultado de *Precision* del modelo fue del 78%, lo que implica que, de todos los sujetos que el modelo identificó como casos de déficit de atención, aproximadamente el 78% de ellos eran clasificaciones correctas. Y finalmente, el F1-Score, fue del 73%; este valor sugiere una consistencia razonable entre la capacidad del modelo para detectar correctamente los casos de déficit de atención (*Recall*) y la exactitud con la que clasifica a los sujetos como casos positivos (*Precision*).

En resumen, el modelo mostró una alta capacidad para detectar y clasificar correctamente tanto casos de déficit de atención como de atención normal. Sin embargo, aún hay margen de mejora, especialmente en términos de precisión general (*Accuracy*).

Capítulo 5. Conclusiones

Actualmente las tecnologías de la información están cada vez más apegadas a los sectores de la salud, el uso de estas tecnologías mejora el proceso de detección de enfermedades permitiendo actuar con tiempo a los médicos para ofrecer un tratamiento adecuado a sus pacientes; hoy en día existe mucha información sobre el TDAH, sobre sus síntomas y posibles aflicciones, también de sus posibles causas, pero eso no deja de lado que su identificación sea un arduo labor por la similitud de sus síntomas con el comportamiento habitual de una persona durante la niñez; y que si no se detecta a tiempo, presenta los síntomas en la edad adulta.

En el análisis presentado en esta tesis, se muestra que existen múltiples investigaciones previas con distintas maneras para realizar un diagnóstico, unas más complejas que otras, y que requieren de la disponibilidad de aparatos cuantiosos o de difícil acceso; sin embargo, se planteó el uso de un dispositivo inteligente, de mayor accesibilidad, que permita la monitorización de la actividad de una persona y así ofrecer un diagnóstico.

Con la problemática descrita y con el objetivo de ofrecer una herramienta que permita determinar si una persona padece o no de este trastorno, se logró el proceso de identificación del nivel del TDAH mediante el desarrollo de un módulo con la capacidad de analizar el comportamiento de distintos biomarcadores para otorgar una identificación del nivel de prevalencia del trastorno utilizando técnicas de inteligencia artificial, logrando así cumplir con el objetivo principal de la presente tesis. Se analizó un conjunto de herramientas de desarrollo con el fin de encontrar las herramientas que mejor se adaptasen a la solución de la problemática, finalmente se optó que en lenguaje TypeScript bajo el marco de trabajo Angular y de Python bajo el marco de trabajo FastAPI, complementado con el uso de MySQL y el aprendizaje automático, fueron las herramientas que mejor se adaptaron al desarrollo de la solución.

La tesis presentada contribuyó significativamente a la sociedad al desarrollar una herramienta que facilita la detección temprana del TDAH en un grupo específico de individuos. Esta herramienta no solo aborda la prevalencia de TDAH, sino que

también tiene el potencial de mejorar la calidad de vida de aquellos que viven con este trastorno. Al proporcionar un medio más eficiente y accesible para el diagnóstico, este trabajo facilitó intervenciones oportunas y efectivas, llevando a mejores resultados a largo plazo para los afectados.

5.1 Recomendaciones

Como recomendaciones, se sugieren las siguientes áreas de mejora y posibles líneas de trabajo futuro que podrían optimizar y expandir el proyecto de detección del nivel de TDAH con técnicas de inteligencia artificial:

Integración con otros Dispositivos *Wearables* con capacidad de leer la actividad cerebral: Una posible evolución del proyecto es la integración de funcionalidad con más de un dispositivo *wearable* como *Emotiv EEG Headsets* o *NeuroSky MindWave*. Esto permitirá recolectar datos directamente relacionados con las funciones cerebrales de los usuarios, brindando información más precisa y relevante para el diagnóstico del TDAH. La diversidad de dispositivos vestibles facilita la adaptación del sistema a las necesidades y preferencias de los usuarios.

Exploración de Nuevos Conjuntos de Datos: Otra recomendación es buscar o disponer de nuevos conjuntos de datos que permitan mejorar el entrenamiento del modelo de inteligencia artificial. Un conjunto de datos más extenso y variado contribuiría a la obtención de diagnósticos más precisos y confiables.


Desarrollo de Aplicación Móvil: Finalmente, se propone la conversión de la aplicación web en una aplicación móvil. Este cambio aprovecha de manera más eficiente la capacidad del hardware de los dispositivos móviles o de escritorio y superar las limitaciones impuestas por los recursos del navegador. Asimismo, una aplicación móvil ofrece una experiencia más accesible y conveniente para los usuarios, al utilizar el sistema en cualquier momento y lugar.

Estas recomendaciones se enfocan en expandir el alcance del proyecto, asegurando que el módulo desarrollado sea más preciso, versátil y accesible para los usuarios que buscan obtener un diagnóstico certero sobre la prevalencia del TDAH.

Productos académicos

Artículo científico

Como parte importante del desarrollo de este trabajo de tesis, se realizó la escritura y publicación de los siguientes artículos académicos.



I. Santarrosa López, G. Alor Hernández, M. Bustos López, L. N. Sánchez Morales, y J. L. Sánchez Cervantes, “Análisis Comparativo de Técnicas de Aprendizaje Automático y Aprendizaje Profundo para la Detección de TDAH”, *Research in Computing Science*, vol. 152(8), núm. ISSN 1870-4069, pp. 21–34, may 2023.

Presentado en: XV Congreso Mexicano De Inteligencia Artificial, COMIA 2023.

Artículo científico

Como resultado de las pruebas realizadas en el Centro Psicológico Infanto – Juvenil CREE-CIMIENTOS, se emitió una carta de usuario que respalda de forma oficial la efectividad y viabilidad del proyecto desarrollado, y demuestra el valor de la colaboración interdisciplinaria en la investigación científica. Agradezco sinceramente a CREE-CIMIENTOS por su apoyo y confianza en mi trabajo.



cree-cimientos
CENTRO PSICOLÓGICO INFANTO JUVENIL

Centro Psicológico del Desarrollo Infantil "CREE CIMIENTOS"

Asunto Carta de usuario
H.Córdoba,Ver., a 14 de febrero del 2024

Ismael Santarrosa López
Giner Alor Hernández
Maritza Bustos López
José Luis Sánchez Cervantes
Laura Nely Sánchez Morales
Jonathan Hernández Capistran
TecNM/Instituto Tecnológico de Orizaba

A quién corresponda

Por medio de la presente, me dirijo a usted con un cordial saludo, al tiempo que expreso el interés del **Centro Psicológico Infanto Juvenil Cree-cimientos** en la implementación del sistema de desarrollo tecnológico denominado **"Identificación del nivel de diagnóstico de TDAH mediante técnicas de inteligencia artificial"**. El propósito fundamental de este sistema es emplear técnicas avanzadas de inteligencia artificial para facilitar la identificación temprana del Trastorno por Déficit de Atención e Hiperactividad (TDAH) en pacientes pediátricos.

Este sistema, diseñado específicamente para profesionales de la salud, ha sido implementado con éxito en el entorno de **Cree-cimientos**, contribuyendo de manera significativa al proceso de identificación de la prevalencia del TDAH en niños. Sus funcionalidades principales se centran en:

- **Apoyo a la Identificación Temprana del TDAH:** Proporciona a los especialistas herramientas avanzadas para la detección precoz de posibles casos de TDAH, permitiendo intervenciones tempranas y personalizadas.
- **Seguimiento de los pacientes:** Facilita un seguimiento detallado de la evolución de los pacientes a lo largo del tiempo, lo que mejora la gestión de la información y la toma de decisiones clínicas.

Av. 15 calles 35 y 37 Col. Marquez Hoyos. Córdoba,Ver. cidi.cree-cimientos@outlook.es 271 730 80 42


Durante su implementación, el sistema ha demostrado su eficacia en la identificación precisa de niveles de diagnóstico del TDAH, brindando un valioso recurso a nuestros especialistas de la salud. Los beneficios observados incluyen:

- Mejora en la eficiencia del proceso de identificación del TDAH.
- Facilitación del seguimiento y análisis histórico de los resultados de los pacientes.
- Identificación de áreas de mejora para futuros desarrollos tecnológicos en el ámbito médico.

Con el deseo de fortalecer la colaboración entre nuestra institución y los desarrolladores de este sistema tecnológico, confiamos en que esta herramienta seguirá apoyando el valioso trabajo de nuestros profesionales de la salud y contribuirá al avance de soluciones tecnológicas en el ámbito del diagnóstico del TDAH.

Quedamos a su disposición para cualquier consulta adicional y agradecemos la oportunidad de haber participado en este proyecto innovador.

Atentamente



Psic. Montserrat Malpica Méndez
Directora y psicóloga
CED.PROF. 09290097
Centro Psicológico del Desarrollo Infantil Cree cimientos



Av. 15 calles 35 y 37 Col.
Marquez Hoyos, Córdoba, Ver.



cidi.cree-cimientos@outlook.es



271 730 80 42

Derechos de autor

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES:	ALOR HERNÁNDEZ GINER BUSTOS LÓPEZ MARITZA HERNÁNDEZ CAPISTRAN JONATHAN SÁNCHEZ CERVANTES JOSÉ LUIS SÁNCHEZ MORALES LAURA NELY SANTARROSA LÓPEZ ISMAEL
TÍTULO:	MÓDULO DE SOFTWARE PARA LA IDENTIFICACIÓN DEL NIVEL DE DIAGNÓSTICO DE TDAH MEDIANTE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO
RAMA:	PROGRAMAS DE COMPUTACION
TITULAR:	SECRETARÍA DE EDUCACIÓN PÚBLICA - TECNOLÓGICO NACIONAL DE MÉXICO(CON FUND. EN EL ART 83 DE LA L.F.D.A. EN RELACION CON EL ART. 46 DEL R.L.F.D.A.)

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

El presente certificado se expide con fundamento en el Decreto por el que se reforman, adicionan y derogan diversas disposiciones de la Ley Orgánica de la Administración Pública Federal, así como de otras leyes para crear la Secretaría de Cultura, publicado el 17 de diciembre de 2015 en el Diario Oficial de la Federación; artículos 26 y 41 Bis, fracción XVIII de la Ley Orgánica de la Administración Pública Federal; artículos 2, 208, 209 fracción III de la Ley Federal del Derecho de Autor; artículo 69-C de la Ley Federal de Procedimiento Administrativo, de aplicación supletoria de acuerdo con lo establecido por la Ley Federal del Derecho de Autor en su artículo 10; artículo 84 de la Ley General de Mejora Regulatoria; artículos 2, apartado B, fracción IV, 26 y 27 del Reglamento Interior de la Secretaría de Cultura; artículos 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I, 9, 16 y 17 del Reglamento Interior del Instituto Nacional del Derecho de Autor; ACUERDO por el que se establecen los Lineamientos para el uso de la Firma Electrónica Avanzada en los actos y actuaciones de los servidores públicos del Instituto Nacional del Derecho de Autor, publicado en el Diario Oficial de la Federación el 19 de mayo del año dos mil veintiuno; y Acuerdo por el que se establecen las reglas para la presentación, substanciación y resolución de las solicitudes de registro de obras, fonogramas, videogramas y edición de libros en línea ante el Instituto Nacional del Derecho de Autor, publicado el 8 de diciembre de 2021 en el Diario Oficial de la Federación.

1/2



CULTURA
SECRETARÍA DE CULTURA



INDAUTOR
INSTITUTO NACIONAL DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

El presente documento electrónico ha sido firmado mediante el uso de la firma electrónica avanzada por el servidor público competente, amparada por un certificado digital vigente a la fecha de su elaboración, y es válido de conformidad con lo dispuesto en los artículos 7 y 9, fracción I, de la Ley de Firma Electrónica Avanzada y artículo 12 de su Reglamento.

Número de Registro: 03-2024-013008123300-01

Ciudad de México, a 30 de enero de 2024

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESÚS PARETS GÓMEZ



NIVpZ8fnyaz4501PG1tMQr4uUjICW0MA0OyHXa1k8rTIAjxHwC+GqRmRt3+EcVRWx4bySR4fbDRwoiZXkiO/
L6Voc0reKxW6ER1dXTxP+yiNOIP6gUUBz6GEw132Zifa61Uhea3ow76b4enDUnZxCpZd++MzN+KG7W6q2a
CJ6/XIbMuxpE6TqQvP8fX3i3+f805eeLi+vPaozJdRpLyGOZy1JonxRyaLTi9Y3iay7G1dRORHuz4btrHTyDDymk
/0CHEIQc4cE/Is49Js7JsqObhrqhY3ZZCUZmMLPrEQXfsdJApRk3Sfxd6rXmVDFd0QcArtiz115Z3VetmX3g==

2/2



CULTURA
SECRETARÍA DE CULTURA



INDAUTOR
INSTITUTO NACIONAL DEL DERECHO DE AUTOR

Bibliografía

- [1] Asociación Americana de Psiquiatría (APA), *Manual diagnóstico y estadístico de los trastornos mentales (DSM-5®)*, 5a ed. Arlington, VA: Editorial Médica Panamericana, 2014. Accessed: Nov. 09, 2023. [Online]. Available: <https://www.federaciocatalanatdah.org/wp-content/uploads/2018/12/dsm5-manualdiagnosticoyestadisticodelostrastornosmentales-161006005112.pdf>
- [2] F. Rusca-Jordán and C. Cortez-Vergara, "Trastorno por déficit de atención con hiperactividad (TDAH) en niños y adolescentes. Una revisión clínica.," *Rev Neuropsiquiatr*, vol. 83, no. 3, pp. 148–156, Oct. 2020, doi: 10.20453/rnp.v83i3.3794.
- [3] L. J. Llanos Lizcano, D. J. García Ruiz, H. J. González Torres, and P. Puentes Roza, "Trastorno por déficit de atención e hiperactividad (TDAH) en niños escolarizados de 6 a 17 años," *Pediatría Atención Primaria*, vol. 21, pp. 101–108, Dec. 2019.
- [4] K. Strimbu and J. A. Tavel, "What are biomarkers?," *Curr Opin HIV AIDS*, vol. 5, no. 6, pp. 463–466, Nov. 2010, doi: 10.1097/COH.0b013e32833ed177.
- [5] R. Pino Díez, A. Gómez Gómez, and N. de Abajo Martínez, *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*, 1st ed., vol. 1. Universidad de Oviedo, 2001.
- [6] M. J. Vidal Ledo, A. Madruga González, and D. Valdés Santiago, "Artificial intelligence in medical teaching," *Educación Médica Superior*, vol. 33, no. 3, Sep. 2019.
- [7] L. Rouhiainen, "Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro," 1st ed., vol. 1, Barcelona: Editorial Planeta, 2018.
- [8] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Comput Sci*, vol. 2, no. 3, p. 160, May 2021, doi: 10.1007/s42979-021-00592-x.
- [9] W. Yu, T. Liu, R. Valdez, M. Gwinn, and M. J. Khoury, "Application of support vector machine modeling for prediction of common diseases: the case of diabetes and pre-diabetes," *BMC Med Inform Decis Mak*, vol. 10, no. 1, p. 16, Dec. 2010, doi: 10.1186/1472-6947-10-16.
- [10] D. Jakhar and I. Kaur, "Artificial intelligence, machine learning and deep learning: definitions and differences," *Clin Exp Dermatol*, vol. 45, no. 1, pp. 131–132, Jan. 2020, doi: 10.1111/ced.14029.

- [11] I. H. Sarker, "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions," *SN Comput Sci*, vol. 2, no. 6, p. 420, Nov. 2021, doi: 10.1007/s42979-021-00815-1.
- [12] S. Murugesan, "Web Application Development: Challenges And The Role Of Web Engineering," in *Human-Computer Interaction Series*, 2008, pp. 7–32. doi: 10.1007/978-1-84628-923-1_2.
- [13] Microsoft, "What is JavaScript?," TypeScript for the New Programmer. Accessed: Oct. 19, 2023. [Online]. Available: <https://www.typescriptlang.org/docs/handbook/typescript-from-scratch.html>
- [14] Python Software Foundation, "¿Qué es Python?," <https://docs.python.org/es/3/faq/general.html#what-is-python>.
- [15] Scikit-Learn, "Scikit-Learn," Machine Learning in Python. Accessed: Oct. 19, 2023. [Online]. Available: <https://scikit-learn.org/stable/>
- [16] Interaxon Inc., "Muse Band." Accessed: Oct. 29, 2023. [Online]. Available: <https://choosemuse.com/>
- [17] Mendi.io, "Mendi." Accessed: Oct. 29, 2023. [Online]. Available: <https://www.mendi.io/>
- [18] K. Zhu, "Analysis of Techniques for Data Mining," in *The 2nd European Symposium on Computer and Communications*, New York, NY, USA: ACM, Apr. 2021, pp. 38–41. doi: 10.1145/3478301.3478308.
- [19] V. Januzaj, "Data mining meets system modelling," in *Proceedings of the 21st ACM/IEEE International Conference on Model Driven Engineering Languages and Systems: Companion Proceedings*, New York, NY, USA: ACM, Oct. 2018, pp. 55–56. doi: 10.1145/3270112.3270133.
- [20] A. Kautzky *et al.*, "Machine learning classification of ADHD and HC by multimodal serotonergic data," *Transl Psychiatry*, vol. 10, no. 1, Dec. 2020, doi: 10.1038/s41398-020-0781-2.
- [21] OMS, "Salud mental del adolescente," Centro de prensa. Accessed: Feb. 10, 2023. [Online]. Available: <https://www.who.int/es/news-room/fact-sheets/detail/adolescent-mental-health>
- [22] Centers for Disease Control and Prevention, "Trastorno por Déficit de Atención e Hiperactividad (TDAH)."
- [23] Bo Miao and Yulin Zhang, *A Feature Selection Method for Classification of ADHD*, 4th ed. 4th International Conference on Information, Cybernetics and Computational Social Systems (ICCSS), 2017. doi: 10.1109/ICCSS.2017.8091376.

- [24] M. Á. Bautista *et al.*, “A Gesture Recognition System for Detecting Behavioral Patterns of ADHD,” *IEEE Trans Cybern*, vol. 46, no. 1, pp. 136–147, Oct. 2014, doi: 10.1109/TCYB.2015.2396635.
- [25] S. Itani, F. Lecron, and P. Fortemps, “A multi-level classification framework for multi-site medical data: Application to the ADHD-200 collection,” *Expert Syst Appl*, vol. 91, pp. 36–45, Jan. 2018, doi: 10.1016/j.eswa.2017.08.044.
- [26] S. Khanna and W. Das, “A Novel Application for the Efficient and Accessible Diagnosis of ADHD Using Machine Learning (Extended Abstract),” in *2020 IEEE / ITU International Conference on Artificial Intelligence for Good, AI4G 2020*, Institute of Electrical and Electronics Engineers Inc., Sep. 2020, pp. 51–54. doi: 10.1109/AI4G50087.2020.9311012.
- [27] M. Uluyagmur-Ozturk *et al.*, “ADHD and ASD Classification Based on Emotion Recognition Data,” in *15th IEEE International Conference on Machine Learning and Applications (ICMLA)*, Institute of Electrical and Electronics Engineers (IEEE), Feb. 2017, pp. 810–813. doi: 10.1109/icmla.2016.0145.
- [28] M. Mengi and D. Malhotra, “Artificial Intelligence Based Techniques for the Detection of Socio-Behavioral Disorders: A Systematic Review,” *Archives of Computational Methods in Engineering*. Springer Science and Business Media B.V., 2021. doi: 10.1007/s11831-021-09682-8.
- [29] D. Kuang and L. He, “Classification on ADHD with deep learning,” in *Proceedings - 2014 International Conference on Cloud Computing and Big Data, CCBBD 2014*, Institute of Electrical and Electronics Engineers Inc., Mar. 2014, pp. 27–32. doi: 10.1109/CCBD.2014.42.
- [30] L. Shao, D. Zhang, H. Du, and D. Fu, “Deep forest in ADHD data classification,” *IEEE Access*, vol. 7, pp. 137913–137919, 2019, doi: 10.1109/ACCESS.2019.2941515.
- [31] J. Anuradha, Tisha, V. Ramachandran, K. V. Arulalan, and B. K. Tripathy, “Diagnosis of ADHD using SVM algorithm,” in *COMPUTE 2010 - The 3rd Annual ACM Bangalore Conference*, 2010. doi: 10.1145/1754288.1754317.
- [32] K. Arthi and A. Tamilarasi, “A HYBRID MODEL IN PREDICTION OF ADHD USING ARTIFICIAL NEURAL NETWORKS,” *International Journal of Information Technology*, vol. 2, no. 1, pp. 209–215, Jan. 2009.
- [33] S. A. Hicks *et al.*, “HYPERAKTIV: An Activity Dataset from Adult Patients with Attention-Deficit/Hyperactivity Disorder (ADHD),” *Association for Computing Machinery (ACM)*, Jun. 2021, pp. 314–319. doi: 10.1145/3458305.3478454.

- [34] K.-C. Chu, H.-J. Huang, and Y.-S. Huang, "Machine Learning Approach for Distinction of ADHD and OSA," *Journal of Data Processing*, vol. 6, pp. 1–9, 2016, doi: 10.1038/s41398-020-0781-2.
- [35] M. Maniruzzaman, J. Shin, and M. A. M. Hasan, "Predicting Children with ADHD Using Behavioral Activity: A Machine Learning Analysis," *Applied Sciences (Switzerland)*, vol. 12, no. 5, Mar. 2022, doi: 10.3390/app12052737.
- [36] Z. Mao *et al.*, "Spatio-temporal deep learning method for ADHD fMRI classification," *Inf Sci (N Y)*, vol. 499, pp. 1–11, Oct. 2019, doi: 10.1016/j.ins.2019.05.043.
- [37] N. Mohammadhasani, H. Fardanesh, J. Hatami, N. Mozayani, and R. A. Fabio, "The pedagogical agent enhances mathematics learning in ADHD students," *Educ Inf Technol (Dordr)*, vol. 23, no. 6, pp. 2299–2308, Nov. 2018, doi: 10.1007/s10639-018-9710-x.
- [38] H. Christiansen *et al.*, "Use of machine learning to classify adult ADHD and other conditions based on the Conners' Adult ADHD Rating Scales," *Sci Rep*, vol. 10, no. 1, Dec. 2020, doi: 10.1038/s41598-020-75868-y.
- [39] V. Khullar, K. Salgotra, H. P. Singh, and D. P. Sharma, "Deep Learning-Based Binary Classification of ADHD Using Resting State MR Images," *Augmented Human Research*, vol. 6, no. 1, p. 5, Dec. 2021, doi: 10.1007/s41133-020-00042-y.
- [40] M. Tosun, "Effects of spectral features of EEG signals recorded with different channels and recording statuses on ADHD classification with deep learning," *Phys Eng Sci Med*, vol. 44, no. 3, pp. 693–702, Sep. 2021, doi: 10.1007/s13246-021-01018-x.
- [41] A. Shoeibi *et al.*, "Automatic diagnosis of schizophrenia and attention deficit hyperactivity disorder in rs-fMRI modality using convolutional autoencoder model and interval type-2 fuzzy regression," *Cogn Neurodyn*, Nov. 2022, doi: 10.1007/s11571-022-09897-w.
- [42] S. K. Khare, N. B. Gaikwad, and V. Bajaj, "VHERS: A Novel Variational Mode Decomposition and Hilbert Transform-Based EEG Rhythm Separation for Automatic ADHD Detection," *IEEE Trans Instrum Meas*, vol. 71, pp. 1–10, 2022, doi: 10.1109/TIM.2022.3204076.
- [43] H. W. Loh, C. P. Ooi, P. D. Barua, E. E. Palmer, F. Molinari, and U. R. Acharya, "Automated detection of ADHD: Current trends and future perspective," *Comput Biol Med*, vol. 146, p. 105525, Jul. 2022, doi: 10.1016/j.combiomed.2022.105525.

- [44] A. Kaur and K. S. Kahlon, "Accurate Identification of ADHD among Adults Using Real-Time Activity Data," *Brain Sci*, vol. 12, no. 7, p. 831, Jun. 2022, doi: 10.3390/brainsci12070831.
- [45] C. Park *et al.*, "Machine Learning-Based Aggression Detection in Children with ADHD Using Sensor-Based Physical Activity Monitoring," *Sensors*, vol. 23, no. 10, p. 4949, May 2023, doi: 10.3390/s23104949.
- [46] A. García, J. M. González, and A. D. Palomino, "Detection of the level of attention in children with ADHD through brain waves and corporal posture1," *Journal of Intelligent & Fuzzy Systems*, vol. 42, no. 5, pp. 4531–4540, Mar. 2022, doi: 10.3233/JIFS-219242.
- [47] J. Franganillo, "Html5: el nuevo estándar básico de la Web," *ThinKEPI*, vol. 5, pp. 261–265, Oct. 2011.
- [48] AngularJS, "What Is AngularJS?," <https://docs.angularjs.org/guide/introduction>.
- [49] FastAPI, "FastAPI," FastAPI Framework. Accessed: Oct. 20, 2023. [Online]. Available: <https://fastapi.tiangolo.com/>
- [50] Microsoft, "VS Code - Overview," <https://code.visualstudio.com/docs>.
- [51] A. T. Norman, "Definiciones: inteligencia artificial vs. Aprendizaje automático vs redes neurales," in *Aprendizaje automático en acción*, Litres, 2019.
- [52] Oracle, "What is MySQL?," <https://www.oracle.com/mysql/what-is-mysql/>.
- [53] D. Wells, "Extreme Programming: A gentle introduction," <http://www.extremeprogramming.org/>.
- [54] S. A. Hicks *et al.*, "HYPERAKTIV," in *Proceedings of the 12th ACM Multimedia Systems Conference*, New York, NY, USA: ACM, Jun. 2021, pp. 314–319. doi: 10.1145/3458305.3478454.
- [55] N. Nichols, "ADHD200." Accessed: Feb. 14, 2023. [Online]. Available: <https://data.world/nicholsn/adhd-200>
- [56] L. Zou, J. Zheng, C. Miao, M. J. Mckeown, and Z. J. Wang, "3D CNN Based Automatic Diagnosis of Attention Deficit Hyperactivity Disorder Using Functional and Structural MRI," *IEEE Access*, vol. 5, pp. 23626–23636, 2017, doi: 10.1109/ACCESS.2017.2762703.
- [57] J. R. Booth *et al.*, "Working Memory and Reward in Children with and without Attention Deficit Hyperactivity Disorder (ADHD).," OpenNeuro. Accessed: Feb. 14, 2023. [Online]. Available: <https://openneuro.org/datasets/ds002424/versions/1.1.1>

- [58] M. N. Lytle, R. Hammer, and J. R. Booth, "A neuroimaging dataset on working memory and reward processing in children with and without ADHD," *Data Brief*, vol. 31, p. 105801, Aug. 2020, doi: 10.1016/j.dib.2020.105801.
- [59] J. R. Booth *et al.*, "Working Memory and Reward in Adults," OpenNeuro. Accessed: Feb. 14, 2023. [Online]. Available: <https://openneuro.org/datasets/ds002687/versions/1.2.0>
- [60] R. Hammer, G. E. Cooke, M. A. Stein, and J. R. Booth, "Functional neuroimaging of visuospatial working memory tasks enables accurate detection of attention deficit and hyperactivity disorder," *Neuroimage Clin*, vol. 9, pp. 244–252, 2015, doi: 10.1016/j.nicl.2015.08.015.
- [61] R. Hammer, M. Tennekoon, G. E. Cooke, J. Gayda, M. A. Stein, and J. R. Booth, "Feedback associated with expectation for larger-reward improves visuospatial working memory performances in children with ADHD," *Dev Cogn Neurosci*, vol. 14, pp. 38–49, Aug. 2015, doi: 10.1016/j.dcn.2015.06.002.
- [62] A. M. Nasrabadi, A. Allahverdy, M. Samavati, and M. Reza Mohammadi, "EEG DATA FOR ADHD / CONTROL CHILDREN," IEEE DataPort. Accessed: Feb. 14, 2023. [Online]. Available: <https://ieee-dataport.org/open-access/eeg-data-adhd-control-children>
- [63] M. R. Mohammadi, A. Khaleghi, A. M. Nasrabadi, S. Rafieivand, M. Begol, and H. Zarafshan, "EEG classification of ADHD and normal children using non-linear features and neural network," *Biomed Eng Lett*, vol. 6, no. 2, pp. 66–73, May 2016, doi: 10.1007/s13534-016-0218-2.