

Universidad Autónoma de Zacatecas

“Francisco García Salinas”

Unidad Académica de Ingeniería Eléctrica



Procesamiento de lecturas de actividad motriz para el desarrollo de un modelo de clasificación de pacientes con depresión y personas sanas.

Carlos Humberto Espino Salinas

**Tesis para obtener el grado de
Maestro en Ciencias del Procesamiento de la Información**

**Con orientación en
Inteligencia Artificial**

Zacatecas, Zacatecas, 18 de Mayo de 2021



SOMOS
ARTE, CIENCIA Y
DESARROLLO
CULTURAL



Zacatecas, Zac., 18 de Mayo de 2021.

C. Carlos Humberto Espino Salina
Estudiante de la MCPI
PRESENTE

At'n: Dr. Huizilopoztli Luna García
Responsable de la MCPI

Nos es grato comunicarle que después de haber sometido a revisión académica la propuesta de Tesis titulada "Procesamiento de lecturas de actividad motriz para el desarrollo de un modelo de clasificación de pacientes con depresión y personas sanas", presentada por el estudiante Ing. Carlos Humberto Espino Salinas y habiendo efectuado todas las correcciones indicadas por este Comité Tutorial, se **AUTORIZA** el documento de tesis para su impresión.

Sin más por el momento reciban un cordial saludo.

COMITÉ TUTORIAL
PROCESAMIENTO Y ANÁLISIS DE DATOS

Dr. Carlos Eric Galván Tejada

Dr. Gamaliel Moreno Chávez

Dr. Oscar Gerardo Ibarra
Manzano

Dr. Enrique García Ceja

Dr. Hamurabi Gamboa Rosales

c.c.p. *Interesado.*

c.c.p. *Responsable de la Maestría en Ciencias del Procesamiento de la Información.*



SOMOS
ARTE CIENCIA Y
DESARROLLO
CULTURAL

**COORDINACIÓN DE
INVESTIGACIÓN Y POSGRADO**

Dr. Huizilopoztli Luna-García
Responsable de la MCPI – UAZ
Presente

Por medio de la presente se hace llegar a usted el resultado del análisis de similitudes del documento:

Procesamiento de lecturas de actividad motriz para el desarrollo de un modelo de clasificación de pacientes con depresión y personas sanas de Carlos Humberto Espino Salas
Mismo que tras haber sido pasado por el software iThenticate de Turnitin salió con un

20% de similitud

De acuerdo al documento hecho llegar a ustedes. Porcentaje que se considera **ACEPTABLE** de acuerdo a los estándares internacionales.

Sin más por el momento aprovecho para enviar un cordial saludo.

ATENTAMENTE

Zacatecas, Zac. a 17 de mayo de 2021

Dr. Carlos Francisco Bautista Capetillo
Coordinador de Investigación y Posgrado
Universidad Autónoma de Zacatecas



Universidad Autónoma de Zacatecas
Unidad Académica de Ingeniería Eléctrica



En la ciudad de Zacatecas, México el día 06 del mes de mayo del año 2021, el que suscribe **Carlos Humberto Espino Salinas** egresado de la **Maestría en Ciencias del Procesamiento de la Información**, con número de matrícula **25600416**, manifiesto que es el autor intelectual del presente trabajo de tesis bajo la dirección del **Dr. Carlos Eric Galván Tejada** y cede los derechos del trabajo titulado **Procesamiento de Lecturas de Actividad Motriz para el Desarrollo de un Modelo de Clasificación de Pacientes con Depresión y Personas Sanas** el cual certifico es trabajo original y que no ha sido previamente publicado, a la **Universidad Autónoma de Zacatecas** para su difusión, con fines académicos y de investigación.

La cesión es por el total de la propiedad, a partir del día de la fecha consignada en la presente Carta de Cesión de derechos. Dicha Cesión se enmarca en una donación voluntaria.

Carlos Humberto Espino

Nombre y firma del autor



Agradecimientos Especiales.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) le agradezco la beca recibida durante la Maestría en Ciencias del Procesamiento de la Información, así como los múltiples apoyos para la presentación de los artículos: Depression Episodes Detection: A Neural Net and Deep Neural Net Comparison, Tiempos Determinantes Para la Clasificación de Personas con Depresión Utilizando Algoritmos Genéticos, BookSense an Application for Mental Disorders Diagnosis: A Case Study for User Evaluation and Redesign y Predicción de la Escala Montgomery-Asberg de Personas con Depresión Utilizando la Actividad Motriz y Técnicas de Aprendizaje Automático Supervisado en congresos internacionales así como el financiamiento para la formación de maestros y doctores durante la investigación.

Universidad Autónoma de Zacatecas

“Francisco García Salinas”

Unidad Académica de Ingeniería Eléctrica

Procesamiento de lecturas de actividad motriz para el desarrollo de un modelo de clasificación de pacientes con depresión y personas sanas.

Carlos Humberto Espino Salinas

**Tesis para obtener el grado de
Maestro en Ciencias del Procesamiento de la Información**

**Con orientación en
Inteligencia Artificial**

Asesor:

Dr. Carlos E. Galván Tejada

Coasesores:

Dr. Gamaliel Moreno Chávez

Dr. Enrique García Ceja

Zacatecas, Zacatecas, 18 de Mayo del 2021

Agradecimiento

Agradezco principalmente el inmenso e incondicional apoyo de mi mamá, que siempre está a mi lado en cualquier situación respaldando cada decisión que tomo, por formar parte de cada proceso de mi vida, por ser pilar fundamental en mi crecimiento académico y profesional, por enseñarme a ser mejor persona cada día. Muchas gracias por todo madre, jamás me alcanzara la vida para pagarte todo lo que has hecho por mí.

También le agradezco a mis asesores y maestros el Dr. Carlos Eric Galván, Dr. Gamaliel Moreno Chávez, Dr. Hamurabi Gamboa Rosales, Dr. Huizilopoztli Luna García, Dr. Jorge Issac Galván Tejada y el Dr. José María Celaya Padilla por todo el apoyo y enseñanzas a lo largo de la maestría, sin ustedes esto jamás hubiera sido posible.

Agradezco a mis amigos que formaron parte de este proceso directa o indirectamente, en especial a Ivan Hernandez Gonzalez y Marcela García Barrios que siempre han estado ahí como mis segundos padres.

También a mis amigos de Fresnillo, Zacatecas que laboran en la Empacadora de Carnes de Fresnillo en especial a Francisco Flores, Carlos Godoy y Margarita Areas que no me dieron la espalda al iniciar este nuevo reto para mi carrera profesional.

Y por último, pero no menos importante a Jessica Rodriguez y Mariela Moreno que con sus sarcasmos, insultos y ocurrencias le dieron un respiro a mi estrés académico.

Gracias de antemano, los llevare siempre en mi corazón.

Dedicatoria

A mi querida y hermosa María Fernanda Sánchez Montoya por darme la motivación necesaria para iniciar la maestría. Te dedico este trabajo con todo mi cariño y amor, por haber estado en todo este proceso y hacerme saber que lo único que se necesita para mejorar en esta vida es dedicación, actitud, perseverancia, trabajo y mucho empeño.

Resumen

La depresión es un trastorno mental que puede volverse crónico y obstaculiza significativamente el rendimiento de la vida diaria. En su forma más grave, puede llevar al suicidio. Las mediciones de actividad motriz se han convertido en un tema emergente en el campo de la salud mental. Varios estudios utilizan sensores para medir los movimientos de los pacientes a lo largo del tiempo para ayudar al diagnóstico. El objetivo es desarrollar un modelo basado en algunas técnicas de aprendizaje automático y algoritmos genéticos, con el fin de clasificar pacientes con depresión y personas sanas utilizando la actividad motriz. Se seleccionaron las lecturas de 55 pacientes (32 pacientes control y 23 pacientes con la afección), durante el periodo de una semana obteniendo un total de 385 observaciones (participantes) y 1440 características (intervalos de tiempo) de las cuales se extrajeron los intervalos de un minuto más representativos para desarrollar un modelo de aprendizaje automático utilizando algoritmos como: redes neuronales, regresión logística, bosques aleatorios, máquinas de soporte vectorial y redes neuronales profundas donde estas últimas obtuvieron el mejor desempeño con un 80.24 % de precisión, fue entrenada con 270 observaciones y fue puesta a prueba con el 30 % de datos restante de los cuales 61 fueron clasificadas como sanas y 32 con depresión de forma correctas. En base a estos resultados, se puede concluir que la implementación de estos modelos en alguna herramienta de diagnóstico asistido puede ayudar evitar casos de depresión severa.

Palabras clave: Depresión, Diagnostico, Actividad motriz, Redes neuronales Profundas, Aprendizaje automático, Depresión dataset.

Abstract

Depression is a mental disorder that can become chronic and significantly hamper the performance of daily life. In its most serious form, it can lead to suicide. Motor activity measurements have become an emerging topic in the field of mental health. Several studies use sensors to measure movements of patients over time to create a diagnosis. The aim is to develop a model based on some machine learning techniques and genetic algorithms, to classify patients with depression and healthy people using motor activity. Readings of 55 patients (32 control patients and 23 patients with condition) were selected, during period of one week, obtaining a total of 385 observations (participants) and 1440 characteristics (time intervals) from which the intervals of one minute more representative to develop a machine learning model using algorithms such as: neural networks, logistic regression, random forests, vector support machines and deep neural networks where the latter obtained the best performance with 80.24% precision, it was trained with 270 of participants and was tested with remaining 30% of data, which 61 were correctly diagnosed as healthy and 32 with depression. Based on these results, it can be concluded that the implementation of these models in an assisted diagnostic tool can help avoid cases of severe depression.

Keywords: Depression, Diagnosis, Motor activity, Deep neural networks, Machine learning, Depression dataset.

Índice General

Agradecimiento	i
Dedicatoria	ii
Resumen	iii
Abstract	iv
Índice General	v
Índice de Figuras	vii
Índice de Tablas	viii
Capítulo 1. Introducción	9
1.1. Planteamiento del problema de investigación.....	13
1.2. Justificación.....	14
1.3. Preguntas de investigación.....	16
1.4. Hipótesis	17
1.5. Objetivo General	17
Objetivos específicos.....	17
1.6. Estructura de la tesis	18
Capítulo 2. Marco teórico y de referencia	19
2.1. Trabajo relacionado.....	20
2.2. Salud Mental	24
Determinantes de la salud mental	25
Promoción y protección de la salud mental.....	25
Atención y tratamiento de trastornos de salud y mental.....	26
2.3. Depresión.....	27
Tipos y síntomas	27
Factores contribuyentes y prevención	28
Diagnóstico y tratamiento	29
2.4. Base de datos de la actividad motriz	30
2.5. Participantes.....	30
2.6. Aprendizaje automático	32
2.7. Modelo o esquema general de investigación	34

Capítulo 3. Método y propuesta de investigación	36
3.1. Obtención de los datos.....	36
3.2. Pre-procesamiento de los datos	37
3.3. Selección de características	41
3.4. Análisis de clasificación.....	45
Redes neuronales artificiales.....	46
Redes neuronales profundas.....	50
Regresión logística	53
Arboles de decisión	54
Máquinas de soporte vectorial	55
3.5. Validación.....	56
Capítulo 4. Resultados y discusión.....	60
4.1. Aplicación de algoritmos genéticos.....	60
4.2. Análisis y procesamiento de los intervalos de tiempo extraídos.....	61
4.3. Comparación de los algoritmos de aprendizaje automático aplicados	62
4.4. Análisis y procesamiento de todos lo intervalos de tiempo seleccionados.....	65
4.5. Comparación de resultados con trabajos relacionados.....	66
Capítulo 5. Conclusiones	71
5.1. Objetivos alcanzados	72
5.2. Hipótesis/Preposiciones demostradas.....	73
5.3. Contribuciones de la investigación	74
5.4. Trabajos Publicados	76
Referencias	77

Índice de Figuras

Figura 1 Medición Actividad motriz	31
Figura 2 Mapa de calor de los niveles de actividad motriz	32
Figura 3 Esquema general de investigación propuesto.....	35
Figura 4 Grafico para verificar la ausencia de campos vacíos	40
Figura 5 Esquema del proceso de los algoritmos genéticos	43
Figura 6 Ranking de aparición de genes.....	44
Figura 7 Modelos usando selección hacia adelante	45
Figura 8 Representación de las partes de una neurona biológica.....	47
Figura 9 modelo simplificado creado por McCulloch y Pitts	48
Figura 10 Esquema de la red neuronal implementada.....	49
Figura 11 Árbol de decisión	55
Figura 12 Representación siempre de una MSV.....	56
Figura 13 Curva ROC para medir el desempeño de una red neuronal artificial.....	57
Figura 14 Estructura de la matriz de confusión	59
Figura 15 Curvas ROC y área bajo la curva de cada modelo generado.....	59
Figura 16 Curvas ROC obtenidas en el trabajo de Galván-Tejada.....	63

Índice de Tablas

Tabla 1 Tabla estadística de los registros del actigraph.....	32
Tabla 2 Resultados obtenidos de cada modelo generado	62
Tabla 3 Tabla comparativa del desempeño de los algoritmos con las características extraídas.....	63
Tabla 4 Matriz de confusión de la RNP.....	64
Tabla 5 Tabla comparativa del desempeño de los algoritmos implementados con todos los intervalos de tiempo.....	66
Tabla 6 Resultados de rendimiento obtenidos en el trabajo de Frogner et al.....	66
Tabla 7 Resultados de rendimiento obtenidos en el trabajo de García Ceja et al	67
Tabla 8 Resultados de clasificación del trabajo de Petter Jakobsen et al.	70
Tabla 9 Resultados de clasificación utilizando intervalos de tiempo clave como características.....	70

Capítulo 1. Introducción

La salud mental abarca una amplia gama de actividades directa o indirectamente relacionadas con el componente de bienestar mental incluido en la definición de salud que da la Organización Mundial de la Salud: <<un estado de completo bienestar físico, mental y social, y no solamente la ausencia de afecciones o enfermedades>>. La depresión es un trastorno mental frecuente, que se caracteriza por la presencia de tristeza, pérdida de interés o placer, sentimientos de culpa o falta de autoestima, trastornos del sueño o del apetito, sensación de cansancio y falta de concentración. La depresión puede llegar a hacerse crónica o recurrente y dificultar sensiblemente el desempeño en el trabajo o la escuela y la capacidad para afrontar la vida diaria. En su forma más grave, puede conducir al suicidio. Si es leve, se puede tratar sin necesidad de medicamentos y psicoterapia profesional. Alrededor de 800,000 personas a nivel mundial se suicidan cada año, y el suicidio es la segunda causa de muerte entre las personas de 15 a 29 años [1]. La depresión contribuye de manera significativa a la carga global de enfermedad [2]. Es una de las principales causas de discapacidad y se estima que afecta a 350 millones de personas en el mundo, con prevalencias que oscilan entre 3.3 y el 21.4 % [3]. Este trastorno generalmente comienza en edades tempranas, reduce sustancialmente el funcionamiento de las personas, es un padecimiento recurrente y tiene importantes costos económicos y

sociales por ello que la depresión se encuentra entre los primeros lugares de la lista de enfermedades incapacitantes y se ha convertido en un objetivo prioritario de atención de todo el mundo [4].

Trastornos mentales como la depresión está asociado con los ritmos biológicos interrumpidos causados por perturbaciones ambientales como el cambio estacional a la luz del día, la alteración de los ritmos sociales debido, por ejemplo, a los turnos de trabajo o los viajes largos; además de estar relacionado con estilos de vida con ritmos diurnos inconscientes con el ciclo natural de la luz del día. La aparición de síntomas depresivos se relaciona además con problemas de salud física, efectos secundarios médicos, eventos de la vida y factores sociales, además del abuso del alcohol y sustancias, y dichos factores también podrían causar síntomas de depresión en todos los humanos. La prevalencia global de depresión en la vida es aproximadamente del 15%, pero la incidencia de episodios con un nivel de gravedad que no cumple con los requisitos para un diagnóstico depresivo es mucho más frecuente [5].

Enfoques alternativos para detectar objetivamente la depresión podrían ser el registro de frecuencia cardíaca [6] y grabación de voz [7]. Sin embargo, estos métodos apenas se estudian en la depresión, probablemente porque la recopilación de dichos datos es una tarea más complicada y desafiante que usar un simple actígrafo para la muñeca para acumular datos de actividad motriz.

La escala de calificación de depresión de *Montgomery-Asberg* (MADRS) se utiliza para calificar la gravedad actual de una depresión en curso [8]. Los médicos califican diez elementos relevantes para la depresión según la observación y la conversación con el paciente, y el puntaje de suma (0-60) indica la gravedad de la depresión. Las puntuaciones

inferiores a 10 se clasifican como ausencia de síntomas depresivos [9], y las puntuaciones superiores a 30 indican un estado depresivo grave [10]. Desafortunadamente, el método de evaluación psiquiátrica actual requiere un gran esfuerzo por parte de los médicos para reunir información completa sobre los pacientes. Además, depende en gran medida del esfuerzo de los pacientes para cooperar en la comunicación de sus síntomas y problemas. Por lo tanto, se necesita un mecanismo de detección objetivo basado en señales, biológicas y de comportamiento para mejorar el método de diagnóstico actual [11].

Las mediciones de actividad motriz se han convertido en un tema emergente en el campo de la salud mental. Varios estudios utilizan sensores para medir los movimientos de los pacientes a lo largo del tiempo para crear un diagnóstico o auto informes [12], [13]. Como se puede ver fácilmente, estos datos también tienen potencial para aplicaciones de aprendizaje automático que se utilizan cada vez más en el contexto de la psiquiatría y la psicología [14]–[16]. Se considera también un método objetivo para el estudio de esquizofrenia y depresión mayor [17].

Trabajos de investigación abordan diferentes enfoques y ciertas técnicas de aprendizaje automático supervisado para crear un modelo capaz de, clasificar a pacientes con depresión, como el presentado en el artículo “Clasificación de la depresión basada en la actividad motriz en pacientes unipolares y bipolares” donde se comparan dos enfoques diferentes de aprendizaje automático para clasificar, bosques aleatorios y redes neuronales profundas. Los resultados generales mostraron que los datos del sensor contienen información que se puede utilizar para determinar el estado de depresión de una persona [18]. También existen métodos que han sido utilizados para el desarrollo de modelos de clasificación conocidos como algoritmos genéticos, los cuales son procedimientos de

búsqueda que se basan en el principio de evolución de selección natural, emulando este proceso usando mecanismos como la sobrevivencia del subconjunto de variables más efectivas, mutación y cruce para mejorar las combinaciones. De esta manera, los algoritmos genéticos computacionales generan una serie de cromosomas, que se forman con variables medidas que sobreviven a procesos de evolución de generaciones que se van creando artificialmente. Los cromosomas que sobreviven finalmente son modelos formados por una o múltiples variables que sobrevivieron durante las generaciones pasadas, basándose en una función de costo que determina su aporte al cromosoma final [19].

Estos son ejemplos de algunos métodos de clasificación utilizando herramientas de aprendizaje automático las cuales se utilizan ampliamente para el estudio de diferentes trastornos mentales, así también se han propuesto sistemas capaces de dar un diagnóstico aproximado acerca de si una persona padece algún trastorno mental que hoy en día resultan ser una herramienta muy útil para la prevención de este tipo de enfermedades como la depresión y que debido a la delicadeza con la que se tratan estos padecimientos es imprescindible saber cómo abordar este tipo de padecimientos. Con base a esta descripción de problemas el presente estudio pretende analizar y procesar las lecturas de actividad motriz de pacientes con depresión (condición) y sin depresión (control). Teniendo como contribución el desarrollo de un modelo de clasificación partiendo de un pre-procesamiento basado en normalización de los datos, verificación de ausencia de campos vacíos y algoritmos genéticos para la selección de características más representativas que hagan más eficiente la aplicación de las diferentes técnicas de aprendizaje automático, que ofrezcan un mayor o similar grado de exactitud que utilizar todo el conjunto de datos ofrecido por la base de datos de depresión que contiene registros de actividad motriz de 23 pacientes deprimidos unipolares y bipolares y 32 controles sanos.

1.1. Planteamiento del problema de investigación

La depresión es un trastorno mental grave con síntomas característicos como tristeza, sensación de vacío, ansiedad y trastornos del sueño, así como pérdida general de iniciativa e interés en las actividades. Además, características como el sentimiento de culpa o inutilidad, energía reducida, problemas de concentración, tendencias suicidas y síntomas psicóticos pueden estar presentes. La gravedad de una depresión está determinada por la cantidad de síntomas, su gravedad y duración, así como las consecuencias sobre la función social y ocupacional. Las depresiones también son comunes en el trastorno bipolar, otro trastorno psiquiátrico grave. La principal diferencia entre la depresión unipolar y el trastorno bipolar es la aparición periódica de manía en este último, un estado asociado con autoestima inflada, impulsividad, mayor actividad, sueño reducido y acciones dirigidas a objetivos, ambas enfermedades son trastornos genéticos y pueden entenderse como una vulnerabilidad genética. La prevalencia global de la vida de la depresión es aproximadamente del 15% pero la incidencia de episodios con un nivel de gravedad que no cumple con los requisitos para un diagnóstico depresivo mucho más frecuente [17]. También se puede experimentar depresión recurrente durante diversas etapas de la vida e incluso puede convertirse en una enfermedad crónica. La distimia, o trastorno depresivo persistente, es uno de los niveles más avanzados de esta enfermedad, y se cree que está profundamente relacionado con factores genéticos. Igual que, como ahora sabemos, el trastorno depresivo mayor.

Otro de los problemas más grandes para tratar la depresión es el estigma que rodea a las enfermedades psiquiátricas. Los enfermos mentales deben enfrentar no solo las complicaciones de su padecimiento, también sufren de marginación social, económica y

laboral, además de lidiar con la falta de apoyo en el entorno social y familiar. La idea general de que los padecimientos mentales son menores o que pueden curarse con solo desearlo, con “echarle ganas”, es a menudo una fuente más de estrés y frustración para muchos.

También es bien sabido que en algunos casos los pacientes con síntomas de depresión tienden a mentir al momento de que el personal médico especializado lo evalúa mediante la observación y conversación, donde califica diez elementos relevantes para determinar la gravedad del trastorno mental esto represente el mayor problema dentro del ámbito clínico y la razón por la que se busca otras posibles vías para tratar esta afección como es la generación de un modelo matemático objetivo, no invasivo y confiable capaz de diagnosticar estados depresivos a tiempo.

1.2. Justificación

La depresión es una de las principales causas de discapacidad en el mundo que incluye países en vías de desarrollo como México, contribuye de forma muy importante a la carga general de morbilidad, según la OMS. Las grabaciones actigráficas de la actividad motriz se consideran un método objetivo para observar la depresión, aunque este tema está lejos de ser exhaustivamente estudiado en la investigación psiquiátrica ya que estos estudios se pueden ver afectados por la disponibilidad de los pacientes, servicios de salud y política de cada región. El desarrollo de estos estudios se realiza con el fin de mejorar la calidad de vida de las personas, además de generar modelos de clasificación que permitan ayudar a identificar de manera oportuna un estado de depresión grave que pueda terminar en una situación de suicidio.

Las enfermedades mentales como la depresión son un desafío ya que son enfermedades que se pueden tratar si se identifican de manera temprana, esto ha permitido el desarrollo de instrumentos para el diagnóstico de esta enfermedad. Por estudios sabemos que los genes aportan alrededor del 40% del riesgo y el otro 60% proviene del ambiente y, afortunadamente, el medio ambiente puede ser modificado ya sea a escala gubernamental, con políticas públicas, pero también a niveles más cercanos, en el lugar de trabajo, en lo familiar y lo individual. Si se pudiera hacer más cosas, habría que reducir la pobreza, la drogadicción, asegurarse de que hay buenas escuelas y atender la salud física. Se debe tener en cuenta que la depresión no siempre es un problema menor, puede haber casos tan severos en términos de su impacto sobre el individuo como en cualquier otro desorden psiquiátrico. Por lo tanto, debido a la dificultad que se presenta para tratar la depresión, se han presentado investigaciones que implementan algoritmos basados en aprendizaje automático e inteligencia artificial donde se usan modelos de clasificación o predicción para identificar a un paciente con depresión y uno sano de manera oportuna, con el fin de poder realizar un diagnóstico preventivo que permita evitar el desarrollo de esta enfermedad a un estado más grave.

En el presente trabajo se propone el análisis y procesamiento de las lecturas de actividad motriz de 23 pacientes deprimidos unipolares y bipolares y 32 controles en un lapso de una semana a través de algoritmos genéticos y de diferentes técnicas de aprendizaje automático, con el fin de determinar cuáles son los tiempos que presentan información significativa para la clasificación de pacientes y de esta manera generar un modelo que ayude al diagnóstico de esta enfermedad de manera eficiente. A través de este proceso se pretende vincular el área de la psicología y el área tecnológica, presentando un modelo que pueda ser implementado en dispositivos que en su conjunto se conviertan en

una herramienta preliminar que pueda ser utilizada por los especialistas con aplicación en la mejora de la salud mental de la población ofreciendo un diagnóstico a través de este tipo de modelos de clasificación basados en el aprendizaje automático.

1.3. Preguntas de investigación

- ¿Qué tan confiable es la aplicación de algoritmos genéticos como método de selección de características para el análisis y procesamiento de los datos de actividad motriz?
- ¿Cuál es el intervalo de tiempo obtenido de los datos de actividad motriz de episodios de depresión en pacientes unipolares y bipolares que presentan información relevante para clasificar a pacientes?
- ¿Cómo se valida que el modelo desarrollado contiene los intervalos de tiempo que aporta la información más significativa para la clasificación de pacientes control y pacientes condición?
- ¿Cuál es el algoritmo basado en aprendizaje automático que permite crear el mejor modelo para la clasificación de pacientes?
- ¿Cómo ayudan los algoritmos genéticos en la aplicación de técnicas de aprendizaje automático para un modelo de clasificación de pacientes?

1.4. Hipótesis

El desarrollo de un modelo de clasificación implementado inicialmente algoritmos genéticos para reducir el número de características obtenidas de Depresión: una base de datos de actividad motriz de episodios de depresión en pacientes unipolares y bipolares, aplicando diferentes técnicas de aprendizaje automático permite clasificar pacientes con presencia de depresión con un grado de aceptación considerable.

1.5. Objetivo General

Desarrollar un modelo basado en algunas técnicas de aprendizaje automático y algoritmos genéticos, con el fin de clasificar pacientes con depresión y personas sanas, utilizando los datos de la actividad motriz obtenida de: una base de datos de actividad motriz de episodios de depresión en pacientes unipolares y bipolares.

Objetivos específicos

- Implementar algoritmos genéticos como método de selección de características que permitan generar un modelo de clasificación de pacientes.
- Determinar dentro de la base de datos de actividad motriz de pacientes con depresión y participantes sanos cual es el intervalo de tiempo que presenta información relevante para el desarrollo de modelos basados en aprendizaje automático.

- Validar que el modelo desarrollado contiene los intervalos de tiempo que aportan la información significativa en la clasificación de pacientes control y pacientes condición.
- Comparar los diferentes algoritmos de aprendizaje automático aplicados para generar un modelo de clasificación de pacientes con presencia de depresión o de pacientes sanos, con el fin de identificar el de mejor desempeño.
- Validar que aplicando algoritmos genéticos ayudan en el trabajo de modelado basado en técnicas de aprendizaje automático para la clasificación de pacientes con depresión y pacientes control.

1.6. Estructura de la tesis

La estructura de la tesis con la que se organiza el presente trabajo de investigación es el siguiente:

Capítulo 2 Detalla artículos relacionados a esta investigación y que se han desarrollado a lo largo de la misma, además de presentar una descripción amplia de los temas teóricos y de referencia que fueron empleados para asentar las bases de esta tesis.

Capítulo 3 Descripción de la metodología propuesta para la realización de esta tesis, analizando de manera detallada la obtención de los datos, el pre-procesamiento, la selección de características, el análisis de clasificación y la validación.

Capítulo 4 Resultados obtenidos de los planteamientos realizados para alcanzar los objetivos establecidos, además de demostrar la hipótesis generada en esta tesis.

Capítulo 5 Principales conclusiones y objetivos alcanzados a través de los resultados derivados de esta investigación.

Capítulo 2. Marco teórico y de referencia

Para comprender los estudios realizados acerca de la depresión, las herramientas que se han utilizado para el diagnóstico, tratamiento y pronóstico, además de los factores que influyen para este padecimiento, este capítulo se profundiza en las definiciones de estos puntos, explicando las técnicas actuales que existen en el área de la salud mental que permiten la evaluación y clasificación de los distintos niveles de depresión y con esto demostrar la necesidad de encontrar un método que combata de manera directa el aumento de casos de suicidio ocasionados por la depresión, presentando una serie de algoritmos y modelos basados en aprendizaje automático desarrollados a través del análisis y procesamiento de los datos que permiten tratar a un paciente de manera adecuada debido al problema que hasta ahora implica la disposición completa de los pacientes para dar solución a este problema.

2.1. Trabajo relacionado

Existen varios trabajos que han sido desarrollados con el fin de medir el nivel de depresión y así prevenir que llegue a un estado grave, aun así, existen obstáculos a una atención eficaz como son la falta de recursos, personal sanitario capacitado, la estigmatización de los trastornos mentales y la evaluación inexacta. Aunque el tratamiento efectivo de los pacientes deprimidos requiere seguimiento regular y monitoreo algunas investigaciones proponen nuevas formas de tratar la depresión.

En el trabajo de Frogner et al. [20] presenta un enfoque de aprendizaje automático para detectar la depresión utilizando un conjunto de datos con registros de actividad motriz de un grupo de personas con depresión y un grupo sin, es decir, el grupo de condición incluye 23 personas unipolares y bipolares, y el grupo control incluye 32 personas sin depresión. Utilizando redes neuronales convolucionales para clasificar a los pacientes deprimidos y no deprimidos. Además, se clasificaron diferentes niveles de depresión. Finalmente, se formó un modelo que predice los puntajes de la escala de depresión de Montgomery-Asberg. Se pudo concluir que la detección de depresión usando datos de actividad es definitivamente posible dentro de un entorno clínico.

También García-Ceja et al. [18] presentaron su trabajo sobre la clasificación de la depresión basada en la actividad motriz en pacientes unipolares / bipolares. Aplicaron el aprendizaje automático para clasificar a los participantes deprimidos y no deprimidos utilizando técnicas como Bosques Aleatorios y Redes Neuronales Profundas. La principal contribución es comprender mejor la asociación entre la depresión y la actividad motriz. Las conclusiones de este trabajo sugieren que la reproductibilidad y la comparabilidad de los

resultados es un factor importante de la investigación de alta calidad. En este artículo se presenta un conjunto de datos en el campo del análisis de depresión que permite la reproducibilidad y la comparabilidad, lo que lo hace único en el campo de la informática y la psicología.

Farholt-Jepsen et al. [21] presento un estudio tipo asociación sobre el trastorno bipolar. Los participantes fueron 29 pacientes bipolares, de donde los autores recopilaron diversas acciones de los teléfonos inteligentes de los pacientes, como el uso diario, la cantidad de llamadas entrantes y la cantidad de mensajes de texto enviados o recibidos, pudiendo concluir que los datos objetivos generados automáticamente sobre aspectos de las actividades conductuales recopilados con teléfonos inteligentes reflejan el nivel de síntomas depresivos, maníacos y se discriminan entre categorías. Además, estos datos objetivos generados automáticamente pueden usarse para detectar la actividad de la enfermedad en pacientes que presentan niveles moderados a severos de síntomas depresivos y maníacos.

Andrew et al. [22] aplico el aprendizaje automático a las fotos publicadas en Instagram. Tuvieron 166 participantes, que publicaron un total 43,950 fotos. Al extraer características estadísticas mediante análisis de colores, metadatos y detección de rostros, lograron modelos que superaron la tasa de éxito promedio del profesional al diagnosticar la depresión (70% de todos los casos deprimidos identificados). La investigación sobre el uso de las redes sociales en el campo de la salud mental es interesante porque, para muchos esas son las plataformas que utilizan para expresar sus sentimientos.

Por otro lado, Zanella-Calzada et al. [23] propone un método para detectar estados depresivos a través de la actividad motriz de los paciente, utilizando datos de una banda inteligente, aplicando un enfoque de extracción de características de la actividad

desarrollada por los pacientes, que permitirá el diagnóstico y tratamiento oportuno, las propuestas en esta investigación, basadas en la información de la actividad física de los pacientes, teniendo en cuenta que los sujetos depresivos tienen más probabilidades de tener movimiento motriz que los pacientes sanos. La profundización en estos aspectos puede contribuir a la prevención de esta psicopatología, así como al desarrollo de tratamientos efectivos, por lo tanto, el principal beneficio presentado en este estudio es una herramienta preliminar que puede respaldar el diagnóstico de especialistas. Saber si un paciente presenta depresión en función del nivel de actividad que tiene en un día completo a través del diagnóstico automático de los sujetos obtenidos al enviar esta información al modelo desarrollado en este trabajo de investigación, relacionando la actividad motriz total con la presencia o ausencia de depresión, que según los resultados presentados tienen una precisión significativamente alta, lo que permite reducir los falsos positivos y los falsos negativos en la detección de esta afección, mejorando así el diagnóstico de esta enfermedad.

En la investigación de Rodríguez-Ruiz et al. [24] se lleva a cabo un proceso de extracción de datos para episodios depresivos clasificados utilizando datos recopilados durante la noche, el día y las 24 horas completas. La comparación entre la clasificación utilizando diferentes datos recopilados a lo largo del tiempo da una mejor imagen de la enfermedad y el comportamiento de los pacientes con el diagnóstico. De acuerdo con los resultados obtenidos, se puede observar que, a partir de la selección de características, el mejor conjunto de características seleccionadas se obtiene de los datos que corresponden al periodo nocturno, ya que la mejor precisión se calcula al clasificar a los sujetos con estas características utilizando los niveles de actividad presentados durante la noche, que generalmente están relacionados con los sujetos que presentan depresión.

Berle et al. [25] propuso estudiar la complejidad de los patrones de actividad motriz en estos pacientes mediante el uso de la actigrafía y concluyó que la actividad motriz se redujo significativamente tanto en pacientes esquizofrénicos como deprimidos. Sin embargo, los pacientes esquizofrénicos diferían tanto de los pacientes deprimidos como de los controles, lo que demuestra patrones de actividad motriz marcados por una menor complejidad y un comportamiento más estructurado. Estos hallazgos pueden indicar que las alteraciones en la actividad motriz reflejan diferentes mecanismos fisiopatológicos en la esquizofrenia en comparación con la depresión mayor.

También en el trabajo de Petter Jakobsen et al. [26] el objetivo era investigar si las medidas objetivas de la actividad motriz pueden ayudar a la práctica diagnóstica existente, mediante la aplicación del aprendizaje automático para analizar patrones de actividad en pacientes deprimidos y controles. Utilizaron algoritmos como: Bosques Aleatorios, Redes Neuronales Profundas y Redes Neuronales Convulsionales para analizar 14 días de actividad motriz registrada en el actígrafo de 23 pacientes deprimidos y 32 controles sanos. Las características estadísticas analizadas fueron la actividad media, la desviación estándar y la proporción cero. Se aplicaron varias técnicas para manejar el desequilibrio de los datos. La red neuronal profunda combinada con la técnica de equilibrio SMOTE se obtuvo una exactitud de 0.84. Las clasificaciones erróneas parecen estar relacionadas con la superposición de datos entre las clases, por lo que propone un enfoque futuro de comparar los estados de ánimo de manera individualista.

Finalmente, Galván-Tejada et al. [27] estudia la señal generada por un acelerómetro de bandas inteligentes para detectar estados depresivos a través de la actividad de los pacientes y proponer una extracción de características (utilizando la evolución temporal y

espectral de la señal), así como una inteligente selección de características basada en un enfoque de algoritmo genético para minimizar los datos necesarios para identificar estos estados depresivos que permiten un diagnóstico no invasivo casi en tiempo real. Los resultados obtenidos en esta investigación demuestran que las características estadísticas extraídas muestran que la información que contienen proporciona una descripción de las características principales de la actividad de un día completo del paciente que permite la diferenciación entre sujetos deprimidos y no deprimidos, teniendo así un modelo de clasificación con una cantidad reducida de características permitiendo un menor costo computacional, lo que facilita el acceso a él, ya que no requiere software o hardware especializado para su implementación. Otro de los principales beneficios demostrados en este trabajo son los valores con alta precisión obtenidos a través de una metodología simple que utiliza una única fuente de datos.

2.2. Salud Mental

De acuerdo con la OMS, la salud es un estado de completo bienestar físico, mental y social, y no de solamente ausencia de afecciones o enfermedades. Una importante consecuencia de esta definición es que considera la salud mental como algo más que la ausencia de trastornos o discapacidades mentales.

La salud mental es un estado de bienestar en el que la persona realiza sus capacidades y es capaz de hacer frente al estrés normal de la vida, de trabajar de forma productiva y de contribuir a su comunidad. En este sentido positivo, la salud mental es el fundamento del bienestar individual y del funcionamiento eficaz de la comunidad. La salud mental y el bienestar son fundamentales para nuestra capacidad colectiva e individual de

pensar, manifestar sentimientos, interactuar con los demás, ganar el sustento y disfrutar de la vida. Sobre esta base se puede considerar que la promoción, la protección y el restablecimiento de la salud mental son preocupaciones vitales de las personas, las comunidades y las sociedades de todo el mundo [1].

Determinantes de la salud mental

La salud mental individual está determinada por múltiples factores sociales, psicológicos y biológicos. Por ejemplo, las presiones socioeconómicas persistentes constituyen un riesgo bien conocido para la salud mental de las personas y las comunidades. Las pruebas más evidentes están relacionadas con los indicadores de la pobreza, y en particular con el bajo nivel educativo. La mala salud mental se asocia asimismo a los cambios sociales rápidos, a las condiciones de trabajo estresantes, a la discriminación de género, a la exclusión social, a los modos de vida poco saludables, a los riesgos de violencia y mala salud física y a las violaciones de los derechos humanos. También hay factores de la personalidad y psicológicos específicos que hacen que una persona sea más vulnerable a los trastornos mentales. Por último, los trastornos mentales también tienen causas de carácter biológico, dependientes, por ejemplo, de factores genéticos o de desequilibrio bioquímicos cerebrales [1].

Promoción y protección de la salud mental

La promoción de la salud mental consiste en acciones que creen entornos y condiciones de vida que propicien la salud mental y permitan a las personas adoptar y mantener modos de vida saludables. Entre ellas hay una serie de acciones para aumentar

las posibilidades de que más personas tengan una mejor salud mental. Un ambiente de respeto y protección de los derechos civiles, políticos, socioeconómicos y culturales básicos es fundamental para la promoción de la salud mental. Sin la seguridad y la libertad que promueven estos derechos resulta difícil mantener un buen nivel de salud mental. Las políticas nacionales de salud mental no deben únicamente de los trastornos mentales, sino reconocer y abordar cuestiones más amplias que fomentan la salud mental como la incorporación de la promoción de la salud mental a las políticas y programas de los sectores gubernamental y no gubernamental. Además del sector de la salud, es esencial la participación de los sectores de la educación, el trabajo, la justicia, el transporte, el medio ambiente, la vivienda o la asistencia social [1].

Atención y tratamiento de trastornos de salud y mental

En el contexto de los esfuerzos nacionales por desarrollar y aplicar políticas relacionadas a la salud mental, es esencial, no solo proteger y promover el bienestar mental de los ciudadanos, si no también satisfacer las necesidades de las personas con trastorno de salud mental. En el último decenio he mejorado considerablemente el conocimiento de lo que hay que hacer en relación con la creciente carga de morbilidad derivada de trastornos mentales. Existe un corpus cada vez mayor de pruebas científicas que demuestran la eficiencia y la buena relación costo-eficacia de intervenciones cruciales para abordar trastornos mentales prioritarios en países con diferentes niveles de desarrollo económico. Entre las intervenciones costo eficaces, viables y accesibles se pueden mencionar:

- Tratamiento de la epilepsia con medicación antiepiléptica;
- Tratamiento de la depresión con psicoterapia y, en casos moderados y graves antidepresivos (genéricos);

- Tratamiento de la psicosis con medicamentos antipsicóticos más antiguos y apoyo psicosocial al paciente;
- Aplicación de impuestos a las bebidas alcohólicas y restricción de su disponibilidad y comercialización.

También existe una serie de medidas eficaces para prevenir el suicidio, prevenir y tratar trastornos mentales en niños, prevenir y tratar la demencia y tratar los trastornos relacionados con el consumo de sustancias. El programa de acción para superar la brecha en salud mental (mhGAP) ha elaborado directrices basadas en la evidencia para que los no especialistas puedan identificar y atender mejor una serie de trastornos mentales prioritarios [1].

2.3. Depresión

La depresión es distinta de las variaciones habituales del estado del ánimo y de las respuestas emocionales breves a los problemas de la vida cotidiana. Puede convertirse en un problema de salud serio, especialmente cuando es de larga duración e intensidad moderada a grave, y puede causar gran sufrimiento y alterar las actividades laborales, escolares y familiares. En el peor de los casos puede llevar al suicidio [1].

Tipos y síntomas

Dependiendo del número y de la intensidad de los síntomas, los episodios depresivos pueden clasificarse como leve, moderados o graves. Una distinción fundamental es la establecida entre la depresión en personas con y sin antecedentes de episodios

maníacos. Ambos tipos de depresión pueden ser crónicos y recidivantes, especialmente cuando no se tratan.

Trastorno depresivo recurrente: como su nombre indica, se caracteriza por repetidos episodios de depresión. Durante estos episodios, hay estado de ánimo deprimido, pérdida de interés y de la capacidad de disfrutar, y reducción de la energía que produce una disminución de la actividad, todo ello durante un mínimo de dos semanas. Muchas personas con depresión también padecen síntomas de ansiedad, alteraciones del sueño y del apetito, sentimientos de culpa y de baja autoestima, dificultades de concentración e incluso síntomas sin explicación médica. Dependiendo del número y de la intensidad de los síntomas, los episodios depresivos pueden clasificarse como leves, moderados o graves. Las personas con episodios depresivos leves tendrán alguna dificultad para seguir con sus actividades laborales y sociales habituales, aunque probablemente no las suspendan completamente. En cambio, durante un episodio depresivo grave es muy improbable que el paciente pueda mantener sus actividades sociales, laborales o domésticas si no es con grandes limitaciones.

Trastorno afectivo bipolar: este tipo de depresión consiste característicamente en episodios maníacos y depresivos separados por intervalos con un estado de ánimo normal. Los episodios maníacos cursan con estado de ánimo elevado o irritable, hiperactividad, logorrea, autoestima excesiva y disminución de la necesidad de dormir [1].

Factores contribuyentes y prevención

La depresión es el resultado de interacciones complejas entre factores sociales, psicológicos y biológicos. Quienes han pasado por circunstancias vitales adversas

(desempleo, luto, traumatismos psicológicos) tienen más probabilidades de sufrir depresión. A su vez, la depresión puede generar más estrés y disfunción, y empeorar la situación vital de la persona afectada y, por consiguiente, la propia depresión. Hay relaciones entre la depresión y la salud física; así, por ejemplo, las enfermedades cardiovasculares pueden producir depresión, y viceversa.

Está demostrado que los programas de prevención reducen la depresión. Entre las estrategias comunitarias eficaces para prevenirla se encuentran los programas escolares para promover un modelo de pensamiento positivo entre los niños adolescentes. Las intervenciones dirigidas a los padres y mejorar los resultados de sus hijos. Los programas de ejercicio para las personas mayores también pueden ser eficaces para prevenir la depresión [1].

Diagnóstico y tratamiento

Hay tratamientos eficaces para la depresión moderada y grave. Los profesionales sanitarios pueden ofrecer tratamientos psicológicos, como la activación conductual, la terapia cognitiva conductual y la psicoterapia interpersonal, o medicamentos antidepressivos, como los inhibidores selectivos de la recaptación de serotonina y los antidepressivos tricíclicos. Los profesionales sanitarios deben tener presentes los posibles efectos adversos de los antidepressivos, las posibilidades de llevar a cabo uno u otro tipo de intervención (por disponibilidad de conocimientos técnicos o del tratamiento en cuestión) y las preferencias individuales. Entre los diferentes tratamientos psicológicos para tener en cuenta se encuentran los tratamientos psicológicos cara a cara, individuales o en grupo, dispensados por profesionales o por terapeutas. Los tratamientos psicosociales también son eficaces en los casos de depresión leve, los antidepressivos pueden ser eficaces en la

depresión moderada a grave, pero no son el tratamiento de elección en los casos leves, y no se deben utilizar para tratar la depresión en niños ni como tratamiento de primera línea en adolescentes, en los que hay que utilizarlos con cautela [1].

2.4. Base de datos de la actividad motriz

El conjunto de datos aquí presentado se recopiló originalmente para el estudio de la actividad motriz en la esquizofrenia y la depresión mayor [25]. La actividad motriz se controló con reloj actigraph usado en la muñeca derecha (*Actiwatch, Cambridge Neurotechnology Ltd, Inglaterra, modelo AW4*). El reloj actigraph mide la actividad mediante el uso de un acelerómetro piezoeléctrico que está programado para registrar la integración de la intensidad, la cantidad y la duración del movimiento en todas las direcciones. La frecuencia de muestro es de 32 Hz y se registran movimientos superiores a 0.05 g (señal producida por encima de un threshold/limite). Se produce un voltaje correspondiente y se almacena como un recuento de actividad en la unidad de memoria del reloj actigraph. El número de conteos es proporcional a la intensidad del movimiento. Se eligió la muñeca derecha para que el procedimiento sea más conveniente para los participantes, ya que la mayoría de ellos tienen sus relojes alrededor de la muñeca izquierda, y es engorroso tener dos dispositivos en el mismo brazo. Los recuentos de actividad total se registraron continuamente en intervalos de un minuto [17].

2.5. Participantes

El conjunto de datos del reloj actigrafo fueron recopilados de 23 pacientes deprimidos unipolares y bipolares (grupo de afecciones). Cinco sujetos fueron

hospitalizados durante su período de recolección de datos y 18 fueron pacientes ambulatorios. El nivel de gravedad de la depresión en curso fue calificado por un médico en la escala de calificación de depresión de *Montgomery-Asberg* [8]. al comienzo y al final de los registros de motoractividad. Además, el conjunto de datos del reloj actigrafo contiene registros de 32 contribuyentes no deprimidos (grupo control), que consta de 23 empleados del hospital, 5 estudiantes y 4 expacientes sin síntomas psiquiátricos actuales. La **Figura 2-1** [17] presenta un gráfico de la actividad motriz del objeto de estudio a lo largo de un día.

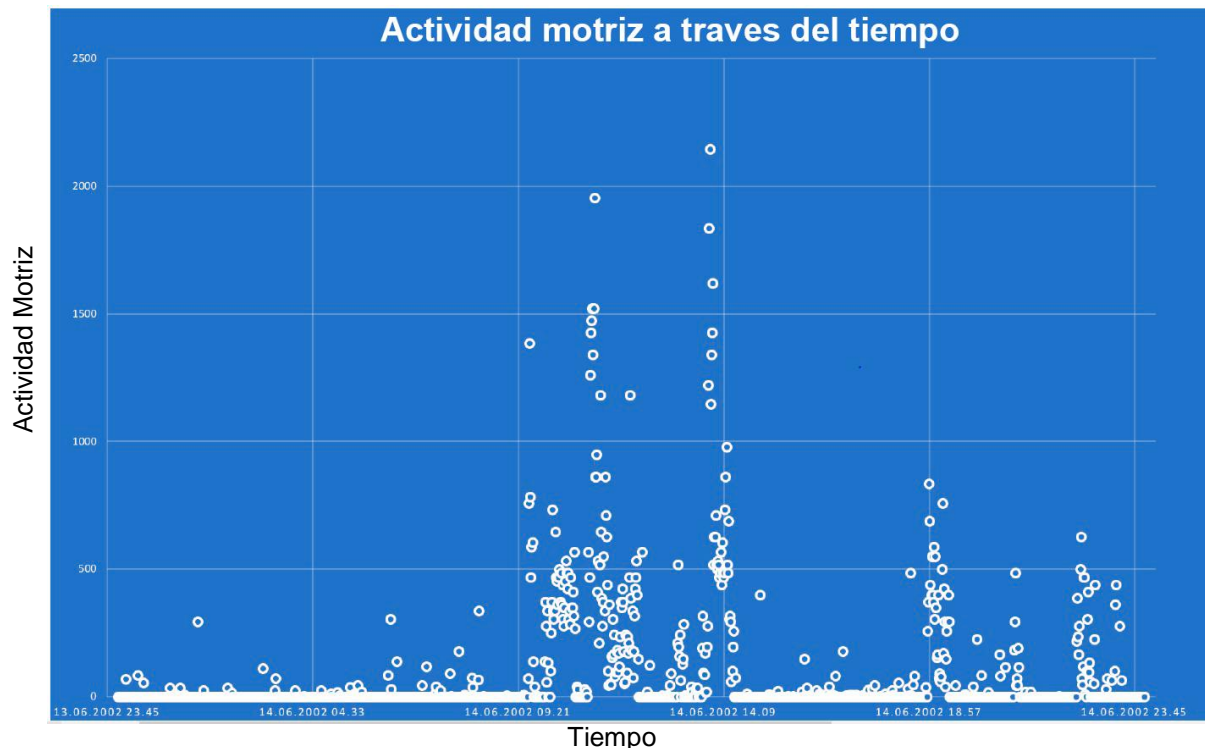


Figura 2-1.: Medición de la actividad motriz de un paciente en un lapso de 24 horas.

Los participantes del estudio utilizaron los dispositivos del reloj actigrafo durante un promedio de 12.6 días en los grupos de control y condición como lo muestra la **Tabla 1**. El número total de días recogidos fue de 693, que comprende 402 días en el grupo de control y 291 en el grupo condición.

Tabla 1. Tabla estadística del número de días registrados por el reloj actigrafo.

	Grupo Control	Grupo Condición
Media	12.6	12.6
Desviación Estándar	2.3	2.7
Máximo	20.0	18.0
Mínimo	8.0	2.0

En la **Figura 2-2** [17]. Se muestran mapas de calor del nivel de actividad promedio por día de la semana y hora del día para el grupo de control y condición, respectivamente. Los valores se normalizaron en ambos grupos para hacerlos comparables. Claramente, el grupo de condición presenta menos nivel de actividad, especialmente durante los fines de semana.

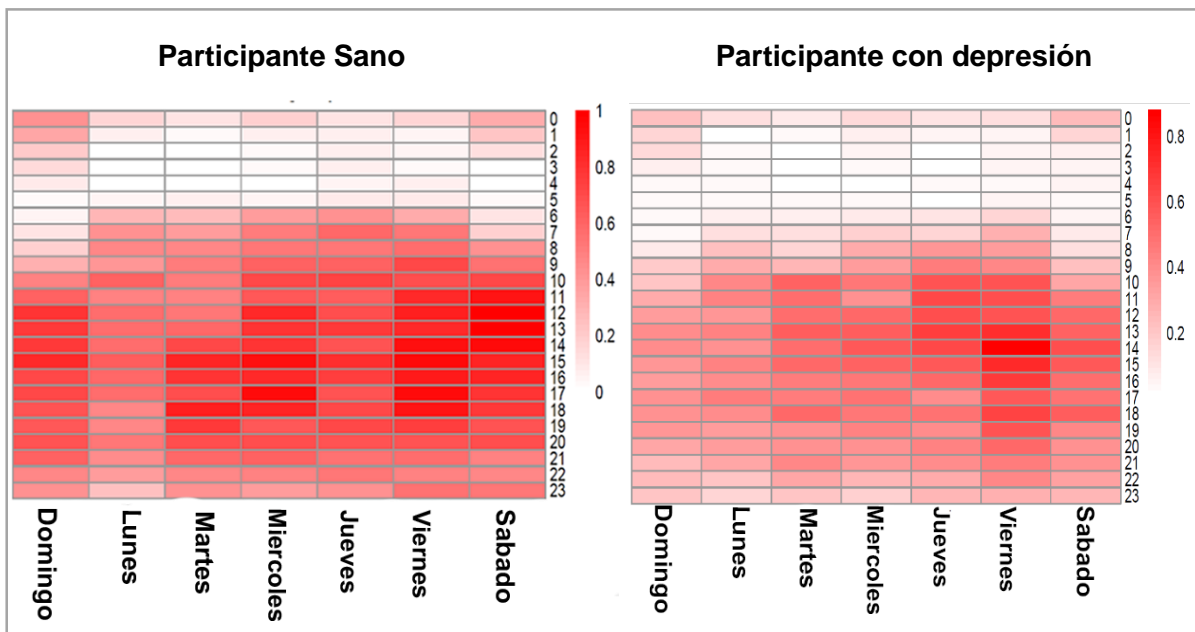


Figura 2-2.: Mapa de calor de los niveles de actividad motriz de los participantes por día de la semana y hora del día.

2.6. Aprendizaje automático

El aprendizaje automático consiste en programar computadoras para optimizar un criterio de rendimiento utilizando datos de ejemplo o experiencias pasadas. Tenemos un

modelo definido hasta algunos parámetros, y el aprendizaje es la ejecución de un programa de computadora para optimizar los parámetros del modelo utilizando los datos de entrenamiento o la experiencia pasada. El modelo puede ser predictivo para hacer predicciones en el futuro, o descriptivo para obtener conocimiento de los datos, o ambos. El aprendizaje automático utiliza la teoría de la estadística en la construcción de modelos matemáticos, porque la tarea central es hacer inferencia a partir de una muestra. Pero el aprendizaje automático no es solo un problema de base de datos también es parte de la inteligencia artificial. Para ser inteligente, un sistema que se encuentra en un entorno cambiante debe tener la capacidad de aprender. Si el sistema puede aprender y adaptarse a tales cambios, el diseñador del sistema no necesita prever y proporcionar soluciones para todas las situaciones posibles [28].

Por otro lado, Russell and Norving [29] dicen que el aprendizaje automático está relacionado con la inteligencia artificial porque un sistema inteligente debería ser capaz de adaptar los cambios en su entorno.

Existen muchas aplicaciones del aprendizaje automático como es el caso del reconocimiento de patrones en el diagnóstico médico, las entradas son la información relevante que tenemos sobre el paciente y las clases son las enfermedades. Las entradas contienen la edad, el sexo, el historial médico pasado y los síntomas actuales del paciente. Es posible que algunas pruebas no se hayan aplicado al paciente y, por lo tanto, faltarían estas entradas. Las pruebas toman tiempo, pueden ser costosas y pueden incomodar al paciente y, por que no se quieren aplicar a menos de que ofrezcan información valiosa. En el caso de un diagnóstico médico, una decisión incorrecta puede conducir a un tratamiento

incorrecto o nulo, y en caso de duda, es preferible que el clasificador rechace y difiera la decisión a un experto de la salud [28].

La técnica de aprendizaje automático que se adaptan al diagnóstico médico asistido por computadora debe tener una buena comprensión. Los métodos de aprendizaje automático para la clasificación proporcionan medios económicos para realizar el diagnóstico, el pronóstico o la detección de ciertos resultados en la investigación de la atención médica. Incluye modelos de redes neuronales como uno de los enfoques atractivos para las tareas de diagnóstico. La mayoría de los conjuntos de datos médicos son patrones no lineales y difíciles de clasificar. Por lo tanto, es necesario mejorar la clasificación mediante métodos de aprendizaje automático. Las redes neuronales artificiales parecían ser uno de los mejores enfoques en los métodos de aprendizaje automático. Las redes neuronales son construcciones de software diseñadas para imitar la forma en que el cerebro humano aprende. La red neuronal puede imitar el proceso del comportamiento humano y resolver asuntos no lineales, lo que la ha hecho ampliamente utilizada en el cálculo y la predicción de sistemas complicados, y ha logrado un efecto mapeado de no linealidad, que la forma de cálculo convencional no podría hacer [30].

2.7. Modelo o esquema general de investigación

El modelo general implementado en esta investigación se resume en 5 etapas, cada una de ellas es presentada en la **Figura 2-3**. (A) es el primer paso, indica la fuente de la cual fueron obtenidos los registros de la actividad motriz de los participantes y/o pacientes. (B) indica el pre-procesamiento, que consiste en seleccionar el tiempo que será usado para el trabajo de esta investigación, una vez establecido el tiempo verificar que no existan

campos vacíos que entorpezcan el proceso del análisis y procesamiento de la información, también se realizó un proceso de normalización de los datos de entrada. (C) La selección de características mediante el uso de algoritmos genéticos permite representar todas las variables establecidas del conjunto de datos, a partir de un número menor de variables, siendo estas las más relevantes. (D) Posteriormente, se aplican diferentes técnicas de aprendizaje automático con el fin de crear un modelo capaz de clasificar de forma autónoma a los participantes entre sanos (control) y con depresión (condición). (E) Finalmente, con el objetivo de conocer el desempeño, precisión y confiabilidad de los diferentes modelos para clasificar a los participantes se lleva a cabo un proceso de validación con diferentes métricas, como: el área bajo la curva (AUC), precisión y F1-Score.

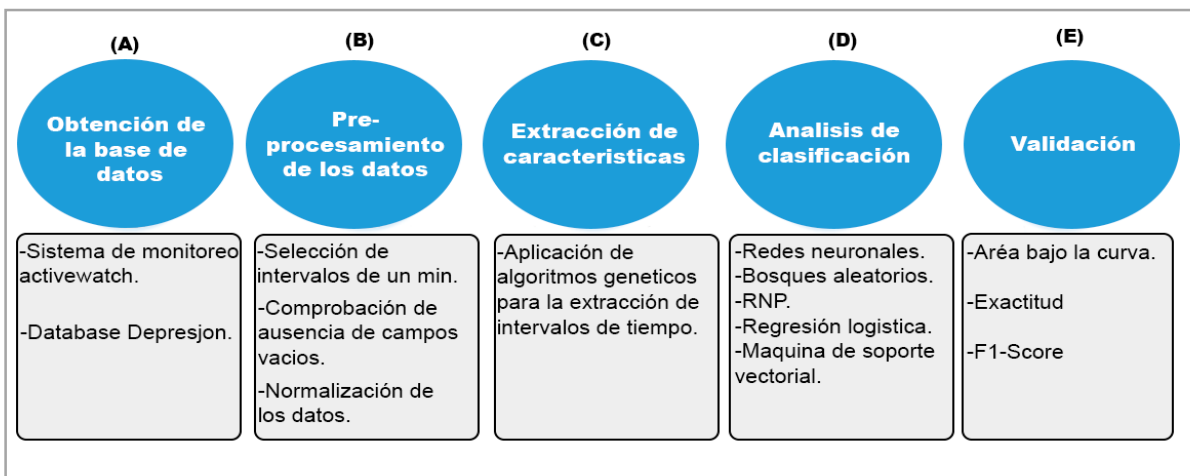


Figura 2-3.: Esquema general de investigación propuesto en este trabajo. Los círculos muestran las etapas realizadas y los paréntesis detallan los procedimientos realizados.

Capítulo 3. Método y propuesta de investigación

Esta investigación propone aplicar una serie de pasos como un método que permita generar un modelo de clasificación de pacientes entre sanos y con depresión mediante el procesamiento de datos recogidos de la actividad motriz de algunos pacientes y/o participantes, así como la aplicación de algoritmos genéticos como parte de la selección de características que optimice el tiempo de entrenamiento y pruebas dentro del análisis de clasificación en el cual se utilizan técnicas de aprendizaje automático y se aplican métricas para validar estos modelos generados.

3.1. Obtención de los datos

Los sensores portátiles que miden diferentes partes de la actividad de las personas son una tecnología común hoy en día. Los datos creados con estos dispositivos tienen mucho potencial además de medir la cantidad de pasos diarios o calorías quemadas, ya que generalmente se recopilan registros continuos de la frecuencia cardíaca y los niveles de actividad. Además, existe una creciente conciencia en el campo de la Psiquiatría sobre cómo estos datos de actividad se relacionan con varios problemas de salud mental, como cambios en el estado de ánimo, la personalidad, la incapacidad para hacer frente a los problemas diario, el estrés, la retirada de amigos y actividades [31], [32].

El número de conteos es proporcional a la intensidad del movimiento. Los recuentos de actividad total se registraron continuamente en intervalos de un minuto. El conjunto de

datos contiene lo siguiente: Dos carpetas, mientras que una contiene los datos para los controles y otra para el grupo de condiciones. Para cada paciente, se proporciona un archivo csv que contiene los datos actividad motriz recopilados a lo largo del tiempo (intervalos de un minuto), fecha (fecha de medición), actividad (medición de actividad del reloj actigrafo) [17]. Además, también proporcionan las puntuaciones de MADRS (*Montgomery and Asberg Depression Rating Scale*).

3.2. Pre-procesamiento de los datos

El pre-procesamiento de datos a menudo puede tener un impacto significativo en el rendimiento de generalización de un algoritmo de aprendizaje automático. La eliminación de instancias de ruidos es uno de los problemas más difíciles en el aprendizaje automático. Por lo general, las instancias eliminadas tienen instancias excesivamente desviadas que tienen demasiados valores de entidad nulos. Estas características excesivamente desviadas también se conocen como valores atípicos. Además, un enfoque común para hacer frente a la imposibilidad de aprender de conjuntos de datos muy grandes es seleccionar una sola muestra del conjunto de datos de gran tamaño. La falta de manejo de datos es otro problema que a menudo se trata en los pasos de preparación de datos [33].

En esta parte, el pre-procesamiento consta de tres pasos principales para evitar problemas de rendimiento, estos son: seleccionar la actividad motriz registrada de los participantes por un lapso de una semana en intervalos de un minuto, reordenarlos para identificar el número de observaciones como una relación entre participante-día, con sus respectivos datos registrados.

Esto quiere decir que se tiene una columna (C) de cada participante con un rango de tiempo de las 00:00 hasta las 23:59 (un día), cada minuto con su respectivo registro de actividad motriz, esta columna se traspone y se agrega a la primera fila de una matriz A con su respectiva salida 0 o 1 dependiendo del *dataset* donde se extrajo la información (control/condición), sucesivamente se aplica lo mismo para los días subsecuentes y participantes hasta completar una semana de información, teniendo como resultado una matriz $A=[385 \times 1441]$ incluyendo su salida, como se explica a continuación.

Dadas las columnas del participante 1 en los días 1,2,3,4,5,6,7 se tiene $C_{11}, C_{12}, C_{13}, C_{14}, C_{15}, C_{16}, C_{17}$, donde cada hora contiene 60 minutos que multiplicado por 24 que es el número de horas que tiene un día se obtiene una columna de 1440 filas que equivale a los minutos de un día, cada uno con un registro de la cantidad de actividad motriz. Esto se representa de la siguiente manera:

$$\begin{array}{l}
 \begin{array}{l}
 00:00 \\
 00:01 \\
 00:02 \\
 00:03 \\
 00:04 \\
 \vdots \\
 23:59
 \end{array}
 \begin{bmatrix}
 168 v \\
 107 v \\
 550 v \\
 157 v \\
 0 v \\
 \vdots \\
 208 v
 \end{bmatrix}
 \quad
 \begin{array}{l}
 00:00 \\
 00:01 \\
 00:02 \\
 00:03 \\
 00:04 \\
 \vdots \\
 23:59
 \end{array}
 \begin{bmatrix}
 168 v \\
 17 v \\
 560 v \\
 167 v \\
 23 v \\
 \vdots \\
 280 v
 \end{bmatrix}
 \quad
 \begin{array}{l}
 00:00 \\
 00:01 \\
 00:02 \\
 00:03 \\
 00:04 \\
 \vdots \\
 23:59
 \end{array}
 \begin{bmatrix}
 118 v \\
 157 v \\
 450 v \\
 157 v \\
 0 v \\
 \vdots \\
 305 v
 \end{bmatrix}
 \quad
 \begin{array}{l}
 00:00 \\
 00:01 \\
 00:02 \\
 00:03 \\
 00:04 \\
 \vdots \\
 23:59
 \end{array}
 \begin{bmatrix}
 148 v \\
 157 v \\
 120 v \\
 457 v \\
 121 v \\
 \vdots \\
 892 v
 \end{bmatrix}
 \\
 \\
 \begin{array}{l}
 00:00 \\
 00:01 \\
 00:02 \\
 00:03 \\
 00:04 \\
 \vdots \\
 23:59
 \end{array}
 \begin{bmatrix}
 168 v \\
 107 v \\
 550 v \\
 157 v \\
 0 v \\
 \vdots \\
 208 v
 \end{bmatrix}
 \quad
 \begin{array}{l}
 00:00 \\
 00:01 \\
 00:02 \\
 00:03 \\
 00:04 \\
 \vdots \\
 23:59
 \end{array}
 \begin{bmatrix}
 168 v \\
 17 v \\
 560 v \\
 167 v \\
 23 v \\
 \vdots \\
 280 v
 \end{bmatrix}
 \quad
 \begin{array}{l}
 00:00 \\
 00:01 \\
 00:02 \\
 00:03 \\
 00:04 \\
 \vdots \\
 23:59
 \end{array}
 \begin{bmatrix}
 118 v \\
 157 v \\
 450 v \\
 157 v \\
 0 v \\
 \vdots \\
 305 v
 \end{bmatrix}
 \end{array}$$

Estas columnas se trasponen para convertirse en un vector (V) donde cada intervalo de un minuto corresponde a una característica y cada vector se agrega a las filas de una matriz A.

$$\begin{array}{r}
 \begin{array}{cccccccc}
 00:00 & 00:01 & 00:02 & 00:03 & 00:04 & \dots & 23:59 \\
 V_{1,1} = [168 v & 107 v & 550 v & 157 v & 0 v & \dots & 208] \\
 V_{1,2} = [168 v & 17 v & 560 v & 167 v & 23 v & \dots & 280] \\
 A = V_{1,3} = [118 v & 157 v & 450 v & 157 v & 0 v & \dots & 305] \\
 V_{1,4} = [148 v & 157 v & 120 v & 457 v & 121 v & \dots & 892] \\
 \vdots \\
 V_{55,7} = [563 v & 124 v & 456 v & 321 v & 265 v & \dots & 201]
 \end{array}
 \end{array}$$

Por cada participante tanto control como condición se extrae su vector por día hasta completar los 7 días que conforman una semana, se va agregando a la matriz A al mismo tiempo que se le asigna su valor de salida y se continua con el siguiente participante hasta completar los 55 participantes que conforman la base de datos de los que se tiene registro, que multiplicado por 7 días equivale a 385 observaciones.

	Matriz de datos generada	Salida
$ A = \begin{bmatrix} C_{11}^T \\ \vdots \\ C_{17}^T \\ C_{551}^T \\ \vdots \\ C_{557}^T \end{bmatrix} = \begin{bmatrix} 0 \\ \vdots \\ 1 \\ 1 \\ \vdots \\ 0 \end{bmatrix} $	$ A = \begin{bmatrix} \text{Sujeto 1} \\ \text{Sujeto 2} \\ \text{Sujeto 3} \\ \vdots \\ \text{Sujeto 385} \end{bmatrix} \begin{bmatrix} \text{min 1} & \text{min 2} & \text{min 3} & \dots & \text{min 1440} \end{bmatrix} $	$ \begin{bmatrix} 0 \\ 1 \\ 1 \\ 1 \\ 0 \\ 0 \end{bmatrix} $

Es así como el conjunto de datos queda establecido para este trabajo, donde se permite un mejor manejo y entendimiento de la información para los procesos siguientes.

la verificación de ausencia de campos vacíos mediante la función missmap que se encuentra dentro de la Librería Amelia en lenguaje R ayuda a visualizar de forma gráfica los campos vacíos en un conjunto de datos que podrían causar problemas al analizar y procesar la información [34]. **La Figura 3-1.** Muestra un ejemplo del grafico de un conjunto de datos con ausencia de campos vacíos y otro con huecos de información.




Figura 3-1.: Grafico para verificar la ausencia de campos vacíos, del lado izquierdo un conjunto de datos sin campos vacíos y del lado derecho un conjunto de datos con un porcentaje de 4 % de campos vacíos.

Por último, la normalización de los datos de entrada sin procesar tiene un gran efecto en la preparación de la información para que sean adecuados para la capacitación. Sin esta normalización, entrenar los modelos de aprendizaje automático habría sido muy lento. Hay muchos tipos de normalización de datos. Se puede usar para escalar los datos en el mismo rango de valores para cada característica de entrada con el fin de minimizar el sesgo dentro del modelo de una característica a otra. La normalización de datos también puede acelerar el tiempo de entrenamiento para cada función dentro de la misma escala. Es especialmente útil para aplicaciones de modelado donde las entradas están generalmente en escalas muy diferentes. Las diferentes técnicas pueden usar diferentes reglas, como la regla máxima, la regla mínima, la regla de suma, la regla del producto, etc.

La normalización estadística o Z-score utiliza la media y la desviación estándar para cada característica en un conjunto de datos de entrenamiento para normalizar cada vector característica de entrada. La media y la desviación estándar se calculan para cada característica [30]. La transformación se da en la **Ecuación 1**.

$$z_i = \frac{x_i - \bar{x}}{\sigma} \quad (1)$$

El uso de la normalización estadística evita los problemas de valores atípicos, ya que maneja los valores atípicos, pero no produce datos normalizados con la misma escala exacta.

3.3. Selección de características

El objetivo principal de la selección de características es obtener los intervalos de un minuto más relevantes del conjunto seleccionado en el pre-procesamiento para la clasificación de pacientes. En el sentido matemático es evitar el sobreajuste durante el análisis de clasificación, reducir redundancia, recuperar características latentes significativas, generar mayor comprensión en el proceso de generación de los datos, así como mejorar su rendimiento, mediante la reducción de características.

Debido a la gran cantidad de minutos con los que cuenta un día durante una semana el procesamiento de estos datos resulta ser muy complejo. En este paso, GALGO, que es un paquete de software genérico que utiliza algoritmos genéticos (AG) para resolver problemas de optimización que implican la selección de un subconjunto de variables para realiza una representación esquemática de una selección de variables de dos clases (0 - control y 1 - condición), que implica la combinación de genes con los que se está trabajando

(cromosomas que representan el modelo multivariable) que permite distinguir entre clases en una función de un método de clasificación, donde hay una serie de modelos que realizan este procesamiento varias veces, con distintas combinaciones. La versión actual GALGO tiene un conjunto de herramientas para apoyar el desarrollo de modelos estadísticos a partir de conjuntos de datos muy grandes, como los datos funcionales de todo genoma.

Los AG son técnicas de búsqueda aleatoria y optimización guiadas por los principios de evolución y genética natural, que tienen una gran cantidad de paralelismo implícito. Los AG realizan búsquedas en ambientes complejos, grandes y multimodales, y brindan soluciones casi óptimas para el objetivo o la función de un problema de optimización. En los AG los parámetros del espacio de búsqueda se codifican en forma de cadenas (llamadas cromosomas). A la colección de tales cadenas se llama población. Inicialmente, se crea una población aleatoria, que representa diferentes puntos en el espacio de búsqueda. Una función de objetivo y de aptitud se asocia con cada cadena que representa el grado de bondad de la cadena. Según el principio de supervivencia del más apto, se seleccionan algunas de las cadenas y a cada una se le asigna una cantidad de copias que van al grupo de apareamiento. En estas cadenas se aplican operadores inspirados biológicamente como el cruce y la mutación para producir una nueva generación. El proceso de selección, cruce y mutación continua durante un número fijo de generaciones o hasta que se cumpla una condición de terminación [35]. Los AG tienen aplicaciones varios campos como el procesamiento de imágenes, redes neuronales, aprendizaje automático, programación de talleres, etc. [36], [37].

En esta investigación, cada minuto se considera como una característica o gen para el proceso de evolución y genética de los AG esto quiere decir que a partir de dos clases

de muestras (condición y control) busca y evoluciona, combinando los genes (cromosomas que representan un modelo multivariante) que distinguen entre clases usando el método de clasificación de regresión logística que utiliza una función sigmoide que se muestra en la **Ecuación 2**.

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

Estos modelos pueden diferir en contenido de genes, pero con una precisión de clasificación alta o similar. Los genes que aparecen varias veces en diferentes modelos sugieren que estos genes o hablando específicamente, los intervalos de un minuto son importantes para el problema de clasificación en un contexto multivariante. Por lo tanto, se calcula el número de veces (frecuencia) que aparece un gen en un modelo como se muestra en la **Figura 3-2**.

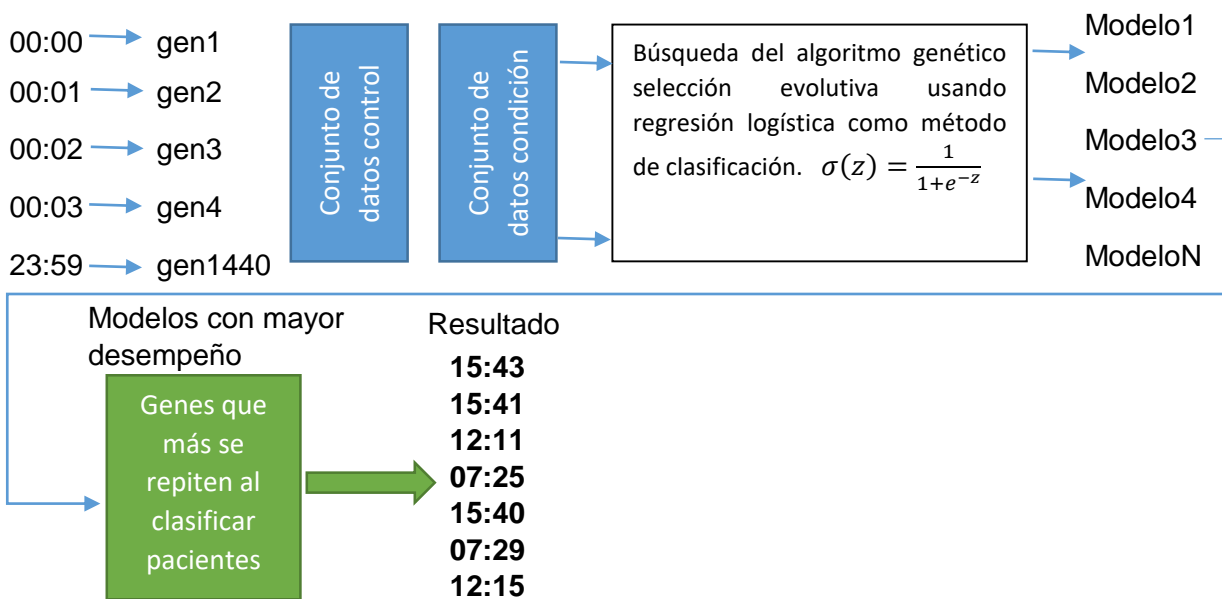


Figura 3-2.: Esquema del proceso de los algoritmos genéticos para para la selección de características más importantes para la clasificación de pacientes con depresión utilizando regresión logística.

La **Figura 3-3.** muestra un ranking de frecuencia de aparición de genes en los modelos creados previamente por los AG. Las características más relevantes a la izquierda y las menos importantes a la derecha. Los intervalos de un minuto con más estabilidad para un modelo clasificación son: 15:43, 15:41, 12:11, 07:25, 15:40, 7:29, 12:15.




Figura 3-3.: Ranking de aparición de genes (intervalos de un minuto) obtenido de los algoritmos genéticos para la generación de un modelo clasificación entre dos clases.

La **Figura 3-4.** Muestra cómo se utiliza una estrategia de selección directa para seleccionar un modelo representativo que genera el error más bajo, indicando el nivel de exactitud más alto alcanzado durante el proceso de generación de modelos para la clasificación de los objetos de estudio aplicando regresión logística, pero es importante mencionar que es posible aplicar diferentes técnicas aprendizaje automático como generadores de modelos de clasificación o predicción según sea el caso.




Figura 3-4.: Modelos usando selección hacia adelante para generar el error más bajo. El conjunto de datos utilizados inicialmente para este trabajo está conformado de 1440 características, después de la selección de estas, el número es reducido a solo 7 características que representan todo el conjunto original para el análisis de clasificación.

3.4. Análisis de clasificación

El aprendizaje automático es un conjunto de algoritmos de análisis estadísticos que mejoran continuamente la respuesta a los datos, construyendo modelos para diferentes propósitos. Dentro de la mejora del proceso, el aprendizaje automático tiende a adaptarse a modelos matemáticos en los datos. En otras palabras, los modelos analizan datos y construyen el mejor modelo a partir de un conjunto o reglas creadas a partir de patrones en los datos [38]. Los algoritmos de aprendizaje automático se pueden dividir en diferentes tipos, siendo los algoritmos supervisados y no supervisados los más comunes. Los algoritmos no supervisados se ocupan de la agrupación de datos que presentan características en común, y todos los datos no están etiquetados. Su objetivo principal es

generar etiquetas que clasifiquen los datos mediante la identificación de características útiles. Mientras que, por otro lado, los algoritmos supervisados requieren datos etiquetados para entrenar su modelo [39].

Como parte del análisis de clasificación se utilizaron algoritmos de aprendizaje automático como lo son: redes neuronales artificiales, redes neuronales profundas, regresión logística, bosques aleatorios y máquinas de soporte vectorial para generar un modelo de clasificación binario ya que los datos cuentan con dos clases posibles de salida, participante con depresión o condición (1) y participante sano o control (0).

Redes neuronales artificiales

El cerebro humano es el órgano biológico más complejo del universo y sigue siendo desconocido para nosotros. Varios países han comenzado grandes programas o alianzas sobre ciencia del cerebro. Juntos, estos proyectos de iniciativa indudablemente conducirán a grandes avances en la comprensión del funcionamiento del cerebro humano, lo que proporcionará posibles soluciones para curar enfermedades relacionadas con el cerebro. Estos proyectos también inspirarán la informática neuromórfica para satisfacer la creciente demanda de inteligencia artificial [40]. para construir una máquina que imite la capacidad de los humanos para diversas aplicaciones.

Para obtener una mejor comprensión del cerebro, se han llevado a cabo investigaciones de redes neuronales biológicas para estudiar las características biológicas, estructurales y funcionales del cerebro. Una de estas investigaciones se centra en la construcción de redes neuronales artificiales (RNA) que podrían emular las características biológicas, estructurales y funcionales de las redes neuronales biológicas. Esta categoría

utiliza modelos simplificados y controlables para probar nuevas teorías de las funciones cerebrales derivada de los datos. Las RNA también proporcionar plataformas informáticas similares al cerebro para la inteligencia artificial con mayores eficiencias [41].

Las contrapartes biológicas de las neuronas artificiales son las neuronas biológicas, que representan miles de millones de neuronas de diferentes tipos y tamaños. La **Figura 3-5.** muestra un esquema de una neurona biológica simplificada con las cuatro unidades fundamentales básicas: dendritas, axones, somas y sinapsis [41].

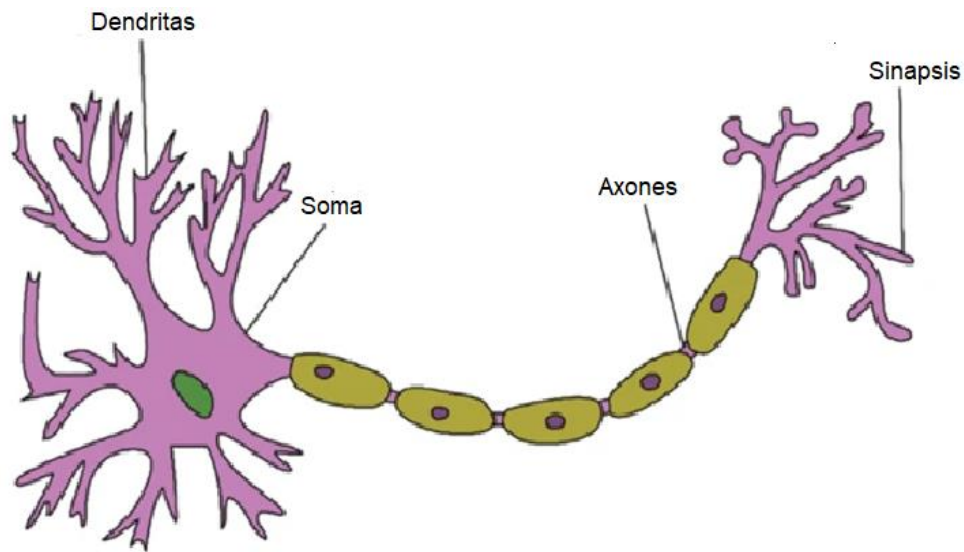


Figura 3-5.: Representación de las partes de una neurona biológica

Las RNA siguen un modelo simplificado creado por McCulloch y Pitts (1943), inspirado en las redes neuronales biológicas como se muestra en la **Figura 3-6** [42].




Figura 3-6.: Esquema matemático simplificado desarrollado por McCulloch y Pitts que emula una red neuronal biológica.

La ejecución de una tarea implica la activación paralela de una o gran cantidad de redes neuronales artificiales, una o más entradas (x) de las otras neuronas se envían a una neurona artificial y las entradas se suman para producir salidas (y) a las otras neuronas en los axones. Separado por un ponderado (w), una función no lineal conocida como función de activación o función de transferencia (f), para obtener una salida; La función de activación puede ser una función escalonada, función sigmoidea, etc. La forma matemática de una neurona artificial se muestra en la **Ecuación 3**.

$$y_j = f\left(\sum_{i=0}^n w_{ij} x_i\right) \quad (3)$$

Existen dos métodos fundamentales para realizar esta tarea. Una *feed-forward* o que se alimenta hacia adelante, tiene conexiones en una sola dirección, es decir, forma un gráfico direccionado acíclico, donde cada nodo recibe la entrada de los nodos anteriores y entrega la salida hacia los nodos posteriores, sin que existan ciclos. Una red que se

alimenta hacia adelante representa una función de su entrada actual, por lo que no tiene otro estado interno más que los mismos pesos [43]

Por otro lado, una red recurrente retroalimenta sus entradas con sus propias salidas. Esto quiere decir que los niveles de activación de la red forman un sistema dinámico que puede lograr un estado estable o exhibir un comportamiento oscilatorio o incluso caótico. Además, la respuesta de la red a una entrada dada depende de su estado inicial, el cual depende de sus entradas previas.

Para el caso de generación de un modelo de clasificación de personas con depresión se implementó un método de redes neuronales *feed-forward* como se muestra en la **Figura 3-7**.




Figura 3-7.: Esquema de la red neuronal implementada para la generación de un modelo de clasificación de pacientes con depresión.

Las redes neuronales artificiales generalmente se arreglan en capas, de las cuales cada unidad puede recibir entradas únicamente de las unidades que se encuentran en la capa anterior. Las capas que se encuentran intermedias se denominan capas ocultas en este caso se cuenta con dos capas ocultas, una de entrada que es alimentada por los datos de actividad motriz de los tiempos extraídos con anterioridad y por último una de salida que proporciona un valor binario 0 para pacientes sanos y 1 para pacientes con depresión.

Redes neuronales profundas

Con el rápido desarrollo de las técnicas de computación, las redes neuronales artificiales han proporcionado un marco poderoso con arquitecturas profundas para el aprendizaje supervisado. En términos generales, el algoritmo de aprendizaje profundo consiste en una arquitectura jerárquica con muchas capas, cada una de las cuales constituye una unidad de procesamiento de información no lineal. Las redes neuronales profundas (RNP) que representan arquitecturas profundas en redes neuronales, pueden representar funciones con mayor complejidad si se aumenta el número de capas y unidades en una sola capa. Dados suficientes conjuntos de datos de entrenamiento etiquetados y modelos adecuados, los enfoques de aprendizaje profundo pueden ayudar a los humanos a establecer funciones de mapeo para la convivencia de la operación [29].

Las redes neuronales artificiales como se mencionó antes generalmente están compuestas en capas, de las cuales cada unidad puede recibir entradas solo de las unidades encontradas en la capa anterior o puede retroalimentarse, dependiendo de la RNA. Las capas intermedias en una RNA se denominan capas ocultas, en una RNA multicapa con múltiples salidas m , el vector error en la capa de salida se puede describir

como $y - h_w(x)$ donde y es la salida esperada y $h_w(x)$ es la salida calculada; sin embargo, el error en las capas ocultas se vuelve complejo de calcular porque los datos de entrenamiento no nos permiten saber qué valor deberían tener los nodos ocultos. Este problema se resuelve con la propagación hacia atrás, donde el error se puede propagar desde la capa de salida de las capas ocultas.

Este proceso surge directamente de la derivación del gradiente de error general. En la capa de salida, la regla para actualizar los pesos para minimizar el error se calcula en la **Ecuación 4**.

$$w_i = w_i + \alpha(y - h_w(x)) \times h_w(x)(1 - h_w(x)) \times x_i \quad (4)$$

Al tener múltiples unidades de salida, Err_k es el componente kth del vector de error $y - h_w$, y el vector de error modificado es $\Delta_k = Err_k \times g'(in_k)$, por lo que la regla de actualización de peso se convierte en la **Ecuación 5**.

$$w_{j,k} = w_{j,k} + \alpha \times a_j \times \Delta_k \quad (5)$$

Para actualizar las conexiones entre las unidades de entrada y las unidades ocultas, es necesario definir una cantidad análoga al final del error para los nodos de salida. Al final del error para los nodos de salida. Esta cantidad se define con el error propagado hacia atrás, donde el nodo oculto j es responsable de una fracción del error Δ_k de cada nodo de salida al que está conectado. Los valores Δ_k luego se dividen de acuerdo con la fuerza de la conexión entre el nodo oculto y el nodo de salida y se propagan hacia atrás para proporcionar los valores Δ_j de la capa oculta. La regla de propagación para los valores Δ se calcula en la **Ecuación 6**.

$$\Delta_j = g'(in_j) \sum_k w_{j,k} \Delta_k \quad (6)$$

Ahora la regla para actualizar los pesos entre las entradas y la capa oculta se convierte en la misma que la regla de actualización para la capa de salida, y se calcula con la **Ecuación 7**.

$$w_{i,j} = w_{i,j} + \alpha \times a_i \times \Delta_j \quad (7)$$

Las redes neuronales profundas también se pueden definir como una técnica que consiste en múltiples capas que procesan la información de una manera no lineal y la transforman en una representación de un mayor nivel de complejidad y abstracción, para la extracción y transformación supervisada o no supervisada de características, y para el patrón de análisis y clasificación [29].

Para este trabajo, se creó una red neuronal profunda compuesta de 4 capas ocultas donde cada una contiene 6, 5, 4 y 3 perceptrones respectivamente cada uno con una función de activación sigmoidea. La primera capa conocida como capa de entrada se compone de los intervalos de un minuto extraídos en los algoritmos genéticos y una capa de salida con una función de activación *softmax*. Esta función en el campo de las matemáticas, especialmente en teoría de probabilidad, se considera la generalización de la función logística o sigmoidea. Se ha aplicado ampliamente en muchos campos prácticos como el aprendizaje automático [39]. Su expresión matemática está dada por la **Ecuación 8**.

$$\phi(j, T_1, \dots, T_n) = \phi_k^j = \frac{\exp(T_j/k)}{\sum_{j=1}^n \exp(T_j/k)} > 0 \quad (8)$$

Regresión logística

La regresión logística (RL) es un método estadístico similar a la regresión lineal, ya que la RL encuentra una ecuación que predice un resultado para una variable binaria, Y, a partir de una o más variables de respuesta, X. Sin embargo, a diferencia de la regresión lineal, las variables de respuesta pueden ser categóricas o continuo, ya que el modelo no requiere estrictamente datos continuos para predecir la pertenencia a un grupo. RL utiliza la razón de probabilidad de registro en lugar de las probabilidades y un método iterativo de máxima verosimilitud en lugar de mínimos cuadrados para ajustarse al modelo final. Esto significa que el investigador tiene más libertad cuando usa RL y el método puede ser más apropiado para datos distribuidos de manera no normal o cuando las muestras tienen matrices de covarianza desiguales.

La regresión logística se puede usar también para resolver problemas de clasificación. En general, el clasificador de regresión logística puede usar una combinación lineal de más de un valor de características o variable explicativa como argumento de la función sigmoide $z_i = \frac{x_i - \bar{x}}{\sigma}$. La salida correspondiente de la función sigmoidea es un número entre 0 y 1. El valor medio se considera como umbral para establecer lo que pertenece a la clase 1 y la clase 0. En particular, una entrada produce un resultado mayor que 0.5 se considera pertenecer a la clase 1. Por lo contrario, si la salida es menor que 0.5, la entrada correspondiente se clasifica como perteneciente a la clase 0 [44]. Como se ha mencionado anteriormente la clase 1 pertenece al grupo de participantes con depresión y la clase 0 como participantes sanos para este trabajo de investigación.

Arboles de decisión

Un árbol de decisión es un clasificador expresado como una partición recursiva del espacio de instancia. El árbol de decisión consta de nodos que forman un árbol enraizado, lo que significa que es un árbol dirigido con un nodo llamado “raíz” que no tiene bordes entrantes. Todos los demás nodos tienen exactamente un borde entrante. Un nodo con bordes salientes se denomina nodo interno o de prueba. Todos los demás nodos se denominan hojas (también conocidos como nodos terminales o de decisión). En un árbol de decisión, cada nodo interno divide el espacio de la instancia en dos o más subespacios de acuerdo con una determinada función discreta de los valores de los atributos de entrada. En el caso más simple y frecuente, cada prueba considera un solo atributo, de modo que el espacio de la instancia se divide de acuerdo con el valor del atributo. En el caso de los atributos numéricos, la condición se refiere a un rango.

Cada hoja se asigna a una clase que representa el valor objetivo más apropiado, alternativamente, la hoja puede contener un vector de probabilidad que indica la probabilidad de que el atributo objetivo tenga un cierto valor. Las instancias se clasifican al navegarlas desde la raíz del árbol hasta una hoja, de acuerdo con el resultado de las pruebas a lo largo del camino [45].

La **Figura 3-8.** describe un árbol de decisión que razona si un participante presenta un estado de depresión o no.

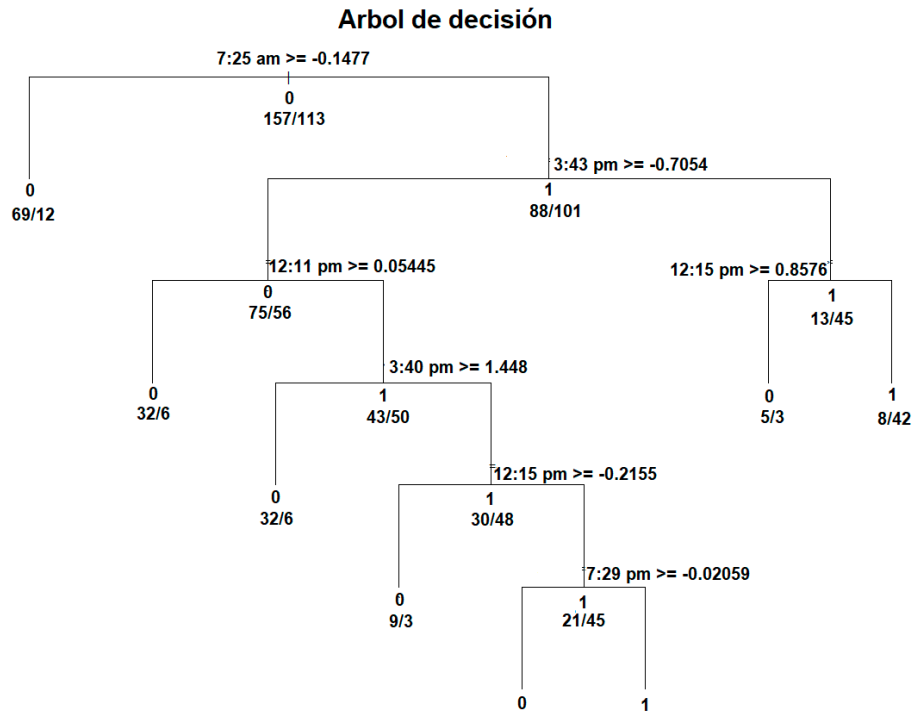


Figura 3-8.: Árbol de decisión para la clasificación de los participantes.

Máquinas de soporte vectorial

Las máquinas de soporte vectorial (MSV) también se usan para la clasificación, como una alternativa a la regresión logística. La idea es que si los puntos de datos se trazaron en espacio N-Dimensional, se puede identificar un hiperplano que separe los puntos que pertenecen a una clase de los puntos que pertenecen a otra. En el caso más simple, donde $N = 2$, el hiperplano es una línea recta. Como generalmente son posibles varias líneas de este tipo, la línea se elige para que el margen entre la línea y los puntos a cada lado de esta (es decir, la distancia perpendicular promedio) se maximice, esto se muestra en la **Figura 3-9**.




Figura 3-9.: Representación simple de una MSV de dos clases (círculos azules y cuadros rojos) que se pueden representar como los dos tipos de participantes seleccionados, separados por una línea que se elige de modo que se maximice el “el margen” entre las clases.

La ventaja de MSV sobre la regresión simple usando una variable $Y=1/0$ es que la regresión lineal usa todos los puntos de datos en el cálculo de la línea de mejor ajuste, mientras que MSV elige enfocarse en el conjunto de puntos más cercanos al margen (ese conjunto de puntos se llama el “vector de soporte”) [46].

3.5. Validación

La evaluación de los resultados obtenidos de cada modelo generado en la etapa del análisis de clasificación se conoce como validación, donde se aplican una serie de métricas

estadísticas que miden el rendimiento de los modelos como es el caso de las curvas ROC. Las curvas ROC se han utilizado ampliamente para medir o visualizar el rendimiento de un clasificador junto con el valor del área bajo la curva (AUC) [47]. Los valores trazados de sensibilidad y especificidad como el umbral de decisión se llama curva ROC y se muestran en la **Figura 3-10**.

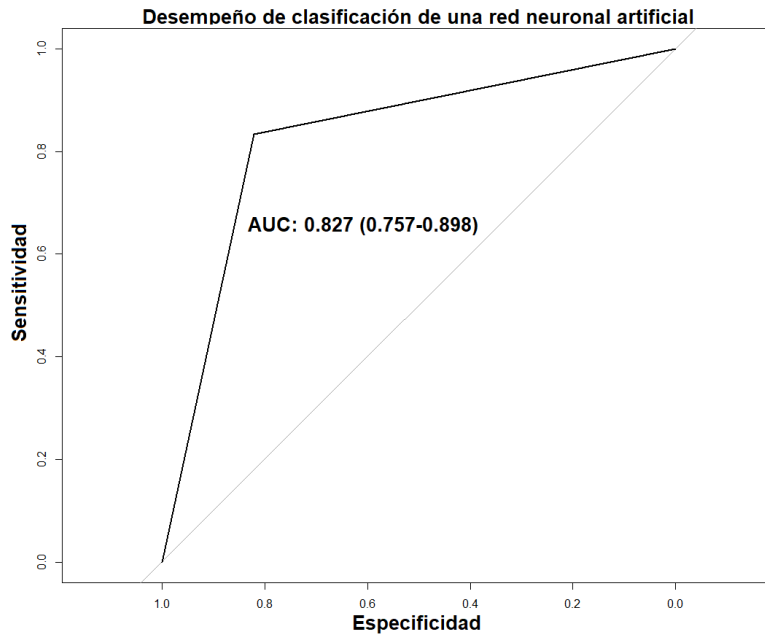


Figura 3-10.: Curva ROC para medir el desempeño de una red neuronal artificial que clasifica a participantes entre sanos y depresivos.

La forma más sencilla de calcular el área bajo la curva es a través de la integración trapezoidal, que se muestra en la **Ecuación 9**.

$$AUC = \sum_i (1 - \beta_i \cdot \Delta\alpha) + \frac{1}{2} [\Delta(1 - \beta) \cdot \Delta\alpha] \tag{9}$$

La sensibilidad, que se refiere a identificar correctamente a las personas con depresión se obtiene mediante la **Ecuación 10**.

$$\text{sensibilidad}(1 - \beta) = \frac{Tp}{Cp} \quad (10)$$

La especificidad, que se refiere a la capacidad de identificar correctamente a aquellos participantes sanos se muestra en la **Ecuación 11**.

$$\text{especificidad}(1 - \alpha) = \frac{Tn}{Cn} \quad (11)$$

Donde Tp son verdaderos positivos, Tn son verdaderos negativos, Cp son verdaderamente positivos y Cn son verdaderamente negativos.

También se pueden extraer medidas más significativas para tener ciertos criterios de rendimiento, como la exactitud, que se refiere al grado en que el resultado del cálculo se ajusta al valor correcto, que se muestra en la **Ecuación 12**.

$$\text{accuracy}(1 - \text{error}) = \frac{Tp + Tn}{Cp + Cn} \quad (12)$$

También, la precisión de un clasificador depende de la relación entre el número de objetivos detectados correctamente y todos los objetivos detectados, se le conoce como precisión (*Precision*), y la relación entre el número de objetivos detectados correctamente y todos los objetivos verdaderos se le conoce como recuperación (*Recall*). Estas dos relaciones se obtienen con las **Ecuaciones 13 y 14**.

$$\text{precision} = \frac{Tp}{Tp + FP} \quad (13)$$

$$\text{recall} = \frac{Tp}{Tp + FN} \quad (14)$$

Donde FP es falso positivo y FN es falso negativo.

Dado que la precisión y la recuperación son necesarias para evaluar capacidades de detección de un algoritmo, es conveniente encontrar una medida única que las considere a ambas. Una medida que combina ambas es el puntaje F1 (F1-Score), que es la media armónica de la precisión y la recuperación [48]. Como se muestra en la **Ecuación 15**.

$$F_1 = \frac{precision \cdot recall}{precision + recall} \quad (15)$$

Dado que solo hay dos posibles valores de salida, los resultados se presentan utilizando una matriz de confusión que muestra la diferencia entre los estados predichos y los reales facilitando el entendimiento de la información obtenida y los valores generados para la aplicación de las ecuaciones mencionadas anteriormente ya que de ahí es de donde se obtienen algunos de los parámetros, como lo muestra la **Figura 3-11**.

		Predicción	
		Positivos	Negativos
Observación	Positivos	Verdaderos Positivos (VP)	Falsos Negativos (FN)
	Negativos	Falsos Positivos (FP)	Verdaderos Negativos (VN)

Figura 3-11.: Estructura de la matriz de confusión que ayuda a medir cómo se comporta nuestro modelo con los datos de pruebas.

Capítulo 4. Resultados y discusión

Esta sección muestra los resultados obtenidos de cada uno los objetivos establecidos en este trabajo de investigación para esto fue necesario establecer diferentes casos de estudio, que no es otra cosa más que una herramienta de investigación y una técnica de aprendizaje que puede ser aplicado en cualquier área del conocimiento, su objetivo fundamental de los estudios de caso es conocer y comprender la particularidad de una situación para distinguir cómo funcionan las partes y las relaciones con el todo.

4.1. Aplicación de algoritmos genéticos

En el primer caso de estudio se presenta una reducción del conjunto de intervalos de tiempo en un minuto (variables) mediante algoritmos genéticos con el fin de conocer su desempeño para clasificar a los participantes entre control y condición mediante un análisis multivariado que se basó en la regresión logística en la que los genes que más se repiten para generar un modelo de clasificación son el resultado final del algoritmo para determinar las variables más relevantes, los resultados son evaluados posteriormente en términos de la precisión.

El algoritmo genético implementado mediante la herramienta Galgo recibe 5 parámetros para establecer un clasificador específico que son: “*chr*” que recibe los genes, el “*parent*” que recibe el objeto *BigBang*, “*tr*” recibe las muestras de entrenamiento, “*te*” recibe las muestras de prueba y “*result*” que reciben 0 para predicción de clase y 1 para precisión. Además, se configura un objeto *MaxBigBangs* que almacenará 1000

cromosomas o máximo de soluciones (*maxSolutions* = 1000) durante 500 generaciones con una precisión del 95 % (*goalFitness* = 0.95). Otros parámetros para definir son el nombre del objeto guardado que se crea y la frecuencia de los resultados de guardado en un archivo (*saveFrequency* = 5). Finalmente, el objeto almacenado tiene los intervalos de un minuto más representativos con mayor estabilidad para generar un modelo de clasificación de todo el conjunto de datos propuesto, estos son: 15:43, 15:41, 12:11, 07:25, 15:40, 7:29, 12: 15, que obtuvieron el mejor nivel validado mediante una precisión del **0.754** utilizando solo una parte del dataset mencionado, esto quiere decir que mediante el procesamiento de un número reducido de variables es posible generar un modelo con un grado aceptable de clasificación de pacientes.

4.2. Análisis y procesamiento de los intervalos de tiempo extraídos.

En esta sección se analizaron y se procesaron las características extraídas a través de los algoritmos genéticos donde de las 385 observaciones generadas el 70 por ciento fue utilizado para entrenar los algoritmos de aprendizaje automático y 30 por ciento para pruebas, con el fin de desarrollar un modelo multivariado basado en los registros de actividad motriz de cada minuto que presento el mejor rendimiento para clasificar a los participantes entre depresivos y sanos para determinar que la información extraída ayuda en el desarrollo de modelos basados en técnicas de aprendizaje automático. Las características seleccionadas fueron sometidas a una etapa de verificación de desempeño basado en la exactitud donde se utilizó la regresión logística una vez más como forma de confirmar los resultados obtenidos anteriormente en la implementación de los algoritmos

genéticos y otras técnicas de aprendizaje automático para comparar los resultados, como se muestra en la **Tabla 2**.

Tabla 2. Resultados obtenidos en cada modelo generado de los algoritmos de aprendizaje automático utilizando solo las 7 características extraídas previamente.

Algoritmo	Precisión
Regresión Logística	0.834
Máquina de Soporte Vectorial	0.808
Arboles de Decisión	0.791
Red Neuronal Artificial	0.826
Red Neuronal Profunda	0.834

Los resultados de la evaluación de los modelos generados presentaron un valor de alguna forma significativo. Ya que la exactitud es muy similar, lo que quiere decir que los intervalos de un minuto extraídos proveen información relevante y resumida de todo el conjunto de datos propuesto en este trabajo de investigación.

Los minutos extraídos del conjunto de datos propuesto se relaciona a un horario diurno ya que los minutos que más prevalecen se encuentran entre las 12:11 hasta las 15:43 y que según lo mencionado en la investigación de Rodríguez-Ruiz et al. [24] la segmentación horaria, se construye en tres subconjuntos diferentes; actividad nocturna (de 21 a 7 horas teniendo en cuenta las horas estándar del amanecer), actividad motora diurna (de 8 a 20 horas) y finalmente actividad motora durante todo el día con el total de horas diurnas. Esta información resultante, indica que tomar en cuenta datos de distintos horarios puede resultar útil para trabajos posteriores o incluso como referencia para personal médico.

4.3. Comparación de los algoritmos de aprendizaje automático aplicados

Con el fin de validar que la actividad motriz extraída de los minutos seleccionados en los algoritmos genéticos aporta información significativa en la clasificación de pacientes control y pacientes condición se compararon los diferentes algoritmos de aprendizaje automático mencionados para determinar cual tiene mejor desempeño. En esta etapa de validación, se utilizó la curva ROC y área bajo la curva que tiene la capacidad de diferenciar a los participantes entre sí y se utiliza para conocer la proporción de sensibilidad, especificidad, también se obtuvo el valor F1-Score. Los resultados se muestran en la

Tabla 3.

Tabla 3. *Tabla comparativa del desempeño de los algoritmos implementados para clasificar a pacientes con depresión.*

Algoritmo	AUC	F1-SCORE	Exactitud
Regresión Logística	0.831	0.857	0.834
Máquina de Soporte Vectorial	0.806	0.833	0.808
Arboles de Decisión	0.780	0.826	0.791
Red Neuronal Artificial	0.827	0.846	0.826
Red Neuronal Profunda	0.832	0.854	0.834

Los resultados arrojados muestran que la red neuronal profunda (RNP) y la regresión logística tuvieron mejor desempeño luego de realizar el pre-procesamiento y la selección de características con una ligera diferencia en el área bajo la curva, donde la RNP tiene mejor resultado así se tiene que, de las 385 observaciones se utilizaron 270 que equivalen al 70% del conjunto total de los datos para entrenar la red neuronal profunda y 115 observaciones equivalentes al 30% se utilizó para la realización de pruebas donde 56 participantes de la prueba fueron clasificados como control o sanos (verdaderos positivos) y 40 con un episodio de depresión o condición (verdadero negativo), además 10

participantes como falsos positivos y 9 como falsos negativos. Estos resultados se presentan en una matriz de confusión en la **Tabla 4**.

Tabla 4. Matriz de confusión del modelo clasificación generado por RNP

	Control	Condición
Control	56	9
Condición	10	40

Adicionalmente, se presentan las curvas ROC en la **Figura 4-1** generadas por cada modelo en donde se muestra de manera gráfica los niveles de sensibilidad y especificidad, además del área bajo la curva.

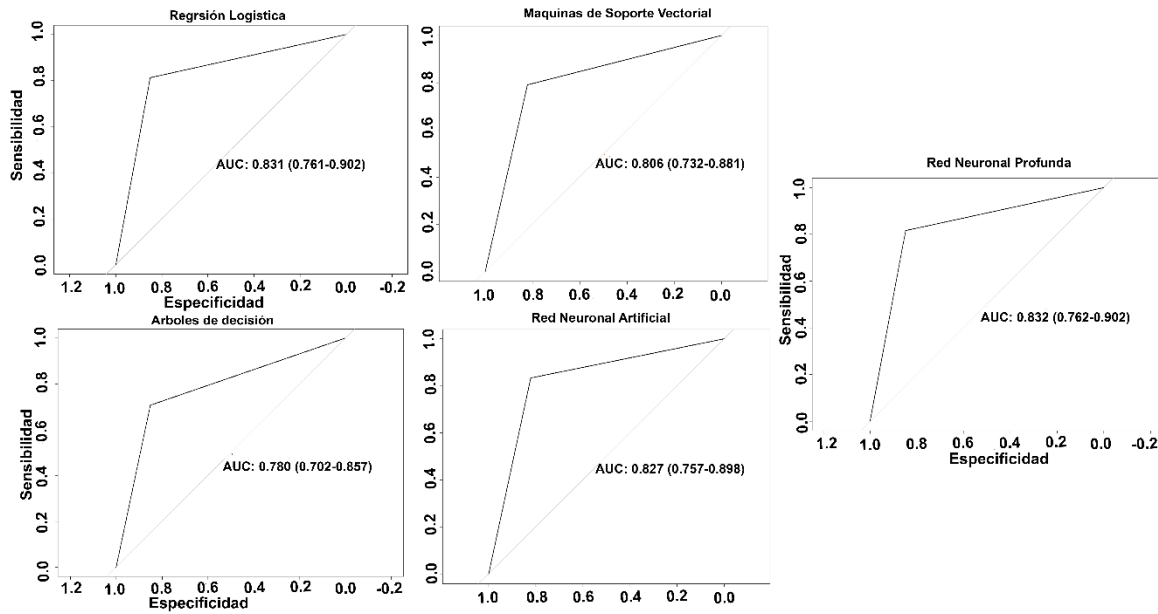


Figura 4-1.: Curvas ROC y área bajo la curva de cada modelo generado mediante diferentes técnicas de aprendizaje automático para la clasificación de los participantes.

4.4. Análisis y procesamiento de todos los intervalos de tiempo seleccionados

Es un hecho que el propósito de esta investigación es crear un modelo de predicción con la menor cantidad de características que permita disminuir el tiempo de procesamiento así como el costo computacional, pero es necesario tener en cuenta los resultados utilizando todo el conjunto de características propuesto para verificar que tan factible es utilizar un mínimo de lecturas de actividad motriz y validando la robustez y solidez de los resultados obtenidos anteriormente, para esto se estableció, procesar y analizar todo el conjunto de datos en cada algoritmo de aprendizaje automático presentando los siguientes resultados.

Para el caso de la regresión logística, el algoritmo no convergió y se produjeron probabilidades ajustadas numéricamente 0 ó 1 (control o condición). Esto quiere decir que el algoritmo se enfrenta a un problema de sobreajuste, ya que existen demasiadas variables, lo que lleva a una separación perfecta de los casos y por lo tanto, no se puede lograr que el modelo converja.

Por otro lado, en la aplicación de los algoritmos restantes (redes neuronales profundas, redes neuronales artificiales, árboles de decisión y máquina de soporte vectorial) para la generación del modelo de predicción estos no produjeron fallo alguno, pero si un menor índice de exactitud, área bajo la curva y F1-Score. Los algoritmos se aplicaron bajo las mismas condiciones, mismas métricas de validación con la única diferencia que el número de características fue mayor. Los resultados se presentan en la **Tabla 5**, que se muestra a continuación.

Tabla 5. Tabla comparativa del desempeño de los algoritmos implementados para clasificar a pacientes con depresión utilizando todos los intervalos de un minuto (donde N/C significa no convergió).

	AUC	F1-SCORE	EXACTITUD
SVM	0.76	0.76	0.747
RL	N/C	N/C	N/C
RNA	0.703	0.715	0.695
RNP	0.718	0.727	0.713
AR	0.705	0.771	0.721

4.5. Comparación de resultados con trabajos relacionados

Para finalizar, se propuso comparar los distintos enfoques de las diferentes investigaciones citadas en este trabajo, que utilizan los mismos datos de referencia con el fin de conocer las diferencias entre resultados y propuestas de solución al problema.

Frogner et al. [20] utilizó los mismos datos que esta investigación donde no se realizó ningún tipo de pre-procesamiento previo. Los participantes en los que se centraron fueron los originalmente adquiridos, marcaron el grupo bipolar y unipolar como el grupo condición, y el grupo no deprimido como el grupo control obteniendo los siguientes resultados que se muestran en la **Tabla 6**.

Tabla 6. Métricas de rendimiento del experimento para la clasificación de control y condición.

Grupo	Exactitud	Precisión	Recuperación	Especificidad	F1-Score
Control	0.71	0.74	0.78	0.61	0.76
Condición	0.71	0.67	0.61	0.78	0.64
Media	0.71	0.71	0.7	0.7	0.7

En el caso de García-Ceja et al. [18] Propusieron el siguiente enfoque. Cada participante recopiló datos para d_i días consecutivos donde d_i representa el numero de días recopilados por el participante i . Luego, extrajeron las características estadísticas de cada día, lo que dio como resultado diferentes vectores de características por participante, además dada la naturaleza desequilibrada de los datos, utilizaron diferentes técnicas de equilibrio de clases y aplicando dos algoritmos de aprendizaje automático, donde Bosques Aleatorios obtuvo los mejores resultados que se muestran en la **Tabla 7**.

Tabla 7. Resultados de la clasificación utilizando Bosques Aleatorios

Grupo	Precisión	REC/SEN	Especificidad	F1-Score
Control	0.77	0.75	0.69	0.76
Condición	0.67	0.69	0.75	0.68
Media	0.73	0.73	0.72	0.73

El enfoque de Zanella- Calzada et al. [23] En la selección de muestras solo se mantuvo el primer valor de los 60 valores adquiridos durante 1 hora, equivalente a los minutos correspondientes a ese lapso, contando ahora la actividad en intervalos de una hora. Este procedimiento se realizó para cada hora de los datos totales. Por otro lado, la selección de sujetos dependió del volumen de datos más equilibrado posible. Se seleccionaron los primeros cuatro controles presentes en el conjunto de datos y los primeros cinco casos, equilibrando así el número de muestras. En la extracción de características obtuvieron una serie de 14 parámetros estadísticos y para el análisis de clasificación utilizaron Bosques Aleatorios con una precisión de 0.893 y un área bajo la curva (AUC) de 0.893.

En la investigación de Rodríguez-Ruiz et al. [24] Propone una segmentación de los datos para formar intervalos de datos de una hora, con base a la segmentación horaria, se construyen tres subconjuntos diferentes; actividad motriz nocturna, actividad motriz diurna y finalmente actividad motriz durante todo el día. Por cada subconjunto se extrajeron sus 24 características estadísticas. En el siguiente paso redujeron la dimensión de los conjuntos de características y seleccionaron el mejor modelo para la descripción de los datos para finalmente aplicar el algoritmo de Bosques Aleatorios para la clasificación. Para el subconjunto de los datos de noche la precisión fue casi perfecta, obteniendo un valor de 99.72%.

Galván-Tejada et al. [27] Utilizó solo el primer valor de los 60 datos adquiridos en los minutos equivalentes a una hora, contando ahora la actividad en intervalos de una hora, mientras que en la selección de sujetos dependía de la cantidad de datos resultantes de la selección de muestras, seleccionando los primeros cuatro controles presentes en el conjunto de datos y los primeros cinco casos para equilibrar el número de muestras. En la extracción de características utilizan dos tipos de datos, temporales y de frecuencia estos últimos se obtienen mediante el cálculo de la transformada de Fourier y para cada tipo de dato se extraen 14 parámetros estadísticos obteniendo un total de 38 características las cuales son reducidas utilizando algoritmos genéticos para después realizar el análisis de clasificación utilizando Bosques Aleatorios obteniendo los siguientes resultados que se muestran en la **Figura 4-2**.




Figura 4-2.: Curvas ROC obtenidas usando (a) todas las características (b) los mejores cromosomas y (c) cromosomas finales.

Otro enfoque diferente que también podemos comparar es el realizado recientemente en el trabajo de Petter Jakobsen et al. [26] en donde utilizando bosques aleatorios, redes neuronales profundas y redes neuronales convolucionales para analizar los patrones de actividad motriz en pacientes con depresión y sanos durante 14 días. Las características estadísticas analizadas en el *dataset* fueron la actividad media, la desviación estándar y la proporción de actividad cero donde también aplicaron varias técnicas para manejar el desequilibrio de datos, y para garantizar la generalización y evitar sobreajuste, se utilizó una estrategia de validación de dejar a un usuario fuera. La red neuronal profunda combinada con la técnica de equilibrio de clases SMOTE realizó un corte por encima del resto con una tasa positiva verdadera de 0.82 (sensibilidad) y una tasa negativa verdadera de 0.84 (especificidad) con una precisión de 0.84. como lo muestra la **Tabla 8**.

Tabla 8. Resultados de la clasificación de aprendizaje automático (segunda ejecución) en series de tiempo de actividad motriz de pacientes deprimidos con retraso motriz (n=17) y controles (n=32).

Técnica de Aprendizaje Automático	Técnica de balanceo de clases	Resultados de la clasificación											
		Sensibilidad	Especificidad	Recuperación ponderada	PPV	NPV	Precisión ponderada	Precisión	MCC	TP	TN	FP	FN
Bosques aleatorios	Baseline	0.18	0.75	0.55	0.27	0.63	0.51	0.55	-0.08	3	24	8	14
	Sin sobremuestreo	0.47	0.84	0.71	0.62	0.75	0.7	0.71	0.34	8	27	5	9
	Sobremuestreo aleatorio	0.65	0.81	0.76	0.65	0.81	0.76	0.76	0.46	11	26	6	6
	SMOTE	0.76	0.78	0.78	0.65	0.86	0.79	0.78	0.53	13	25	7	4
Redes neuronales Profundas	Baseline	0.06	0.91	0.61	0.25	0.64	0.51	0.61	-0.06	1	29	3	16
	Sin sobremuestreo	0.53	0.91	0.78	0.75	0.78	0.77	0.78	0.48	9	29	3	8
Red neuronal de línea base profunda ponderada	Sobremuestreo aleatorio	0.82	0.78	0.8	0.67	0.89	0.81	0.8	0.58	14	25	7	3
	SMOTE	0.82	0.84	0.84	0.74	0.9	0.84	0.84	0.65	14	27	5	3
Red neuronal de línea base convolucional ponderada	Baseline	0.06	0.88	0.59	0.2	0.64	0.49	0.59	-0.1	1	28	4	16
	Sin sobremuestreo	0.82	0.75	0.78	0.64	0.89	0.8	0.78	0.55	14	24	8	3
Red neuronal de línea base convolucional ponderada	Baseline	0.18	0.78	0.57	0.3	0.64	0.52	0.57	-0.05	3	25	7	14
	Sin sobremuestreo	0.65	0.81	0.76	0.65	0.81	0.76	0.76	0.46	11	26	6	6

Por otro lado, la **Tabla 9.** obtenida en esta investigación solo se limita a presentar resultados de cada algoritmo sin ninguna técnica de balanceo de clases y omitiendo métricas de validación como la recuperación ponderada, precisión ponderada y el coeficiente de correlación de Mathews. Con esto es posible observar una ligera diferencia entre los resultados obtenidos, en donde ambos trabajos concluyen que la implementación de redes neuronales profundas ofrece mejor de rendimiento de clasificación pero que para el caso del trabajo de Petter Jakobsen et al. [26] utiliza una técnica de balance de clases conocida como SMOTE que crea nuevas muestras sintéticas que se generan al azar desde puntos vecinos similares [49].

Tabla 10. Resultados de la clasificación de aprendizaje automático utilizando intervalos de tiempo como características, sin balanceo de clases.

Técnica de Aprendizaje Automático	Técnica de balanceo de clases	Resultados de la clasificación										
		Sensibilidad	Especificidad	Recuperación	PPV	NPV	Precisión	TP	TN	FP	FN	
Regresión Logística	Sin balanceo de clases	0.82	0.85	0.82	0.88	0.77	0.88	55	41	12	7	
Maquina de Soporte Vectorial	Sin balanceo de clases	0.8	0.83	0.8	0.87	0.75	0.87	54	40	13	8	
Arboles de decisión	Sin balanceo de clases	0.85	0.7	0.85	0.8	0.77	0.8	57	34	14	10	
Red Neuronal artificial	Sin balanceo de clases	0.82	0.83	0.82	0.87	0.76	0.87	55	40	12	8	
Redes neuronales profundas	Sin balanceo de clases	0.84	0.81	0.84	0.86	0.8	0.86	56	40	10	9	

Capítulo 5. Conclusiones

A lo largo de esta investigación se pudo comprobar que efectivamente es posible crear un modelo de clasificación con alto índice de confianza y que los intervalos de tiempo que muestran mejores resultados se encuentran dentro de un horario diurno donde se toman en cuenta cada registro por minuto sin extraer sus características estadísticas o aplicando técnicas más complejas basadas en Fourier como se reporta en la bibliografía.

Empleando la generación de una matriz con registros de actividad motriz en intervalos de un minuto con una normalización “Z”, algoritmos genéticos y redes neuronales profundas se obtiene una mayor eficiencia la cuál es imprescindible al momento de ser aplicadas en algún dispositivo no invasivo, de fácil uso y que operen en tiempo real (menor costo computacional y menor tiempo), ya que se realiza una clasificación empleando un número reducido de datos.

La selección de características por medio de algoritmos genéticos puede ser útil como método de reconocimiento de patrones capaces de mejorar la comprensión de enfermedades, como en el caso de la depresión, pero está comprobado que este tipo de técnicas aumentan el tiempo y costo computacional, pero por otra parte facilitan análisis de clasificación reduciendo el número de variables.

Con esta investigación se concluye que es posible crear un sistema de clasificación confiable utilizando solo tiempos claves y no todo el conjunto de datos sin un pre-procesamiento.

El desempeño del clasificador mejoraría notablemente si se aumentaran el número de observaciones, intervalos de tiempo y otras variables como educación, trabajo, género, edad, etc. teniendo así una mayor diversidad de datos y resultados más precisos. Además, si se aplicarán técnicas de aprendizaje automático no supervisadas podrían ayudar a la clasificación de los pacientes con o sin depresión. También, si se aplican métodos de validación más complejos como la prueba no paramétrica de *Wilcoxon Signed Rank Test* se obtendría un parámetro de diferenciación entre dos muestras (control y condición).

Por lo tanto, se propone incluir una etapa de selección de características donde se comparen diferentes métodos y así conocer cuál es mejor para contribuir en la detección de episodios de depresión.

5.1. Objetivos alcanzados

Los algoritmos genéticos permitieron desarrollar una serie de modelos multivariados que clasifican la presencia o ausencia de depresión con una precisión estadísticamente significativa involucrando solo un conjunto reducido de características, concluyendo a través de estos que si los sujetos son clasificados solo utilizando ciertos registros por minuto es posible desarrollar un modelo de clasificación de pacientes así como también afirmar que la implementación de los AG resulta útil para esta tarea.

Por otro lado, se pudo determinar que tiempos presentaron información clave y resumida de todo el conjunto de datos propuesto para el desarrollo de modelos basados en aprendizaje automático a partir de conocer sus valores resultantes de las distintas métricas

de validación, para este caso específico 7 características fueron las extraídas al final y fueron suficientes para conocer su contribución al desarrollo de los modelos multivariados. Con los resultados obtenidos de cada modelo generado también se pudo establecer que las redes neuronales profundas como algoritmo de aprendizaje automático tuvieron el mejor desempeño al momento de identificar sujetos caso y control a partir de una menor cantidad de características, reduciendo el tiempo y costo computacional que conlleva este tipo de algoritmos.

Finalmente podemos decir que se alcanzaron todos los objetivos propuestos ya que se compararon, validaron y determinaron todos los planteamientos generados en este trabajo de tesis obteniendo resultados muy similares en cada modelo generado haciendo uso de intervalos de tiempo clave obteniendo un grado de clasificación aceptable que podría ser de ayuda en trabajos futuro o relacionados.

5.2. Hipótesis/Preposiciones demostradas

Como hipótesis se tenía que el desarrollo de un modelo de clasificación implementando algoritmos genéticos como método de selección de características para reducir el número de variables (intervalos de tiempo) de la base de datos de actividad motriz de episodios de depresión en pacientes unipolares y bipolares aplicando diferentes técnicas de aprendizaje automático permite clasificar pacientes con presencia de depresión con un grado de exactitud aceptable, si bien el índice obtenido en esta investigación no es mejor que algunos de los trabajos mencionados, la hipótesis se demuestra de manera satisfactoria ya que al obtener un porcentaje de aceptación del 80% para clasificar a los

pacientes se puede considerar una forma viable para el desarrollo de herramientas que ayuden a identificar este tipo de trastornos mentales.

5.3. Contribuciones de la investigación

Una de las contribuciones más importantes es que no es imprescindible el uso de un gran conjunto de datos para generar modelos capaces de realizar clasificación de pacientes entre controles y sanos pero que si resulta importante al momento de implementar métodos matemáticos de extracción y/o selección de características ya que estos hacen uso de funciones exhaustivas de problemas de optimización, lo que con lleva al uso de una gran cantidad de características para poder resumir esta información en solo las principales que dan detalle sobre los momentos en los que un paciente puede estar entre un estado u otro.

Otra contribución importante es el hecho de que el enfoque tomado fue muy práctico al momento de establecer cuáles serían las características de los objetos de estudio ya que con esto es posible complementar distintas investigaciones uniendo los intervalos obtenidos, extrayendo sus características estadísticas y utilizando métodos de balanceo que puedan mejorar en muchos aspectos el desempeño de los algoritmos aplicados para crear modelos de clasificación o predicción.

5.4. Limitaciones y supuestos

Para poder implementar un sistema de este tipo en la vida real sería necesario generar un modelo que detecte episodios de depresión, que trabaje en tiempo real, que pueda generar alto grado de precisión para detectar este tipo de enfermedades (como es el caso de las redes neuronales artificiales) y hardware lo suficientemente potente para procesar

grandes cantidades de datos, si bien estos dos elementos ya se encuentran a disposición de cualquier persona no existen dispositivos que combinen estas herramientas como los sensores de actividad motriz y un sistema dedicado al procesamiento de esta información lo cual implica una limitante considerable para poder implementar los modelos generados a través de técnicas de aprendizaje automático pero que a la vez representa una área de oportunidad para futuras investigaciones.

Por otro lado, existe las limitaciones humanas que deben ser consideradas, como es el hecho de la existencia de personas con depresión que no pueden ser clasificadas mediante este método de procesamiento de lecturas de actividad motriz ya que existen personas deprimidas funcionales que pueden realizar sus actividades de manera normal, sin ver afectada de alguna manera significativa sus lecturas motrices. En esta investigación suponemos que al agregar otras variables como son el tipo de alimentación, antecedentes familiares, lugar de nacimiento, sus hábitos y entorno social podrían ayudar en un futuro a mejorar el diagnóstico oportuno y objetivo de esta enfermedad mental.

5.5. Trabajos Publicados

- [1] Carlos H. Espino-Salinas et al, "Depression Episodes Detection: A Neural Net and Deep Neural Net Comparison." In 19th Mexican International Conference on Artificial Intelligence", MICAI 2020.
- [2] Carlos H. Espino-Salinas et al., "Tiempos Determinantes Para la Clasificación de Personas con Depresión Utilizando Algoritmos Genéticos," In I Congreso Internacional en Odontología Zacatecas, 2020.
- [3] Carlos H. Espino-Salinas et al," BookSense an Application for Mental Disorders Diagnosis: A Case Study for User Evaluation and Redesign" In VI Jornadas Iberoamericanas de Interacción Humano Computador, 2020.
- [4] Carlos H. Espino-Salinas et al, "Predicción de la Escala Montgomery-Asberg de Personas con Depresión Utilizando la Actividad Motriz y Técnicas de Aprendizaje Automático Supervisado," In VI Jornadas Internacionales de Investigación en Odontología, 2019.

Referencias

- [1] WHO, "OMS | Salud mental," *Who*. 2017, [Online]. Available: http://www.who.int/mental_health/es/.
- [2] C. J. L. Murray and . Lopez, Alan D, "The Global burden of disease : a comprehensive assessment of mortality and disability from diseases, injuries, and risk factors in 1990 and projected to 2020,," 1996. doi: 10.1088/1742-6596/707/1/012025.
- [3] R. C. Kessler *et al.*, "Lifetime prevalence and age-of-onset distributions of mental disorders in the World Health Organization's World Mental Health Survey Initiative," *World psychiatry : official journal of the World Psychiatric Association (WPA)*, vol. 6, no. 3, pp. 168–176, Oct. 2007, [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/18188442>.
- [4] S. Berenzon, M. A. Lara, R. Robles, and M. E. Medina-Mora, "Depresión: Estado del conocimiento y la necesidad de políticas públicas y planes de acción en México," *Salud Publica de Mexico*, vol. 55, no. 1, 2013, doi: 10.1590/S0036-36342013000100011.
- [5] E. Garcia-Ceja *et al.*, "Depresjon: A Motor Activity Database of Depression Episodes in Unipolar and Bipolar Patients," in *Proceedings of the 9th ACM Multimedia Systems Conference*, 2018, pp. 472–477, doi: 10.1145/3204949.3208125.
- [6] G. Valenza *et al.*, "Wearable monitoring for mood recognition in bipolar disorder based on history-dependent long-term heart rate variability analysis," *IEEE Journal of Biomedical and Health Informatics*, vol. 18, no. 5, 2014, doi: 10.1109/JBHI.2013.2290382.
- [7] N. Vanello *et al.*, "Speech analysis for mood state characterization in bipolar patients," 2012, doi: 10.1109/EMBC.2012.6346375.
- [8] S. A. Montgomery and M. Asberg, "A new depression scale designed to be sensitive to change," *British Journal of Psychiatry*, vol. 134, no. 4, 1979, doi: 10.1192/bjp.134.4.382.
- [9] C. J. Hawley, T. M. Gale, and T. Sivakumaran, "Defining remission by cut off score on the MADRS: Selecting the optimal value," *Journal of Affective Disorders*, 2002, doi: 10.1016/S0165-0327(01)00451-7.
- [10] M. J. Müller, H. Himmerich, B. Kienzle, and A. Szegedi, "Differentiating moderate and severe depression using the Montgomery-Åsberg depression rating scale (MADRS)," *Journal of Affective Disorders*, 2003, doi: 10.1016/S0165-0327(02)00120-9.
- [11] S. Khairuddin *et al.*, "Classification of the Correct Quranic Letters Pronunciation of Male and Female Reciters," 2017, doi: 10.1088/1757-899X/260/1/012004.
- [12] J. O. Berle, E. R. Hauge, K. J. Oedegaard, F. Holsten, and O. B. Fasmer, "Actigraphic registration of motor activity reveals a more structured behavioural pattern in

- schizophrenia than in major depression," *BMC research notes*, vol. 3, p. 149, May 2010, doi: 10.1186/1756-0500-3-149.
- [13] N. Razavi *et al.*, "Measuring motor activity in major depression: The association between the Hamilton Depression Rating Scale and actigraphy," *Psychiatry Research*, 2011, doi: 10.1016/j.psychres.2011.05.028.
- [14] N. Keshan, P. v. Parimi, and I. Bichindaritz, "Machine learning for stress detection from ECG signals in automobile drivers," 2015, doi: 10.1109/BigData.2015.7364066.
- [15] E. Garcia-Ceja, V. Osmani, and O. Mayora, "Automatic Stress Detection in Working Environments from Smartphones' Accelerometer Data: A First Step," *IEEE Journal of Biomedical and Health Informatics*, 2016, doi: 10.1109/JBHI.2015.2446195.
- [16] L. B. Leng, L. B. Giin, and W. Y. Chung, "Wearable driver drowsiness detection system based on biomedical and motion sensors," 2015, doi: 10.1109/ICSENS.2015.7370355.
- [17] E. Garcia-Ceja *et al.*, "Depresjon: A motor activity database of depression episodes in unipolar and bipolar patients," 2018, doi: 10.1145/3204949.3208125.
- [18] E. Garcia-Ceja *et al.*, "Motor Activity Based Classification of Depression in Unipolar and Bipolar Patients," 2018, doi: 10.1109/CBMS.2018.00062.
- [19] S. Bouktif, A. Fiaz, A. Ouni, and M. A. Serhani, "Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches," *Energies*, 2018, doi: 10.3390/en11071636.
- [20] J. I. Frogner *et al.*, "One-dimensional convolutional neural networks on motor activity measurements in detection of depression," 2019, doi: 10.1145/3347444.3356238.
- [21] M. Faurholt-Jepsen *et al.*, "Behavioral activities collected through smartphones and the association with illness activity in bipolar disorder," *International Journal of Methods in Psychiatric Research*, 2016, doi: 10.1002/mpr.1502.
- [22] A. G. Reece and C. M. Danforth, "Instagram photos reveal predictive markers of depression," *EPJ Data Science*, 2017, doi: 10.1140/epjds/s13688-017-0110-z.
- [23] L. A. Zanella-Calzada *et al.*, "Feature extraction in motor activity signal: Towards a depression episodes detection in unipolar and bipolar patients," *Diagnostics*, 2019, doi: 10.3390/diagnostics9010008.
- [24] J. G. Rodríguez-Ruiz *et al.*, "Comparison of night, day and 24 h motor activity data for the classification of depressive episodes," *Diagnostics*, 2020, doi: 10.3390/diagnostics10030162.
- [25] J. O. Berle, E. R. Hauge, K. J. Oedegaard, F. Holsten, and O. B. Fasmer, "Actigraphic registration of motor activity reveals a more structured behavioural pattern in

- schizophrenia than in major depression," *BMC Research Notes*, 2010, doi: 10.1186/1756-0500-3-149.
- [26] E. A. N. D. R. M. A. N. D. S. L. A. A. N. D. N. T. A. N. D. T. J. A. N. D. F. O. B. A. N. D. O. K. J. Jakobsen Petter AND Garcia-Ceja, "Applying machine learning in motor activity time series of depressed bipolar and unipolar patients compared to healthy controls," *PLOS ONE*, vol. 15, no. 8, pp. 1–16, Sep. 2020, doi: 10.1371/journal.pone.0231995.
- [27] C. E. Galván-Tejada *et al.*, "Depression Episodes Detection in Unipolar and Bipolar Patients: A Methodology with Feature Extraction and Feature Selection with Genetic Algorithms Using Activity Motion Signal as Information Source," *Mobile Information Systems*, 2019, doi: 10.1155/2019/8269695.
- [28] E. Alpaydin, *Introduction to Machine Learning*, 2nd ed. The MIT Press, 2010.
- [29] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach (International Edition)*. 2002.
- [30] T. Jayalakshmi and A. Santhakumaran, "Statistical Normalization and Back Propagation for Classification," *International Journal of Computer Theory and Engineering*, 2011, doi: 10.7763/ijcte.2011.v3.288.
- [31] The National Institute of Mental Health, "Definitions of the RDoC Domains and Constructs," *Www.Nimh.Nih.Gov*, 2015.
- [32] F. J. Penedo and J. R. Dahn, "Exercise and well-being: A review of mental and physical health benefits associated with physical activity," *Current Opinion in Psychiatry*. 2005, doi: 10.1097/00001504-200503000-00013.
- [33] S. B. Kotsiantis and D. Kanellopoulos, "Data preprocessing for supervised learning," *International Journal of ...*, 2006, doi: 10.1080/02331931003692557.
- [34] J. Honaker, G. King, and M. Blackwell, "Amelia II: A Program for Missing Data," *Journal of Statistical Software, Articles*, vol. 45, no. 7, pp. 1–47, 2011, doi: 10.18637/jss.v045.i07.
- [35] J. L. Ribeiro Filho and P. C. Treleaven, "Genetic-Algorithm Programming Environments," *Computer*, 1994, doi: 10.1109/2.294850.
- [36] S. K. Pal and D. Bhandari, "Selection of optimal set of weights in a layered network using genetic algorithms," *Information Sciences*, vol. 80, no. 3, pp. 213–234, 1994, doi: [https://doi.org/10.1016/0020-0255\(94\)90076-0](https://doi.org/10.1016/0020-0255(94)90076-0).
- [37] "Proceedings of the 6th International Conference on Genetic Algorithms," 1995.
- [38] G. James, D. Witten, T. Hastie, and R. Tibshirani, *An Introduction to Statistical Learning: With Applications in R*. Springer Publishing Company, Incorporated, 2014.

- [39] R. Ramos-Pollán, M. Á. Guevara-López, and E. Oliveira, "A Software Framework for Building Biomedical Machine Learning Classifiers through Grid Computing Resources," *Journal of Medical Systems*, vol. 36, no. 4, pp. 2245–2257, 2012, doi: 10.1007/s10916-011-9692-3.
- [40] B. Schölkopf, "Artificial intelligence: Learning to see and act," *Nature*. 2015, doi: 10.1038/518486a.
- [41] Q. Zhang, H. Yu, M. Barbiero, B. Wang, and M. Gu, "Artificial neural networks enabled by nanophotonics," *Light: Science & Applications*, vol. 8, no. 1, p. 42, 2019, doi: 10.1038/s41377-019-0151-0.
- [42] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The Bulletin of Mathematical Biophysics*, 1943, doi: 10.1007/BF02478259.
- [43] L. A. Zanella-Calzada *et al.*, "Deep artificial neural networks for the diagnostic of caries using socioeconomic and nutritional features as determinants: Data from NHANES 2013–2014," *Bioengineering*, 2018, doi: 10.3390/bioengineering5020047.
- [44] E. A. DiGangi and J. T. Hefner, "Chapter 5 - Ancestry Estimation," in *Research Methods in Human Skeletal Biology*, E. A. DiGangi and M. K. Moore, Eds. Academic Press, 2013, pp. 117–149.
- [45] O. Rokach Lior and Maimon, "Decision Trees," in *Data Mining and Knowledge Discovery Handbook*, L. Maimon Oded and Rokach, Ed. Boston, MA: Springer US, 2005, pp. 165–192.
- [46] P. Nadkarni, "Chapter 4 - Core Technologies: Machine Learning and Natural Language Processing," in *Clinical Research Computing*, P. Nadkarni, Ed. Academic Press, 2016, pp. 85–114.
- [47] A. P. Bradley, "The use of the area under the ROC curve in the evaluation of machine learning algorithms," *Pattern Recognition*, vol. 30, no. 7, pp. 1145–1159, 1997, doi: [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2).
- [48] A. A. AlBeladi and A. H. Muqaibel, "Evaluating compressive sensing algorithms in through-the-wall radar via F1-score," *International Journal of Signal and Imaging Systems Engineering*, vol. 11, no. 3, 2018, doi: 10.1504/IJSISE.2018.093268.
- [49] N. v. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic minority over-sampling technique," *Journal of Artificial Intelligence Research*, vol. 16, 2002, doi: 10.1613/jair.953.