



**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS
DEL INSTITUTO POLITÉCNICO NACIONAL**

UNIDAD ZACATENCO

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

SECCIÓN DE ELECTRÓNICA DEL ESTADO SÓLIDO

**“Sistema para la detección y monitoreo de actividad física
mediante el uso de acelerómetros”**

T E S I S

Que presenta

M. en C. ANDREA LÓPEZ TAPIA

Para obtener el grado de

DOCTORA EN CIENCIAS

EN LA ESPECIALIDAD DE

INGENIERÍA ELÉCTRICA

Directores de la Tesis:

Dr. Mario Alfredo Reyes Barranca

Dra. Griselda Stephany Abarca Jiménez

Ciudad de México

Noviembre, 2024

AGRADECIMIENTOS

Al Cinvestav y Conahcyt, por abrirme las puertas de esta gran institución, brindarme una educación de calidad y las herramientas necesarias para poder alcanzar el título de Doctora en Ciencias.

A mis padres y hermana, por el ejemplo de vida, los valores, la dedicación, la perseverancia, la honestidad y el respeto que me han inculcado, por darme su amor y apoyo incondicional que me ha ayudado a alcanzar esta meta.

A todas las personas que me han acompañado en este camino, especialmente a mi compañero de vida, Luis Sánchez Márquez, quien ha sido un pilar fundamental y un gran apoyo durante todos estos años; y a mi profesor y guía, Luis Martín Flores Nava, de quien he aprendido valiosas lecciones que me han permitido llegar hasta aquí. En memoria del querido profesor Dr. José Antonio Moreno Cadenas, a quien tuve el honor de conocer y de quien aprendí mucho.

A Yesenia Cervantes Aguirre, por el cariño y aprecio que me transmite, y cuya labor en la Coordinación Académica ha sido de gran apoyo durante mi estancia.

A mis asesores Dr. Alfredo Reyes y Dra. Griselda Abarca por el apoyo incondicional, paciencia, consejos y orientación que me brindaron para culminar con este paso de mi carrera profesional, Muchas Gracias.

CONTENIDO

Resumen	VII
Abstract.....	VIII
Objetivos	IX
Justificación.....	XI
1 Introducción.....	1
1.1 Métodos para evaluación de pasos.....	2
1.2 Estado del arte.....	3
1.3 Conclusiones del capítulo.....	7
2 Aspectos teóricos.....	9
2.1 Medición de vibraciones.....	9
2.2 Parámetros de las pisadas.....	10
2.2.1 Parámetros característicos.....	11
2.2.2 Parámetros estadísticos.....	13
2.3 Redes neuronales.....	14
2.3.1 Neurona artificial.....	15
2.3.2 Redes neuronales multicapa.....	16
2.3.3 Uso de redes neuronales para clasificación.....	17
2.4 Clasificador neurodifuso adaptable con modificadores lingüísticos (ANFC-LH) ...	18
2.5 Métricas para evaluar la clasificación.....	20
2.6 Reducción de dimensionalidad.....	21
2.7 Conclusiones del capítulo.....	22
3 Diseño.....	23
3.1 Adquisición de la base de datos.....	23
3.1.1 Protocolo experimental.....	24
3.1.2 Selección del sensor.....	25
3.1.3 Montaje del sistema y pruebas de campo.....	31
3.1.4 Transmisión y recepción de datos.....	34
3.2 Procesamiento y almacenamiento de datos.....	35
3.3 Extracción de parámetros.....	36
3.4 Clasificación de datos.....	41
3.5 Conclusiones del capítulo.....	42

4	Resultados	43
4.1	Selección del método de clasificación (pruebas preliminares)	45
4.1.1	Clasificación por edad.....	45
4.1.2	Clasificación por IMC.....	48
4.1.3	Clasificación por tipo de caminata	50
4.2	Clasificaciones finales	53
4.2.1	Clasificación por edad.....	55
4.2.2	Clasificación por género	58
4.2.3	Clasificación por IMC.....	60
4.2.4	Clasificación por tipo de caminata	62
4.3	Pruebas adicionales	64
4.4	Conclusiones del capítulo	65
5	Conclusiones generales.....	67
5.1	Trabajo a futuro	69
6	Referencias.....	71
7	Anexos.....	77
	Anexo A	77
	Anexo B	78
	Anexo C	80
	Anexo D	81
	Anexo E.....	85
	Anexo F.....	86
	Anexo G	87
	Anexo H	90
	Anexo I.....	91
	Anexo J	92
	Anexo K.....	93

ÍNDICE DE FIGURAS

Figura 1-1. Métodos de evaluación A. Uso de cámaras y micrófonos[14] B. Uso de acelerómetro triaxial[5] C. Uso de celular e IMU[15] D. Uso de acelerómetro y giroscopio[16].	3
Figura 2-1 Estructura de acelerómetro MEMS con transducción capacitiva	10
Figura 2-2 Parámetros característicos de las pisadas (señal obtenida a partir de la caminata de uno de los sujetos de estudio)	11
Figura 2-3 Estructura básica de neurona artificial	16
Figura 2-4 Estructura de red neuronal multicapa	17
Figura 2-5 Arquitectura de ANFC-LH (Modificada de [39])	20
Figura 3-1 Diagrama a bloques del sistema	23
Figura 3-2 Etapas de la adquisición de la base de datos	24
Figura 3-3 Ancho de banda de respuesta en frecuencia de un acelerómetro (Modificada de [45])	26
Figura 3-4 Señal del acelerómetro ADXL320 durante una caminata de prueba.	28
Figura 3-5 Base de resina epóxica A. Montaje de la base B. Encapsulado del sensor	32
Figura 3-6 Ejes coordenados, orientación y posición del sensor	32
Figura 3-7 Pista de medición	33
Figura 3-8 Diagrama de flujo del microcontrolador	35
Figura 3-9 Diagrama de flujo de procesamiento y almacenamiento de datos	36
Figura 3-10 Diagrama de flujo de extracción de parámetros	37
Figura 3-11 Señal de las pisadas A. Original B. Modificada con referencia a cero y filtro pasa bajas	38
Figura 3-12 Ejemplo de medición de prominencia en la señal de una pisada	39
Figura 3-13 Esquemas de A. Red neuronal multicapa B. Red neuronal multicapa con softmax	42
Figura 4-1 Mediciones de aceleración en A. Eje X B. Eje Y C. Eje Z	43
Figura 4-2 Espectro de frecuencias de la señal generada por las pisadas de cinco personas A. Gráfica en g^2/Hz B. Gráfica en dB	44
Figura 4-3 Resultado de la clasificación de edad A. Red neuronal multicapa B. Matriz de confusión	46
Figura 4-4 Resultado de la clasificación de edad A. Red neuronal multicapa con función de activación softmax B. Matriz de confusión	47
Figura 4-5 Resultado de la clasificación de edad A. Clasificador neurodifuso adaptable con modificadores lingüísticos B. Matriz de confusión	47
Figura 4-6 Resultado de la clasificación de IMC A. Red neuronal multicapa B. Matriz de confusión	49
Figura 4-7 Resultado de la clasificación de IMC A. Red neuronal multicapa con función de activación softmax B. Matriz de confusión	49
Figura 4-8 Resultado de la clasificación de IMC A. Clasificador neurodifuso adaptable con modificadores lingüísticos B. Matriz de confusión	50
Figura 4-9 Resultado de la clasificación de tipo de caminata A. Red neuronal multicapa B. Matriz de confusión	51

Figura 4-10 Resultado de la clasificación de tipo de caminata A. Red neuronal multicapa con función de activación softmax B. Matriz de confusión	51
Figura 4-11 Resultado de la clasificación de tipo de caminata A. Clasificador neurodifuso adaptable con modificadores lingüísticos B. Matriz de confusión.....	52
Figura 4-12 Resultado de la clasificación por edad con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D	56
Figura 4-13 Validación de clasificación por edad *Posible sujeto mal clasificado.....	57
Figura 4-14 Resultado de la clasificación por género con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D	59
Figura 4-15 Validación de clasificación por género.....	59
Figura 4-16 Resultado de la clasificación por IMC con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D	61
Figura 4-17 Validación de clasificación por IMC *Posible sujeto mal clasificado	61
Figura 4-18 Resultado de la clasificación por tipo de caminata con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D	63
Figura 4-19 Validación de la clasificación por tipo de caminata	63
Figura 4-20. Resultados de pruebas adicionales (*Sujeto mal clasificado).....	64
Figura 7-1 Conjuntos difusos para clasificador de edad con ANFC-LH	87
Figura 7-2 Base de reglas para clasificador de edad con ANFC-LH	87
Figura 7-3 Conjuntos difusos para clasificador de IMC con ANFC-LH.....	88
Figura 7-4 Base de reglas para clasificador de IMC con ANFC-LH.....	88
Figura 7-5 Conjuntos difusos para clasificador de tipo de caminata con ANFC-LH	89
Figura 7-6 Base de reglas para clasificador de tipo de caminata con ANFC-LH	89

ÍNDICE DE ECUACIONES

Ecuación 1	12
Ecuación 2	12
Ecuación 3	12
Ecuación 4	14
Ecuación 5	14
Ecuación 6	14
Ecuación 7	14
Ecuación 8	14
Ecuación 9	14
Ecuación 10	14
Ecuación 11	14
Ecuación 12	16
Ecuación 13	17
Ecuación 14	31
Ecuación 15	31
Ecuación 16	54

ÍNDICE DE TABLAS

Tabla 1: Comparación de artículos en el área de estudio (*invasiva, **no invasiva).....	6
Tabla 2 Parámetros estadísticos en el dominio del tiempo y la frecuencia	14
Tabla 3 Métricas para evaluar clasificaciones.....	21
Tabla 4 Comparación de sensores analógicos	27
Tabla 5 Comparación de sensores digitales.....	29
Tabla 6 Comparación de resultados de pruebas de clasificación preliminares empleando cada método.	53
Tabla 7 Características y resultados de las clasificaciones finales	65

RESUMEN

Se presenta un sistema diseñado para monitorear los pasos de una persona, con el objetivo de determinar parámetros característicos y estadísticos de su caminata. Este enfoque no invasivo utiliza un acelerómetro capacitivo comercial de bajo costo para detectar las vibraciones causadas por cada paso mientras la persona camina sobre el suelo. El sistema captura las señales del acelerómetro, que luego son procesadas para obtener diferentes parámetros de la señal (como la duración del paso, cadencia, duración de la zancada, curtosis, asimetría, etc.), proporcionando información sobre cada sujeto en estudio. La información recopilada se almacena en una base de datos, y en este trabajo se emplean redes neuronales artificiales (RNA) para clasificar tipos o estilos de marcha, así como para identificar el género, la edad y el índice de masa corporal (IMC) de la persona. Con la implementación de clasificadores, las características físicas pueden agruparse, enfocándose potencialmente en diagnósticos o identificaciones biométricas basadas en los datos recabados. Finalmente, se presentan los resultados obtenidos de pruebas realizadas en 30 voluntarios, verificando el rendimiento del acelerómetro y la efectividad del algoritmo, con porcentajes de precisión de hasta el 99.2% en la clasificación. Los resultados muestran un alto nivel de coincidencia y son prometedores para la futura mejora del sistema.

Palabras Clave: Acelerómetro capacitivo, Vibración, Inteligencia artificial, Análisis de pisadas, Actividad humana.

ABSTRACT

A system designed for monitoring the footsteps of a person is presented, aimed at determining characteristic and statistical parameters of the individual's gait. This non-invasive approach utilizes a low-cost commercial capacitive accelerometer to sense the vibrations caused by each step as an individual walks on the floor. The system captures signals from the accelerometer, which are then processed to obtain different signal parameters (such as step duration, cadence, stride duration, kurtosis, skewness, etc.), providing information about each subject under study. The collected information is stored in a database, and artificial neural networks (ANN) are employed in this report to classify types or styles of walking, as well as to identify the person's gender, age, and body mass index (BMI). With the implementation of classifiers, physical characteristics can be grouped, potentially focusing on diagnoses or identifications based on specific data. Finally, the results obtained from tests performed on 30 volunteers are presented, verifying the accelerometer's performance and the algorithm's effectiveness, with accuracy percentages up to 99.2% for classification. The results show a high level of coincidence and are promising for the future improvement of the system.

Keywords: Capacitive accelerometer, Vibration, Artificial intelligence, Footprint analysis, Human activity.

OBJETIVOS

Objetivo general

Realizar de manera no invasiva la captura de la señal de la caminata de una persona con la ayuda de un acelerómetro, dentro de un espacio de vida cotidiano, para procesar la señal y determinar los parámetros característicos del movimiento de una persona.

Objetivos específicos

- Diseñar un montaje que permita hacer pruebas de campo de tal manera que el sensor se encuentre en contacto directo con el suelo y que no sea necesario que el usuario porte el sensor.
- Realizar mediciones para obtener las señales de los pasos (vibraciones en el suelo) mediante un acelerómetro.
- Crear una base de datos a partir de las mediciones realizadas a diferentes sujetos de estudio, garantizando su integridad física.
- Analizar y procesar la base de datos para extraer parámetros estadísticos y característicos de las vibraciones producidas por las pisadas.
- Implementar un algoritmo de inteligencia artificial que permita identificar y clasificar características o comportamientos específicos de las pisadas, lo que proporcionará una base para futuras investigaciones relacionadas con la medición y clasificación de parámetros biométricos.

JUSTIFICACIÓN

En cuestiones de salud pública, existen diferentes maneras de evaluar a los pacientes, dependiendo de los recursos disponibles y del objetivo de la evaluación. Entre éstas, en años recientes se han desarrollado dispositivos y sistemas comerciales basados en sensores piezoeléctricos como en el caso del trabajo presentado en [1], utilizando cámaras [2], [3] y micrófonos [4], que ayudan a monitorear la actividad física del individuo a evaluar. Sin embargo, el costo de estos sistemas (alrededor de 1800 dólares) puede llegar a ser una limitante para su uso, por lo que los elementos del sistema propuesto deberán ser de bajo costo y accesible ya que puede ser implementado en cualquier habitación.

Otra de las características de estos sistemas complejos es que el sujeto de estudio debe portar el o los sensores en el cuerpo, es decir, son invasivos, o deben realizar las pruebas dentro de un laboratorio con una instalación especializada. Algunos reportes de sistemas invasivos se pueden encontrar en [5], [6], [7], [8], estos sistemas pueden inducir modificaciones en el comportamiento del paciente, lo que podría ocultar características representativas de alguna patología. Asimismo, un estudio reciente que se hizo en [9], evaluó la aceptación de los adultos a utilizar dispositivos digitales para el monitoreo de la movilidad. Tomando en consideración el tiempo que el dispositivo debe ser portado para el registro de datos fiables y cómo se emplean los datos obtenidos después del monitoreo del paciente, al parecer, crea un conflicto entre la expectativa del paciente y la utilidad del dispositivo. Además, la comodidad de llevar estos dispositivos es motivo de preocupación, con problemas como sensaciones de presión o irritaciones de la piel en las zonas donde se colocan, sobre todo en personas de edad avanzada, lo que indica que todavía hay retos importantes que abordar para la aceptación general de los dispositivos digitales corporales.

Incluso si los sensores se colocan dentro de una habitación acondicionada en una clínica u hospital, hay situaciones como aquellas en las que el paciente sabe que está siendo evaluado, lo que puede inducir un falso comportamiento debido a un sentimiento de intimidación por la observación crítica y cercana del personal y de los dispositivos utilizados, haciendo de la evaluación una experiencia incómoda.

Para hacer frente a estas preocupaciones, el sistema propuesto trabajará con un enfoque no invasivo, es decir, la persona no portará un dispositivo para realizar las pruebas y su privacidad no se verá comprometida. Sin embargo, dado que este trabajo es un primer acercamiento a la clasificación de características biométricas, se controlarán las condiciones bajo las cuales se realiza el estudio. El cual consiste en medir las vibraciones en el suelo producidas por las pisadas del paciente. En este sentido, la realización de mediciones en entornos cotidianos comunes (o en cualquier espacio distinto de los laboratorios altamente equipados) ofrece una opción flexible, robusta y sencilla. Esto permitiría medir y analizar la variabilidad de los pasos, que puede relacionarse con la salud personal mostrando posibles inquietudes que pueden dar lugar a acciones preventivas. Sin embargo, con todo lo mencionado anteriormente no implica que el sistema propuesto en este trabajo reemplace a un laboratorio especializado.

Finalmente, el monitoreo de la actividad física (caminar de una persona) puede servir como herramienta en la evaluación del estado de salud, principalmente entre gente de edad avanzada y/o discapacitados, así como también para evaluaciones deportivas, rehabilitación física, reconocimiento humano para cuestiones de seguridad, empleando algoritmos de Inteligencia Artificial (IA).

1 INTRODUCCIÓN

Un área de la tecnología de micromecanizado que ha experimentado un crecimiento considerable es la de los Sistemas Microelectromecánicos (MEMS, del significado en inglés, Micro Electro Mechanical Systems) que abarca una amplia variedad de dispositivos que combinan sistemas microelectrónicos [10].

A partir de su aparición, los MEMS han tenido un continuo y extenso desarrollo, y se mueven junto con las tecnologías de la información y las comunicaciones, con la integración de circuitos, módulos de comunicación inalámbrica y redes de sensores inalámbricos, lo que permite el diseño de sistemas compactos, de alto rendimiento, de baja potencia y soluciones de bajo costo para una amplia gama de aplicaciones [11], [12].

Sus aplicaciones se pueden ver en diferentes aspectos de la vida cotidiana e industrial, lo que implica la integración y el desarrollo continuo de tecnologías MEMS inteligentes, capaces de fusionar sus capacidades de medición con otras características, como el procesamiento de señales y la elaboración de inteligencia embebida [13].

Tomando en cuenta lo anterior, en lo que se refiere al dominio del cuidado de la salud, representa uno de los sectores más atractivos para contribuir al desarrollo tecnológico de sistemas de medición para variables fisiológicas como señales del corazón, presión arterial, temperatura, etc., utilizadas en el diagnóstico de enfermedades específicas, así como también, sistemas para atender a la población de adultos mayores, a pacientes con enfermedades crónicas o en rehabilitación.

En lo que respecta a la adquisición de señales fisiológicas, en específico para la evaluación de pasos de una persona, éstas pueden ser obtenidas mediante diferentes dispositivos que pueden ser: cámaras, micrófonos, sensores piezoeléctricos para medir la presión plantar, así como acelerómetros o giroscopios.

Dentro de las ventajas asociadas con el uso de estos dispositivos es que sirven como herramienta para brindar una evaluación cuantitativa y objetiva [13], sin embargo, no sustituye la interpretación de un profesional de la salud. Esto puede ser útil para detectar pequeñas diferencias entre una evaluación y otra de extremidades inferiores.

1.1 Métodos para evaluación de pasos

Para poder tener un poco más de contexto acerca de los diferentes métodos que existen para evaluar los pasos de una persona, se presentarán algunos de ellos encontrados en la literatura. El primer método[14] consiste en un montaje de cámaras al frente y en los laterales, así como micrófonos dentro de un ambiente controlado para realizar el monitoreo de las pisadas de una persona como se muestra en la Figura 1-1 A. Un segundo método[5] es como el que se muestra en la Figura 1-1 B en el cual la persona camina en una cinta de correr controlada por computadora y las señales de aceleración de la marcha son capturadas a través de un acelerómetro triaxial colocado sobre la columna de la persona a estudiar. El tercer método [15] consiste en hacer uso de un acelerómetro y giroscopio integrados en un celular, el cual porta la persona en la mano mientras camina en línea recta, así como una Unidad de Medida Inercial (IMU) colocada en el pie (ver Figura 1-1 C). Finalmente, en la Figura 1-1 D se muestran dispositivos como acelerómetros y giroscopios que se colocan sobre el cuerpo de la persona bajo estudio a la altura de la cintura [16] (en este caso sobre una playera acondicionada con todos los dispositivos necesarios para la recolección de los datos); dicha playera se porta durante cierto lapso para recopilar toda la información.

Como se pudo observar, en los métodos anteriores existen diferentes maneras de montar estos sensores, ya sea colocándolos sobre el paciente en diferentes partes del cuerpo (cintura, tobillos, columna, etc.) o posicionando cámaras, micrófonos o sensores de presión plantar dentro de un ambiente controlado como un laboratorio. Sin embargo, existe la posibilidad de colocar acelerómetros sobre el suelo para

detectar las vibraciones ocasionadas por cada pisada, y de esta manera obtener una señal que muestra las perturbaciones del suelo.

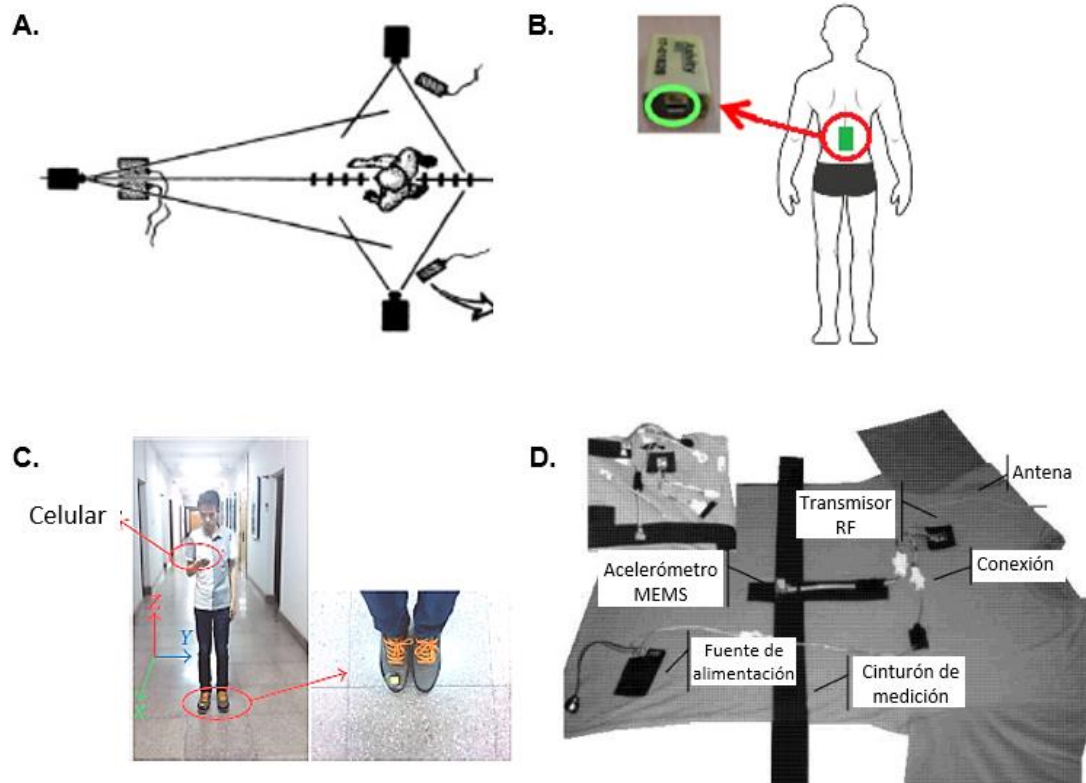


Figura 1-1. Métodos de evaluación A. Uso de cámaras y micrófonos[14] B. Uso de acelerómetro triaxial[5] C. Uso de celular e IMU[15] D. Uso de acelerómetro y giroscopio[16].

1.2 Estado del arte

Se consultaron diferentes artículos relacionados con el sistema propuesto para detectar y monitorear la actividad física y en lo que respecta a temas de prevención de la salud se ha sugerido el uso de este tipo de sistemas, junto con el procesamiento de la señal derivada de cada paso, para evaluar a personas con discapacidad [17], lesiones deportivas, personas mayores [18], obesidad, enfermedad de Parkinson [13], etc. Este monitoreo de la actividad física puede llevar a establecer recomendaciones o sugerir estrategias médicas preventivas o correctivas, pero también, en función de los resultados, puede utilizarse para

establecer una rutina de identificación biométrica [19], [20], por ejemplo, para cuestiones de seguridad de la propiedad privada.

Se han descrito varios enfoques con objetivos diversos que buscan principalmente identificar características específicas de enfermedades y anomalías en los patrones de comportamiento, considerando, entre otros fines, la prevención de la evolución de determinadas enfermedades o la posibilidad de un diagnóstico precoz. Esta inquietud ha dado lugar, de igual manera, a dispositivos comerciales basados en tapetes o alfombras electrónicas como GAITRite [21] y ProtoKinectics Zeno [22], y basados en acelerómetros y giroscopios portátiles como DynaPort 7 [23]. Además, de dispositivos como los relojes inteligentes son otra opción dentro de los dispositivos disponibles que se ofrecen para el monitoreo de la salud. Se pueden considerar como un dispositivo que puede ofrecer datos relacionados con el estado de salud del usuario, pero con el riesgo de que el usuario pase por alto y desestime la interpretación profesional de los datos, ya que se está utilizando casi como una guía de estilo de vida, a pesar de la inutilidad de la amplia gama de indicadores de salud que ofrece.

Por otra parte, el trabajo presentado hizo uso de redes neuronales artificiales para identificar tipos de caminata (esto se refiere a modificaciones en el comportamiento de los pasos de una persona), y para determinar las características físicas de los participantes (edad, género e índice de masa corporal). Algunas aplicaciones de clasificación e identificación se mencionan en algunos trabajos como [24], [25]. Sin embargo, en estas aplicaciones se identifican actividades humanas como: caminar, pararse, sentarse, acostarse, agacharse, caerse, andar en bicicleta, entre otras. Además, estas aplicaciones se centran en el desarrollo de un sistema de salud basado en un hogar inteligente para las personas mayores y discapacitadas.

El objetivo de este trabajo es evaluar el rendimiento de un acelerómetro comercial y económico como sensor de la marcha. Nuestro enfoque consiste en diseñar un sistema asequible de adquisición y almacenamiento de datos, seguido de un análisis

mediante redes neuronales artificiales (RNA) para clasificar e identificar los tipos de marcha, el sexo, la edad y el índice de masa corporal (IMC) de los individuos. En comparación con los estudios referenciados en [24], [26], este trabajo no sólo obtiene parámetros característicos y estadísticos de las pisadas, sino que también logra clasificaciones de diversos atributos físicos.

Como se puede apreciar en la Tabla 1, diversos estudios se han centrado en la evaluación de la marcha para extraer distintos tipos de información, como la longitud del paso, el tipo de movimiento (caminar, correr, sentarse, tumbarse, etc.) y la velocidad de la pisada. Estos estudios han empleado diversos métodos de medición, como cámaras, micrófonos, sensores piezoeléctricos y sensores de presión. Además, la colocación de los sensores en estos estudios varía significativamente, desde tapetes, en diferentes partes del cuerpo hasta paredes y otras superficies. Del mismo modo, hay trabajos más recientes que implican el uso de unidades de medición inercial, que se llevan en distintas partes del cuerpo. Cuyo objetivo es reconocer la actividad física o identificar las fases de la marcha mediante la aplicación de inteligencia artificial.

Referencia	Tipo de dispositivo utilizado	Lugar de colocación del dispositivo	Parámetros obtenidos	Uso de redes neuronales	Tipo de aplicación	Resultados
Giorgi, et al. [27]*	Teléfono y reloj inteligentes	Bolsillo del pantalón y muñeca	Aceleración y velocidad angular	Red neuronal recurrente (RNN)	Reconocimiento de actividad humana (caminar, subir escaleras, bajar escaleras, sentarse, pararse y recostarse)	Exactitud de hasta el 98,4%.
Farah, et al. [28]*	IMU (Unidad de masa inercial)	En la rodilla y pierna	Respuesta de carga, empuje, balanceo, balanceo final	Modelo logístico de árbol de decisión (LMT) Clasificador y verificación y corrección de secuencias de transición (TSVC)	Identificar las fases de la marcha sobre diferentes superficies y a distintas velocidades.	La exactitud es del 90,60% con LMT y aumenta hasta el 98,61% con TSVC.

Capítulo 1: Introducción

Recher, et al. [29] *	IMU (Unidad de masa inercial)	En el tórax, pelvis, parte superior e inferior de la pierna derecha/izquierda, pie derecho/izquierdo	Promedio y desviación estándar de la aceleración, la velocidad angular y el campo magnético	Clasificador jerárquico ponderado	Optimización de un sistema de reconocimiento de actividades (sentado, de pie, transición (sentado a de pie, de pie a sentado), pasos laterales, escaleras y desplazamientos).	La selección de la ubicación de los sensores en el cuerpo pasa de 5 sensores a 3.
Ekimov & Sabatier [1]**	Acelerómetro piezoeléctrico, cámara digital y micrófono	En el suelo	Parámetros de presión acústica y frecuencia	N/A	Análisis del estilo de andar (normal, suave y sigiloso)	Los espectros de las respuestas de vibración se encuentran en la gama de frecuencias de 20 Hz-16,5 kHz
Walker & Goldman [3]**	Sensores acústicos, sísmicos, cámara digital, acelerómetros y sensores de campo eléctrico	En el suelo y sobre tripie	Parámetros de tiempo	N/A	Control de la actividad humana (hacer la comida, ir a por café, abrir y cerrar la puerta del refrigerador)	Señales de sensores acústicos, sísmicos, acelerómetros y de campo electrónico. Resultados no numéricos.
Okuda, et al. [6]*	Acelerómetro	A nivel de la columna vertebral L4 de la persona	Velocidad y aceleración del paso	N/A	Diferenciar entre una persona con enfermedad de Parkinson y una persona sana	La velocidad de la marcha en los pacientes con enfermedad de Parkinson fue significativamente más lenta que en los adultos mayores sanos ($P < 0,05$).
Lee, et al. [24]**	Acelerómetro	En la parte inferior de la pared	Parámetros estadísticos	N/A	Estimación del nivel de actividad física en interiores	N/A
Palumbo, et al. [25]*	Acelerómetro	5 portables (en el pecho, en los brazos y en los tobillos) y 4 sensores de entorno	Parámetros de tiempo	Redes neuronales recurrentes	Actividad de reconocimiento (caminar, levantarse, sentarse, tumbarse, agacharse, caerse y montar en bicicleta)	En este trabajo sólo dos de las siete actividades se prueban logrando un 91,1% de exactitud.
Karantonis, et al. [8]*	Acelerómetro	En la cintura	SMA (área de magnitud de señal) de las aceleraciones del cuerpo.	N/A	Reconocimiento de la actividad (caminar lento, caminar normal, caminar rápido, levantarse, sentarse, tumbarse y caerse)	Porcentajes de exactitud de hasta el 96,7% (para la clasificación del tipo de caminata)

*Tabla 1: Comparación de artículos en el área de estudio (*invasiva, **no invasiva).*

Debido a la diversidad de metodologías y aplicaciones, resulta complejo hacer comparaciones directas con los trabajos aquí presentados. Un área en la que sí es posible hacer algunas comparaciones es en la exactitud de la clasificación del tipo de

marcha. Es evidente que sólo unos pocos estudios son parcialmente comparables con el trabajo presentado. En particular, este trabajo se distingue por su enfoque, que emplea una arquitectura de red neuronal para clasificar características físicas como la edad, el sexo y el IMC, así como por la metodología adoptada para clasificar los estilos de caminar.

Esta tabla ayuda a comparar los diferentes trabajos desarrollados con el que aquí se presenta, y éste es momento para recordar los principales objetivos del sistema propuesto, que son los de diseñar un sistema no invasivo, el cual podrá ser usado en un ambiente cotidiano que reduzca comportamientos forzados de parte del sujeto bajo estudio, que podrían provocar datos alejados de la realidad física del sujeto, y que además sea de bajo costo, al no emplear elementos caros, sofisticados y especializados como los que se instalan dentro de un consultorio, hospital o laboratorio de estudios clínicos. Además, se propone el uso de algoritmos basados en la Inteligencia Artificial, apoyados en arquitecturas de Redes Neuronales Artificiales, cuya eficiencia para clasificar es evaluada. De tal manera que sirva de aportación para configurar investigaciones más profundas y variadas, cosa que el tema lo permite, ya que existen diferentes vertientes que se le pueden dar a investigaciones como esta.

1.3 Conclusiones del capítulo

Este capítulo se realizó con la finalidad de tener un contexto general del desarrollo de este tipo de sistemas, además de mostrar posibles aplicaciones de estos, las cuales son de diferente índole tanto en el sector de la salud como en seguridad. Por otra parte, se realizó una búsqueda bibliográfica para mostrar las características principales (tipo de dispositivo utilizado, lugar de colocación del dispositivo, tipo de aplicación, etc.) de trabajos similares al sistema realizado en esta tesis que se presentará en los siguientes capítulos.

2 ASPECTOS TEÓRICOS

2.1 Medición de vibraciones

Hablando brevemente acerca de vibraciones, para que éstas sean generadas es necesario una fuente de energía que puede ser un terremoto, una explosión, una antena que transmite ondas electromagnéticas, entre otras [30]. En el caso del trabajo presentado, la fuente son los impactos del pie de una persona sobre el suelo. Dicha fuente genera una onda que se propaga a través del medio, en este caso el suelo.

Con respecto a su propagación es importante mencionar que según la teoría clásica de placas (dado que se emplearán las vibraciones del suelo, y éste se representa con ellas), la vibración en placas presenta dos componentes de onda: la componente en el plano u onda longitudinal (llamada onda P) y la componente fuera del plano u onda transversal (llamada onda S) [30]. En el caso de este trabajo es de especial interés la componente transversal para detectar los impactos de las pisadas, ya que dicha componente posee la mayor cantidad de energía de la onda producida en comparación con la energía de la componente longitudinal [31]. Esta consideración es importante, ya que esto definirá cuál de los tres ejes de acción existentes dentro de la estructura del acelerómetro, se utilizará para el estudio, como se verá en la sección 3.1.3.

Por otra parte, enfocándose en la medición de vibraciones, la forma más común para medirlas es emplear sensores de vibración, los cuales pueden ser de desplazamiento o de no contacto (por medio de campos magnéticos), velocímetros o acelerómetros [32]. Todos estos miden el movimiento en uno o varios ejes dependiendo del tipo de transductor empleado.

En el caso de los acelerómetros capacitivos, su principio de funcionamiento consiste en monitorear el desplazamiento de una masa de prueba sostenida por resortes. Dicha masa móvil tiene peines integrados, que se empalman con otros peines que

permanecen estáticos para formar entre ellos capacitores variables ($C1$ y $C2$) como se muestra en la Figura 2-1. De tal manera que, cuando una fuerza externa (debido a la aceleración) actúa sobre la masa móvil, ésta se mueve y provoca un cambio en la distancia entre los peines móviles y los estáticos, generando un cambio en la capacitancia. Esta variación puede ser utilizada para medir el cambio correspondiente de voltaje, el que a su vez se emplea para obtener la aceleración en un eje. En el caso del sistema propuesto, se mide la aceleración debido a las vibraciones en el suelo en el eje perpendicular a éste.

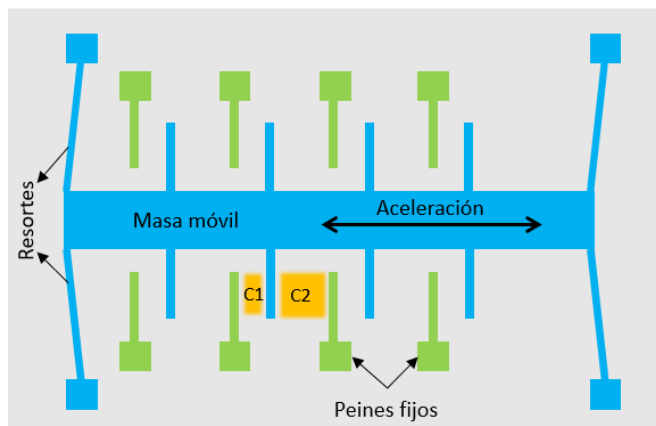


Figura 2-1 Estructura de acelerómetro MEMS con transducción capacitiva

2.2 Parámetros de las pisadas

Algunos de los parámetros que pueden obtenerse de la señal de aceleración que representa una caminata son los que se mencionan a continuación, de los cuales cuatro son parámetros característicos [33] y ocho son parámetros estadísticos [34]. Estos parámetros son de gran utilidad ya que, como se demostrará, pueden ayudar a detectar diferencias entre todos los sujetos de estudio, e incluso se pueden detectar sutiles cambios en el modo de caminar de un mismo sujeto de estudio, lo cual puede ser indicativo de algún problema físico.

2.2.1 Parámetros característicos

La Figura 2-2 muestra un ejemplo de la señal de cuatro pisadas, la cual fue adquirida con el acelerómetro, donde cada una de las pisadas comienza con un pico máximo. Uno de los primeros parámetros característicos a determinar, a partir de esta señal, es la duración de pisadas (S), que consiste en el tiempo transcurrido desde el pico máximo (etiquetado como Max) hasta el pico mínimo (etiquetado como Min) de la pisada, como se muestra en la Figura 2-2, donde están etiquetadas como S_i y S_d , para pie izquierdo y derecho respectivamente; otro parámetro importante es la duración de la zancada (T), que es la diferencia de tiempo ($IP-S$) como se muestra en la Figura 2-2, donde están etiquetados como T_i y T_d , para pie izquierdo y derecho, respectivamente.

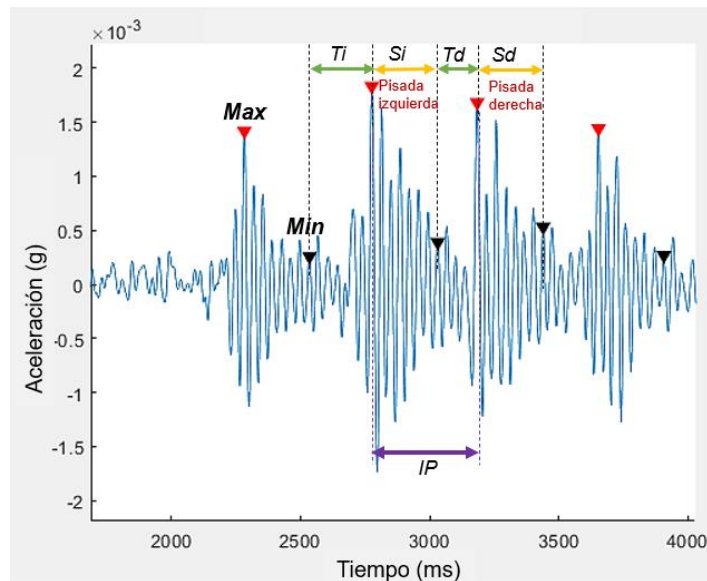


Figura 2-2 Parámetros característicos de las pisadas (señal obtenida a partir de la caminata de uno de los sujetos de estudio)

El tercer parámetro característico es la energía de la señal (E) de cada pisada, la cual considera como energía de la señal al área bajo la curva desde el punto máximo hasta el punto mínimo, o equivalentemente, la integral de la señal. Además, de manera cualitativa se asume que la energía que emplea un individuo al pisar es

proporcional a la energía de la señal producida por la vibración medida por un acelerómetro MEMS.

Retomando que la energía de la señal se considera como la integral de la señal, entonces se tiene que debido a que se restan los valores que se encuentran por encima de la media (en el eje de aceleración) de los que se encuentran debajo de ésta, se considera el cuadrado de la señal, de tal forma que los valores serán siempre positivos y no se cancelarán entre sí. Considerando que es una señal discreta (esto por el muestreo característico de un acelerómetro digital, como el empleado en este trabajo), lo que corresponde para el cálculo de la energía, entonces se hace la sumatoria en lugar de la integral, como se muestra en la Ecuación 1 [24], que como se puede ver en la Figura 2-2, se define que una pisada comienza desde el punto máximo (*Max*) y termina en el punto mínimo (*Min*), y donde n es el número de muestra y $x(n)$ es su respectivo valor de aceleración.

Finalmente, la cadencia de la pisada, que es el número de pisadas por segundo, tanto para el pie derecho (Vd) como para el pie izquierdo (Vi), están dadas por la Ecuación 2 y la Ecuación 3 respectivamente [24].

$$E = \sum_{n=Max}^{Min} |x(n)|^2 \quad \text{Ecuación 1}$$

$$Vd = 1/[Td + Sd] \quad \text{Ecuación 2}$$

$$Vi = 1/[Ti + Si] \quad \text{Ecuación 3}$$

2.2.2 Parámetros estadísticos

Los parámetros estadísticos en el dominio del tiempo y la frecuencia que se extraen de la señal de aceleración de cada paso y sus ecuaciones se muestran en la Tabla 1, donde $x(n)$ es el valor de aceleración de cada muestra, que tiene valores de $n = 1, 2, \dots, N$. Donde N es el número total de muestras por cada pisada. Asimismo, $s(k)$ es el espectro para el valor de frecuencia $k = 1, 2, \dots, K$. Donde K es el número de líneas del espectro.

El primer parámetro a definir es la desviación estándar (Ecuación 5), que se utiliza para medir la dispersión del conjunto de datos con respecto a la media (véase la Ecuación 4); a continuación se define la raíz cuadrática media (Ecuación 6), que es la raíz cuadrada de la media aritmética de los cuadrados de los valores; también es necesario definir la curtosis (Ecuación 7), que determina el grado de concentración que presentan los valores de una variable en torno a la zona central de la distribución de frecuencias; también es necesario definir la asimetría estadística (Ecuación 8), la cual permite establecer el grado de simetría (o asimetría) que presenta una distribución de probabilidad de una variable aleatoria, sin necesidad de realizar su representación gráfica; es necesario definir también a la desviación media absoluta (Ecuación 9), que es una medida para calcular cuánto varían los valores de un conjunto de datos con respecto a la media; sigue la definición de la media de la frecuencia dada por la Ecuación 10; por otra parte la mediana de la frecuencia, la cual, si todos los datos se ordenan de menor a mayor, es el valor que ocupa la posición central; y finalmente se obtiene la media de la potencia, que corresponde a la suma de los cuadrados absolutos de las muestras de dominio de tiempo dividida entre la longitud de la señal o, de forma equivalente, el cuadrado de su valor cuadrático medio (RMS) dado por la Ecuación 11.

Parámetro	Ecuación	
Media	$T_1 = \frac{\sum_{n=1}^N x(n)}{N}$	Ecuación 4
Desviación estándar	$T_2 = \sqrt{\frac{\sum_{n=1}^N (x(n) - T_1)^2}{N - 1}}$	Ecuación 5
Raíz cuadrática media	$T_3 = \sqrt{\frac{\sum_{n=1}^N (x(n))^2}{N}}$	Ecuación 6
Curtosis	$T_4 = \frac{\sum_{n=1}^N (x(n) - T_1)^4}{(N - 1)T_2^4}$	Ecuación 7
Asimetría estadística	$T_5 = \frac{\sum_{n=1}^N (x(n) - T_1)^3}{(N - 1)T_2^3}$	Ecuación 8
Desviación media absoluta	$T_6 = \sqrt{\frac{\sum_{n=1}^N (x(n) - T_1)^2}{N - 1}}$	Ecuación 9
Media de la frecuencia	$F_1 = \frac{\sum_{k=1}^K s(k)}{K}$	Ecuación 10
Media de la potencia	$T_7 = \frac{\sum_{n=1}^N (x(n))^2}{N}$	Ecuación 11

Tabla 2 Parámetros estadísticos en el dominio del tiempo y la frecuencia

Una vez definidos los parámetros característicos y estadísticos, que serán de utilidad para la clasificación que se plantea realizar en este trabajo, a continuación, se explicarán las características de las redes neuronales artificiales, que ayudarán en la tarea de clasificación. Con estas bases, se evaluarán diferentes alternativas para definir aquella que tenga mejor desempeño, para su uso en el sistema de clasificación.

2.3 Redes neuronales

Las redes neuronales artificiales forman parte de los llamados algoritmos de Aprendizaje de Máquina (*Machine Learning*) que a su vez forman parte de la Inteligencia Artificial. Dichas redes son empleadas para reproducir algunas características de los seres humanos, como la habilidad para memorizar y asociar hechos. El elemento básico de procesamiento de estas redes se basa en la unidad fundamental del sistema nervioso humano: la neurona. Las redes neuronales artificiales están compuestas por unidades de procesamiento que intercambian

datos o información, lo que les permite aprender a través de la experiencia y extraer características que son esenciales a partir de entradas que representan información que no tiene utilidad aparente [35]. Por otra parte, hablando acerca de una de las ventajas de estas redes, es que tienen la capacidad de resolver problemas que no son linealmente separables.

En cuanto a las aplicaciones de estas redes, se tienen en diferentes áreas como en la clasificación de objetos por medio de imágenes, predicción del comportamiento de usuarios de una plataforma, reconocimiento de voz, control de producción en líneas de procesos, etc.

2.3.1 Neurona artificial

Como se ha mencionado anteriormente, el elemento fundamental de las redes neuronales es la neurona artificial, la cual cuenta con varios elementos (ver Figura 2-3): entradas(p), las cuales son el estímulo que se recibe del exterior; pesos sinápticos(w) y bias(b), a partir de los cuales se adapta la neurona al exterior y aprende de él, modificando a estos últimos elementos; cuenta también con la función de activación o transferencia; y el elemento final es la salida(a), que está dada por la Ecuación 12 [36].

Comparando el comportamiento de una neurona artificial con el de una neurona biológica la cual puede estar activa o inactiva, se puede decir que son equivalentes ya que en las neuronas artificiales tienen diferentes funciones de activación o transferencia (lineal, sigmoideal, tangente hiperbólica, etc.). Esta función de activación calcula el estado de actividad de una neurona, es decir, transforma el valor de la entrada en un valor de activación que puede tomar un valor entre $[0,1]$ o $[-1,1]$, dependiendo de la función con la que se trabaje [35].

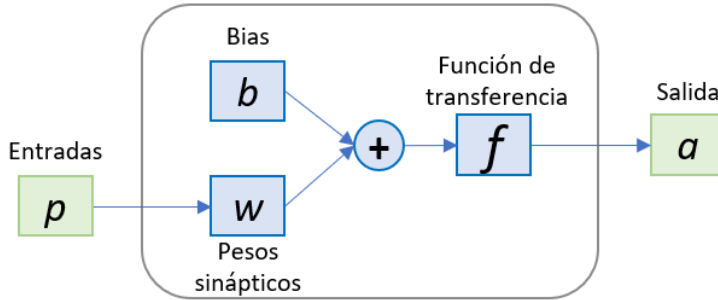


Figura 2-3 Estructura básica de neurona artificial

$$a = f(wp + b) \quad \text{Ecuación 12}$$

2.3.2 Redes neuronales multicapa

La red neuronal multicapa es aquella cuya arquitectura cuenta con varias neuronas artificiales agrupadas en diferentes niveles o capas. Los elementos básicos que componen a una red neuronal multicapa son los que se muestran en la Figura 2-4. En dicha figura se puede observar que la red está formada por neuronas interconectadas y distribuidas en diferentes capas. De las capas que se pueden distinguir son: la primera capa que es la de entrada, cuya función es recibir los datos que se desean procesar con la red; posteriormente, cuenta con la capa o capas ocultas, que son aquellas que se encuentran de manera interna en la red y no tienen contacto directo con el exterior (entrada o salida); y finalmente la capa de salida, que se encarga de entregar el resultado de la red al exterior.

Prestando especial atención a la capa de salida, su función de activación puede ser de diferentes tipos (función identidad, lineal, binaria, softmax, etc.) [35], sin embargo, se hablará un poco más acerca de la función softmax.

La función de activación softmax puede ser utilizada para representar la distribución de probabilidad sobre K diferentes posibles salidas (o clases). Se calcula mediante la Ecuación 13, donde σ toma valores reales en el rango de $[0, 1]$ y z_j es el valor del dato que entra a la función [37]. Como se puede observar de la ecuación, esta

función proporciona la distribución de probabilidades de que un dato pertenezca a cada clase sobre el total de clases existentes. La suma de las probabilidades de que el dato de entrada pertenezca a cada clase será igual a uno.

La función de activación softmax es muy utilizada en aplicaciones de clasificación multiclase [37], en el caso de estas aplicaciones la clase que presente el mayor valor de probabilidad se trata de la clase objetivo.




Figura 2-4 Estructura de red neuronal multicapa

$$\sigma(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{para } j = 1, \dots, K \quad \text{Ecuación 13}$$

2.3.3 Uso de redes neuronales para clasificación

Una de las tantas aplicaciones de las redes neuronales, es para realizar clasificaciones con dos o más clases. El objetivo de un clasificador es que al ser entrenado e ingresando datos de entrada ligeramente distorsionados o diferentes a los que se utilizaron para el entrenamiento, éste pueda reconocer y clasificar sin problemas [35].

El primer paso es construir la red neuronal, para lo cual se requiere saber el número de nodos de entrada, este número depende del número de parámetros con los que se está trabajando. Por otra parte, se debe considerar el número de nodos de salida

que corresponderá al número total de clases [38]. Posteriormente, se entrena a la red con los datos seleccionados para entrenamiento con sus respectivas clases objetivo, es decir, la clase a la que realmente pertenecen, con la cual se puede cotejar el resultado de la red y determinar si se tuvo un acierto o un error de clasificación, esta comparación se utiliza para calcular el porcentaje total de aciertos al finalizar el entrenamiento.

2.4 Clasificador neurodifuso adaptable con modificadores lingüísticos (ANFC-LH)

Aquellos sistemas que integran el uso de conjuntos difusos con redes neuronales se les conoce como sistemas neurodifusos [39]. El cerebro humano interpreta la información sensorial de manera imprecisa e incompleta, tal como la recibe de los órganos sensoriales. La teoría de conjuntos difusos ofrece un método sistemático para manejar esa información de forma lingüística, permitiendo realizar cálculos numéricos a través de etiquetas lingüísticas, definidas mediante funciones de pertenencia[40]. A diferencia de los conjuntos clásicos, un conjunto difuso no tiene límites claramente definidos y puede incluir elementos con grados parciales de pertenencia[41].

El papel de las redes neuronales en este tipo de sistema es optimizar los parámetros de las funciones de membresía y los pesos de éste. En particular, el ANFC-LH agrega una capa de modificadores lingüísticos (mas, menos, extremadamente, muy, entre otros) [39] en los conjuntos difusos, que trata de determinar cuáles características son discriminativas y cuales producen traslape entre clases para evitar usarlas. La presencia de traslapes puede provocar malas clasificaciones.

ANFC-LH se basa en un modelo difuso de tipo Sugeno de orden cero. Si se observa la arquitectura del ANFC-LH en la Figura 2-5, se tienen 7 capas las cuales son:

- La capa 1, en la cual se introducen los valores de entrada, es decir, las características o parámetros.
- La capa 2, en la cual se obtiene el grado de membresía (o pertenencia μ) de cada entrada a los conjuntos difusos.
- La capa 3, en la cual se calculan los significados secundarios (μ^p), es decir, se redefine el grado de membresía con ayuda del valor de los modificadores lingüísticos(p).
- La capa 4 que establece el grado de presencia de interacción (β) de la regla difusa para la muestra; el número total de nodos es el resultado de multiplicar el número de características por el número de salidas.
- La capa 5, en la cual se calculan las salidas ponderadas (o), y cada clase puede ser afectada por cada regla dependiendo de sus pesos (w), es decir, se realiza la defuzzificación.
- La capa 6, en la cual se normalizan las salidas de la red, ya que es necesario para que la suma de los pesos sea menor que 1.
- Finalmente, la capa 7 es la salida de la red (la clase resultante, C) y es la suma de todas las intensidades de regla.

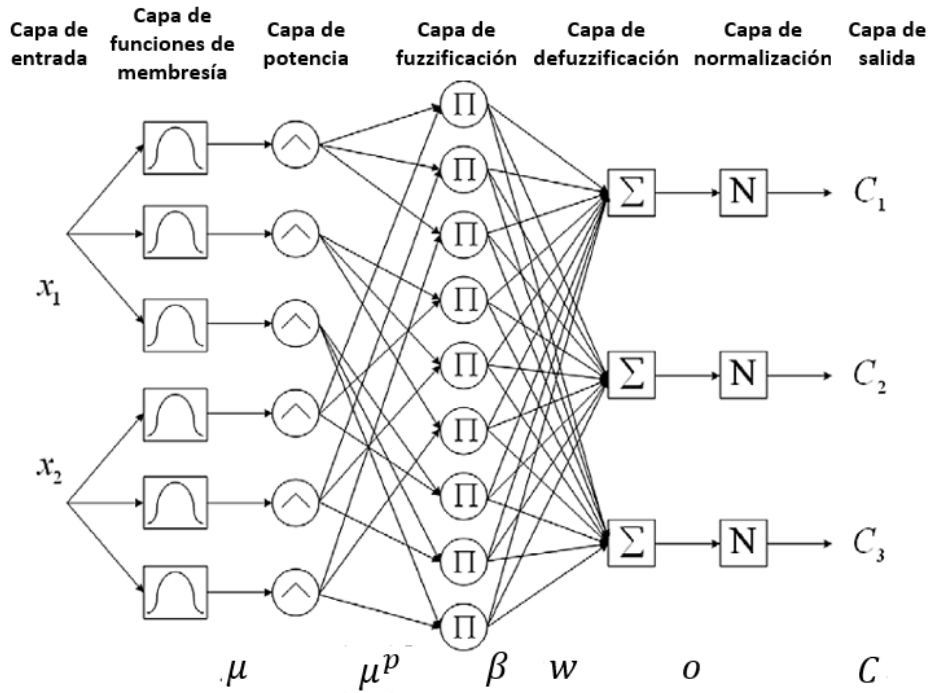


Figura 2-5 Arquitectura de ANFC-LH (Modificada de [39])

2.5 Métricas para evaluar la clasificación

Cuando se realiza una clasificación, después de entrenar el algoritmo, ordinariamente se evalúa su desempeño. Algunos de los criterios para evaluar una clasificación se presentan en [42], y sus ecuaciones se muestran en la Tabla 3. Donde N_v es el número total de vectores probados, q es el número total de clases, TP son vectores verdaderos positivos, FP son vectores falsos positivos y FN son vectores falsos negativos. El primer criterio es la exactitud (Acc), que se define como la relación entre el número de vectores clasificados correctamente y el número total de vectores probados. Por otra parte, la precisión (Pr) representa el porcentaje de vectores que se han clasificado en una clase y pertenecían realmente a ella. Exhaustividad o sensibilidad (Re), es la relación entre el número de vectores correctamente identificados como positivos y el número total de verdaderos positivos. Una vez formuladas la precisión y la exhaustividad de cada clase individual, es necesario definir estas medidas para todas las clases, es decir, la

precisión macro (Pr_{macro}) y la exhaustividad macro (Re_{macro}). Por último, el valor $F1_{macro}$ permite comparar el rendimiento combinado de precisión y exhaustividad.

Parámetro	Ecuación
Exactitud	$Acc = \frac{TP_1 + \dots + TP_q}{Nv}$
Precisión	$Pr = \frac{TP}{TP + FP}$
Exhaustividad	$Re = \frac{TP}{TP + FN}$
Precisión macro	$Pr_{macro} = \frac{Pr_1 + \dots + Pr_q}{Nv}$
Exhaustividad macro	$Re_{macro} = \frac{Re_1 + \dots + Re_q}{Nv}$
Valor F1 macro	$F1_{macro} = \frac{2 \times Pr_{macro} \times Re_{macro}}{Pr_{macro} + Re_{macro}}$

Tabla 3 Métricas para evaluar clasificaciones

2.6 Reducción de dimensionalidad

Actualmente los conjuntos de datos poseen cada vez más características o parámetros, por lo cual es necesario en algunas ocasiones emplear métodos para reducir el número de características del conjunto de datos original con la finalidad de simplificar y ayudar en la interpretación de los resultados. Cabe mencionar que esto no afecta la operación y desempeño de la red. Ordinariamente esto se utiliza ya sea para mejorar el rendimiento del sistema o para poder visualizar los resultados obtenidos, ya que conserva la estructura de los datos sin perjuicio del análisis [43].

Uno de los algoritmos que se emplean en este trabajo es el *t-Distributed Stochastic Neighbor Embedding* (t-SNE). Este algoritmo convierte las distancias euclidianas entre puntos de datos, en distribuciones de probabilidad que representen las similitudes entre vecinos. Este algoritmo ordinariamente consiste en tres pasos [44]:

- Se calculan las similitudes de puntos en el espacio inicial de grandes dimensiones.

- Se crea un espacio dimensional más pequeño en el que se representan los datos, y se distribuyen de forma aleatoria en este espacio. De igual forma se calculan las similitudes de los puntos en dicho espacio.
- Se comparan las similitudes de los puntos en los dos espacios, es decir, se minimiza la diferencia entre las distribuciones de probabilidad del espacio original y del espacio de menor dimensión. Esto con el fin de representar fielmente los puntos en el espacio dimensional más pequeño.

Los conceptos anteriores serán utilizados más adelante, con la finalidad de realizar un análisis que entregue resultados que puedan ser interpretados según los propósitos de este trabajo.

2.7 Conclusiones del capítulo

En general este capítulo sirve para establecer las bases teóricas de los recursos que se utilizarán en el capítulo siguiente, como son: principio de funcionamiento del acelerómetro empleado en este trabajo para medir las vibraciones, definición de cada uno de los parámetros que se obtienen de las pisadas, conceptos básicos de las redes neuronales artificiales y su estructura, así como su aplicación para realizar clasificaciones. En el capítulo siguiente se tendrá mayor detalle de cómo se implementaron cada uno de estos dispositivos y conceptos.

3 DISEÑO

En este capítulo se abordará cómo se realizó el diseño del sistema completo para la detección y monitoreo de actividad física de manera no invasiva, el cual se muestra en el diagrama a bloques de la Figura 3-1. Este diagrama muestra de manera general las etapas de las que consta dicho sistema y las tareas que realiza cada una de ellas. La primera etapa consiste en la adquisición de la base de datos con ayuda de un acelerómetro capacitivo triaxial colocado en el suelo, el cual trabaja como el medio de transducción de las vibraciones mecánicas provocadas por las pisadas. Posteriormente, se hace uso del protocolo I²C para enviar la señal generada por el sensor (acelerómetro) a un microcontrolador. En la segunda etapa se envía de manera serial a una computadora, donde se crea un archivo con todas las muestras de la señal generada. En la tercera etapa todos los datos se procesan y analizan para extraer cuatro parámetros característicos de las pisadas y ocho parámetros estadísticos de tiempo y frecuencia de las pisadas. En la cuarta etapa, con ayuda de estos parámetros se realizan diferentes clasificaciones mediante el uso de redes neuronales. A continuación, se explicará con mayor detalle cada uno de los bloques mencionados anteriormente.




Figura 3-1 Diagrama a bloques del sistema

3.1 Adquisición de la base de datos

De manera general, en este bloque (ver Figura 3-2) se tienen como entradas del sistema, las vibraciones en el suelo generadas por las pisadas, con dichas vibraciones se excita al sensor y se realiza su lectura con la ayuda de un microcontrolador por medio de comunicación I²C. Una vez obtenidos los datos, se envían de manera serial

a la computadora, la cual recibe los datos y los guarda en un archivo con extensión CSV.




Figura 3-2 Etapas de la adquisición de la base de datos

3.1.1 Protocolo experimental

Antes de explicar más a fondo el bloque de adquisición de la base de datos, se presenta el protocolo experimental. Dado que las pruebas de esta tesis requerían la participación de personas, fue necesario crear un protocolo experimental, así como someterlo a revisión. Se hablará brevemente de dicho protocolo en esta sección, sin embargo, en secciones posteriores se hablará más detalladamente de las condiciones y las pruebas realizadas.

Las pruebas se aplicaron a 30 individuos sanos (17 hombres y 13 mujeres), con un rango de edad de 25 a 72 años, con peso de 43 a 120kg, y rango de altura de 1.52m a 1.81m. El protocolo ha sido aprobado por el Comité de Bioética para la Investigación en Seres Humanos (COBISH-CINVESTAV) con el número de folio: 086/2022 (ver Anexo A). Cada uno de los participantes dieron su consentimiento informado por escrito.

La participación de cada sujeto consistió en caminar libremente en condiciones naturales y habituales a lo largo de una ruta predeterminada, sin esfuerzos físicos fuera de lo que normalmente se realiza en la rutina diaria, ni tampoco fueron expuestos a algún tipo de riesgo para su integridad física. Además, todos los participantes respondieron a un cuestionario con datos personales como sexo, edad, peso, altura y enfermedades, los cuales son tratados de forma confidencial. Estos

registros se utilizan exclusivamente para obtener información relacionada con las señales generadas por un acelerómetro triaxial al caminar. Asimismo, esta información será analizada para determinar parámetros particulares relacionados con el estilo de la forma de dar cada paso, esto con el objetivo de realizar una clasificación de las características físicas y la identificación de los tipos de marcha realizados por la persona objeto de estudio.

3.1.2 Selección del sensor

Retomando lo relacionado a la adquisición de la base de datos, se profundizará a continuación, en todo lo relacionado con el sensor empleado para las mediciones.

Para extraer una señal de buena calidad es necesaria la búsqueda de un sensor capacitivo con las características más apropiadas para diseñar el sistema de adquisición de datos. Una de las características primordiales, debe ser que el ruido sea menor que la señal obtenida por las vibraciones y otra de ellas es que se logre excitar el sensor con las vibraciones del suelo para obtener los picos deseados. De manera que tomando esto en consideración, es importante que el sensor tenga una alta sensibilidad, un bajo nivel de ruido, un ancho de banda adecuado y además es deseable un sensor de bajo costo. De igual manera, es necesario realizar su caracterización para conocer sus parámetros reales de funcionamiento, que es de vital importancia para extraer una señal de mejor calidad y lograr su mejor aprovechamiento.

Antes de mencionar las características de diferentes sensores, es necesario aclarar algunos aspectos como la sensibilidad que normalmente se especifica en “ mV/g ” en el caso de acelerómetros analógicos y “ LSB/g ” para acelerómetros digitales, donde $1g$ se refiere a la aceleración debida a la gravedad de la tierra, que es igual a $9,8 m/s^2$, y LSB es el bit menos significativo.

La relación de sensibilidad y número de g máximo que puede medir un acelerómetro es de gran importancia para su selección, ya que a menor número de g que se puede medir más alta será la sensibilidad.

Otro aspecto es el ancho de banda, que es el rango de frecuencias en las que puede medir el acelerómetro antes de que la señal de salida resulte distorsionada o recortada. Como se muestra en la Figura 3-3, donde se grafica la magnitud de la señal del acelerómetro contra frecuencia, existe un valor mínimo y máximo de la frecuencia en la que el sensor opera de manera adecuada, fuera de esas frecuencias existe un decremento o aumento de la magnitud, lo que implica la posibilidad de tener mediciones erróneas, como resultado de la distorsión ocasionada.




Figura 3-3 Ancho de banda de respuesta en frecuencia de un acelerómetro (Modificada de [45])

Para realizar la selección del sensor, es decir, un acelerómetro capacitivo, se hizo una comparación de las características de algunos sensores comerciales analógicos y algunos digitales, con uno de los sensores más utilizados en trabajos realizados para el monitoreo de vibraciones [1], [4] que es el acelerómetro tipo piezoeléctrico PCB356B18. Buscando aproximarse lo más posible a las características del sensor piezoeléctrico, como su sensibilidad, ancho de banda y rango de aceleración medible, entre otras.

De manera inicial se realiza la comparación de algunos sensores analógicos como se muestra en la Tabla 4, en la cual se puede apreciar que no se pueden tener todas las características deseables (alta sensibilidad, bajo nivel de ruido y un ancho de banda grande) en un solo sensor comparadas con el sensor piezoeléctrico. En general al tener una mejor sensibilidad implica un aumento en el ruido, y las vibraciones que se requieren medir generan aceleraciones de pequeña magnitud comparado con la aceleración de un cuerpo en movimiento. Por otra parte, se observa que el costo del piezoeléctrico es muy elevado comparado con los sensores capacitivos analógicos. A pesar de todas las desventajas que presentan los sensores analógicos se realizaron unas pruebas preliminares con un sensor analógico común ADXL320, con el objetivo de familiarizarse con este tipo de sensores y observar su comportamiento. Para realizar estas pruebas, se implementó un circuito de acondicionamiento el cual consiste en un filtro pasa altas de 10Hz, un filtro pasa bajas de 1kHz y una etapa de amplificación. De igual manera, el sensor se coloca en contacto directo con el suelo y se realizan caminatas alrededor de él.

Matrícula	PCB356B18 (piezoeléctrico)	ADXL320 (capacitivo)	MMA7361 (capacitivo)	LIS344ALHTR (capacitivo)
Fabricante	PCB Piezotronic	Analog Devices	NXP	ST Microelectronics
Rango de aceleración	±5g	±5g	±1.5g	±2g
Sensibilidad (mV/g)	1000	174	800	660 (720 con Vdd=3.6V)
Ruido (µg/√Hz)	0.4	250	350	50
Ruido (mV rms) a 500Hz	-	1.23	7.92	0.84
Ancho de banda (Hz)	0.5-3000	0.5-1000	0.1-300	1-1800
Precio (USD)	1865	13.90	20.67	5.62

Tabla 4 Comparación de sensores analógicos

Como se muestra en la Figura 3-4, en una de las pruebas, el ruido presente en el acelerómetro sobrepasa o iguala la señal generada por las pisadas de una caminata normal que es del orden de 0.35mV. Dicho ruido tiene un valor pico-pico de 880mV debido a la ganancia del circuito de acondicionamiento. Sin embargo, sin la ganancia, el ruido tiene una amplitud de 9.77mV *pico-pico*. Sabiendo que la

sensibilidad del acelerómetro es de 174mV/g , el ruido tiene un valor de $56 \times 10^{-3}g$, cuyo valor impide visualizar la señal generada por las pisadas que se encuentra en el rango de $1 \times 10^{-3}g$ a $2 \times 10^{-3}g$ según los resultados obtenidos en este trabajo.




Figura 3-4 Señal del acelerómetro ADXL320 durante una caminata de prueba.

Debido a que las características de los acelerómetros analógicos capacitivos reportados en la Tabla 4 no son adecuadas para medir las vibraciones provocadas por las pisadas, tal como se mostró en la Figura 3-4, se decidió hacer la búsqueda de un sensor digital que se acercara lo más posible a las características deseadas (alta sensibilidad, bajo nivel de ruido y un ancho de banda similares al PCB356B18). De manera general, una de las ventajas de trabajar con sensores digitales, es la facilidad que brindan para leer sus mediciones con un microcontrolador y posteriormente procesarlas en una computadora. En la Tabla 5 se muestra nuevamente una comparación de varios sensores digitales con el sensor piezoeléctrico mencionado anteriormente. Todos los sensores fueron elegidos de acuerdo con las necesidades de medición, es decir, que sus rangos de medición de aceleración fueran de 2 a $2.5g$, ya que la señal de las pisadas que se desea medir es de una magnitud pequeña, la cual va de $1 \times 10^{-3}g$ a $2 \times 10^{-3}g$. De igual manera, se consideró para la selección aquellos que tuvieran un mayor número de bits en su convertidor analógico digital (ADC), ya que esto implica una mayor resolución en el caso de los acelerómetros digitales.

Una ventaja de este tipo de sensores presentados en la Tabla 5 es que se tiene un menor nivel de ruido y una mejor sensibilidad comparado con los sensores analógicos. Finalmente, comparando todas las características de los sensores, se elige el sensor digital ADXL355, ya que presenta una mejor relación entre sensibilidad y ruido, y el ancho de banda de respuesta en frecuencia es de un valor intermedio. En general presenta características similares a las del sensor piezoeléctrico.

Matrícula	PCB356B18 (piezoeléctrico)	LSM303D	LIS3DHH	ADXL355	ADXL345	ADXL362
Fabricante	PCB Piezotronic	ST Microelectronics	ST Microelectronics	Analog Devices	Analog Devices	Analog Devices
Rango de aceleración	±5g	±2g	±2.5g	±2g	±2g	±2g
Número de bits	-	16	16	20	10	12
Sensibilidad (LSB/g)	1000mV/g	16,393 (825mV/g)	13,157 (662mV/g)	256,000 (812mV/g)	256 (825mV/g)	1000 (805mV/g)
Ruido (µg/√Hz) a 1kHz	0.4 (16µg)	150 (6mg)	45(1.8mg)	25 (1mg)	430 (17.2mg)	350 (14mg)
Ancho de Banda (Hz)	0.5-3000	773	235 o 440	1000	3200	400
Precio (USD) Tarjeta de evaluación	1865	1.58	19.50	47.13	20	22

Tabla 5 Comparación de sensores digitales

3.1.2.1 Características del sensor

Dado que el sensor elegido fue el ADXL355 (en el caso de este trabajo se emplea la tarjeta de evaluación EVAL-ADXL355-PMDZ), observando nuevamente sus características en la Tabla 5, se tiene que es un acelerómetro digital de 20 bits, que tiene una sensibilidad de 256,000 LSB/g o bien $3.9 \mu g/LSB$ (esto significa que con cada cambio de $3.9 \mu g$ que el sensor detecta, el bit menos significativo-LSB cambia) y una densidad de ruido de $25 \mu g/\sqrt{Hz}$. Además, cuenta con comunicación I²C o SPI, realiza la medición de la aceleración en 3 ejes (X, Y, Z) y proporciona los datos en formato complemento a dos. De igual manera cuenta con un filtro pasabanda integrado de 1Hz a 1kHz, el cual puede ser programado para trabajar en el rango deseado. El acelerómetro es comúnmente utilizado para medir la vibración o la

aceleración de un objeto; para más información sobre el acelerómetro consultar [46].

Una vez identificadas sus características, se configura el sensor modificando los registros correspondientes obtenidos de la hoja de datos de éste [46], de tal manera que trabaje en un rango de $\pm 2g$, que realice la lectura del eje Z para poder colocar el sensor de manera horizontal en contacto directo con el suelo (debido a que la magnitud de las vibraciones producidas en este eje es mayor comparado con los otros dos ejes X y Y).

Además, se configura para que utilice la comunicación I²C a 400 000 *bit/s* para transmitir los datos al microcontrolador y se configura el filtro para que únicamente se encuentre activo el filtro pasa bajas con frecuencia de corte de 62.5Hz. Es importante el rango de frecuencia en el que trabaja el sensor, ya que de esta manera no habrá modificaciones o atenuaciones en las mediciones. Ordinariamente la frecuencia de las pisadas (debido a la fuerza normal del talón al golpear el piso) se encuentra por debajo de 500Hz según investigaciones realizadas por [47] y en otra investigación realizada por [48] se reportan frecuencias en el rango de 1-75Hz.

3.1.2.2 Interpretación de la lectura

Para poder realizar la lectura del sensor y emplear los datos de manera correcta, es necesario interpretar los datos entregados por el mismo, y para ello se realizan una serie de cálculos. También es necesario realizar una calibración de éste, ya que dependiendo del rango de aceleración en el que se va a estar trabajando cambia la sensibilidad, así como también entre un sensor y otro pueden presentarse ligeros cambios en los valores entregados de aceleración.

Primero se calcula la sensibilidad, es decir, el número de LSB por cada *g* como se muestra en la Ecuación 14. Donde LSB_{1g} es la sensibilidad, LSB_{max} es el número máximo de LSB con los que cuenta el sensor, es decir, 2^{n-1} (*n* es el número de bits

del convertidor), X_g es el número de g 's que se programan en el acelerómetro ($\pm 2.048g$ en este caso).

$$LSB_{1g} = \frac{LSB_{max}}{X_g} = \frac{2^{19} LSB}{2.048 g} = 256000 LSB/g \quad \text{Ecuación 14}$$

Finalmente, para convertir estos valores leídos de la aceleración en número de g (que es una manera ordinaria de expresar la aceleración cuando se emplean acelerómetros), se utiliza la Ecuación 15, donde Acc_{zg} es la lectura de la aceleración en el eje Z dada en g y Acc_{zLSB} es la lectura de la aceleración dada en LSB por el sensor.

$$Acc_{zg} = \frac{Acc_{zLSB}}{LSB_{1g}} \quad \text{Ecuación 15}$$

Para realizar la lectura de los datos del sensor, se hace uso de un microcontrolador y para la conversión se hace uso del lenguaje de programación *Python* como se explicará más adelante.

3.1.3 Montaje del sistema y pruebas de campo

Con respecto al montaje del sensor, fue necesario realizar el diseño y la fabricación de una base de resina epóxica que facilita la colocación del sensor en el suelo (ver Figura 3-5 A), además ayuda a resguardar al microcontrolador, colocar las conexiones y encapsular al sensor (ver Figura 3-5 B) de tal manera que se encuentre en contacto directo con el suelo y en una posición fija. Dicha base no modifica el comportamiento del sensor, únicamente se emplea como auxiliar para fijar el sensor en su posición de medición. La orientación en la que se coloca el sensor sobre el suelo es como se muestra en la Figura 3-6, de tal manera que el eje Z del sensor quede perpendicular al plano del suelo como ya se explicó anteriormente. Es

importante agregar, que este montaje lo hace portátil, lo cual sugiere una propiedad adicional al sistema propuesto, pues se podría montar en diferentes habitaciones o espacios.

Respecto a las condiciones bajo las cuales se realizaron las pruebas, éstas se efectuaron en una habitación ubicada en la planta baja de un edificio, con dimensiones de $4.2m \times 5.1m$ con piso de linóleo. Para realizar cada una de las mediciones se hace uso de una pista circular de $1m$ de radio propuesta en otros trabajos como en [4], en la cual se encuentra colocada la base de resina con el sensor en el centro de la pista como se muestra en la Figura 3-7. Una razón más de la elección de este tipo de pista es el alcance en distancia del sensor empleado, de tal manera que, si se aleja considerablemente del sensor, éste dejaría de ser excitado por las vibraciones de las pisadas, lo cual no es conveniente.




Figura 3-5 Base de resina epóxica A. Montaje de la base B. Encapsulado del sensor




Figura 3-6 Ejes coordenados, orientación y posición del sensor




Figura 3-7 Pista de medición

En cuanto a las pruebas de campo, el sujeto bajo estudio camina sobre la pista mencionada en dirección de las manecillas del reloj durante 20 segundos en cada prueba; de cada individuo se toman un total de 13 pruebas, de entre las cuales, 10 son seleccionadas para analizarlas, de tal manera que se tengan tres pruebas adicionales por persona como respaldo en caso de presentarse errores de medición. Se les indica que caminen de manera natural con la única condición de comenzar la caminata con el pie derecho, esto con la finalidad de poder distinguir dentro de la señal obtenida entre las pisadas izquierdas y las derechas, con ayuda del procesamiento de los datos.

Finalmente, con los datos recabados se obtiene una base de datos con un total de 30 personas diferentes y los datos recopilados de cada una son: peso, estatura y edad.

En una prueba adicional, bajo las mismas condiciones, se le indica a un individuo en particular, que realice diferentes tipos de caminata: cojeando de un pie, cojeando y arrastrando un pie, caminata lenta, caminata normal y caminata rápida. De igual manera que con las pruebas anteriores, se guarda la base de datos de los diferentes comportamientos del individuo para ser analizada posteriormente y evaluar la eficacia del algoritmo empleado para la clasificación de tipos de caminata.

3.1.4 Transmisión y recepción de datos

Como se puede apreciar en el esquema de las etapas de la adquisición de la base de datos (ver Figura 3-2), el último bloque se encarga de la transmisión y recepción de los datos provenientes del sensor; este bloque consiste en el microcontrolador que recibe dato por dato de parte del acelerómetro por medio de comunicación I²C y los envía de manera serial a la computadora (UART).

En la Figura 3-8 se muestra el diagrama de las funciones del microcontrolador ATmega328P. El algoritmo propuesto es realizado con lenguaje de programación C++ (ver Anexo B). Lo primero que realiza el algoritmo es la configuración del sensor, es decir, configurar los registros del acelerómetro de tal manera que trabaje bajo los parámetros deseados que se mencionaron anteriormente: rango de aceleración, que realice la lectura de la aceleración en el eje Z, que utilice la comunicación I²C (400 000 *bit/s*) para transmitir los datos y que configure el filtro como pasa bajas.

Posteriormente inicia la comunicación serial con la computadora y se queda en modo de espera hasta que recibe la instrucción (bandera de arranque) por medio del teclado de la computadora para comenzar la lectura del sensor. Una vez recibida la bandera, lee el dato presente en el sensor y convierte el dato recibido a decimal tipo entero largo (*long*), ya que los datos de aceleración están dados por el sensor en complemento a dos y en un formato de 20 *bits*. Finalmente envía el dato modificado a la computadora de manera serial UART (Receptor/Transmisor Asíncrono Universal) con una velocidad de 115 200 *bit/s*.

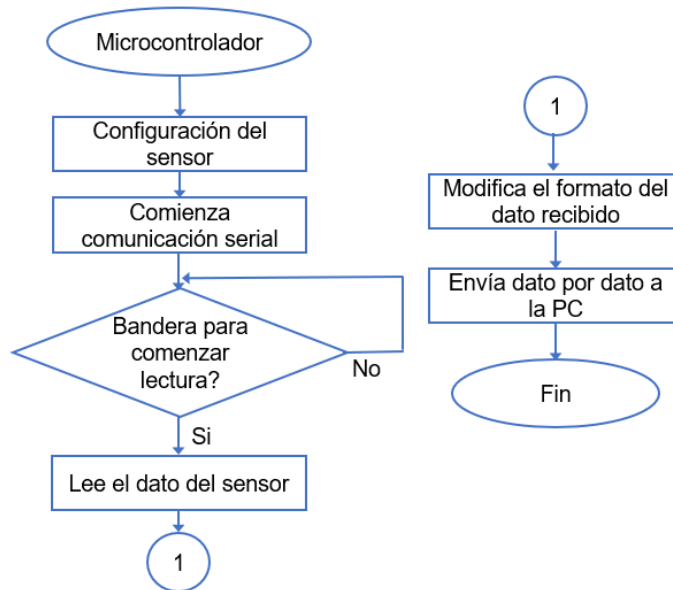


Figura 3-8 Diagrama de flujo del microcontrolador

3.2 Procesamiento y almacenamiento de datos

Observando el diagrama a bloques del sistema en la Figura 3-1, el segundo bloque es el encargado del procesamiento y almacenamiento de los datos, para lo cual se hace uso de la computadora con un algoritmo en Python (ver Anexo C) que recibe los datos enviados de manera serial por el microcontrolador; su diagrama de flujo se muestra en la Figura 3-9.

Dentro del algoritmo se inicia la comunicación serial con el microcontrolador. Una vez que el usuario a cargo establezca la pauta para comenzar las mediciones (con una instrucción ingresada mediante el teclado), el algoritmo envía una bandera al microcontrolador para comenzar el proceso de obtener los datos del sensor y recibirlos vía serial. Posteriormente se realiza el cálculo del número correspondiente de g basándose en la conversión digital del acelerómetro utilizando la Ecuación 14 y la Ecuación 15. Finalmente, almacena los datos del tiempo y la aceleración en un archivo de extensión *.csv. Debido a que únicamente se realiza la lectura del eje Z, la matriz generada sólo contiene los datos de la aceleración en Z y sus respectivos tiempos, y cuya frecuencia de muestreo es de 857Hz. Para consultar la base de datos

completa, es decir, de los 30 sujetos bajo estudio, acceder a https://www.vlsilab.cinvestav.mx/rev_marb.html.

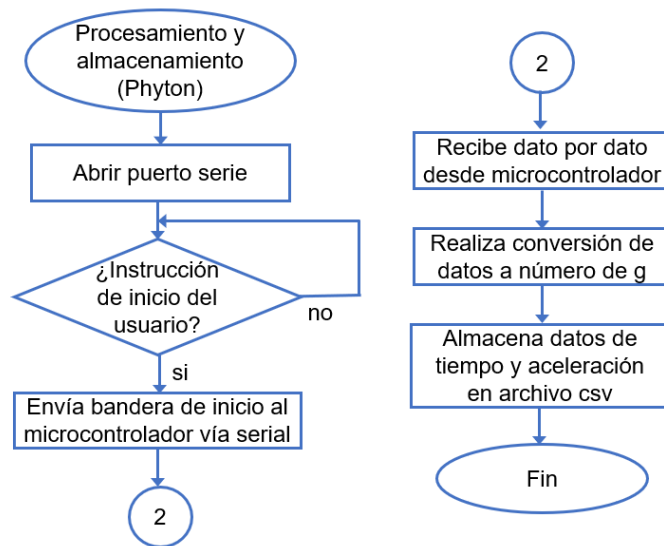


Figura 3-9 Diagrama de flujo de procesamiento y almacenamiento de datos

3.3 Extracción de parámetros

Como ya se mencionó en la sección 2.2 los parámetros que se obtienen de la señal de aceleración son 4 parámetros característicos y 8 parámetros estadísticos. Para cada uno de ellos se hizo el promedio de su valor para el pie derecho y para el pie izquierdo. Los parámetros característicos son: la duración de pisadas (S), duración de la zancada (T), la energía de la señal de cada pisada (E) y la cadencia (V). Por otra parte, también se obtienen los parámetros estadísticos que son: la desviación estándar (T_2), la raíz cuadrática media (T_3), la curtosis (T_4), la asimetría estadística (T_5), la desviación media absoluta (T_6), la media de la frecuencia (F_1), la mediana de la frecuencia y la media de la potencia (T_7).

Con los parámetros definidos, se procede a la extracción de estos a partir de la matriz de datos obtenida con el algoritmo de procesamiento y almacenamiento, es decir, el archivo con extensión *.csv, que consta de dos columnas: una corresponde al tiempo y la otra a la aceleración correspondiente, en el eje Z. Para la extracción,

se crea el algoritmo que se muestra en la Figura 3-10 , el cual se implementa en Matlab R2021b (ver Anexo D).

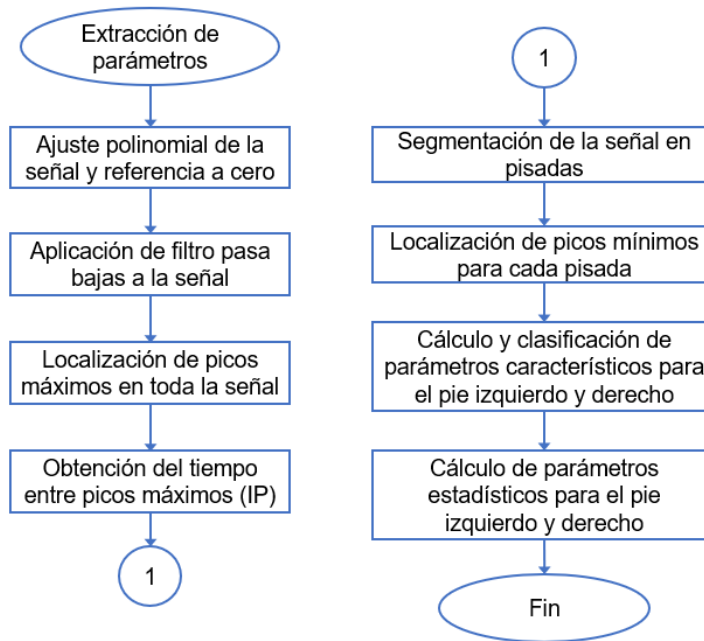


Figura 3-10 Diagrama de flujo de extracción de parámetros

Primero se hace uso de un ajuste de mínimos cuadrados a un polinomio mediante la función *polyfit* de Matlab. Posteriormente, se referencia la señal a cero en el eje de la aceleración, debido a que originalmente la señal está referenciada a $1g$, ya que al colocar el sensor en el suelo y medir la aceleración en el eje Z, ya se considera la presencia de la gravedad.

El siguiente paso es aplicar un filtro pasa bajas a la señal con el fin de reducir el ruido presente en la señal original, un ejemplo de la señal resultante se muestra en la Figura 3-11.

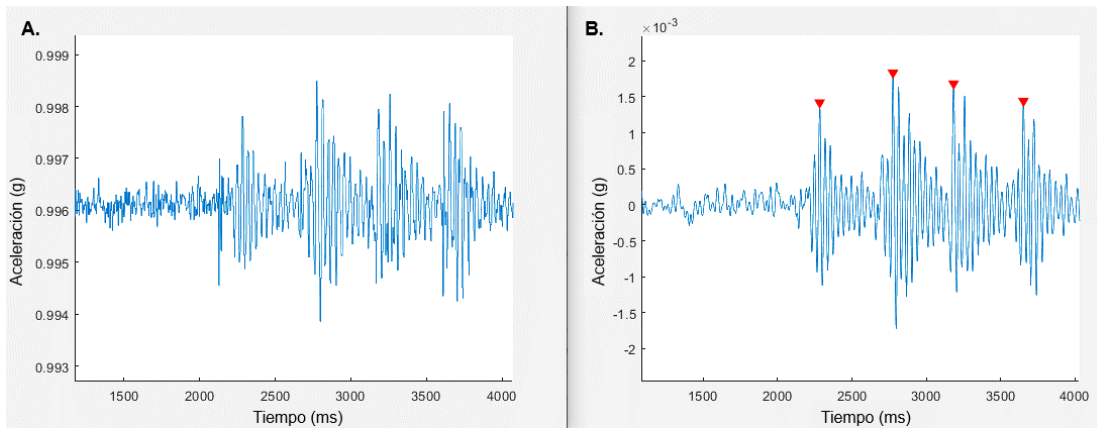


Figura 3-11 Señal de las pisadas A. Original B. Modificada con referencia a cero y filtro pasa bajas

Posteriormente, se procede a realizar una segmentación automatizada, localizando los picos máximos de la señal, que representan los impactos del pie en el suelo. Se emplea la función *findpeaks* de Matlab [49] para este propósito, mediante la selección de un valor mínimo de prominencia que se considera para descartar picos no representativos, así como una distancia mínima entre picos, es decir, la distancia mínima en el eje del tiempo que se considera para descartar picos intermedios. Para comprender un poco mejor esta técnica, se procede a explicar un poco mejor la definición de prominencia.

La prominencia de un pico mide cuánto se destaca el pico debido a su altura intrínseca y su ubicación en relación con otros picos. Para calcular la prominencia de un pico se realizan los siguientes pasos (ver Figura 3-12) [50]:

1. Se marca el pico que se desea medir.
2. Se extiende una línea horizontal desde el pico hacia la izquierda y la derecha hasta que ocurra alguna de las siguientes situaciones:
 - La línea interseca la señal debido a que hay un pico más alto.
 - La línea alcanza el borde izquierdo o derecho de la señal.

3. Se identifica el punto mínimo de la señal en cada uno de los dos segmentos definidos en el paso 2. Este punto será un valle o uno de los extremos de la señal.
4. El mayor de estos dos mínimos será el nivel de referencia. La distancia del pico por encima de este nivel representa su prominencia.




Figura 3-12 Ejemplo de medición de prominencia en la señal de una pisada

Con los valores de la ubicación de los picos máximos en el eje del tiempo, se calcula la diferencia en tiempo entre ellos, lo que nos da el valor de IP , es decir la distancia entre picos. Para apreciarlo gráficamente, se puede observar la señal de cuatro pisadas que se muestra en la Figura 2-2.

A continuación, se segmenta la señal de tal manera que se pueda analizar cada pisada, esto con la ayuda de la localización de los picos máximos, es decir, se toman segmentos de la señal desde la posición del pico máximo $(p-1)$ hasta el siguiente (p) , donde p toma un valor máximo equivalente al número total de picos máximos presentes en la señal. Este proceso continúa hasta el último pico máximo presente en la señal. Una vez realizado lo anterior, se procede a localizar el pico mínimo dentro de cada segmento, es decir, para cada pisada. Lo primero que se realiza es

localizar los picos presentes dentro del segmento, de igual forma, con un valor de prominencia y distancia mínima entre picos con la función *findpeaks*. Después de este proceso, de todos los picos obtenidos en un segmento se selecciona aquel que posea un valor del 3% del valor del pico máximo, valor seleccionado empíricamente, basándose en todas pruebas realizadas y en los diferentes valores de aceleración obtenidos para cada una de las 30 personas, de esta manera se obtiene el pico mínimo por cada segmento.

Tomando la diferencia entre el valor de la posición en el tiempo de todos los picos mínimos y de todos los picos máximos, se obtiene el valor de la duración de la pisada (S), ver Figura 2-2. Considerando que la caminata completa comienza con el pie derecho, se procede a clasificar las duraciones de pisada del pie izquierdo y derecho.

Después al calcular la diferencia entre los tiempos IP y S , se obtiene el valor de la duración de la zancada T , y de igual manera se realiza su clasificación entre izquierda y derecha.

A continuación, se calcula la energía por cada segmento de la señal, es decir, por cada paso con la Ecuación 1, el cálculo de la sumatoria se realiza desde la posición del pico máximo del paso que se desea analizar hasta la posición del pico mínimo. De igual manera se clasifica entre pie izquierdo y pie derecho.

En el caso de la cadencia de las pisadas, cuyo valor depende de los valores de la duración de la pisada (S), así como de la duración de la zancada (T), haciendo uso de la Ecuación 2 y la Ecuación 3, se obtiene su valor para el pie derecho e izquierdo.

Finalmente, los parámetros estadísticos se pueden obtener aplicando sus respectivas ecuaciones (ver Tabla 2) dentro de cada segmento, es decir, para cada paso. Igualmente se clasifican para pie derecho e izquierdo.

Por otra parte, cabe mencionar que esta obtención de parámetros se hace para cada una de las mediciones tomadas en las pruebas y para cada persona. Una vez obtenidos, se unen todos los archivos de una persona (ver Anexo E). Con estos datos se calcula el promedio de la pisada izquierda y derecha, además de obtener 20 vectores de datos por persona (ver Anexo F). Esto con el fin de tener una base de datos homogénea, en cuanto al número de vectores por persona.

3.4 Clasificación de datos

Para conseguir uno de los objetivos establecidos para esta tesis, la clasificación de los datos se hace con ayuda de redes neuronales artificiales. Para poder elegir el método a emplear para la clasificación de los datos, se hacen pruebas con tres diferentes métodos, los cuales se mostrarán en la sección 4.1. De dichas pruebas se elige aquel método que tiene el mejor rendimiento. El primero de ellos es la red neuronal multicapa, que como ya se ha mencionado en la sección 2.3.2, tiene la capacidad de resolver problemas que no son linealmente separables. Su representación esquemática es la que se muestra en la Figura 3-13 A, donde la capa de entrada consta de N neuronas y su función de activación es una sigmoide tangencial; la capa oculta consta de M neuronas y su función de activación es lineal.

El segundo es la red neuronal multicapa con una función de activación softmax cuya única diferencia es la función de activación softmax de la capa de salida (véase la Figura 3-13B), que de igual manera se explica en la sección 2.3.2, y que puede utilizarse para representar la distribución de probabilidad sobre las distintas salidas posibles.

El tercer método es el clasificador neurodifuso adaptable con modificadores lingüísticos (ANFC-LH). Este modelo incorpora el uso de conjuntos difusos dentro de una red neuronal, como ya se mencionó en la sección 2.4. El ANFC-LH añade una capa de modificadores lingüísticos que intenta determinar qué características son discriminativas y cuáles producen traslape entre clases para evitar su uso.




Figura 3-13 Esquemas de A. Red neuronal multicapa B. Red neuronal multicapa con softmax

3.5 Conclusiones del capítulo

Con respecto a la detección de picos que se realiza para localizar las pisadas dentro de la señal obtenida por el sensor, se debe considerar que entre una persona y otra existen pequeñas diferencias en la magnitud de los picos dentro de la señal, así como su separación. Por lo tanto, se requiere hacer una calibración para cada persona en el algoritmo de extracción de parámetros, en específico en la parte del algoritmo donde se realiza la detección de picos.

Por otra parte, el montaje propuesto para el sistema (base de resina), fue de gran ayuda para mantener las mismas condiciones entre una medición y otra, lo cual ayuda a tener mejores clasificaciones.

4 RESULTADOS

Retomando lo mencionado en la sección 2.1 para comprobar que las vibraciones que dominan en el piso son aquellas que son perpendiculares al plano, es decir, las del eje Z, se hacen mediciones en todos los ejes. En la Figura 4-1 se presentan los resultados de dichas mediciones, las tres bajo la misma escala y se puede observar que tanto en el eje X como en el eje Y existe una atenuación considerable de las vibraciones comparadas con la señal medida en el eje Z. Con estas pruebas se reafirma que es mejor realizar las mediciones en el eje Z del sensor para obtener una señal de mayor amplitud.

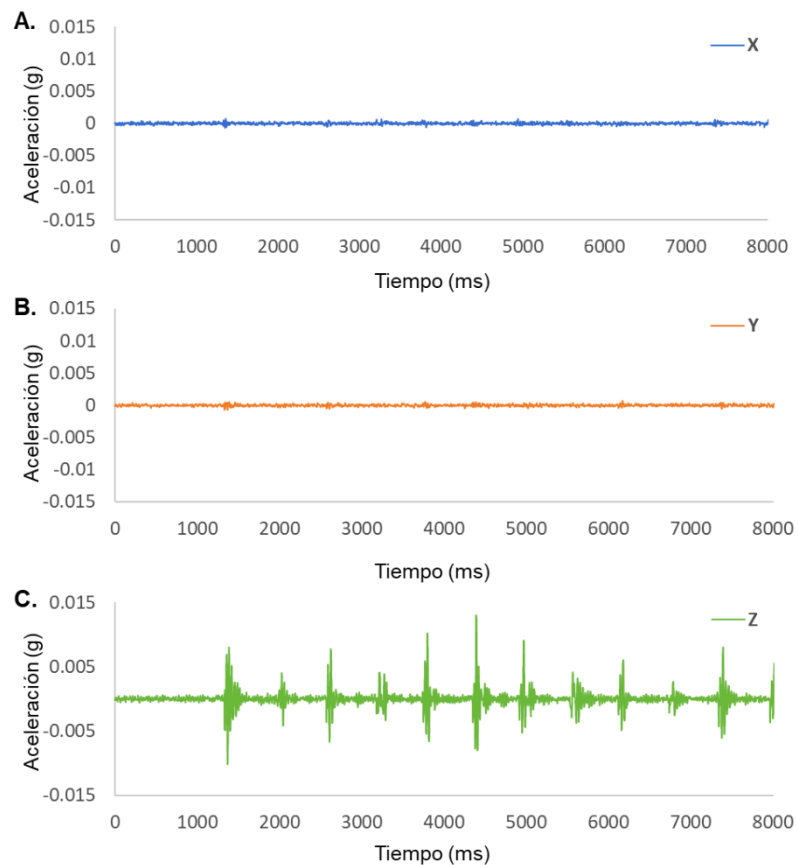


Figura 4-1 Mediciones de aceleración en A. Eje X B. Eje Y C. Eje Z

La Figura 4-2 A muestra el espectro de frecuencia de la señal generada por las pisadas de cinco sujetos bajo estudio, en la cual se observa que, sin importar la persona, todas presentan un rango de frecuencias similar. Por otra parte, la Figura 4-2 B muestra el espectro de frecuencia en decibeles, donde se aprecia con mayor claridad el rango de frecuencias de las cinco personas, el cual se encuentra por debajo de 500Hz como se reportó en [47], [48].

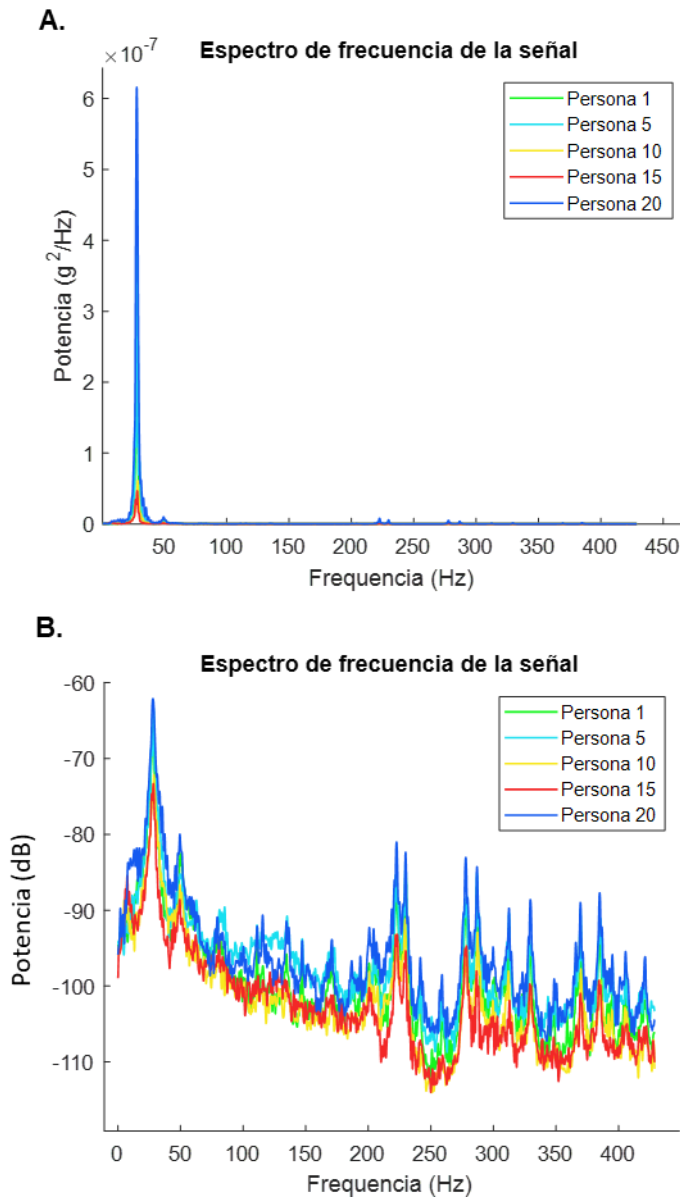


Figura 4-2 Espectro de frecuencias de la señal generada por las pisadas de cinco personas A. Gráfica en g^2/Hz B. Gráfica en dB

Una vez explicadas cada una de las partes del sistema en el capítulo 3, es conveniente realizar varias pruebas en cuanto a la clasificación, cada una de ellas se realizó en Matlab. Dentro de estas se realizaron pruebas preliminares y su objetivo es obtener el mejor método para realizar tres de las clasificaciones propuestas. Dichas pruebas se realizan con una base de datos preliminar de 17 personas, sin embargo, es ampliada la base de datos para los resultados finales presentados en la sección 4.2. Una vez elegido el método, las pruebas finales consisten en realizar las cuatro clasificaciones, pero únicamente con el método elegido haciendo ligeros cambios en los parámetros de la red, con el objetivo de mejorar su capacidad de clasificación y asertividad. Así como también es importante mencionar que, para estas pruebas finales, se utiliza la base de datos de 30 personas.

4.1 Selección del método de clasificación (pruebas preliminares)

En esta sección se mostrarán los resultados obtenidos en las pruebas preliminares, utilizando los tres métodos mencionados en la sección 4.2. Cada uno de los métodos se prueba inicialmente para tres identificaciones o clasificaciones. Debe aclararse nuevamente que se hace uso de una base de datos de pisadas preliminar obtenida con los algoritmos de las secciones anteriores, sin embargo, únicamente para 17 personas. Esto con el objetivo de elegir el mejor método para realizar las clasificaciones finales.

4.1.1 Clasificación por edad

La primera clasificación consiste en identificar cuatro clases de edad: 15-25 años, 26-35 años, 36-50 años y 51-60 años. Utilizando únicamente los parámetros estadísticos de tiempo y frecuencia, así como la red neuronal multicapa con 20 neuronas en la primera capa y 10 neuronas en la segunda capa (ver Figura 4-3 A). Con respecto a la base de datos se empleó la base preliminar de 17 personas. Se

realizaron 30 ejecuciones, de las que se selecciona la mejor de ellas, es decir, aquella en la que el porcentaje de clasificación correcta de cada clase es proporcional y el mayor posible.

En este caso, la mejor ejecución fue aquella con un porcentaje de aciertos general de 92.54%, en la cual se obtiene un porcentaje del 95.1% para la clase 1, 94.2% para la clase 2, 96.8% para la clase 3 y 86.6% para la clase 4; estos se muestran en la matriz de confusión de la Figura 4-3 B. Es importante mencionar que este porcentaje de aciertos se obtiene comparando las salidas de la red neuronal con los vectores objetivo de la base de datos.

Por otra parte, utilizando la red neuronal multicapa con función de activación softmax, con los mismos parámetros como se muestra en la Figura 4-4 A y el mismo número de ejecuciones, se obtiene que la mejor ejecución (porcentaje general del 86.1%) es aquella con un porcentaje de aciertos del 100% para la clase 1, 87.8% para la clase 2, 58.1% para la clase 3 y 89.6% para la clase 4; estos se muestran en la matriz de confusión de la Figura 4-4 B.

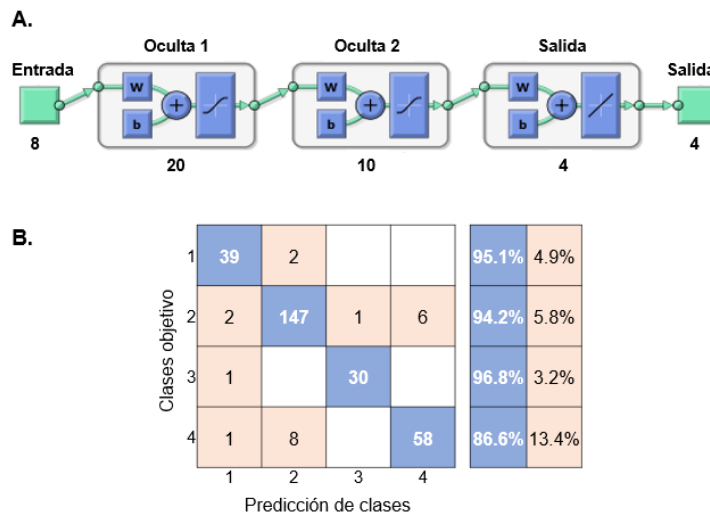


Figura 4-3 Resultado de la clasificación de edad A. Red neuronal multicapa B. Matriz de confusión

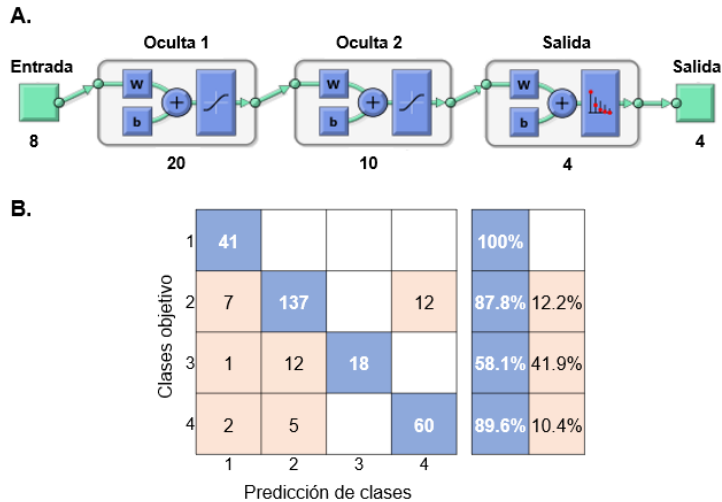


Figura 4-4 Resultado de la clasificación de edad A. Red neuronal multicapa con función de activación softmax B. Matriz de confusión

De igual manera se emplea el clasificador neurodifuso adaptable con modificadores lingüísticos con 8 reglas y modelo difuso tipo Sugeno (ver Figura 4-5 A). Los conjuntos difusos y la base de reglas generados por el Toolbox tras el entrenamiento se pueden consultar en el Anexo G. Se realizaron 20 ejecuciones y se toma la mejor de ellas (con porcentaje general del 74.14%), la cual da un porcentaje de aciertos del 97.6% para la clase 1, 70.5% para la clase 2, 45.2% para la clase 3 y 50.7% para la clase 4, como se muestra en la matriz de confusión de la Figura 4-5 B.

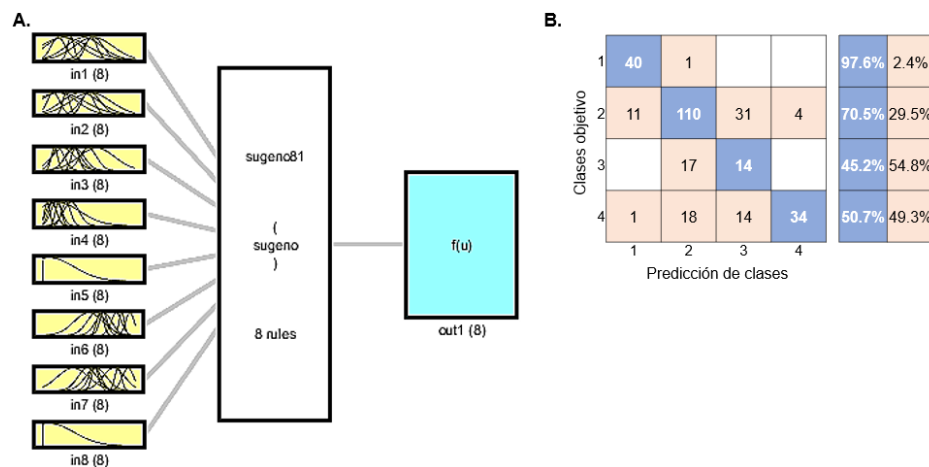


Figura 4-5 Resultado de la clasificación de edad A. Clasificador neurodifuso adaptable con modificadores lingüísticos B. Matriz de confusión

4.1.2 Clasificación por IMC

La segunda clasificación consiste en identificar el índice de masa corporal ($IMC = \text{Peso}/\text{Estatura}^2$) de la persona bajo estudio que puede clasificarse como: bajo peso (menor a 18.50), normal (18.50-24.90), sobrepeso (25.00-29.90) y obesidad (30.00-36.00). De la base de datos se emplea únicamente un individuo de cada clase, es decir, cuatro personas en total de tal manera que la diferencia de su IMC entre ellos es de aproximadamente 5.

En estas pruebas se utilizan los parámetros característicos, así como la red neuronal multicapa con 20 neuronas en la primera capa y 10 neuronas en la segunda capa (ver Figura 4-6 A), se realizaron 30 ejecuciones, de las cuales se selecciona también la mejor de ellas. Para este caso, la mejor ejecución fue la que tuvo un porcentaje de aciertos general del 94.81%, en la cual se tiene el 94.2% para la clase 1, 98.1% para la clase 2, 94.3% para la clase 3 y 92.7% para la clase 4; estos se muestran en la matriz de confusión de la Figura 4-6 B.

Con el segundo método, es decir, la red neuronal multicapa con función de activación softmax, con los mismos parámetros como se muestra en la Figura 4-7 A y el mismo número de ejecuciones, se obtiene que la mejor ejecución (con porcentaje de aciertos general del 95.28%) es aquella con un porcentaje de aciertos del 92.7% para la clase 1, 96.2% para la clase 2, 100% para la clase 3 y 94.2% para la clase 4; estos se muestran en la matriz de confusión de la Figura 4-7 B.

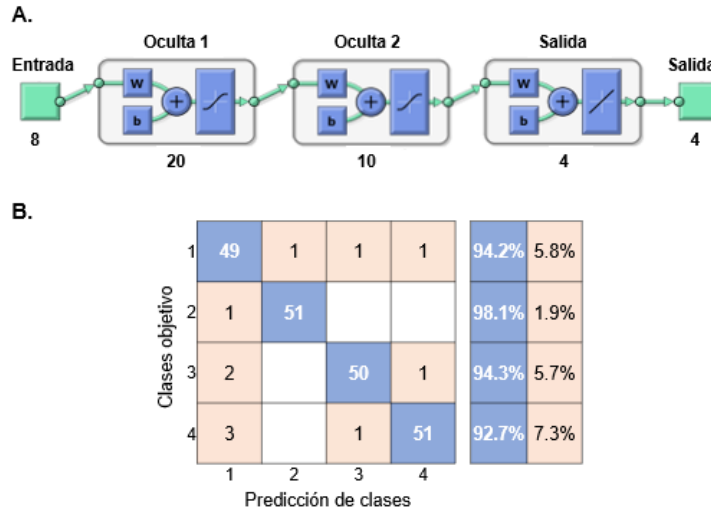


Figura 4-6 Resultado de la clasificación de IMC A. Red neuronal multicapa B. Matriz de confusión




Figura 4-7 Resultado de la clasificación de IMC A. Red neuronal multicapa con función de activación softmax B. Matriz de confusión

Con el tercer método, es decir, el clasificador neurodifuso adaptable con modificadores lingüísticos con 8 reglas y modelo difuso tipo Sugeno (ver Figura 4-8 A). Los conjuntos difusos y la base de reglas generados por el Toolbox tras el entrenamiento se pueden consultar en el Anexo G.

Se realizaron 20 ejecuciones y se toma la mejor de ellas (con porcentaje de aciertos general del 83.01%), la cual da un porcentaje de aciertos del 73.1% para la clase 1, 92.3% para la clase 2, 88.7% para la clase 3 y 85.5% para la clase 4, como se muestra en la matriz de confusión de la Figura 4-8 B.

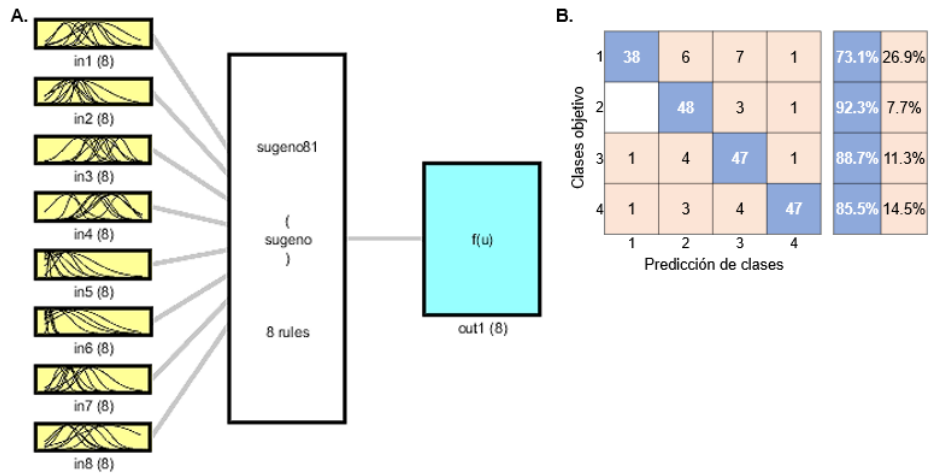


Figura 4-8 Resultado de la clasificación de IMC A. Clasificador neurodifuso adaptable con modificadores lingüísticos B. Matriz de confusión

4.1.3 Clasificación por tipo de caminata

La tercera clasificación consiste en identificar el tipo de caminata de una sola persona: cojeando, cojeando y arrastrando, caminata lenta, caminata normal y caminata rápida. De la base de datos se emplea únicamente un individuo en particular, que realiza diferentes tipos de caminata para emular diferentes comportamientos. El objetivo de esta prueba es poder distinguir variaciones en el caminar de una misma persona, como se haría en pruebas hechas a un paciente con alguna lesión y al cual se requiere dar seguimiento de su progreso.

De igual manera se utilizan en este caso los parámetros característicos, así como la red neuronal multicapa con 20 neuronas en la primera capa y 10 neuronas en la segunda capa (ver Figura 4-9 A), se realizaron 30 ejecuciones, de las cuales se selecciona también la mejor de ellas con un porcentaje de aciertos general del 99.2%. Para este caso, se tiene un porcentaje del 100% para la clase 1, 95% para la clase 2, 100% para la clase 3, 98.3% para la clase 4 y 100% para la clase 5; estos se muestran en la matriz de confusión de la Figura 4-9 B.

Con el segundo método, es decir, la red neuronal multicapa con función de activación softmax, con los mismos números de neuronas como se muestra en la

Figura 4-10 A y el mismo número de ejecuciones, se obtiene que la mejor ejecución (con porcentaje de aciertos general del 99.6%) es aquella con un porcentaje de aciertos del 100% para la clase 1, 100% para la clase 2, 100% para la clase 3, 98.3% para la clase 4 y 100% para la clase 5; estos se muestran en la matriz de confusión de la Figura 4-10 B.

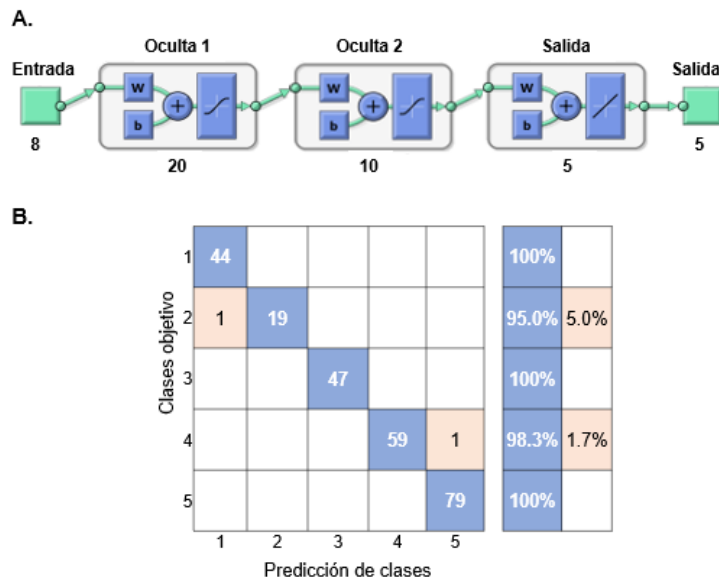


Figura 4-9 Resultado de la clasificación de tipo de caminata A. Red neuronal multicapa B. Matriz de confusión

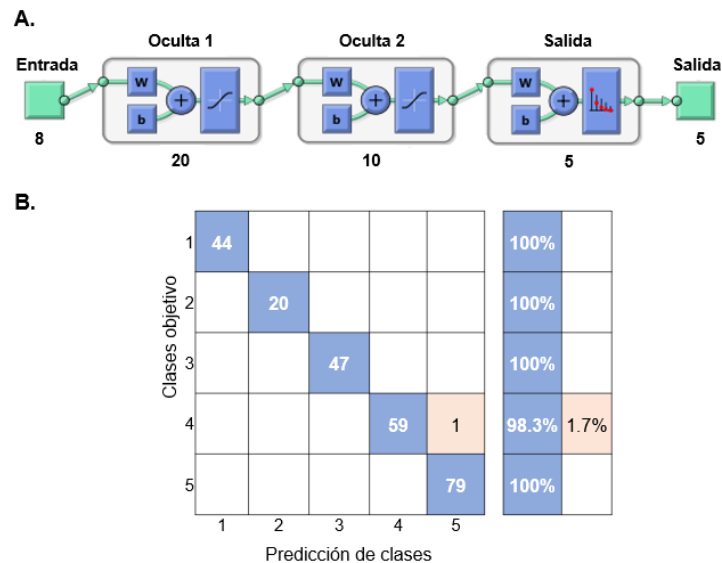


Figura 4-10 Resultado de la clasificación de tipo de caminata A. Red neuronal multicapa con función de activación softmax B. Matriz de confusión

Con el tercer método, es decir, el clasificador neurodifuso adaptable con modificadores lingüísticos con 10 reglas y modelo difuso tipo Sugeno (ver Figura 4-11 A). Los conjuntos difusos y la base de reglas generados por el Toolbox tras el entrenamiento se pueden consultar en el Anexo G. Se realizaron 20 ejecuciones y se toma la mejor de ellas (con porcentaje de aciertos general del 92%), la cual da un porcentaje de aciertos del 0% para la clase 1, 40% para la clase 2, 83% para la clase 3, 73.3% para la clase 4 y 98.7% para la clase 5, como se muestra en la matriz de confusión de la Figura 4-11 B.

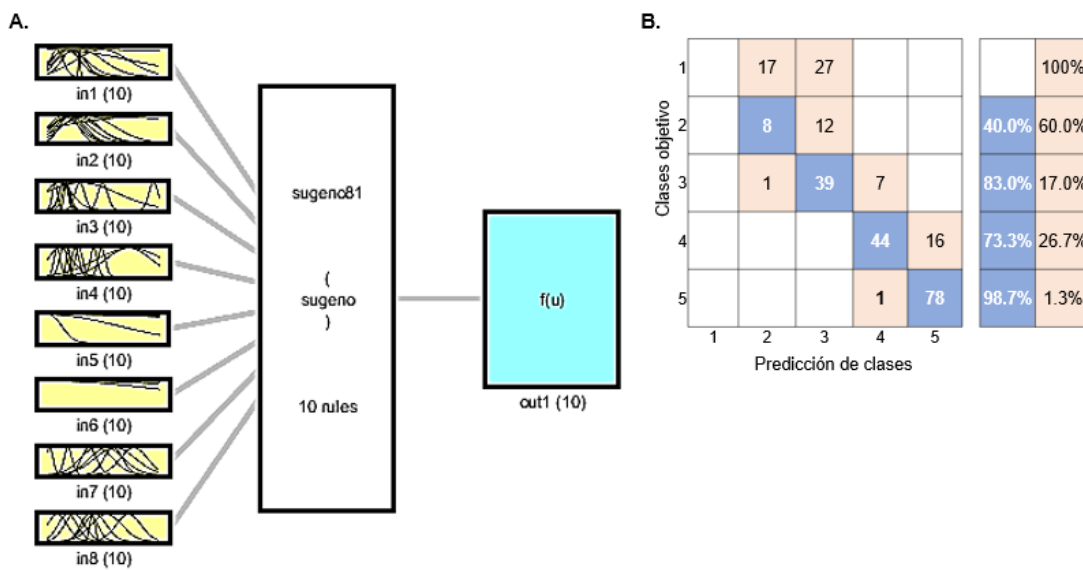


Figura 4-11 Resultado de la clasificación de tipo de caminata A. Clasificador neurodifuso adaptable con modificadores lingüísticos B. Matriz de confusión

Finalmente, se presenta la Tabla 6 con un resumen de los resultados de estas pruebas preliminares (las pruebas finales se presentan en la sección 4.2). Después de observar el comportamiento de todos los métodos en cada una de las clasificaciones preliminares realizadas, se opta por trabajar con la red neuronal multicapa con función de activación softmax, debido al mejor desempeño al momento de clasificar el tipo de datos que se manejan en este trabajo, en comparación con los otros dos métodos. Para todas las pruebas se utilizó *Deep Learning Toolbox* de Matlab para programar cada uno de los métodos.

Clasificación evaluada	Método empleado	Características de la red	Resultados (Porcentaje de exactitud)
Clasificación por edad: Clase 1 (15-25 años) Clase 2 (26-35 años) Clase 3 (36-50 años) Clase 4 (51-60 años)	Red neuronal multicapa	Primera capa: 20 neuronas Segunda capa: 10 neuronas	92.54%
	Red neuronal multicapa con función de activación softmax	Primera capa: 20 neuronas Segunda capa: 10 neuronas	86.1%
	Clasificador neurodifuso adaptable con modificadores lingüísticos	8 reglas y modelo difuso Sugeno	74.14%
	Red neuronal multicapa	Primera capa: 20 neuronas Segunda capa: 10 neuronas	94.81%
Clasificación por índice de masa corporal: bajo peso (menos de 18.50) normal (18.50-24.90) sobrepeso (25.00-29.90) obesidad (30.00-36.00)	Red neuronal multicapa con función de activación softmax	Primera capa: 20 neuronas Segunda capa: 10 neuronas	95.28%
	Clasificador neurodifuso adaptable con modificadores lingüísticos	8 reglas y modelo difuso Sugeno	83.01%
	Red neuronal multicapa	Primera capa: 20 neuronas Segunda capa: 10 neuronas	99.2%
Clasificación por tipo de caminata: cojeando, cojeando y arrastrando, caminata lenta, caminata normal y caminata rápida	Red neuronal multicapa con función de activación softmax	Primera capa: 20 neuronas Segunda capa: 10 neuronas	99.6%
	Clasificador neurodifuso adaptable con modificadores lingüísticos	10 reglas y modelo difuso Sugeno	92%
	Red neuronal multicapa	Primera capa: 20 neuronas Segunda capa: 10 neuronas	99.2%

Tabla 6 Comparación de resultados de pruebas de clasificación preliminares empleando cada método.

4.2 Clasificaciones finales

En esta sección se mostrarán los resultados obtenidos utilizando redes neuronales con función de activación softmax para realizar cuatro identificaciones diferentes, a partir de la base de datos de pisadas completa que cuenta con 30 individuos, a excepción de la última identificación que se realiza con un individuo. De igual manera se realizan algunas modificaciones tanto en la red como en los parámetros de entrada para poder mejorar el desempeño, ya que la base de datos empleada es de un mayor número de individuos.

Para determinar el número adecuado de neuronas en cada capa de la red neuronal multicapa con función de activación softmax, en primer lugar, se consideraron las reglas propuestas en [51] para iniciar con un número específico de neuronas y

capas. Posteriormente, se ajustaron el número de neuronas y capas a través de varias ejecuciones aumentando gradualmente el número de neuronas en cada capa. Este proceso iterativo permitió determinar el número adecuado de neuronas necesario para alcanzar el punto en el que el rendimiento de la red deja de mejorar. Para la programación de las redes neuronales se emplea Deep Learning Toolbox, destinando el 70% de los datos al entrenamiento y el 30% a las pruebas.

Las primeras clasificaciones se emplean para determinar las características físicas de los participantes (edad, género e índice de masa corporal) y la última para identificar los tipos de caminata (haciendo referencia a las modificaciones en el comportamiento de los pasos de una persona). Las tres primeras clasificaciones se realizan con la ayuda de los ocho parámetros estadísticos (pie derecho e izquierdo promediados) y la última clasificación con la ayuda de los cuatro parámetros característicos (para pie derecho e izquierdo).

Para los clasificadores de edad, género e índice de masa corporal, el vector p de entrada de las redes neuronales está formado por ocho componentes (parámetros estadísticos) como se muestra en la Ecuación 16.

$$p = [p_1 \ p_2 \ p_3 \ p_4 \ p_5 \ p_6 \ p_7 \ p_8] \quad \text{Ecuación 16}$$

Donde p_1 es la desviación estándar, p_2 es la raíz cuadrática media, p_3 es la curtosis, p_4 es la asimetría estadística, p_5 es la desviación media absoluta, p_6 es la media de la frecuencia, p_7 la mediana de la frecuencia y p_8 la media de la potencia.

Por otra parte, para el clasificador de tipos de caminata, el vector p de entrada de las redes neuronales está formado por ocho parámetros característicos. Donde p_1 es la duración de la pisada izquierda, p_2 es la duración de pisada derecha, p_3 es la duración de la zancada izquierda, p_4 es la duración de la zancada derecha, p_5 es la

energía de señal de la pisada izquierda, p_6 es la energía de la señal de la pisada derecha, p_7 la cadencia del pie izquierdo y p_8 la cadencia del pie derecho.

Para cualquiera de las clasificaciones, a cada vector de entrada p le corresponde un vector objetivo T , el cual contiene las clases objetivo, y está dado por $T = [t_1 t_2 \dots t_j]$. Donde j es el número de clases, y cuyo valor varía dependiendo de la clasificación que se está realizando. Suponiendo que se tengan tres clases ($j = 3$), T tiene la forma $T = [1 0 0]$ para la clase 1, $T = [0 1 0]$ para la clase 2 y $T = [0 0 1]$ para la clase 3.

Durante el entrenamiento, el vector T se compara con la salida a de la red neuronal y se lleva a cabo un entrenamiento supervisado utilizando retropropagación para actualizar los valores de pesos sinápticos y bias de la red neuronal. Posteriormente, el algoritmo de optimización Levenberg-Marquardt, se emplea para realizar estos ajustes de manera eficiente, reduciendo el error entre la salida de la red y el objetivo.

4.2.1 Clasificación por edad

La primera clasificación consiste en identificar tres clases de edad: joven (25-34 años), adulto (35-54 años) y adulto mayor (55-72 años). Utilizando la red neuronal multicapa con función de activación softmax con 20 neuronas en la primera capa y 5 neuronas en la segunda capa (ver código en Anexo H), se realizaron 25 ejecuciones, de las que se selecciona la mejor de ellas, es decir, aquella en la que el porcentaje de clasificación correcta de cada clase es proporcional y el mayor posible. En este caso, la mejor ejecución fue aquella con un porcentaje de aciertos para los datos de prueba del 63.9% para la clase 1, 63.9% para la clase 2 y 65.5% para la clase 3; estos se muestran en la matriz de confusión de la Figura 4-12 A. Por otra parte, la Figura 4-12 B muestra la matriz de confusión de todos los datos, para la cual se tiene un porcentaje de aciertos del 78.5% para la clase 1, 80% para la clase 2 y 76.5% para la clase 3. Estos porcentajes se calcularon comparando la salida de la red neuronal con

los vectores objetivo de la base de datos, tomando en consideración que cada individuo cuenta con 20 vectores. La Figura 4-12 C gráficamente ilustra el resultado de la clasificación en una gráfica de dispersión. Las salidas que entrega la red neuronal representadas con puntos que tienen cierto grado de pertenencia a cada clase, y por otra parte el color indica la clase objetivo. Entonces, a mayor cercanía de los puntos de cada color a los vértices (donde el valor de cada eje es igual a 1), mejor clasificación se tiene.

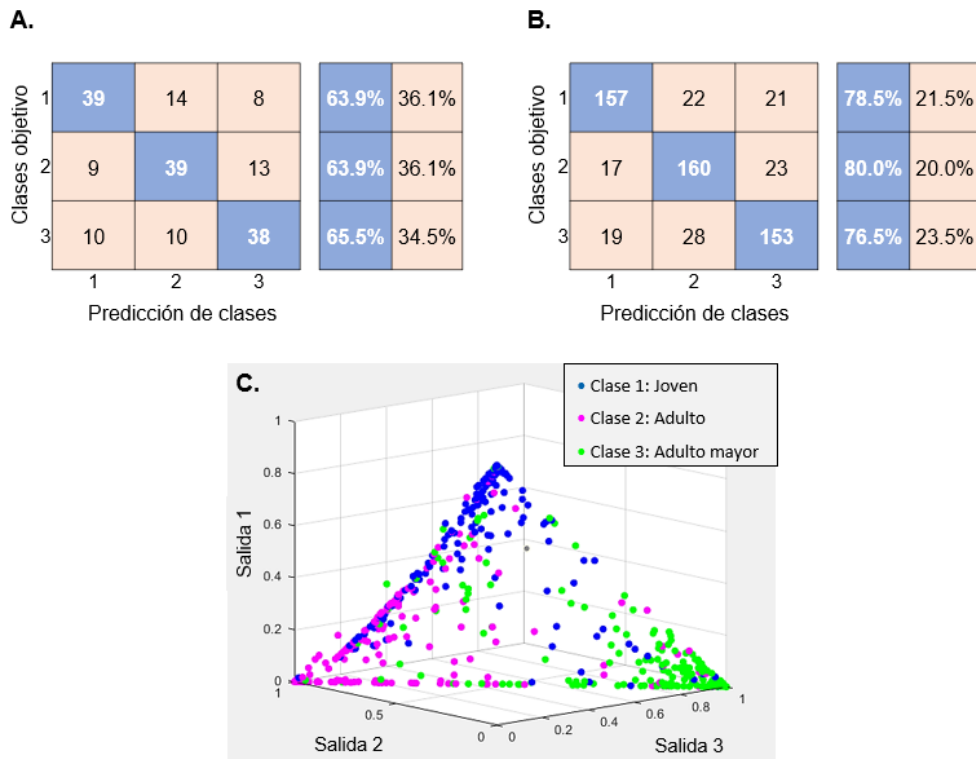


Figura 4-12 Resultado de la clasificación por edad con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D

Por otra parte, es importante mencionar que no solo es posible validar el modelo por vector, recordando que un vector representa los datos por cada pisada, sino también por individuo. Por lo tanto, es posible conocer con mayor claridad si cada persona está clasificada correctamente. Teniendo en cuenta que cada persona tiene 20 vectores de parámetros para ésta y las siguientes clasificaciones, ya sean parámetros característicos o estadísticos, se puede realizar una validación, es decir, se analiza cómo se clasifica cada uno de los vectores.

Teniendo en cuenta que hay 20 vectores por persona, algunos de estos vectores se clasificarán como jóvenes, adultos o adultos mayores, dependiendo de cada persona. Por ejemplo, en la Figura 4-13, el eje horizontal representa a los 30 participantes en la prueba, mientras que el eje vertical indica el número de vectores previstos para cada clase de edad. Tomando como ejemplo al sujeto 12, vemos 3 vectores clasificados como joven, 8 como adulto y 9 como adulto mayor. Este sujeto, por tanto, se clasifica predominantemente como adulto mayor, coincidiendo con su edad real de 59 años. Como el valor real de su edad es 59 años, entonces la clase real a la que pertenece es adulto mayor, por lo tanto, coincide con la clasificación realizada por la red neuronal. Por otro lado, aún podría estar mal clasificado ya que hay una pequeña diferencia entre las dos clases (8 vectores para la clase 2 y 9 para la clase 3). A pesar de la proximidad de los recuentos entre las dos clases predominantes en algunos casos, este método arrojó una exactitud del 100% en la clasificación basada en personas.

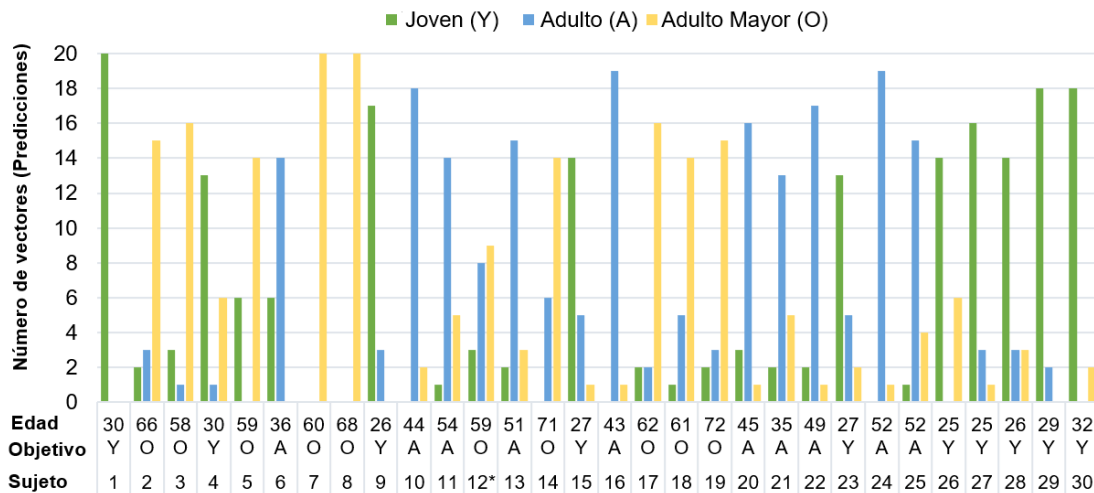


Figura 4-13 Validación de clasificación por edad *Posible sujeto mal clasificado

4.2.2 Clasificación por género

La segunda clasificación consiste en identificar el género de la persona: hombre o mujer. Utilizando la red neuronal multicapa con función de activación softmax con 25 neuronas en la primera capa y 15 neuronas en la segunda (ver el código en Anexo I), se realizaron 25 ejecuciones. Seleccionando la mejor de las ejecuciones como en la clasificación anterior, es decir, el porcentaje de acierto en la clasificación de cada clase es proporcional y el mayor posible.

En este caso, la mejor ejecución fue la que tuvo un porcentaje de aciertos para los datos de prueba del 89.4% para la clase 1 y 81.6% para la clase 2; estos se muestran en la matriz de confusión de la Figura 4-14 A. La Figura 4-14 B muestra la matriz de confusión de todos los datos, para la cual se tiene un porcentaje de aciertos del 93.5% para la clase 1 y 90.8% para la clase 2. La Figura 4-14 C muestra gráficamente el resultado de clasificación obtenido por la red neuronal, en el cual se observa que aún existen deficiencias en la clasificación, ya que aún no se separan notablemente los puntos de ambas clases.

Realizando nuevamente la validación por persona como en la clasificación anterior, se obtiene la Figura 4-15, la cual reveló algunos errores en la clasificación de los vectores. Sin embargo, la clasificación general de los individuos fue precisa, lo que afirma un porcentaje de aciertos del 100% en la identificación del género por persona.

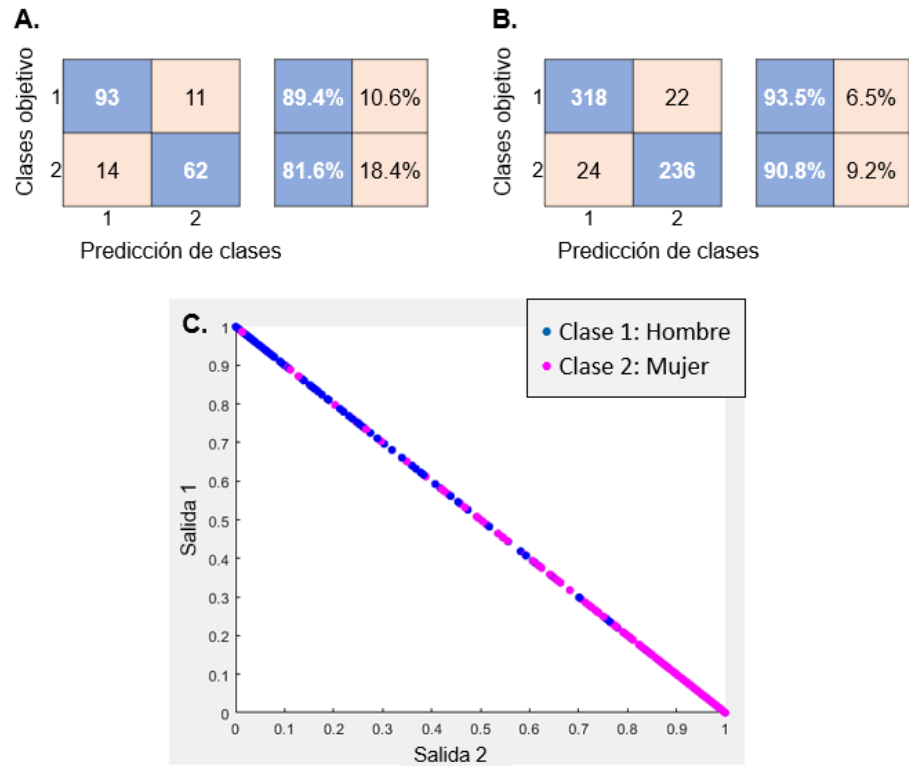


Figura 4-14 Resultado de la clasificación por género con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D




Figura 4-15 Validación de clasificación por género

4.2.3 Clasificación por IMC

La tercera clasificación consiste en identificar el índice de masa corporal de la persona bajo estudio, la cual puede clasificarse como: normal (18.50-24.90), sobrepeso (25.00-29.90) y obesidad (30.00-36.00). Utilizando la red neuronal multicapa con función de activación softmax con 25 neuronas en la primera capa y 15 neuronas en la segunda capa (ver el código en Anexo J), se realizaron 25 ejecuciones, de las cuales se selecciona también la mejor de ellas, como en las clasificaciones anteriores. La Figura 4-16 A presenta la matriz de confusión para los datos de prueba con un porcentaje de aciertos del 81.1% para la clase 1, 76.1% para la clase 2 y 89.5% para la clase 3. Por otra parte, la Figura 4-16 B muestra la matriz de confusión que incluye todos los datos con un porcentaje de aciertos del 89.6% para la clase 1, 85.8% para la clase 2 y 86.7% para la clase 3. La Figura 4-16 C muestra gráficamente el resultado de la clasificación obtenida con la red neuronal, en este caso se alcanza a distinguir mejor separación de los puntos de colores que representan cada clase, los cuales se ven más concentrados en cada vértice.

Realizando una validación se obtiene la Figura 4-17, muestra que de manera general cada persona se clasifica correctamente. Sin embargo, aparece una ambigüedad como en el caso del sujeto 13, el cual aún podría ser mal clasificado, ya que existe una pequeña diferencia entre dos de las tres clases (8 vectores se posicionan en la clase 1 y 10 vectores en la clase 2). A pesar de todo ello, esta validación también obtiene 100% de aciertos en la clasificación de índice de masa corporal por persona.

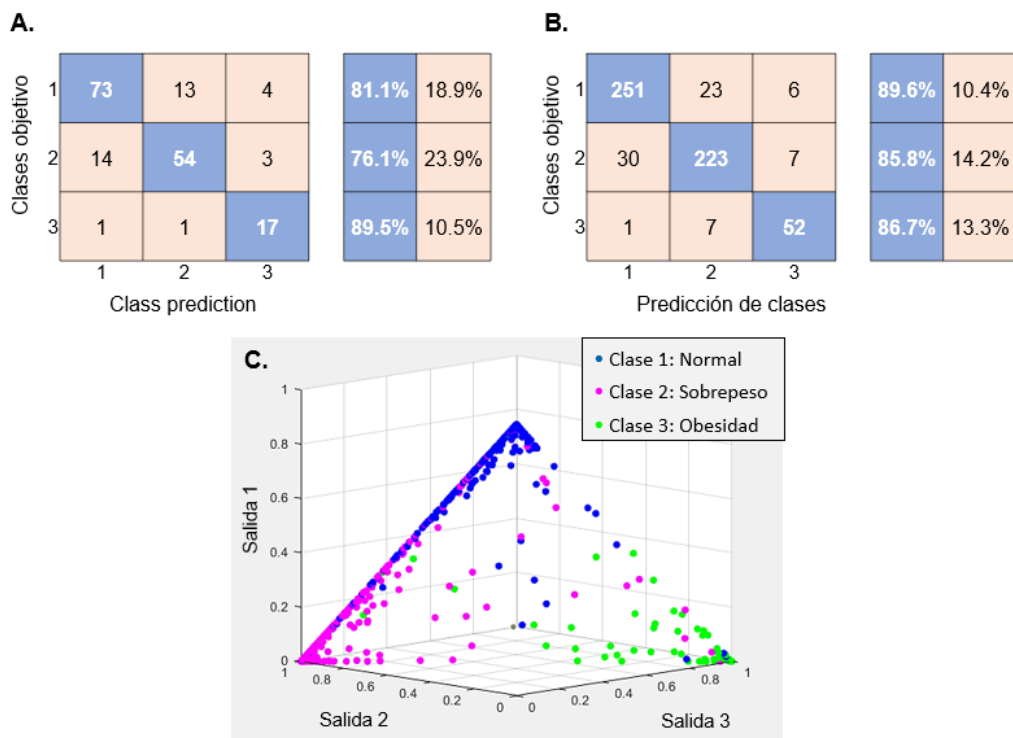


Figura 4-16 Resultado de la clasificación por IMC con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D

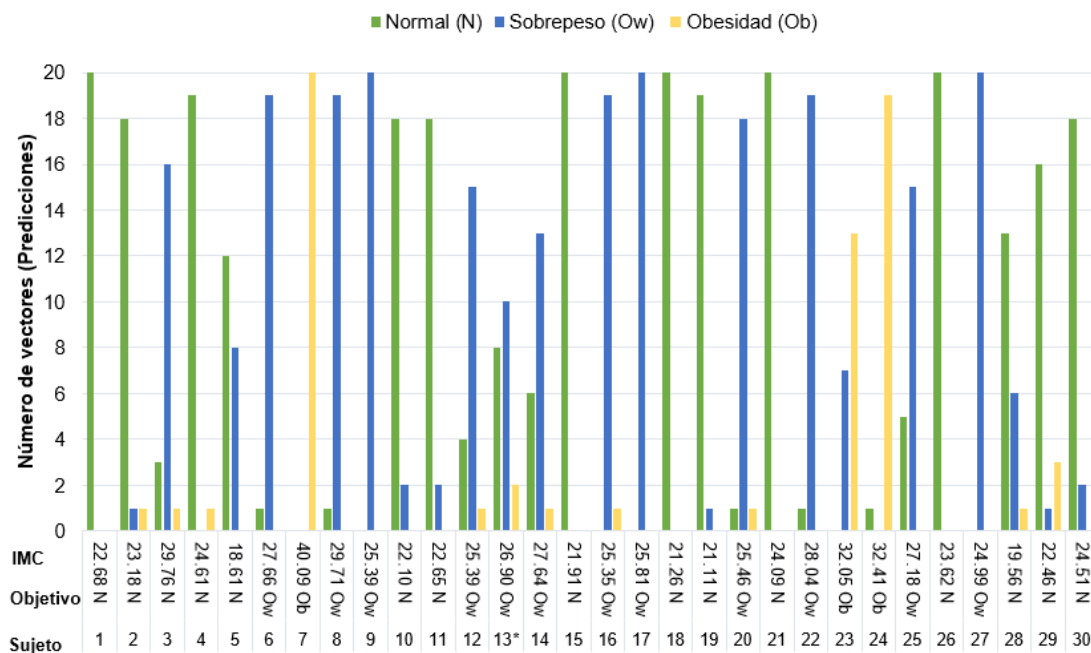


Figura 4-17 Validación de clasificación por IMC *Posible sujeto mal clasificado

4.2.4 Clasificación por tipo de caminata

La cuarta clasificación consiste en identificar el tipo de caminata de la persona analizada que puede ser: cojeando de un pie (clase 1), cojeando y arrastrando un pie (clase 2), caminata lenta (clase 3), caminata normal (clase 4) y caminata rápida (clase 5). Utilizando la red neuronal multicapa con función de activación softmax con 20 neuronas en la primera capa y 10 neuronas en la segunda capa (ver algoritmo en Anexo K), se realizaron 25 ejecuciones, de las cuales se selecciona la mejor de ellas como en las clasificaciones anteriores.

Para este caso, la Figura 4-18 A presenta la matriz de confusión para los datos de prueba con un porcentaje de aciertos del 100% para la clase 1, 80% para la clase 2, 100% para la clase 3, 93.8% para la clase 4 y 100% para la clase 5. Por otra parte, la Figura 4-18 B muestra la matriz de confusión para todos los datos con un porcentaje de aciertos del 100% para la clase 1, 95% para la clase 2, 100% para la clase 3, 98.3% para la clase 4 y 100% para la clase 5. La Figura 4-18 C muestra gráficamente el resultado de la clasificación obtenida con la red neuronal, gracias a la ayuda del algoritmo t-SNE que ayuda a reducir la dimensionalidad. En este caso se tienen 5 clases y no dos o tres como en el caso de las clasificaciones anteriores. Por lo tanto, así como se tienen los datos no es posible graficar y visualizar los resultados, de tal manera que se pasa de 5 dimensiones a 3 dimensiones para poder visualizar el comportamiento de la clasificación para las cinco clases. Viendo la Figura 4-18 C se puede distinguir que los puntos pertenecientes a cada clase se agrupan de manera notable y bien definida.

Por último, se realizó la validación para la clasificación del tipo de caminata (ver Figura 4-19). Los resultados fueron altamente precisos, ya que se relacionó correctamente la mayoría de los vectores con su respectiva clase, de tal manera que se tiene un 100% de porcentaje de aciertos para clasificar cada tipo de caminata de un individuo.

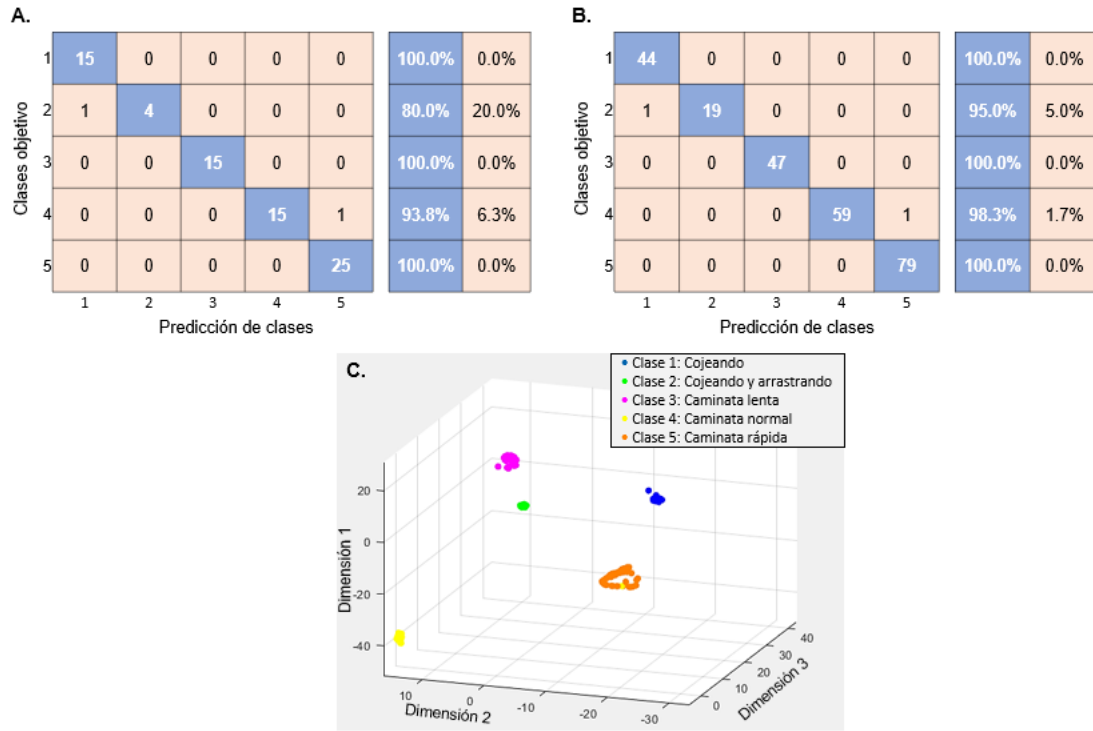


Figura 4-18 Resultado de la clasificación por tipo de caminata con red neuronal con función de activación softmax A. Matriz de confusión de datos de prueba B. Matriz de confusión de todos los datos C. Gráfico 3D




Figura 4-19 Validación de la clasificación por tipo de caminata

4.3 Pruebas adicionales

Para finalizar el análisis de los resultados, se evaluó a otras cinco personas que no forman parte de la base de datos de 30 personas para poner a prueba el sistema. Los datos de estas personas se evaluaron con las mismas redes neuronales bajo las mismas condiciones, y los resultados de su clasificación se muestran a continuación.

La Figura 4-20 A muestra los resultados de la clasificación por edad de los cinco sujetos y como se puede observar, el porcentaje de aciertos es del 100%. Por otro lado, la Figura 4-20 B muestra los resultados de la clasificación por sexo, en este caso la persona número 35 presenta algunos problemas, por lo que el porcentaje de aciertos en este caso es del 80%. La Figura 4-20 C muestra los resultados de la clasificación por índice de masa corporal, en la que el porcentaje de aciertos es del 100%. Estos resultados pueden mostrar que, en general, el sistema funciona bien con datos nuevos, es decir, con datos que no se utilizaron durante el entrenamiento.

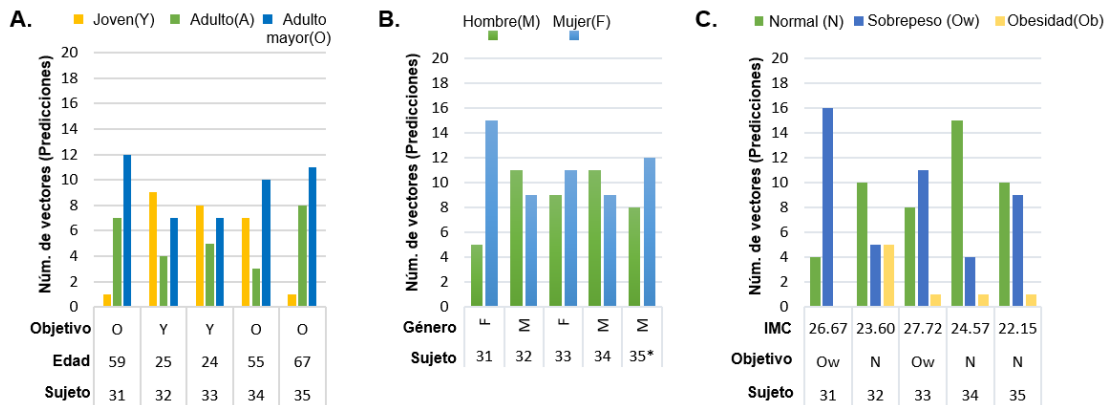


Figura 4-20. Resultados de pruebas adicionales (*Sujeto mal clasificado)

4.4 Conclusiones del capítulo

Como se pudo apreciar a lo largo de todo el capítulo, todas las pruebas dieron resultados interesantes y lo suficientemente acertados para poder realizar diferentes tipos de clasificaciones o identificaciones, como se puede observar en la Tabla 7, donde se presentan de manera resumida los resultados finales para cada una de las clasificaciones. Estos resultados fueron realmente alentadores teniendo en cuenta las condiciones bajo las cuales se hacen las pruebas, como es el caso del tipo de sensor empleado, así como el montaje para realizar las mediciones que emplea únicamente las vibraciones del suelo e incluso considerando el ruido que pueda estar presente en los alrededores del cuarto donde se realizaron las pruebas.

Clasificación evaluada	Método aplicado	Características de la red	Parámetros	Resultados	
Clasificación por edad:					
joven (25-34 años) adulto (35-54 años) adulto mayor (55-72 años).		Primera capa:	Parámetros estadísticos	Exactitud	0.7833
		20 neuronas		Exhaustividad macro	0.7833
		Segunda capa:		Precisión macro	0.7840
		5 neuronas		F1_macro	0.7836
Clasificación por género:					
Hombre o Mujer	Red neuronal multicapa con función de activación softmax	Primera capa:	Parámetros estadísticos	Exactitud	0.9233
		25 neuronas		Exhaustividad macro	0.9214
		Segunda capa:		Precisión macro	0.9222
		15 neuronas		F1_macro	0.9218
Clasificación por índice de masa corporal:					
normal (18.50-24.90)		Primera capa:	Parámetros estadísticos	Exactitud	0.8766
sobrepeso (25.00-29.90)		25 neuronas		Exhaustividad macro	0.8736
obesidad (30.00-36.00)		Segunda capa:		Precisión macro	0.8571
		15 neuronas		F1_macro	0.8653
Clasificación por tipo de caminata:					
cojeando, cojeando y arrastrando, caminata lenta, caminata normal y caminata rápida		Primera capa:	Parámetros característicos	Exactitud	0.9920
		20 neuronas		Exhaustividad macro	0.9866
		Segunda capa:		Precisión macro	0.9930
		10 neuronas		F1_macro	0.9898

Tabla 7 Características y resultados de las clasificaciones finales

Por otra parte, es importante mencionar que este trabajo derivó en un artículo publicado en la revista Measurement Science and Technology, cuya editorial es IOP Publishing Ltd., que cuenta con un factor de impacto de 2.86 y es cuartil Q2. Si se desea, se puede consultar en la referencia [52].

5 CONCLUSIONES GENERALES

Los resultados de este estudio subrayan la eficacia del método con enfoque no invasivo utilizado para la adquisición de señales de pisadas. A diferencia de otros métodos en los que los sensores se fijan al cuerpo del paciente, el sistema propuesto en este trabajo emplea acelerómetros capacitivos colocados en el suelo, para obtener la señal de las vibraciones generadas por las pisadas del sujeto de estudio. Este método permite al sujeto de estudio caminar de manera más libre y natural.

Una aportación significativa del sistema propuesto es su capacidad para obtener parámetros característicos y estadísticos de las pisadas utilizando acelerómetros asequibles en una habitación convencional. Este sistema podría ser una alternativa distinta a los métodos actuales, que a menudo se basan en acelerómetros piezoeléctricos o cámaras y micrófonos de alto costo que requieren espacios especialmente acondicionados para las mediciones (laboratorios equipados destinados exclusivamente a monitorear pisadas). La asequibilidad y sencillez del método empleado lo hacen más accesible y práctico.

Además, el montaje del sensor, integrado en una base de resina junto con el microcontrolador, demostró un rendimiento fiable y reproducible, con la ventaja añadida de su portabilidad. De los resultados obtenidos, se puede afirmar que para montar el sistema propuesto no se requieren habitaciones acondicionadas para realizar las mediciones, como laboratorios equipados.

En cuanto a lo que se refiere a la selección del sensor, se prestó especial atención en seleccionar el más adecuado para las necesidades del sistema. Lo principal fue lograr sensor las vibraciones generadas por las pisadas en una habitación ordinaria, de tal manera que, se pudieran distinguir pequeñas variaciones en las pisadas. La adecuada elección del acelerómetro y su acondicionamiento en función de la actividad a realizar, permitieron obtener señales de alta calidad, lo cual favoreció los resultados de las clasificaciones.

En lo que respecta al procesamiento de los datos obtenidos por el acelerómetro, fue de vital importancia hacer una buena interpretación, conversión, así como filtrar y preparar la señal para trabajar con ella para la obtención de los parámetros característicos y estadísticos de las pisadas. Con dicho procesamiento de los datos se logró obtener una base de datos propia que cuenta con 30 sujetos de estudio.

La aplicación de la inteligencia artificial en este estudio, en particular el uso de redes neuronales multicapa con funciones de activación softmax, ha sido otra de las aportaciones de este trabajo y ha demostrado su eficacia para efectuar clasificaciones biométricas. Esto incluye la identificación de los tipos de marcha, así como el IMC, el género y la edad, estas últimas son clasificaciones que no han sido reportadas en otros trabajos. Haciendo una comparación de los resultados presentados en otras investigaciones del porcentaje de exactitud al clasificar el tipo de marcha, se tiene que en dichos trabajos se obtuvieron porcentajes del 91.1%[25] y 96.7%[8], y en el caso de este trabajo se alcanza un valor del 99.2%.

5.1 Trabajo a futuro

Dado que el trabajo propuesto, es un primer acercamiento a este tipo de sistemas, así como también se está trabajando con una base de datos de autoría propia, quedan mejoras por hacer, por ejemplo:

- Realizar estudios posteriores para suelos de diferentes durezas y materiales, lo que implicará caracterizar el sistema con cada uno de ellos.
- Realizar más mediciones para personas con índice de masa corporal de bajo peso, así como de edades menores a 25 años y con ello crear una base de datos más completa.
- Realizar una base de datos en la que se evalúan pacientes de manera periódica para desarrollar aplicaciones de evaluaciones del estado de salud, o aplicaciones de seguimiento en una rehabilitación física.
- Mejorar y automatizar el proceso para la obtención de la base de datos.
- Desarrollar posibles aplicaciones del sistema como evaluación del estado de salud, principalmente para gente de edad avanzada y/o discapacitados, así como también para evaluaciones deportivas, rehabilitación física y reconocimiento humano para cuestiones de seguridad.
- Aumentar el tamaño de la base de datos para que tenga un número equilibrado de individuos de cada clase, lo que ayuda a dotar de mayor robustez a la red neuronal para realizar las clasificaciones.
- Desarrollar algoritmos más sofisticados con aprendizaje profundo para la detección de patrones en la marcha, ya que el trabajo presentado es un primer acercamiento.

6 REFERENCIAS

- [1] A. Ekimov y J. M. Sabatier, "Vibration and sound signatures of human footsteps in buildings", *J Acoust Soc Am*, vol. 120, núm. 2, pp. 762–768, ago. 2006, doi: <https://doi.org/10.1121/1.2217371>.
- [2] D. Aiswariyadevi y P. C. D. Rajaganapathyp, "GAIT ANALYSIS BY DIFFERENT TECHNIQUES", *Elysium Journal Engineering research & Management*, vol. 1, pp. 76–79, 2014, [En línea]. Disponible en: <http://healthsciences.qmuc.ac.uk/labweb/Equipment/electr>
- [3] S. H. Walker y G. H. Goldman, "Detecting Human Activity using Acoustic, Seismic, Accelerometer, Video, and E-field Sensors", Adelphi, MD, 2011.
- [4] A. Ekimov y J. M. Sabatier, "Broad frequency acoustic response of ground/floor to human footsteps", *Data Mining, Intrusion Detection, Information Assurance, and Data Networks Security 2006*, vol. 6241, p. 62410L, abr. 2006, doi: <https://doi.org/10.1117/12.663978>.
- [5] S. Del Din, A. Godfrey, B. Galna, S. Lord, y L. Rochester, "Free-living gait characteristics in ageing and Parkinson's disease: Impact of environment and ambulatory bout length", *J Neuroeng Rehabil*, vol. 13, núm. 1, pp. 1–12, may 2016, doi: [10.1186/s12984-016-0154-5](https://doi.org/10.1186/s12984-016-0154-5).
- [6] S. Okuda *et al.*, "Gait analysis of patients with Parkinson's disease using a portable triaxial accelerometer", *Neurol Clin Neurosci*, vol. 4, núm. 3, pp. 93–97, may 2016, doi: <https://doi.org/10.1111/ncn3.12043>.
- [7] B. Sijobert, M. Benoussaad, J. Denys, R. Pissard-Gibollet, C. Geny, y C. A. Coste, "Implementation and Validation of a Stride Length Estimation Algorithm, Using a Single Basic Inertial Sensor on Healthy Subjects and Patients Suffering from Parkinson's Disease", *Health N Hav*, vol. 07, núm. 06, pp. 704–714, 2015, doi: <https://doi.org/10.4236/health.2015.76084>.
- [8] D. M. Karantonis, M. R. Narayanan, M. Mathie, N. H. Lovell, y B. G. Celler, "Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring", *IEEE Transactions on Information Technology in Biomedicine*, vol. 10, núm. 1, pp. 156–167, ene. 2006, doi: <https://doi.org/10.1109/TITB.2005.856864>.
- [9] A. Keogh *et al.*, "Acceptability of wearable devices for measuring mobility remotely: Observations from the Mobilise-D technical validation study", *Digit Health*, vol. 9, ene. 2023, doi: [10.1177/20552076221150745](https://doi.org/10.1177/20552076221150745).
- [10] S. Kumar y R. Assistant, "A SURVEY MEMS MICROMOTOR ASSEMBLIES & APPLICATIONS", *International Journal of Engineering Research and General Science*, vol. 3, núm. 3, 2015, [En línea]. Disponible en: www.ijergs.org
- [11] M. Magno, L. Benini, C. Spagnol, y E. Popovici, "Wearable low power dry surface wireless sensor node for healthcare monitoring application", en *2013 IEEE 9th International*

- Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, IEEE, oct. 2013, pp. 189–195. doi: 10.1109/WiMOB.2013.6673360.
- [12] MNX Company, “What Is MEMS Technology?” Consultado: el 31 de diciembre de 2022. [En línea]. Disponible en: <https://www.mems-exchange.org/MEMS/what-is.html>
- [13] G. Ciuti, L. Ricotti, A. Menciasci, y P. Dario, “MEMS sensor technologies for human centred applications in healthcare, physical activities, safety and environmental sensing: A review on research activities in Italy”, *Sensors (Switzerland)*, vol. 15, núm. 3, pp. 6441–6468, mar. 2015, doi: <https://doi.org/10.3390/s150306441>.
- [14] D. Aiswariyadevi y P. C. D. Rajaganapathyp, “Gait analysis by different techniques”, *Elysium Journal*, vol. 1, núm. 1, pp. 76–79, 2014, [En línea]. Disponible en: <http://healthsciences.qmuc.ac.uk/labweb/Equipment/electr>
- [15] H. Xing, J. Li, B. Hou, Y. Zhang, y M. Guo, “Pedestrian Stride Length Estimation from IMU Measurements and ANN Based Algorithm”, *J Sens*, vol. 2017, pp. 1–11, 2017, doi: 10.1155/2017/6091261.
- [16] M. Guler y S. Ertugrul, “Measuring and Transmitting Vital Body Signs Using MEMS Sensors”, en *2007 1st Annual RFID Eurasia*, IEEE, sep. 2007, pp. 1–4. doi: 10.1109/RFIDEURASIA.2007.4368100.
- [17] F. Negrini, G. Gasperini, E. Guanziroli, J. A. Vitale, G. Banfi, y F. Molteni, “Using an accelerometer-based step counter in post-stroke patients: Validation of a low-cost tool”, *Int J Environ Res Public Health*, vol. 17, núm. 9, p. 3177, may 2020, doi: <https://doi.org/10.3390/ijerph17093177>.
- [18] A. Godfrey, S. Del Din, G. Barry, J. C. Mathers, y L. Rochester, “Instrumenting gait with an accelerometer: A system and algorithm examination”, *Med Eng Phys*, vol. 37, núm. 4, pp. 400–407, abr. 2015, doi: <https://doi.org/10.1016/j.medengphy.2015.02.003>.
- [19] S. Drira, S. G. S. Pai, Y. Reuland, N. F. H. Olsen, y I. F. C. Smith, “Using footstep-induced vibrations for occupant detection and recognition in buildings”, *Advanced Engineering Informatics*, vol. 49, núm. 101289, pp. 1–18, ago. 2021, doi: <https://doi.org/10.1016/j.aei.2021.101289>.
- [20] B. Mukhopadhyay, S. Anchal, y S. Kar, “Person Identification using Seismic Signals generated from Footfalls”, *Cornell University*, pp. 1–9, sep. 2018, doi: <https://doi.org/10.48550/arXiv.1809.08783>.
- [21] GAITRite, “Applications Proprietary Software for GAITRite Walkways”. Consultado: el 8 de julio de 2023. [En línea]. Disponible en: <https://www.gaitrite.com/about-gait-analysis>
- [22] ProtoKinetics, “Measuring GAIT Function”. Consultado: el 8 de julio de 2023. [En línea]. Disponible en: <https://www.protokinetics.com/>
- [23] mcroberts, “DynaPort 7”. Consultado: el 8 de julio de 2023. [En línea]. Disponible en: <https://www.mcroberts.nl/products/dynaport7/>

- [24] H. Lee *et al.*, “Estimation of Indoor Physical Activity Level Based on Footstep Vibration Signal Measured by MEMS Accelerometer for Personal Health Care Under Smart Home Environments”, *Mobile Entity Localization and Tracking in GPS-less Environments. Lecture Notes in Computer Science*, vol. 5801, pp. 148–162, 2009, doi: https://doi.org/10.1007/978-3-642-04385-7_11.
- [25] F. Palumbo, P. Barsocchi, C. Gallicchio, S. Chessa, y A. Micheli, “Multisensor Data Fusion for Activity Recognition Based on Reservoir Computing”, *Communications in Computer and Information Science*, vol. 386, pp. 24–35, 2013, doi: https://doi.org/10.1007/978-3-642-41043-7_3.
- [26] R. Senden, B. Grimm, I. C. Heyligers, H. H. C. M. Savelberg, y K. Meijer, “Acceleration-based gait test for healthy subjects: Reliability and reference data”, *Gait Posture*, vol. 30, núm. 2, pp. 192–196, ago. 2009, doi: <https://doi.org/10.1016/j.gaitpost.2009.04.008>.
- [27] G. Giorgi, A. Saracino, y F. Martinelli, “Using recurrent neural networks for continuous authentication through gait analysis”, *Pattern Recognit Lett*, vol. 147, pp. 157–163, jul. 2021, doi: [10.1016/j.patrec.2021.03.010](https://doi.org/10.1016/j.patrec.2021.03.010).
- [28] J. D. Farah, N. Baddour, y E. D. Lemaire, “Design, development, and evaluation of a local sensor-based gait phase recognition system using a logistic model decision tree for orthosis-control”, *J Neuroeng Rehabil*, vol. 16, núm. 1, feb. 2019, doi: [10.1186/s12984-019-0486-z](https://doi.org/10.1186/s12984-019-0486-z).
- [29] F. Recher, O. Banos, C. Nikamp, L. Schaake, C. Baten, y J. Buurke, “Optimizing activity recognition in stroke survivors for wearable exoskeletons”, *IEEE International Conference on Biomedical Robotics and Biomechatronics*, ago. 2018.
- [30] S. Alajlouni, M. Albakri, y P. Tarazaga, “Impact localization in dispersive waveguides based on energy-attenuation of waves with the traveled distance”, *Mech Syst Signal Process*, vol. 105, pp. 361–376, may 2018, doi: [10.1016/j.ymssp.2017.12.007](https://doi.org/10.1016/j.ymssp.2017.12.007).
- [31] K. F. Graff, *Wave motion in elastic solids*. New York: Dover Publications, 1975.
- [32] Predictiva21, “Como se miden las vibraciones y como son Interpretadas”. Consultado: el 10 de abril de 2023. [En línea]. Disponible en: <https://predictiva21.com/19-1-como-miden-vibraciones-interpretadas/>
- [33] H. Lee *et al.*, “Estimation of Indoor Physical Activity Level Based on Footstep Vibration Signal Measured by MEMS Accelerometer for Personal Health Care Under Smart Home Environments”, Florida, jun. 2009. [En línea]. Disponible en: www.ctia.ufl.edu
- [34] H. Helmi y A. Forouzantabar, “Rolling bearing fault detection of electric motor using time domain and frequency domain features extraction and ANFIS”, *IET Electr Power Appl*, vol. 13, núm. 5, pp. 662–669, 2019, doi: [10.1049/iet-epa.2018.5274](https://doi.org/10.1049/iet-epa.2018.5274).
- [35] D. J. Matich, “Redes Neuronales: Conceptos Básicos y Aplicaciones”, Rosario, mar. 2001.
- [36] K. Rojas-Jiménez, *Ciencia de datos para ciencias naturales*. Costa Rica, 2022.

- [37] M. Paluszek y S. Thomas, *Practical MATLAB deep learning: A project-based approach*. Apress Media LLC, 2020. doi: 10.1007/978-1-4842-5124-9.
- [38] P. Kim, *MATLAB Deep Learning*. Seoul, Korea: Apress, 2017. doi: 10.1007/978-1-4842-2845-6.
- [39] B. Cetisli, "Development of an adaptive neuro-fuzzy classifier using linguistic hedges: Part 1", *Expert Syst Appl*, vol. 37, núm. 8, pp. 6093–6101, ago. 2010, doi: 10.1016/j.eswa.2010.02.108.
- [40] J.-S. Roger Jang, C.-T. Sun, y E. Mizutani, *Neuro fuzzy and soft computing. A computational approach to learning and machine intelligence*. Prentice Hall, 1997.
- [41] MathWorks, *Fuzzy Logic Toolbox™ User's Guide R2021a*. The MathWorks, Inc., 2021. [En línea]. Disponible en: www.mathworks.com
- [42] M. Fahmy Amin, "Confusion Matrix in Three-class Classification Problems: A Step-by-Step Tutorial", *Journal of Engineering Research*, vol. 7, núm. 1, pp. 0–0, mar. 2023, doi: 10.21608/erjeng.2023.296718.
- [43] K. Berlemont, "Dimensionality Reduction Techniques", <https://towardsdatascience.com/6-dimensionality-reduction-techniques-how-and-when-to-use-them-e4891c10b5db>.
- [44] DataScientest, "Comprende el algoritmo t-SNE en 3 pasos", <https://datascientest.com/es/comprende-el-algoritmo-t-sne-en-3-pasos>.
- [45] PCB Piezotronics, "Model 356B18 Installation and Operating Manual". Consultado: el 31 de diciembre de 2022. [En línea]. Disponible en: <https://www.pcb.com/products?model=356b18>
- [46] A. Devices, "Low Noise, Low Drift, Low Power, 3-Axis MEMS Accelerometers ADXL354/ADXL355", 2022. [En línea]. Disponible en: www.analog.com
- [47] K. M. Houston y D. P. McGaffigan, "Spectrum Analysis Techniques for Personnel Detection Using Seismic Sensors", *SPIE's Proceedings on Unattended Ground Sensor Technologies and Applications*, vol. 5090, pp. 162–173, 2003.
- [48] S. Alajlouni y P. Tarazaga, "A passive energy-based method for footprint impact localization, using an underfloor accelerometer sensor network with Kalman filtering", *JVC/Journal of Vibration and Control*, vol. 26, núm. 11–12, pp. 941–951, jun. 2020, doi: 10.1177/1077546319890520.
- [49] The MathWorks Inc., "findpeaks". Consultado: el 31 de julio de 2023. [En línea]. Disponible en: <https://la.mathworks.com/help/signal/ref/findpeaks.html>
- [50] MathWorks, "Prominencia". Consultado: el 31 de marzo de 2024. [En línea]. Disponible en: <https://la.mathworks.com/help/signal/ug/prominence.html>
- [51] J. Heaton, *Introduction to Neural Networks for Java*, 2nd. USA: Heaton Research, Inc., 2008.

- [52] A. López-Tapia, M. A. Reyes-Barranca, G. S. Abarca-Jiménez, L. Sánchez-Márquez, y L. M. Flores-Nava, "Assessment of a system for gait parameter extraction and individual feature classification using artificial neural networks and a low-cost accelerometer", *Meas Sci Technol*, vol. 36, ene. 2025, doi: 10.1088/1361-6501/ad817b.

Anexo A

DICTAMEN



**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS
DEL INSTITUTO POLITÉCNICO NACIONAL**

**COMITÉ DE BIOÉTICA PARA LA INVESTIGACIÓN EN SERES HUMANOS
(COBISH)-CINVESTAV**

Folio 086/2022

DICTAMEN

Director del Proyecto: Dr. Mario Alfredo Reyes Barranca

Departamento: Ingeniería Eléctrica-SEES

Título del Proyecto: "Monitoreo de actividad física mediante el registro de pisadas con base a las señales derivadas de un acelerómetro MEMS".

El Comité de Bioética para la Investigación en Seres Humanos del Centro de Investigación y de Estudios Avanzados del IPN (COBISH), después de revisar la información de los instrumentos que se utilizarán para realizar su estudio y que sometió para su evaluación, dictamina:

Que el estudio: "Monitoreo de actividad física mediante el registro de pisadas con base a las señales derivadas de un acelerómetro MEMS" cumple con los lineamientos bioéticos establecidos para la investigación en seres humanos.

Se firma el presente a los treinta días del mes de junio del 2022, en el Centro de Investigación y de Estudios Avanzados del IPN.

Dra. María Betzabet Quintanilla Vega
Presidenta del COBISH

c.c.p. Expediente

Anexo B

CÓDIGO EN C++ DE TRANSMISIÓN Y RECEPCIÓN DE DATOS

```

//En este programa se configuran los registros del sensor ADXL355,
//Este programa espera a que se le envíe una bandera ('a') a través del puerto serie,
//una vez recibida la bandera comienza a leer las aceleraciones XYZ y
//se envían a través del puerto serie

#include <Wire.h>
#include <math.h>

//ACCELEROMETRO
#define ADXL355 0x1D // dirección del acelerómetro (fabricante) con ASEL=0 (MISO) Pin 4 del chip

//Direcciones de los registros a utilizar
#define XDATA3 0x08
#define XDATA2 0x09
#define XDATA1 0x0A
#define YDATA3 0x0B
#define YDATA2 0x0C
#define YDATA1 0x0D
#define ZDATA3 0x0E
#define ZDATA2 0x0F
#define ZDATA1 0x10

#define ACT_EN 0x24
#define FILTER 0x28
#define RANGE 0x2C
#define POWER_CTL 0x2D
#define RESET 0x2F

//Variables
long z1,z2,z3;//Lecturas de aceleraciones
long Ac_z;//Aceleración en cada eje
String Ac_z_string;

char dato_leido = 0; // para datos seriales entrantes
//Bandera que nos indica cuándo se recibe la orden de empezar a enviar datos
//a través del puerto serie
int bandera = 0;
unsigned long muestra = 0;

void setup()
{
  //Comunicaciones
  Serial.begin(115200); //comunicación Serial
  Wire.begin();//comunicación I2C

  //configuración acelerómetro
  Wire.beginTransmission(ADXL355);
  Wire.write(RESET); //registro inicial a escribir
  Wire.write(0x52);//Reset a todos los registros
  Wire.endTransmission();

  //Hay que hacer una nueva transmisión aquí,
  //ya que la dirección se autoincrementa de acuerdo a la hoja de datos
  Wire.beginTransmission(ADXL355);
  Wire.write(FILTER);//Nueva dirección a escribir
  Wire.write(0x04); // ODR 250HZ, LowPassFilter 62.5Hz

```

```

void setup()
{
  //Comunicaciones
  Serial.begin(115200); //comunicación Serial
  Wire.begin();//comunicación I2C

  //configuración acelerómetro
  Wire.beginTransmission(ADXL355);
  Wire.write(RESET); //registro inicial a escribir
  Wire.write(0x52); //Reset a todos los registros
  Wire.endTransmission();

  //Hay que hacer una nueva transmisión aquí,
  //ya que la dirección se autoincrementa de acuerdo a la hoja de datos
  Wire.beginTransmission(ADXL355);
  Wire.write(FILTER); //Nueva dirección a escribir
  Wire.write(0x04); // ODR 250HZ, LowPassFilter 62.5Hz
  Wire.endTransmission();

  Wire.beginTransmission(ADXL355);
  Wire.write(RANGE); //registro inicial a escribir
  Wire.write(0x01); //Range -I2C speed=Fast mode; +-2g
  Wire.endTransmission();

  Wire.beginTransmission(ADXL355);
  Wire.write(POWER_CTL); //Nueva dirección a escribir
  Wire.write(0x06); // Power Control -DRDY deshabilitado; Procesamiento de temperatura deshabilitado; Measure mode
  Wire.endTransmission();
}

void loop ()
{
  if (bandera == 0) // Si no se ha recibido la orden de empezar a enviar datos
  {
    if (Serial.available() > 0)
    {
      dato_leido = Serial.read();
      //este dato se recibe desde el teclado de la computadora e
      //indica que se puede empezar a enviar los datos
      if (dato_leido == 'a')
      {
        bandera=1;
      }
      else
      {
        //no hace nada
      }
    }
  }
  else //Ya se recibió la orden de enviar datos
  {
    //Lectura de las 3 direcciones de datos
    Wire.beginTransmission(ADXL355);
    Wire.write(ZDATA3);
    Wire.endTransmission();

    Wire.requestFrom(ADXL355,3); //3 BYTES A LEER
    z3=Wire.read();
    z2=Wire.read();
    z1=Wire.read();

    //Union de los tres Bytes de la medición (z1 LSBits z3 MSBits)
    Ac_z = (z1 >> 4) | (z2 << 4) | (z3 << 12);

    if (Ac_z >= 0x80000) //ya que en complemento a dos el primer bit siempre estará en uno
    {
      Ac_z =Ac_z|0xFFFF0000; //1111 1111 1111 0000 0000 0000 0000 0000 se lo agregamos para completar
      //los 32 bits del tipo de dato long porque el sensor es de 20 bits
      // y la información estaría como: 0000 0000 0000 XXXX XXXX XXXX XXXX
    }
    Ac_z_string=String(Ac_z);

    Serial.println(String(muestra)+"-"+Ac_z_string); //Envia el número de muestra y la aceleración separados por una coma
    muestra = muestra+1;
  }
}

```

Anexo C

CÓDIGO EN PHYTON DE PROCESAMIENTO Y
ALMACENAMIENTO DE DATOS

```

import serial, time, csv

file_name = "S36_01.csv"
num_datos = 8577*2 #8577*2=aprox 20seg (8577*2)+4288
bandera = 0
entrada="null"

i = 0
#newline='' es para que no deje espacios entre columnas
file = open(file_name,"w",newline='')
Xg = 2.048 #Aceleración seleccionada en el acelerómetro (+-2g)

try:

    ser = serial.Serial("COM3", 115200)

    print("Iniciando el sistema, espera")
    time.sleep(1)
    while bandera != 1:

        if entrada == 'a':
            bandera = 1
            msj = "a".encode()#"Reset".encode()
            ser.write(msj)#"Reset".encode('utf-8')

        else:
            entrada=input("Presiona la letra 'a' para iniciar : ")
            time.sleep(5)
    bandera = 0

    thewriter = csv.writer(file,delimiter=",")
    thewriter.writerow(["t(ms)", "Acel"])
    t=1.165908826;#tiempo en ms por cada muestra
    while i <= num_datos:
        recibido = str(ser.readline())
        datos = recibido[2:][:5] #Sólo se queda con los datos relevantes
        #de la cadena proveniente del coordinador
        lista = datos.split(sep=',') # Hace una lista de los datos
        #separados por comas
        lista[0] = float(lista[0])*t;
        lista[1] = (float(lista[1])*Xg)/(2<<18) #(2<<18)=2^19
        print(lista)
        thewriter.writerow(lista)
        i=i+1

finally:
    file.close() # cierra archivo csv
    ser.close() # cierra puerto serie

```


Anexo D

CÓDIGO EN MATLAB DE EXTRACCIÓN DE PARÁMETROS

```

clc
close all
for doc=1:10 %*****
    numero= 30; %Número de persona *****
    if doc==1
        filename = "S"+numero+"_01.csv";
    elseif doc==2
        filename = "S"+numero+"_02.csv";
    elseif doc==3
        filename = "S"+numero+"_03.csv";
    elseif doc==4
        filename = "S"+numero+"_04.csv";
    elseif doc==5
        filename = "S"+numero+"_05.csv";
    elseif doc==6
        filename = "S"+numero+"_06.csv";
    elseif doc==7
        filename = "S"+numero+"_07.csv";
    elseif doc==8
        filename = "S"+numero+"_08.csv";
    elseif doc==9
        filename = "S"+numero+"_09.csv";
    elseif doc==10
        filename = "S"+numero+"_10.csv";
    end

    pisadas = csvread(filename,1,0); %Lectura del archivo,
    % sólo la primer fila se ignora
    time = pisadas(:,1); %primer columna de los datos tiempo
    accz = pisadas(:,2); %segunda columna de los datos aceleración en z

    %-----
    %Reducción de ruido y referenciación a 0

    %p(x)=p1x^n+p2x^n?1+...+pnx+pn+1.
    %Regresa los coeficientes para un polinomio p(x) de grado n que es el
    % mejor ajuste (con mínimos cuadrados) para los datos en y. |
    p = polyfit(time,accz,2);
    f_y=polyval(p,time);
    accz_p=accz-f_y; %señal con menos ruido

    %Obtención de espectro de frecuencias
    fs=1/((time(2)-time(1))*10^-3); %Frecuencia de muestreo
    [pp,f] = pspectrum(accz_p,fs);

    %Aplicación de filtro pasabajas para parámetros ordinarios*****
    fpass=10; %Frecuencia de filtro en Hz
    accz_data = lowpass(accz_p,fpass,fs);

    %Aplicación de filtro pasabajas para parámetros estadísticos
    fpass2=10; %Frecuencia de filtro en Hz
    accz_data2 = lowpass(accz_p,fpass2,fs);

```

```

%Detección de picos de mayor magnitud*****
[picos,loc_picos] = findpeaks(accz_data,'MinPeakHeight',0.00035,'MinPeakDistance',350);
%entrega la magnitud de los picos máximos y el índice en el que se localizan

%-----
%Calculo de tiempos entre picos máximos
interval_pico = diff(time(loc_picos)); %calcula las diferencias entre los
% elementos adyacentes del vector Y = [X(2)-X(1) X(3)-X(2) ... X(m)-X(m-1)]
num_pasos=length(loc_picos);
tentrepisada_prom=mean(interval_pico);

%-----
%Calculo de tiempos de duración de pisada S, segmentación en pisadas
n=length(loc_picos);
m=length(accz_data);
loc_S=zeros(1,n-1);
accz_paso=zeros(1,length(accz_data));
for i=1:n
    if i<=(n-1)
        accz_paso(loc_picos(i):loc_picos(i+1))=accz_data(loc_picos(i):loc_picos(i+1));
        altura=0.03*picos(i);
        [mag,minloc_paso]= findpeaks(accz_paso,'MinPeakHeight',altura,'MinPeakDistance',15);
        loc_S(i) = minloc_paso(8);

    else
        accz_paso(loc_picos(i):m)=accz_data(loc_picos(i):m);
        altura=0.03*picos(i);
        [mag,minloc_paso]= findpeaks(accz_paso,'MinPeakHeight',altura,'MinPeakDistance',15);
        loc_S(i) = minloc_paso(8);
    end

    accz_paso=zeros(1,length(accz_data));
end

%Duración de pisadas
S=time(loc_S)-time(loc_picos);

%Tiempos S para pie izquierdo y derecho
z=1;
w=1;
for k=1:length(S)
    if mod(k,2) == 0
        Si(z)=S(k);
        z=z+1;
    else
        Sd(w)=S(k);
        w=w+1;
    end
end
Si_prom=mean(Si);
Sd_prom=mean(Sd);

```

```

%-----
%Calculo de tiempos entre final e inicio de pisadas T
v=length(interval_pico);
T=zeros(1,v);
for j=1:v
T(j)=interval_pico(j)-S(j);
end

%Tiempos T pie izquierdo y derecho
x=1;
y=1;
for q=1:length(T)
    if mod(q,2) == 0
        Td(x) = T(q);
        x=x+1;
    else
        Ti(y) = T(q);
        y=y+1;
    end
end
Ti_prom=mean(Ti);
Td_prom=mean(Td);

%-----
%Calculo de energía de señal de pisadas izquierda y derecha
t=length(loc_picos);
Q=0;
E=zeros(1,t);
xx=1;
yy=1;
for r=1:t
    for s=loc_picos(r):loc_S(r)
        E(r) = E(r)+(accz_data(s))^2;
    end

    if mod(r,2) == 0
        Ei(xx) = E(r);
        xx=xx+1;
    else
        Ed(yy) = E(r);
        yy=yy+1;
    end
end
Ei_prom=mean(Ei);
Ed_prom=mean(Ed);

%-----
%Cálculo de cadencia pie izquierdo y derecho
for c=1:length(Ti)
    Vi(c) =(1/(Ti(c)+Si(c)))*10^3;
end
for cc=1:length(Td)
    Vd(cc) = (1/(Td(cc)+Sd(cc+1)))*10^3;
end
Vi_prom=mean(Vi);
Vd_prom=mean(Vd);

```

```

%-----
%Calculo de parámetros estadísticos tiempo-frecuencia de señal de pisadas izquierda y derecha
aa=1;
bb=1;
for ss=1:length(loc_picos)
    %v_paso=accz_data2(loc_picos(ss):loc_5(ss));
    if ss<=length(loc_picos)-1
        v_paso=accz_data2(loc_picos(ss):loc_picos(ss+1)); %Vector de datos de pico a pico máximo
    else
        v_paso=accz_data2(loc_picos(ss):length(accz_data2));
    end

    T1(ss)=std(v_paso); %desviación estándar
    T2(ss)=rms(v_paso); %raíz cuadrática media
    T3(ss)=kurtosis(v_paso); %kurtosis
    T4(ss)=skewness(v_paso); %Asimetría estadística
    T5(ss)=mad(v_paso);%Desviación absoluta media
    T6(ss)=meanfreq(v_paso,fs); %frecuencia media
    T7(ss)=medfreq(v_paso,fs); %mediana de la frecuencia
    T8(ss)=bandpower(v_paso); %promedio de la potencia

    if mod(ss,2) == 0
        T1i(aa) = T1(ss);
        T2i(aa) = T2(ss);
        T3i(aa) = T3(ss);
        T4i(aa) = T4(ss);
        T5i(aa) = T5(ss);
        T6i(aa) = T6(ss);
        T7i(aa) = T7(ss);
        T8i(aa) = T8(ss);
        aa=aa+1;
    else
        T1d(bb) = T1(ss);
        T2d(bb) = T2(ss);
        T3d(bb) = T3(ss);
        T4d(bb) = T4(ss);
        T5d(bb) = T5(ss);
        T6d(bb) = T6(ss);
        T7d(bb) = T7(ss);
        T8d(bb) = T8(ss);
        bb=bb+1;
    end
end

%-----
%Se guardan los datos de cada prueba de una persona en un archivo csv
filename2 ="Ps_"+numner+"_ "+ doc +".csv";
fid2 = fopen(filename2, 'w');
fprintf(fid2, ['Si (duracion)',',','Sd (duracion)',',','Ti(zancada)',',','Td (zancada)',',',...
    'Ei(energia)',',','Ed(energia)',',','Vi(cadencia)',',','Vd(cadencia)',',',...
    'T1i',',','T1d',',','T2i',',','T2d',',','T3i',',','T3d',',','T4i',',','T4d',',','T5i',',','T5d',',',...
    'T6i',',','T6d',',','T7i',',','T7d',',','T8i',',','T8d','\n']);
for j=1:length(Sd)-1
    fprintf(fid2, ['%f',',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',',...
        ',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',',...
        ',','%f',',','%f',',','%f',',','%f',',','e',',','e','\n'],...
        Si(j),Sd(j+1),Ti(j),Td(j),Ei(j),Ed(j+1),Vi(j),Vd(j),...
        T1i(j),T1d(j+1),T2i(j),T2d(j+1),T3i(j),T3d(j+1),T4i(j),T4d(j+1),T5i(j),T5d(j+1),...
        T6i(j),T6d(j+1),T7i(j),T7d(j+1),T8i(j),T8d(j+1));
end
clear
end

```

Anexo E

CÓDIGO EN MATLAB DE UNIFICACIÓN DE DATOS POR PERSONA

```
m=30; %número de persona
numarchivos=10;
archivoall=zeros(1,24);
for n=1:numarchivos
    a= csvread("Ps_"+m+"_"+n+".csv",1,0); %Lectura del archivo, sólo la primer fila se ignora
    archivoall=[archivoall;a];
end

filename = "Ps_"+m+"_all.csv";
fid = fopen(filename, 'w');
fprintf(fid, ['Si (duracion)',',','Sd (duracion)',',','Ti(zancada)',',','Td (zancada)',',',...
    'Ei(energia)',',','Ed(energia)',',','Vi(cadencia)',',','Vd(cadencia)',',',...
    'T1i',',','T1d',',','T2i',',','T2d',',','T3i',',','T3d',',','T4i',',','T4d',',','T5i',',','T5d',',',...
    'T6i',',','T6d',',','T7i',',','T7d',',','T8i',',','T8d','\n']);
for n=1:length(archivoall)-1
    fprintf(fid, ['%f',',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',',...
        ',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',','%f',',',...
        ',','%f',',','%f',',','%f',',','%f',',','e',',','e','\n'],archivoall(n+1,:));
end
```

Anexo F

CÓDIGO EN MATLAB DE REDUCCIÓN DE VECTORES

```

clc
clear all
close all
filename = 'Ps_30_all.csv';
m=30; %número de persona
P_T = csvread(filename,1,0); %Lectura del archivo, sólo la primer fila se ignora

%Promedio de datos izq y der
C1p = mean(P_T(:,1:2),2); %S
C2p = mean(P_T(:,3:4),2); %T
C3p = mean(P_T(:,5:6),2); %E
C4p = mean(P_T(:,7:8),2); %V
P1p = mean(P_T(:,9:10),2); %T1
P2p = mean(P_T(:,11:12),2); %T2
P3p = mean(P_T(:,13:14),2); %T3
P4p = mean(P_T(:,15:16),2); %T4
P5p = mean(P_T(:,17:18),2); %T5
P6p = mean(P_T(:,19:20),2); %T6
P7p = mean(P_T(:,21:22),2); %T7
P8p = mean(P_T(:,23:24),2); %T8

Pp=[C1p,C2p,C3p,C4p,P1p,P2p,P3p,P4p,P5p,P6p,P7p,P8p];

%Promedio de datos de 5 en 5
if mod(length(Pp),5)~=0
    N=length(Pp)-mod(length(Pp),5);
else
    N=length(Pp);
end
j=1;
for i=1:5:N
    Ppp(j,:) = mean(Pp(i:i+4,:));
    j=j+1;
end

%Creación de archivo cvs de promedios para una persona

filename2 = "Ps_"+m+"_all_mean20.csv";
fid = fopen(filename2, 'w');
fprintf(fid, ['S',' ','T',' ','E',' ','V',' ','...',
    'T1',' ','T2',' ','T3',' ','T4',' ','T5',' ','...',
    'T6',' ','T7',' ','T8','\n']);
for j=1:20
    fprintf(fid, ['%f',' ','%f',' ','%f',' ','%f',' ','...',
    '%f',' ','%f',' ','%f',' ','%f',' ','%f',' ','...',
    '%f',' ','%f',' ','%f',' ','%e','\n'],Ppp(j,:));
end

```

Anexo G

En este anexo se presentan los conjuntos difusos y la base de reglas para las diferentes clasificaciones usando el clasificador neurodifuso adaptable con modificadores lingüísticos (ANFC-LH). Como se observa en las figuras, tras el entrenamiento del clasificador neurodifuso, se modifican tanto el centro como el ancho de las campanas de Gauss de los conjuntos difusos. Como consecuencia, los efectos de algunos conjuntos difusos en las reglas se pueden incrementar o decrementar.

CONJUNTOS DIFUSOS Y BASE DE REGLAS PARA CLASIFICACIÓN DE EDAD

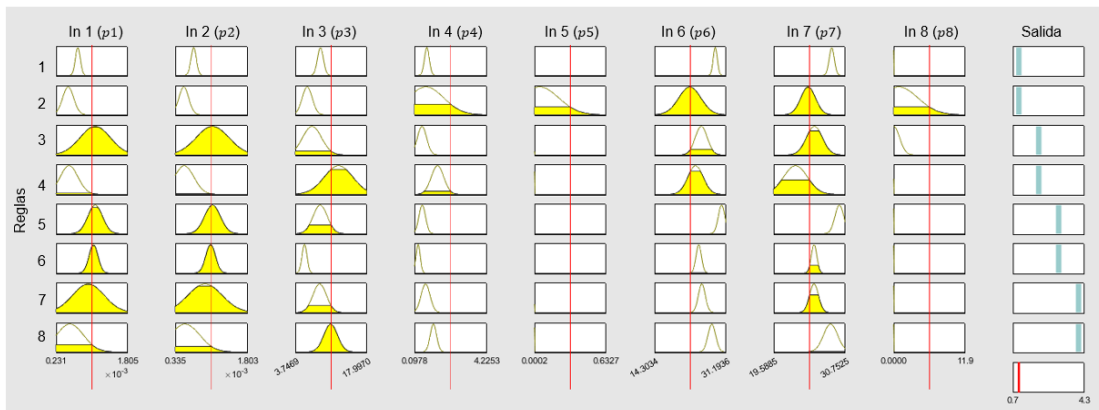


Figura 7-1 Conjuntos difusos para clasificador de edad con ANFC-LH

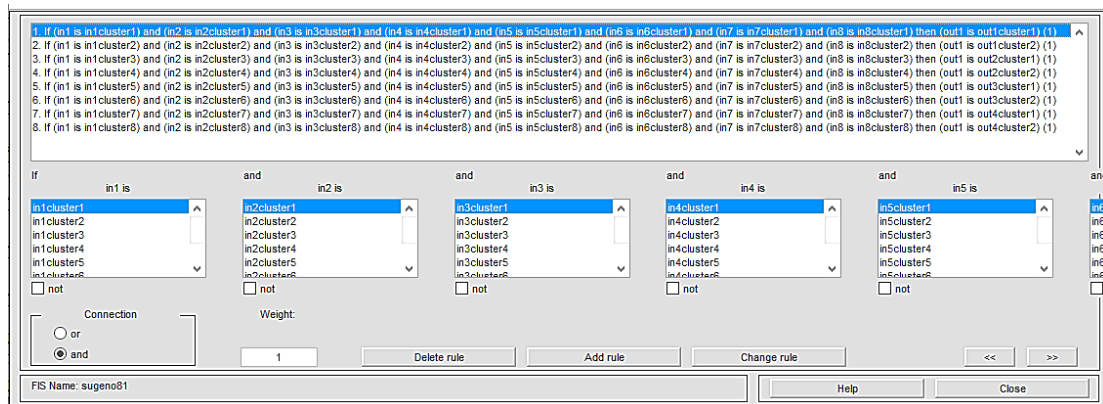


Figura 7-2 Base de reglas para clasificador de edad con ANFC-LH

CONJUNTOS DIFUSOS Y BASE DE REGLAS PARA CLASIFICACIÓN DE IMC

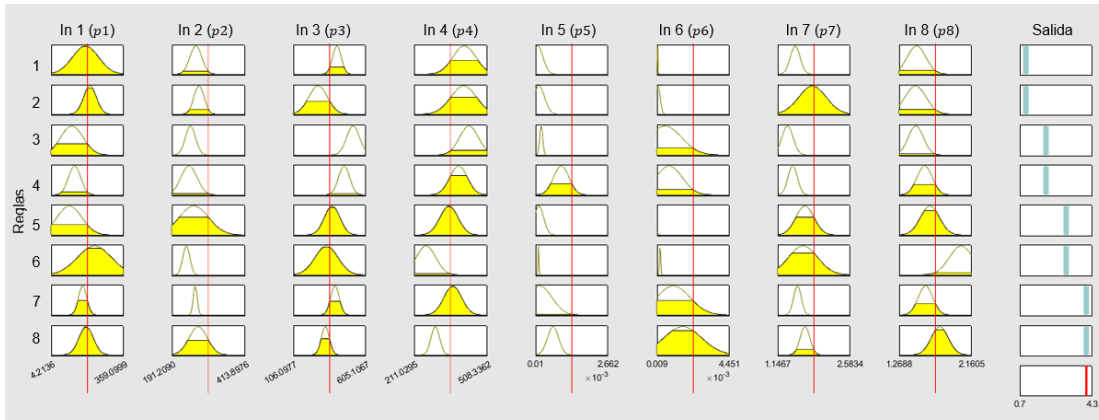


Figura 7-3 Conjuntos difusos para clasificador de IMC con ANFC-LH

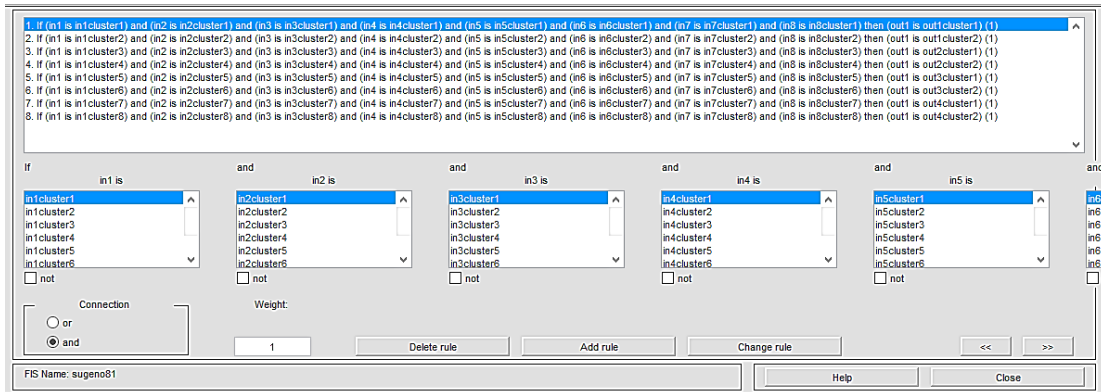


Figura 7-4 Base de reglas para clasificador de IMC con ANFC-LH

CONJUNTOS DIFUSOS Y BASE DE REGLAS PARA CLASIFICACIÓN DE TIPO DE CAMINATA

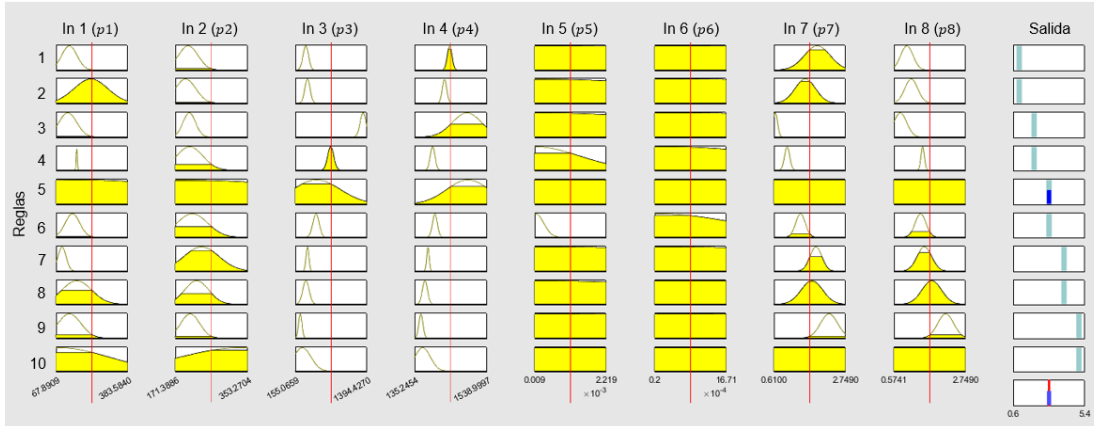


Figura 7-5 Conjuntos difusos para clasificador de tipo de caminata con ANFC-LH

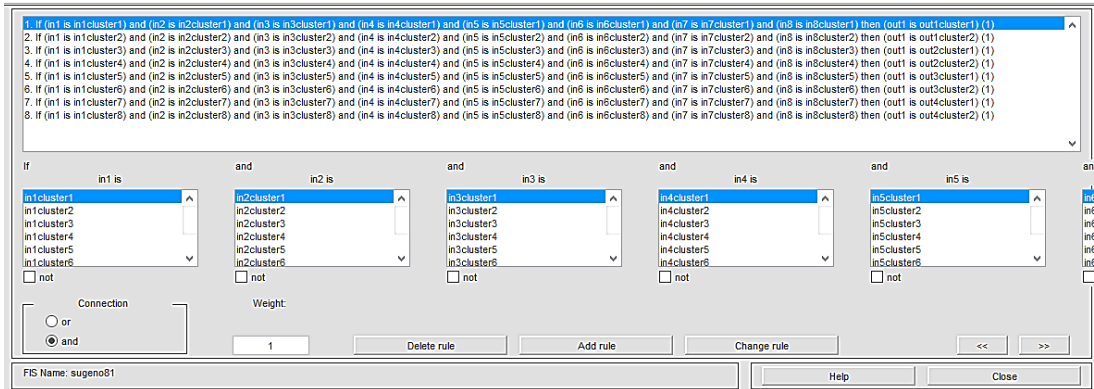


Figura 7-6 Base de reglas para clasificador de tipo de caminata con ANFC-LH

Anexo H

CÓDIGO EN MATLAB DE CLASIFICACIÓN DE EDAD

```

% Clasificador de Edad con Softmax
clear
close all
% Carga los vectores de prueba y las salida deseadas
load('Data.csv');
P = Data(:,5:12)';
T = max(0,Data(:,17:19)');
T1 = Data(:,16);

% Definiendo el tipo de RED
net = patternnet([20 5], 'trainlm', 'mse');

% Definiendo parámetros de entrenamiento
net.trainParam.epochs = 100;
net.trainParam.goal = 5e-3;
net.trainParam.max_fail = 20;

% Entrenando la RED
[net,tr] = train(net,P,T);

% Simulando la RED
a = sim(net,P);
mse = perform(net,a,T);
classes = vec2ind(a);

Q = size(P,2);

% Verificación aciertos
for i = 1:Q
    y(i) = (classes(i) == T1(i));
end

Numero_Aciertos = sum(y);
Porcentaje_Aciertos = Numero_Aciertos/Q*100;

cm = confusionchart(T1,classes);
cm.Title = 'Clasificación de Edad';
cm.RowSummary = 'row-normalized';
cm.XLabel = 'Predicción de clases';
cm.YLabel = 'Clases objetivo';
%-----

figure
clases = vec2ind(flipud(T));
color = [0,0,255; %01 clase 1 azul
         255,0,255; %05 clase 3 Rosa Mexicano
         0,255,0]/255;%02 clase 2 Verde

scatter3(a(1,:),a(2,:),a(3,:),30,color(clases,:), 'filled');

```

Anexo I

CÓDIGO EN MATLAB DE CLASIFICACIÓN DE GÉNERO

```

% Clasificador de Género
clear
close all

% Carga los vectores de prueba y las salida deseadas
load('Data.csv');
P = Data(:,5:12)';
T = Data(:,21:22)';
T1 = Data(:,20);

% Definiendo el tipo de RED
net = patternnet([25 15], 'trainlm', 'mse');

% Definiendo parámetros de entrenamiento
net.trainParam.epochs = 100;
net.trainParam.goal = 5e-3;
net.trainParam.max_fail = 20;

% Entrenando la RED
[net,tr] = train(net,P,T);

% Simulando la RED
a = sim(net,P);
mse = perform(net,a,T);
classes = vec2ind(a);

Q = size(P,2);

% Verificación aciertos
y = zeros(1,600);
for i = 1:Q
    y(i) = (classes(i) == T1(i));
end

Numero_Aciertos = sum(y);
Porcentaje_Aciertos = Numero_Aciertos/Q*100;

% Salida de la red
figure
a = a';
scatter(a(:,1),a(:,2),25,T1,'filled','MarkerEdgeColor','k');

% Matriz de confusión
cm = confusionchart(T1,classes);
cm.Title = 'Clasificación de Género';
cm.RowSummary = 'row-normalized';
cm.XLabel = 'Predicción de clases';
cm.YLabel = 'Clases objetivo';

%-----
figure
clases = vec2ind(flipud(T));
color = [0,0,255; %01 clase 1 azul
        255,0,255]/255; %05 clase 2 Rosa Mexicano

scatter(a(:,1),a(:,2),30,color(clases,:), 'filled');

```

Anexo J

CÓDIGO EN MATLAB DE CLASIFICACIÓN DE IMC

```

% Clasificación de personas por IMC

clear
close all
% Carga los vectores de prueba y las salida deseadas
load('Dataset_IMC_8paramStad20cu_2.mat');
P = P_T(1:8,:);
T = P_T(9:11,:);

% Definiendo el tipo de RED
net = patternnet([25 15], 'trainlm', 'mse');

% Definiendo parámetros de entrenamiento
net.trainParam.epochs = 500;
net.trainParam.goal = 5e-3;
net.trainParam.max_fail = 20;

% Entrenando a la RED
[net,tr] = train(net,P,T);

% Simulación de la RED
a = sim(net,P);

a1 = (a > 0.5);
Q = size(P,2);

% Verificación del número de aciertos
for i = 1:Q
    y1(:,i) = (a1(:,i) == T(:,i));
end

NumeroAciertos = sum(sum(y1)==3);
PorcentajeAciertos = NumeroAciertos/Q*100;

%-----
figure
clases = vec2ind(flipud(T));
color = [0,0,255; %01 clase 1 azul
         255,0,255; %05 clase 3 Rosa Mexicano
         0,255,0]/255;%02 clase 2 Verde

scatter3(a(1,:),a(2,:),a(3,:),30,color(clases,:), 'filled');

%-----
figure
cm = confusionchart(vec2ind(flipud(T)),vec2ind(flipud(a1)));
cm.Title = 'Clases por intervalos de IMC';
cm.RowSummary = 'row-normalized';
cm.XLabel = 'Predicción de clases';
cm.YLabel = 'Clases verdaderas';

```

Anexo K

CÓDIGO EN MATLAB DE CLASIFICACIÓN DE TIPO DE CAMINATA

```

% Clasificación de personas por tipo de caminata

clear
close all
% Carga los vectores de prueba y las salida deseadas
load('Dataset_tipocamina_2.mat');

% Normalización de datos
[P1n,PS] = mapminmax(Dataset_tipocamina_2(1:2,:)); %S   y = (ymax-ymin)*(x-xmin)/(xmax-xmin) + ymin;
P1n=(P1n/2)+0.5;
[P2n,PS2] = mapminmax(Dataset_tipocamina_2(3:4,:)); %T
P2n=(P2n/2)+0.5;
[P3n,PS3] = mapminmax(Dataset_tipocamina_2(5:6,:)); %E
P3n=(P3n/2)+0.5;
[P4n,PS4] = mapminmax(Dataset_tipocamina_2(7:8,:)); %V
P4n=(P4n/2)+0.5;

Pn=[P1n;P2n;P3n;P4n];

T=Dataset_tipocamina_2(9:13,:);

% Definiendo el tipo de RED
net = patternnet([20 10]); %25

% Definiendo parámetros de entrenamiento
net.trainParam.epochs = 100;
net.trainParam.goal = 1e-3;
net.trainParam.max_fail = 10;

% Entrenando a la RED
[net,tr] = train(net,Pn,T);

% Simulación de la RED
a = sim(net,Pn);

a1 = (a > 0.5);
Q = size(Pn,2);

% Verificación del número de aciertos
for i = 1:Q
    y1(:,i) = (a1(:,i) == T(:,i));
end

NumeroAciertos = sum(sum(y1)==5);
PorcentajeAciertos = NumeroAciertos/Q*100;

%-----
clases = vec2ind(flipud(T));
color = [0,0,255; %01 clase 1 azul
         0,255,0; %02 clase 2 Verde
         255,0,255; %05 clase 3 Rosa Mexicano
         255,255,0; % clase 4 Amarillo
         255,128,0]/255;% clase 5 Naranja

[Z,loss] = tsne(a,'Algorithm','barnesht','NumDimensions',3,'Theta',0.5);
scatter3(Z(:,1),Z(:,2),Z(:,3),30,color(clases,:),'filled');

%-----
figure
cm = confusionchart(vec2ind(flipud(T)),vec2ind(flipud(a1)));
cm.Title = 'Clases por tipos de caminata';
cm.RowSummary = 'row-normalized';
cm.XLabel = 'Predicción de clases';
cm.YLabel = 'Clases verdaderas';

```