



**EDUCACIÓN**

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO

# Tecnológico Nacional de México

Centro Nacional de Investigación  
y Desarrollo Tecnológico

## Tesis de Doctorado

Clasificación de Actividad Física Mediante Señales de  
Acelerometría y Redes Neuronales

presentada por

**MC. Elizabeth Cavita Huerta**

como requisito para la obtención del grado de

**Doctor en Ciencias de Ingeniería  
Electrónica**

Director de tesis

**Dr. Juan Reyes Reyes**

Codirector de tesis

**Dr. Héctor Manuel Romero Ugalde**

Cuernavaca, Morelos, México. Diciembre de 2024.

 <small>Centro Nacional de Investigación y Desarrollo Tecnológico</small>	<b>ACEPTACIÓN DE IMPRESIÓN DEL DOCUMENTO DE TESIS DOCTORAL</b>	<b>Código: CENIDET-AC-006-D20</b>
		<b>Revisión: 0</b>
	<b>Referencia a la Norma ISO 9001:2008 7.1, 7.2.1, 7.5.1, 7.6, 8.1, 8.2.4</b>	<b>Página 1 de 1</b>

Cuernavaca, Mor., a 14 de noviembre de 2024

**Dr. Carlos Manuel Astorga Zaragoza**  
 Subdirector Académico  
 Presente

**At'n: Dr. Víctor Manuel Alvarado Martínez**  
 Presidente del Claustro Doctoral  
 del Departamento De Ing. Electrónica

Los abajo firmantes, miembros del Comité Tutorial de la estudiante **Elizabeth Cavita Huerta** manifiestan que después de haber revisado el documento de tesis titulado "**Clasificación de Actividad Física Mediante Señales de Acelerometría y Redes Neuronales**", realizado bajo la dirección del **Dr. Juan Reyes Reyes** y la codirección del **Dr. Héctor Manuel Romero Ugalde**, el trabajo se **ACEPTA** para proceder a su impresión.

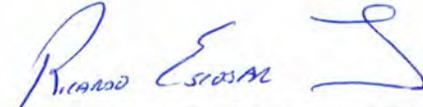
ATENTAMENTE



Dr. Víctor Manuel Alvarado Martínez  
 CENIDET



Dra. Gloria Lilia Osorio Gordillo  
 CENIDET



Dr. Ricardo Fabricio Escobar Jiménez  
 CENIDET



Dr. Héctor Manuel Romero Ugalde



Dr. Juan Reyes Reyes  
 CENIDET

c.c.p: M.T.I Maria Elena Gómez Torres/ jefa del Departamento de Servicios Escolares.  
 c.c.p: Dr. Jarniel García Morales / jefe del Departamento de Ingeniería Electrónica.  
 c.c.p: Expediente.



TECNOLOGICO  
NACIONAL DE MEXICO.



Centro Nacional de Investigación  
y Desarrollo Tecnológico  
Subdirección Académica

Cuernavaca, Mor.,  
No. De Oficio:  
Asunto:

21/noviembre/2024  
SAC/356/2024  
Autorización de  
impresión de tesis

**ELIZABETH CAVITA HUERTA  
CANDIDATA AL GRADO DE DOCTORA  
EN CIENCIAS EN INGENIERÍA ELECTRÓNICA  
P R E S E N T E**

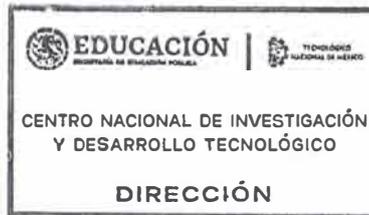
Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado “Clasificación de Actividad Física Mediante Señales de Acelerometría y Redes Neuronales”, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

**ATENTAMENTE**

*Excelencia en Educación Tecnológica-  
“Conocimiento y Tecnología al Servicio de México”*

**CARLOS MANUEL ASTORGA ZARAGOZA  
SUBDIRECTOR ACADÉMICO**



C. c. p. Departamento de Ingeniería Electrónica  
Departamento de Servicios Escolares

CMAZ/lmz



Av. Interior Internado Palmira S/N, Col. Palmira, C. P. 62490, Cuernavaca, Morelos  
Tel. 01 [777] 3627770, ext. 4104, E-mail: acad\_cenidet@tecnm.mx | tecnm.mx | cenidet.tecnm.mx



# Dedicatoria

*A mi amado **Samuel**, eres el motor que me impulsa a seguir adelante, el faro que ilumina mis días y me recuerda, en cada paso, el verdadero significado del amor incondicional. Tu fuerza, tu ternura y tu bondad me inspiran a ser mejor cada día. Te amo profundamente, hijo mío; que la luz que irradia tu alma nunca deje de guiarme, y que siempre encuentres en mí el refugio y el apoyo que necesitas para alcanzar tus sueños.*

# Agradecimientos

Agradezco profundamente a mis padres, **César** y **Dolores**, por su amor y apoyo incondicional a lo largo de toda mi vida. Por los consejos sabios y la amistad que siempre me han brindado. Las metas alcanzadas son el reflejo de su dedicación y esfuerzo, y no sería quien soy sin su guía. Me siento orgullosa y agradecida de ser su hija, y los amo con todo mi corazón.

A mis queridos hermanos **César** y **Felipe**, que han llenado mis días de alegría con sus ocurrencias y risas. Su entusiasmo y energía son contagiosos, y me inspiran a ser mejor cada día. Nunca dejen de perseguir sus sueños ni de creer en sí mismos.

A mis asesores, **Dr. Juan Reyes Reyes** y el **Dr. Héctor Manuel Romero Ugalde** quienes me guiaron, apoyaron y siempre me brindaron su consejo durante este trabajo de tesis. Gracias por sus enseñanzas y ayuda.

A mis revisores el **Dra. Glorira L. Osorio Gordillo**, **Dr. Ricardo F. Escobar Jiménez** y **Dr. Víctor M. Alvarado Martínez** cuyos comentarios y observaciones fueron muy valiosos para el desarrollo del presente trabajo.

De manera muy especial, quiero agradecer a mi compañero de aventuras, cómplice y amigo **Eduardo**. Sin duda, la vida me recompensó al encontrarte en esta travesía, para iluminar mis días, sanar mis tristezas y motivarme a ser mejor cada día. Que la vida nos regale la oportunidad de seguir compartiendo juntos no solo momentos de felicidad y triunfos, sino también los desafíos que aún nos esperan en el camino que nos queda por recorrer.

A mi entrañable amigo **Eusebio**, quién fue parte de mi nueva familia lejos de casa, todas las experiencias compartidas siempre me traerán gratos recuerdos, estoy segura que nos volveremos a encontrar.

A mi equipo **Monarca** y al **Dr. Carlos Daniel García Beltrán**. Sin duda las experiencias vividas me trajeron muchas enseñanzas, me llevo todos esos agradables momentos que compartimos en nuestra aventura en Colima.

Al Consejo Nacional de Ciencias y Tecnología (**CONAHCYT**) por el apoyo económico brindado para poder realizar y culminar mis estudios de doctorado.

Finalmente, agradezco al Centro Nacional de Investigación y Desarrollo Tecnológico (**CENIDET**) por darme la oportunidad de estudiar y desarrollar mis habilidades, me llevo experiencias muy gratas y las enseñanzas de sus excelentes investigadores.

# Resumen

El reconocimiento de la actividad física mediante acelerometría es un campo en rápida evolución, con profundas implicaciones para la salud, la ciencia del deporte y la tecnología portátil. Este trabajo de tesis propone un enfoque original para clasificar actividades físicas, utilizando exclusivamente datos de acelerometría procesados a través de redes neuronales artificiales (RNA). La metodología abarca desde la adquisición de datos y el preprocesamiento, hasta la extracción de características y la aplicación de algoritmos de aprendizaje profundo, todo ello orientado a identificar patrones de actividad con precisión.

Una de las contribuciones más significativas de esta investigación es la incorporación del radio de curvatura como una nueva característica derivada del dominio temporal. Este parámetro se calcula segmentando las señales de acelerometría en ventanas temporales y realizando una doble integración para obtener datos posicionales. Posteriormente, se estima una circunferencia a partir de estos datos, evaluando el movimiento en los tres planos (coronal, sagital y transversal). Este enfoque no solo enriquece el análisis cinemático, sino que también establece una conexión fundamental entre la anatomía del movimiento y la clasificación de actividades físicas, ya que aprovecha la información temporal y del espacio bidimensional de los planos de movimiento.

El uso del radio de curvatura proporciona una herramienta robusta y completa para la clasificación de actividades, mejorando notablemente la precisión de los modelos RNAs, que alcanzan más del 95% de exactitud. Esto resalta la importancia del dominio temporal en la identificación de patrones de movimiento, lo que es esencial para optimizar los sistemas de monitoreo físico en dispositivos portátiles. Los hallazgos de esta investigación subrayan el potencial de este método, que permite mejorar la precisión y confiabilidad del reconocimiento de actividad física, abriendo nuevas vertientes para la aplicación de la acelerometría en la salud y el deporte.

# Abstract

The recognition of physical activity through accelerometry is a rapidly evolving field, with profound implications for health, sports science, and portable technology. This thesis presents an original approach to classifying physical activities, using exclusively accelerometry data processed through artificial neural networks (ANN). The methodology encompasses data acquisition and preprocessing, feature extraction, and the application of deep learning algorithms, all aimed at accurately identifying activity patterns.

One of the most significant contributions of this research is the incorporation of the radius of curvature as a new feature derived from the temporal domain. This parameter is calculated by segmenting the accelerometry signals into time windows and performing double integration to obtain positional data. Subsequently, a circumference is estimated based on this data, evaluating movement in the three planes (coronal, sagittal, and transverse). This approach not only enriches kinematic analysis but also establishes a fundamental connection between the anatomy of movement and the classification of physical activities, as it leverages the temporal and two-dimensional spatial information of the planes of movement.

The use of the radius of curvature provides a robust and comprehensive tool for activity classification, significantly enhancing the accuracy of ANN models, which achieve over 95% accuracy. This highlights the importance of the temporal domain in identifying movement patterns, which is essential for optimizing physical monitoring systems in portable devices. The findings of this research underscore the potential of this method to improve the accuracy and reliability of physical activity recognition, opening new avenues for the application of accelerometry in health and sports.

# Índice general

Índice de figuras	VIII
Índice de tablas	X
Nomenclatura	XI
<b>1. Introducción</b>	<b>1</b>
1.1. Introducción . . . . .	1
1.1.1. Actividad Física . . . . .	3
1.1.2. Acelerometría . . . . .	4
1.2. Estado del Arte . . . . .	5
1.2.1. Clasificación de Actividades Mediante Acelerometría . . . . .	5
1.2.2. Redes Neuronales en la Clasificación de Actividades . . . . .	6
1.2.3. Características Usadas en Clasificación de Actividades . . . . .	9
1.2.4. Conclusión del Estado del Arte . . . . .	11
1.3. Planteamiento del Problema . . . . .	11
1.4. Objetivo General . . . . .	12
1.4.1. Objetivos Específicos . . . . .	13
1.5. Metas . . . . .	13
1.6. Justificación . . . . .	13
1.7. Alcance . . . . .	15
1.8. Contribución . . . . .	15
<b>2. Marco Teórico</b>	<b>17</b>
2.1. Introducción . . . . .	17
2.2. Cadena de Reconocimiento de Actividad Humana . . . . .	17
2.2.1. Adquisición de Señales . . . . .	19
2.2.2. Procesamiento de Señales . . . . .	21
2.2.3. Extracción y Selección de Características . . . . .	23
2.2.4. Modelos de Clasificación en HAR . . . . .	25
2.2.5. Evaluación de Modelos HAR . . . . .	26
2.3. Radio de Curvatura . . . . .	27
2.4. Redes Neuronales Artificiales . . . . .	29
2.4.1. Funciones de Activación . . . . .	30
2.4.2. Redes Neuronales Multicapa . . . . .	32
2.4.3. Entrenamiento de Redes Neuronales . . . . .	35

---

2.4.4.	Función de Pérdida, Entropía Cruzada Categórica . . . . .	35
2.4.5.	Algoritmo de Optimización Adam . . . . .	36
2.5.	Clasificador de Bosques Aleatorios . . . . .	37
2.5.1.	Detección de Posición del Transductor . . . . .	39
2.5.2.	Importancia de la Detección de Posición del Transductor . . . . .	41
<b>3.</b>	<b>Propuesta Metodológica para la Clasificación de Actividades Humanas</b>	<b>43</b>
3.1.	Adquisición de Datos . . . . .	44
3.1.1.	Dataset Generado ACTDATA . . . . .	44
3.1.2.	Conjunto de Actividades Propuestas . . . . .	45
3.1.3.	Participantes . . . . .	46
3.1.4.	Configuración Antropométrica de los Acelerómetros . . . . .	46
3.1.5.	Módulo de Adquisición de Señales . . . . .	49
3.1.6.	Protocolo de Adquisición (TCP) . . . . .	50
3.2.	Procesamiento de Señales . . . . .	51
3.2.1.	Filtrado de Señales . . . . .	52
3.2.2.	Enventanado de Señales . . . . .	54
3.2.3.	Conversión de Aceleración a Posición . . . . .	56
3.3.	Propuesta de la Nueva Característica . . . . .	57
3.3.1.	Cálculo del Radio de Curvatura Plano Coronal . . . . .	58
3.3.2.	Cálculo del Radio de Curvatura Plano Sagital . . . . .	61
3.3.3.	Cálculo del Radio de Curvatura Plano Transversal . . . . .	63
3.3.4.	Vector de Características Propuesto . . . . .	65
3.4.	Modelo de Detección de Posición . . . . .	65
3.4.1.	Algoritmo de Bosques Aleatorios . . . . .	66
3.5.	Clasificación de Actividades . . . . .	68
3.5.1.	Diseño y Selección del Esquema de Red Neuronal . . . . .	69
3.5.2.	Estructura del Modelo de RNAf del Pecho . . . . .	70
3.5.3.	Estructura del modelo de RNAf de la cadera . . . . .	71
3.5.4.	Estructura del modelo de RNAf de la muñeca . . . . .	73
3.5.5.	Entrenamiento y Validación . . . . .	76
3.5.6.	Base de Datos, Repositorio UCI (mHealth) . . . . .	77
<b>4.</b>	<b>Resultados de Implementación</b>	<b>81</b>
4.1.	Base de Datos Generada ACTDATA . . . . .	81
4.2.	Resultados Detección de Posición, Base de Datos ACTDATA . . . . .	83
4.2.1.	Resultados Detección de Posición, Repositorio UCI (mHealth) . . . . .	85
4.3.	Resultados Clasificación de Actividades, (ACTDATA) . . . . .	86
4.3.1.	Validación LOSO, (ACTDATA) . . . . .	89
4.3.2.	Resultados Clasificación de Actividades, (mHealth) . . . . .	90
4.3.3.	Validación LOSO, (mHealth) . . . . .	93
<b>5.</b>	<b>Conclusiones</b>	<b>94</b>
5.1.	Discusión y Limitaciones . . . . .	95
5.2.	Trabajos futuros . . . . .	96
	<b>Bibliografía</b>	<b>98</b>

---

---

<b>Anexos</b>	<b>109</b>
<b>A. Producción Científica</b>	<b>110</b>

# Índice de figuras

1.1. Aplicaciones comunes del monitoreo de actividades . . . . .	1
1.2. Características sistemas HAR . . . . .	2
1.3. Tipos de AF . . . . .	4
1.4. Distribución de los ejes en el cuerpo humano . . . . .	4
1.5. Esquema propuesto . . . . .	12
1.6. Esquema de clasificación de actividades propuesto . . . . .	15
2.1. Cadena de reconocimiento de actividad . . . . .	18
2.2. Preprocesamiento de señales . . . . .	22
2.3. Dominios de extracción de características . . . . .	23
2.4. Características monoaxiales . . . . .	24
2.5. Características multiaxiales . . . . .	24
2.6. Proceso de selección de características . . . . .	25
2.7. RC asociados a diferentes puntos . . . . .	28
2.8. Estructura neurona artificial . . . . .	29
2.9. Función de activación tanh . . . . .	31
2.10. Función de activación ReLu . . . . .	31
2.11. Función de activación SoftMax . . . . .	32
2.12. Red FFNN tipo densa con $j - m$ neuronas, $i$ entradas y $n$ salidas . . . . .	34
2.13. Estructura clasificador RF . . . . .	38
2.14. Señales de acelerometría en diferentes posiciones . . . . .	39
2.15. Planos de movimiento . . . . .	40
3.1. Estructura del esquema propuesto . . . . .	43
3.2. Marco de referencia ejes x,y,z . . . . .	45
3.3. Ubicación antropométrica acelerómetros . . . . .	47
3.4. Distribución antropométrica de los módulos . . . . .	48
3.5. Estructura módulo de adquisición de señales . . . . .	49
3.6. Estructura interna módulo de adquisición . . . . .	49
3.7. Protocolo de adquisición de datos . . . . .	50
3.8. Aplicación desarrollada en Python . . . . .	50
3.9. Procesamiento base de datos . . . . .	52
3.10. Aplicación del filtro pasa-bajo . . . . .	54
3.11. Enventanado y superposición de señales de aceleración, velocidad y posición . . . . .	55
3.12. Integración de señales de aceleración . . . . .	56
3.13. Señales de aceleración, velocidad y posición en x,y,z . . . . .	57

---

3.14. Gráfica del punto $[h_c, k_c]^T$ y el RC, plano coronal . . . . .	58
3.15. RC obtenido en la actividad correr, plano coronal . . . . .	60
3.16. Gráfica del punto $[h_s, k_s]^T$ y el RC, plano sagital . . . . .	61
3.17. Gráfica del punto $[h, k]$ y el RC, plano transversal . . . . .	63
3.18. Estructura detección de posición . . . . .	66
3.19. Estructura del RF propuesto . . . . .	68
3.20. Estructura del sistema HAR propuesto . . . . .	69
3.21. Proceso de entrenamiento-prueba en RNAs . . . . .	76
3.22. Base de datos inicial, sujeto 1 . . . . .	78
3.23. Base de datos sujeto 1, señales del pecho . . . . .	79
3.24. Etiquetas, sujeto 1 . . . . .	79
3.25. Separación de señales sujeto 1, base de datos mHealth . . . . .	80
4.1. Base de datos inicial, sujeto 4 . . . . .	82
4.2. Señales pecho, sujeto 4 . . . . .	82
4.3. Etiquetas, sujeto 4 . . . . .	83
4.4. Separación de señales sujeto 4, base de datos ACTDATA . . . . .	83
4.5. Matriz de confusión detección de posición ACTDATA . . . . .	84
4.6. Métricas modelo detección de posición ACTDATA . . . . .	84
4.7. Matriz de confusión detección de posición mHealth . . . . .	85
4.8. Métricas modelo detección de posición mHealth . . . . .	85
4.9. Matriz de confusión clasificación de AF del pecho, ACTDATA . . . . .	86
4.10. Métricas modelo clasificación de AF del pecho, ACTDATA . . . . .	87
4.11. Matriz de confusión clasificación de AF de muñeca, ACTDATA . . . . .	87
4.12. Métricas modelo clasificación de AF de muñeca, ACTDATA . . . . .	88
4.13. Matriz de confusión clasificación de AF de cadera, ACTDATA . . . . .	88
4.14. Métricas modelo clasificación de AF de cadera, ACTDATA . . . . .	89
4.15. Matriz de confusión clasificación de AF en pecho, mHealth . . . . .	90
4.16. Métricas modelo clasificación de AF en pecho, mHealth . . . . .	91
4.17. Matriz de confusión clasificación de AF en tobillo, mHealth . . . . .	91
4.18. Métricas modelo clasificación de AF en tobillo . . . . .	92
4.19. Matriz de confusión clasificación de AF en muñeca . . . . .	92
4.20. Métricas modelo clasificación de AF en muñeca, mHealth . . . . .	93
A.1. Publicación realizada en Mathematical and Computational Applications . . . . .	110
A.2. Publicación realizada en Boletín de Ciencias Básicas e Ingeniería del ICBI . . . . .	111

---

# Índice de cuadros

1.1. Comparación precisión modelo propuesto vs métodos de vanguardia . . . . .	8
1.2. Comparación tratamiento de datos en sistemas HAR con el modelo propuesto .	10
3.1. Actividades y etiquetas utilizadas en la base de datos (ACTDATA) . . . . .	46
3.2. Características participantes (ACTDATA) . . . . .	47
3.3. Tabla de características. . . . .	65
3.4. Base de datos mHealth . . . . .	77
3.5. Estructura base de datos mHealth . . . . .	78
4.1. Estructura base de datos ACTDATA . . . . .	81
4.2. Resultados validación cruzada (LOSO), ACTDATA . . . . .	89
4.3. Resultados validación cruzada (LOSO), mHealth . . . . .	93

# Nomenclatura

$\hat{r}_c$	—	Radio de curvatura plano coronal.
$\hat{r}_t$	—	Radio de curvatura plano transversal.
$\hat{r}_s$	—	Radio de curvatura plano sagital.
$a_x$	—	Aceleración eje x.
$a_y$	—	Aceleración eje y.
$a_z$	—	Aceleración eje z.
$v_x$	—	Velocidad eje x.
$v_y$	—	Velocidad eje y.
$v_z$	—	Velocidad eje z.
$K$	—	Número de ventanas.
$R$	—	Factor de overlap.
$S_r$	—	Frecuencia de muestreo
$W_s$	—	Tamaño de ventana en (s).
$O_{LP}$	—	Porcentaje de overlap.
$TP$	—	Número de casos positivos verdaderos.
$TN$	—	Número de casos negativos verdaderos.
$FP$	—	Número de falsos positivos.
$FN$	—	Número de falsos negativos.
$f(z)$	—	Función de activación

## Acrónimos

$AF$	—	Actividad Física.
$HAR$	—	Reconocimiento de Actividad Física.
$RNA$	—	Redes Neuronales Artificiales.
$RNAf$	—	Redes Neuronales FeedForward.
$SVM$	—	Máquinas de Soporte Vectorial.
$CNN$	—	Redes Neuronales Convolucionales.
$RF$	—	Clasificador de Bosques Aleatorios.
$RC$	—	Radio de Curvatura.
$LSTM$	—	Redes Neuronales Recurrentes de Memoria a Largo Plazo.
$KNN$	—	K-Nearest Neighbors.
$DFT$	—	Transformada Discreta de Fourier.

---

*LOSO* — Leave- One-Subject-Out.  
*FFNN* — FeedForward Neural Network.

# Capítulo 1

## Introducción

### 1.1. Introducción

Por varios años en el campo de la investigación se han realizado trabajos que han demostrado los efectos positivos que proporciona la actividad física humana (AF) en la salud, por ejemplo en la etapa temprana del desarrollo físico humano [Janssen and LeBlanc, 2010] exploraron los beneficios de la AF en niños y jóvenes en edad escolar; en [Merglen et al., 2014] se mostraron las ventajas de la práctica deportiva semanal para el bienestar de los adolescentes; en [Biddle and Asare, 2011] estudiaron la asociación entre enfermedades mentales y la falta de actividad física; en las últimas etapas del desarrollo humano. El trabajo realizado en [Chodzko-Zajko et al., 2009] concluyó que la AF reduce los factores de riesgo de enfermedades crónicas en adultos mayores, y ayuda a construir un estilo de vida saludable [Mehrang et al., 2018].

La inactividad física es alarmantemente reconocida como el cuarto factor de riesgo principal para la mortalidad global [Cao, 2015]. La estrecha asociación entre la participación en actividades físicas y deportivas con una variedad de beneficios para la salud está bien documentada [Black et al., 2019, Atiq et al., 2019]. En consecuencia, mejorar los estilos de vida, promover comportamientos saludables y mitigar enfermedades crónicas se han convertido en prioridades críticas [Afshin et al., 2016]. Por ello, se han desarrollado aplicaciones de seguimiento y monitoreo de la actividad física humana, con diversos propósitos. Figura 1.1.



Figura 1.1: Aplicaciones comunes del monitoreo de actividades

Además, la integración de tecnología sofisticada y cómputo en el cuidado de la salud juega un papel cada vez más importante en nuestras vidas diarias, abriendo numerosas áreas potenciales de investigación, especialmente en el Reconocimiento de Actividad Humana (HAR) [Ungurean and Brezulianu, 2017, Ramanujam et al., 2021].

Para diseñar y evaluar cualquier sistema HAR, tradicionalmente se deben seguir pasos específicos para obtener información sobre la actividad del sensor. Estos pasos se conocen como la cadena de reconocimiento de actividad [AlShorman et al., 2020]. Generalmente este proceso incluye cuatro etapas: (1) recolección de datos, (2) pre-procesamiento de señales, (3) selección y extracción de características y (4) entrenamiento y prueba de los modelos de clasificación. Los sensores recopilan datos sin procesar, que luego se envían a un servidor para su posterior procesamiento. Las características se seleccionan y se extraen de los datos preprocesados, posteriormente se aplican técnicas de clasificación para reconocer las actividades físicas [Saha et al., 2018]. Algunas características de la operación de los sistemas HAR se describen a continuación, Figura 1.2.

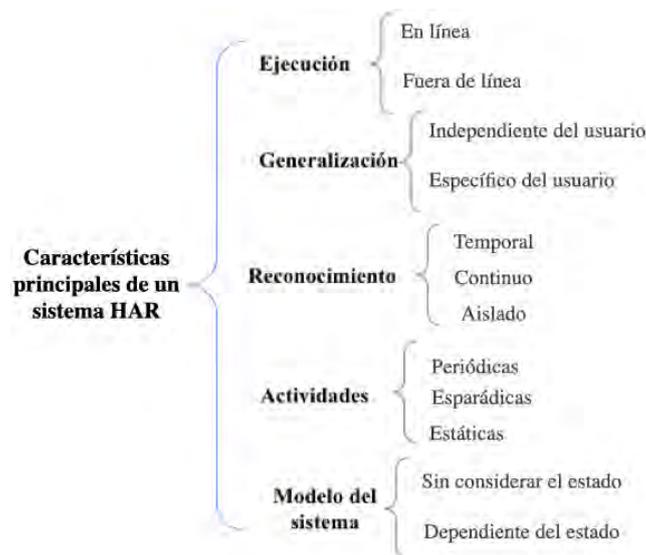


Figura 1.2: Características sistemas HAR

Cada etapa del proceso afecta el desempeño del sistema de reconocimiento de actividad. La recopilación de datos es la primera etapa en el proceso de reconocimiento de actividades, la cual plantea muchos desafíos, como la configuración del sensor, la longitud del período de seguimiento, número de sensores, posición de los sensores, etc. [Chaix, 2018]. El preprocesamiento de datos utiliza métodos para ajustar las señales y extraer las características que se utilizan como información de entrada en los modelos de clasificación. Durante la extracción de características, muchos datos no siempre conducirán a una clasificación precisa de la AF [Banos et al., 2014a], por lo tanto, utilizar características que aporten información útil sobre los movimientos del cuerpo humano, pueden mejorar la capacidad de clasificación de los modelos. Así mismo, la elección de las técnicas de aprendizaje automático a emplear es un factor importante, ya que influye en el rendimiento del sistema HAR, considerando que existe una gran diversidad de algoritmos de clasificación, de los cuales se pueden obtener múltiples resultados [Alzahrani and Kammoun, 2016, Benson et al., 2018].

---

Un punto importante a mencionar es que los sistemas HAR ha ganado un interés creciente dada la disponibilidad de dispositivos de hardware básicos (es decir, teléfonos inteligentes, dispositivos portátiles, etc.). Estos dispositivos contienen un conjunto de sensores, como acelerómetros, giroscopios y GPS (Global Positioning System, por sus siglas en inglés), que pueden proporcionar los datos básicos necesarios para realizar el reconocimiento de actividad, como se detalla en [Andreu-Perez et al., 2015].

Uno de los sensores más utilizados en sistemas HAR es el acelerómetro, debido a que son sensores ligeros y pequeños, además estos sensores pueden registrar la frecuencia, la intensidad y la duración de la actividad, por lo tanto reducen la variación de la estimación subjetiva encontrada en los autoinformes [Lane et al., 2010]. También, los datos de aceleración podrían indicar el patrón de movimiento dentro de un período de tiempo determinado, lo que es útil en el reconocimiento de actividades complejas.

Como un poderoso mecanismo de clasificación, el aprendizaje profundo ha logrado mejoras significativas [Krizhevsky et al., 2012, LeCun et al., 2015]. Los sistemas HAR utilizan modelos de aprendizaje automático o profundo basados en redes neuronales artificiales (RNAs) para reconocer actividades [Wang et al., 2019]. Los cuales han fortalecido el rendimiento y la robustez del HAR [Sharifani and Amini, 2023], acelerando su adopción. Estos modelos pueden reducir el trabajo computacional en las fases de procesamiento de datos y extracción de características, al tiempo que mejoran el rendimiento de generalización y fiabilidad del modelo [Kanjo et al., 2019].

Por lo tanto, considerando la información antes mencionada, la recopilación, evaluación y análisis de datos para el reconocimiento de actividades humanas utilizando acelerómetros y algoritmos basados en RNAs constituyen elementos que en conjunto, se convierten en una herramienta poderosa en el campo de los sistemas HAR [Paraschiakos et al., 2020].

### 1.1.1. Actividad Física

La realización de AF se ha relacionado directamente con la disminución de los índices de incidencia de enfermedades y mortalidad prematura en múltiples estudios. La actividad física se puede definir como cualquier movimiento corporal producido por los músculos esqueléticos que exige un gasto de energía [OMS et al., 2010].

De acuerdo a la Figura 1.3, la AF que realiza una persona se puede clasificar de tres maneras: actividades estáticas, dinámicas y de transición, donde las últimas representan un mayor reto en la clasificación de los sistemas HAR, debido al cambio abrupto de los movimientos [Bharti et al., 2019].



Figura 1.3: Tipos de AF

### 1.1.2. Acelerometría

La detección continua de movimiento del individuo o monitorización del mismo requiere la incorporación de algún dispositivo a la vida diaria del sujeto. Para ello se han desarrollado diversos sistemas basados en sensores. Estos artefactos han de ser portátiles, poco pesados y de un tamaño preferiblemente pequeño, de manera que al llevarlos puestos no interfieran en el desarrollo de las tareas diarias de una persona [Bulling et al., 2014a].

En particular, los acelerómetros electrónicos destacan como los sensores de movimiento más prometedores para evaluar la actividad física de las personas, dado el avance actual en la tecnología de circuitos integrados, hay excelentes posibilidades de desarrollar sistemas de acelerómetros muy compactos y livianos que se puedan usar durante días o incluso semanas.

La acelerometría es una disciplina que usa acelerómetros, sensores que miden el cambio de la velocidad que experimenta una masa (su aceleración), estos dispositivos son diseñados para detectar y registrar las fuerzas de aceleración en diferentes direcciones o ejes, Figura 1.4. Pueden ser empleados en diferentes aplicaciones, para medir el nivel de actividad, seguir los patrones de actividad, detección de caídas, etc. Debido a que son capaces de proporcionar características indicativas del movimiento humano, además de que responden a la frecuencia e intensidad del movimiento, así como a la inclinación. Todos son aspectos importantes y enriquecedores para evaluar las posturas estáticas y dinámicas de las personas, [Garnotel et al., 2019].

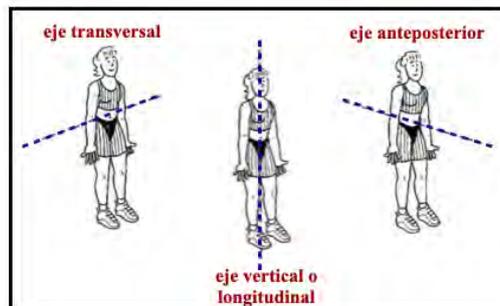


Figura 1.4: Distribución de los ejes en el cuerpo humano

---

A partir de las señales que son entregadas por un acelerómetro, se pueden aplicar una serie de técnicas para preprocesar la información, estos enfoques se basan en convertir o transformar las señales de entrada hacia y desde diferentes dominios de representación [Preece et al., 2008].

En cada dominio existen métodos específicos para abstraer datos de estas señales, por lo tanto, es necesario establecer un método para poder modelar las señales procedentes de los acelerómetros y así compararlas entre sí. Existen distintos procedimientos, los cuales permiten extraer sus características principales “Feature extraction”, información que es utilizada en el entrenamiento de los modelos de RNAs, [Alshorman et al., 2020].

## 1.2. Estado del Arte

### 1.2.1. Clasificación de Actividades Mediante Acelerometría

La clasificación de actividades mediante acelerometría implica el uso de datos obtenidos de acelerómetros para identificar y distinguir entre diferentes tipos de movimientos o actividades físicas. Los acelerómetros registran datos sobre la aceleración en tres ejes (x, y, z), estos datos reflejan cómo se mueve el cuerpo al que están adheridos los sensores.

La clasificación de actividades físicas mediante acelerometría ha evolucionado significativamente en los últimos años, impulsada por el avance de la tecnología y la creciente necesidad de métodos precisos para la identificación de movimientos humanos. En este contexto, el artículo de [Alfonso Mantilla, 2017] destaca el papel de los acelerómetros como herramientas innovadoras en fisioterapia, subrayando su potencial para desarrollar protocolos estandarizados en la evaluación y rehabilitación. Este trabajo proporciona un marco inicial que establece la importancia de la acelerometría en el contexto de la salud.

A medida que la tecnología avanza, la adopción de los nuevos enfoques se integran en este campo de investigación, por ejemplo en [Strackiewicz et al., 2019] realizan una revisión sistemática sobre el reconocimiento de actividades humanas utilizando acelerómetros de smartphones, enfatizando la importancia de los datos de aceleración obtenidos de dispositivos móviles, lo que sugiere una tendencia hacia la integración de tecnología en la vida cotidiana para mejorar la salud y el bienestar.

Así mismo en [Maczák et al., 2021] exploran la clasificación de actividades físicas utilizando señales de sensores de smartphones, destacando aplicaciones en diagnóstico médico y análisis deportivo. Centrándose en la aplicación de algoritmos de aprendizaje automático para mejorar la precisión en la clasificación de actividades, enfatizando la importancia de entender la estructura de los modelos de machine learning.

Inicialmente, para que los datos sean adecuados para el análisis, se preprocesan. Primero hay que filtrar las señales. Para eliminar los componentes de alta frecuencia, se utilizan filtros de paso bajo [Arvidsson et al., 2019]. Además de la técnica de filtrado, en esta etapa se realizan las transformaciones necesarias de las señales.

El tratamiento y preparación de las señales de acelerometría antes de realizar la clasificación

---

de la AF es de suma importancia, en [Garnotel et al., 2019] se realiza un estudio donde se utiliza un acelerómetro, mientras se ejecuta un circuito de actividades, los datos del acelerómetro se convierten en cuentas por minuto y estas cuentas se pueden usar por sí mismas para cuantificar la intensidad y la duración de un período de AF, información importante en la clasificación de actividades. Lo que refleja la complejidad de la etapa de preprocesamiento.

Las investigaciones apuntan que cuando se realiza una apropiada preparación de las señales de acelerometría, un número de (2-3) acelerómetros son suficientes para obtener una precisión mayor al 93 %, como se demuestra [Gjoreski and Gams, 2011] al desempeñar siete actividades diferentes, empleando un algoritmo de aprendizaje automático para su evaluación.

También en [Catal and Akbulut, 2018], [Lu et al., 2018], [Kang et al., 2021], [Bharti et al., 2018], [Henpraserttae et al., 2011], [Ustev et al., 2013], se realiza la clasificación de AF considerando diferentes posiciones, sin embargo es necesario el uso de otros sensores como temperatura, frecuencia cardíaca, respuesta galvánica, etc. para lograr una precisión mayor al 90 % en las actividades propuestas; ellos sugieren mejorar los sistemas de transformación de coordenadas para reducir las variaciones de las señales, debido a las diferentes posiciones que se contemplan y realizar el diseño de múltiples modelos según la ubicación del sensor, lo cual es un nicho de oportunidad. Sin embargo, también se ha ilustrado en muchos estudios que un acelerómetro, es capaz de capturar la mayoría de las actividades básicas [Hanai et al., 2009], [Lee et al., 2003], [Jeon et al., 2007], [Khan et al., 2008].

La salida de un acelerómetro varía en diferentes posiciones del cuerpo, incluso para la misma actividad. Por lo tanto, los sistemas de reconocimiento de actividad basados en acelerómetros que requieren una conexión firme del sensor al cuerpo del usuario [Van Kasteren et al., 2008], [Crouter et al., 2015] [Clevenger et al., 2020a], [Bao and Intille, 2004], [White et al., 2019], son poco prácticos para el monitoreo de actividades a largo plazo, ya que obliga a los sujetos a un patrón de vida fijo que en ocasiones resulta incomodo al desempeñar sus actividades diarias. Estos presentan un desempeño de precisión bajo al no utilizarse en la posición asignada por diseño [Khan et al., 2008], realizó la clasificación de la AF con una precisión del 99 %, pero el sensor requería estar fijo al pecho, cuando se probó en otras posiciones del cuerpo, la precisión disminuyó al 47 %.

Como se ha podido observar uno de los principales problemas en los sistemas HAR que implementan el uso de señales de acelerometría, es la sensibilidad de las señales respecto de la posición del sensor, que en muchas ocasiones limita el seguimiento de actividad ante diversos escenarios durante la vida diaria de las personas. Por lo tanto, desarrollar un sistema que permita utilizar un acelerómetro en diversas partes del cuerpo, manteniendo un nivel de precisión alto, resulta ser una solución útil.

### **1.2.2. Redes Neuronales en la Clasificación de Actividades**

Aunque hay varias técnicas y modelos matemáticos disponibles para clasificar la actividad física, los modelos basados en RNAs han demostrado ser efectivos y precisos. Los métodos de aprendizaje automático tradicionales, como máquinas de soporte vectorial (SVM) o árboles de

---

decisión, han sido superados por las RNA en términos de precisión y capacidad para manejar grandes volúmenes de datos.

Las RNAs pueden mejorar significativamente el rendimiento de los sistemas de clasificación de actividades, logrando precisiones superiores al 95 % en entornos no controlados, siempre y cuando se seleccionen las características y parámetros adecuados [Kanjo et al., 2019].

El uso de RNAs en la clasificación de la AF ha demostrado ser una herramienta poderosa, que proporciona resultados satisfactorios, en [Gil-Martin et al., 2020], la clasificación se realiza utilizando una estructura basada en redes neuronales convolucionales (CNN), obteniendo un desempeño entre (89 %-95 %) en 12 actividades distintas.

En [Ordóñez and Roggen, 2016] se presentó un modelo híbrido que combina redes CNN y redes neuronales recurrentes de memoria a largo plazo (LSTM) para el reconocimiento de actividades a partir de datos de múltiples sensores portátiles. El enfoque aprovecha las capacidades de las CNN para extraer características espaciales de los datos, mientras que las LSTM capturan las dependencias temporales. Los resultados muestran mejoras significativas en la precisión de la clasificación de 9 % en comparación con enfoques más simples.

Otro enfoque utilizado en clasificación de actividades son los autoencoders (autoassociative learning module) se han adoptado ampliamente como un método no supervisado para el aprendizaje de características. Como tal, las salidas de los autoencoders se utilizan a menudo como entradas para otras redes y algoritmos para mejorar el rendimiento. Un autoencoder se compone generalmente de un módulo de codificación y un módulo de decodificación. La capacidad de un autoencoder para la reducción de dimensionalidad se ha aplicado en el HAR cuando se utilizan dispositivos portátiles, ya que se utilizan comúnmente para limpiar y eliminar el ruido de los datos crudos de los sensores [Mohammed and Tashev, 2017, Gao et al., 2019, Valarezo et al., 2020], un problema conocido con las señales de dispositivos portátiles que afecta la capacidad para aprender patrones en los datos.

En [Hutabarat et al., 2023], se propone un modelo simple de red neuronal feedforward (RNAf) equipado con cuatro capas completamente conectadas para mejorar la precisión del sistema HAR. Los resultados experimentales realizados en un conjunto de datos muestran que el modelo RNAf propuesto alcanza una precisión que supera a otros algoritmos existentes, como K-Nearest Neighbors (KNN) y SVM, lo que destaca la efectividad de una arquitectura de red neuronal simplificada en la mejora del rendimiento del sistema HAR [D'Arco et al., 2023], logrando resultados satisfactorios en términos de precisión y velocidad de procesamiento.

Otro enfoque en la investigación sobre la medición de la actividad física utilizando RNAs no se centra en el desarrollo de nuevas arquitecturas, sino en la identificación de la ubicación óptima del acelerómetro [Mackintosh et al., 2016]. Este tipo de investigación valida y compara redes neuronales entrenadas con datos de acelerómetros colocados en diversas posiciones anatómicas y combinaciones de los mismos. Por ello, se han propuesto alternativas para desarrollar múltiples modelos de clasificación que consideren distintas posiciones del sensor en el cuerpo [Mannini et al., 2015, Fujinami and Kouchi, 2012, Durmaz Incel, 2015, Kunze and Lukowicz, 2008]. Esto ofrece al usuario una mayor flexibilidad en la elección de la ubicación del sensor,

---

aumentando así la probabilidad de éxito en el seguimiento de la actividad.

A pesar de sus diversas aplicaciones, los algoritmos de clasificación utilizados en los sistemas HAR siguen enfrentándose a varios retos, como: 1) complejidad y diversidad de las actividades diarias, 2) variabilidad entre sujetos para una misma actividad, 3) ineficiencia computacional en dispositivos portátiles, y 4) dificultad en el manejo de datos [Lara and Labrador, 2012].

La Tabla 1.1 proporciona una comparación entre el modelo propuesto basado en RNaf y otros enfoques de vanguardia en la clasificación de actividades. Esta comparación destaca las diferencias en metodologías y métricas de rendimiento a través de varios estudios. Se resalta que el modelo basado en RNaf tiene un rendimiento competitivo que es igual o superior al de los modelos más precisos, lo que demuestra que el enfoque desarrollado es tan efectivo o más en la clasificación de actividades humanas en comparación con las técnicas de última generación.

La versatilidad del modelo se evidencia en su capacidad para generalizar diversas tareas de clasificación, lo que lo convierte en una opción atractiva en el campo de la inteligencia artificial.

<b>Autores</b>	<b>Métodos</b>	<b>Accuracy</b>
Geravesh, and Rupapara, et al. [Geravesh and Rupapara, 2023]	KNN	94 %
Gil Hafeez, Alotaibi, et al. [Hafeez et al., 2023]	Logistic Regression	93 %
Jantawong, Ponnipa, et al. [Jantawong et al., 2021]	InceptTime model	88 %
Zhang, Haoxi, et al. [Zhang et al., 2019]	Multi-head Convolutional Attention	95 %
Mekruksavanich, Jitpattanakul, et al. [Mekruksavanich et al., 2022b]	ResNet-SE model	94–97 %
Lohit, Wang, et al. [Lohit et al., 2019]	Temporal Transformer Networks	78 %
Neverova, Natalia, et al. [Neverova et al., 2016]	Dense Clockwork RNN	93 %
Modelo Propuesto (2024)	FFNN	95–97 %

Tabla 1.1: Comparación precisión modelo propuesto vs métodos de vanguardia

---

### 1.2.3. Características Usadas en Clasificación de Actividades

La extracción de características es un paso crucial en la clasificación de actividades físicas utilizando acelerómetros. Este proceso implica identificar y extraer información relevante de las señales de aceleración que pueda ser utilizada para distinguir entre diferentes tipos de actividades, que serán la información de entrada en los modelos de clasificación.

La clasificación automática de los datos de acelerometría requiere una fase de preprocesamiento en la que se utilizan diversas técnicas para mejorar las señales, como el filtrado, la segmentación de señales y la extracción de características. Se necesitan técnicas complejas de extracción de características para mejorar el éxito, lo que conllevaría un aumento de la potencia de procesamiento de los datos [Preece et al., 2008].

Dentro de la etapa de preprocesamiento, se realiza la segmentación, donde los datos del sensor de series de tiempo se segmentan antes de la extracción de características; la técnica de ventana deslizante es un ejemplo común de las metodologías utilizadas en esta etapa [Dehghani et al., 2019]. Algunas investigaciones también implementan la superposición entre dos segmentos o ventanas consecutivas con el objetivo de evitar la pérdida de información importante, que se utiliza en la construcción del vector de características [San-Segundo et al., 2016]. La extracción de características se puede clasificar en dos dominios principales: el dominio del tiempo y el dominio de la frecuencia, siendo el dominio del tiempo el más utilizado debido a su simplicidad de cálculo [Shoaib et al., 2015].

Los sistemas HAR que usan sensores inerciales portátiles, como los acelerómetros, utilizan señales temporales. Este tipo de señal no ha sido investigado exhaustivamente, lo que requiere enfoques innovadores para extraer características valiosas. [Zhang et al., 2019] mejora la precisión del reconocimiento de actividades al incorporar atención en redes neuronales convolucionales multi-cabeza para una mejor extracción y selección de características.

En un trabajo relacionado, [Hu et al., 2019] propuso un método de reconocimiento de actividades incremental de características llamado FIRF, que evalúa el rendimiento del reconocimiento continuo de nuevas características emergentes. Estas características, extraídas de un nuevo sensor, se añaden de manera incremental en diferentes momentos. Además, [Kuncan et al., 2019] propuso el método de Patrón Binario Local Unidimensional con Muestreo Descendente. Su sistema HAR consta de dos etapas: en primer lugar, se aplicó una conversión a las señales del sensor para extraer características estadísticas de las señales recién formadas, y en segundo lugar, se realizó la clasificación utilizando estas características.

En [Wei and Wang, 2024], los mecanismos de atención mejoran las redes neuronales convolucionales temporales (TCNs) para capturar mejor las dependencias temporales e identificar patrones clave en los datos de actividad. De manera similar, en el trabajo presentado por [Ray et al., 2024] se mejora el rendimiento del modelo al combinar sensores de luz ambiental portátiles con IMUs (Inertial Measurement Unit) para detectar cambios ambientales vinculados a actividades, lo que lleva a una mejor precisión. Además, [Liandana et al., 2024] explora el uso de un acelerómetro triaxial único, para extraer características en dominio temporal y de frecuencia, para capturar de manera más completa la dinámica de la actividad humana.

La selección de características en la clasificación de actividades impacta directamente en el desempeño de los modelos de clasificación, explorar nuevas características estrechamente relacionadas con la dinámica del movimiento humano podría proporcionar suficiente información para mejorar la precisión del modelo, por lo que en este trabajo se prioriza la búsqueda y obtención de características que proporcionen información útil, para ejecutar el sistema HAR de manera más eficiente.

En la Tabla 1.2 se observa la comparativa del modelo propuesto en este trabajo de tesis (Capítulo 3), que se basa únicamente en el uso de acelerómetros, mientras que otros estudios utilizan múltiples sensores y realizan la extracción de características en los dominios de frecuencia y tiempo, o combinaciones de estos, lo que incrementa la complejidad del procesamiento para lograr un alto rendimiento. Por lo tanto, el modelo propuesto podría servir como una alternativa viable para dispositivos con recursos limitados, ya que su rendimiento equilibra el uso de múltiples sensores y transformaciones complejas.

<b>Autores</b>	<b>Dataset</b>	<b>Sensores</b>	<b>Modelo</b>	<b>Dominio</b>	<b>Accuracy</b>
Bennasar M. et al. [Bennasar et al., 2022]	WISDIM	Acelerómetro	SVM, KNN	Frecuencia, Tiempo	90.6–93.2 %
Gil M. et al. [Gil-Martin et al., 2020]	PAMAP2	Acelerómetro	CNNs	Frecuencia	89.8–96.6 %
Dua N. et al. [Dua et al., 2021]	PAMAP2	Acelerómetro, Giroscopio, Magnetómetro	Multi-Input CNN-GRU	Tiempo	95.2 %
Kutlay M. et al. [Kutlay and Gagula-Palalic, 2016]	mHealth	Acelerómetro, Giroscopio, Magnetómetro	SVM, MLP	Tiempo	91.7 %, 83.2 %
Cosma G. et al. [Cosma and Mcginnity, 2019]	mHealth	Acelerómetro, Giroscopio	KNN	Tiempo, Frecuencia	47.5–82.3 %
Modelo Propuesto (2024)	mHealth	Acelerómetro	FFNN	Tiempo	95–97 %

Tabla 1.2: Comparación tratamiento de datos en sistemas HAR con el modelo propuesto

---

### 1.2.4. Conclusión del Estado del Arte

Aunque existen diferentes técnicas y modelos matemáticos para la realizar la clasificación de la AF, los modelos basados en RNAs han demostrado ser una herramienta eficiente y precisa que mejoran el desempeño de sistemas de clasificación de actividad, realizando una adecuada etapa de preprocesamiento y eligiendo características y parámetros adecuados pueden obtener desempeños satisfactorios, en entornos no controlados.

Si bien el uso de acelerómetros y RNAs para la estimación de AF permite una mayor precisión, la limitación de uso en múltiples partes del cuerpo genera problemas en el desempeño de los modelos, limitando su éxito en el seguimiento de actividad a largo plazo. Por tal motivo, el diseño de sistemas donde el uso del acelerómetro no esté limitada a una sola posición es un nicho de oportunidad.

### 1.3. Planteamiento del Problema

El reconocimiento de actividades en los seres humanos es un problema desafiante que requiere soluciones de investigación, consiste en el modelado de actividades, la supervisión del comportamiento y el entorno, el procesamiento de datos y el reconocimiento de patrones.

A pesar de sus diversas aplicaciones, los algoritmos de los sistemas HAR aún enfrentan varios desafíos, como: 1) la complejidad y diversidad de las actividades diarias, 2) la variabilidad entre sujetos para una misma actividad, 3) la ineficiencia computacional en dispositivos embebidos y portátiles, y 4) la dificultad para manejar los datos [Lara and Labrador, 2012]. Los sistemas HAR que utilizan sensores inerciales portátiles, como los acelerómetros, trabajan con señales temporales.

Este tipo de señal no ha sido ampliamente investigado, lo que requiere enfoques innovadores para extraer características valiosas en los sistemas HAR. En [Zhang et al., 2019], la precisión en el reconocimiento de actividades se mejora incorporando mecanismos de atención en redes neuronales convolucionales multi-cabeza para una mejor extracción y selección de características. En un trabajo relacionado, [Hu et al., 2019] se propuso un método incremental de reconocimiento de actividades llamado FIRF, que evalúa el rendimiento de la identificación continua de nuevas características emergentes. Estas características, extraídas de un nuevo sensor, se agregan de manera incremental en diferentes pasos de tiempo. Además, en [Kuncan et al., 2019] se propuso el método de patrón binario local unidimensional con submuestreo (Down-Sampling One-Dimensional Local Binary Pattern). Su sistema de HAR consta de dos etapas: primero, se aplicó una conversión a las señales del sensor para extraer características estadísticas de las señales recién formadas, y segundo, se realizó la clasificación utilizando estas características. También en [Wei and Wang, 2024], los mecanismos de atención mejoran las redes convolucionales temporales (TCN) para capturar mejor las dependencias temporales e identificar patrones clave en los datos de actividades. De manera similar, en [Ray et al., 2024] se mejora el rendimiento del modelo al combinar sensores portátiles de luz ambiental con IMUs tradicionales para detectar cambios en el entorno vinculados a actividades, lo que lleva a una mayor precisión. Finalmente, en [Liandana et al., 2024] se explora el uso de un solo acelerómetro triaxial con características de los dominios temporal, de frecuencia y estadístico para capturar de manera

integral la dinámica de la actividad humana.

Trabajos como los mencionados, destacan la relevancia de desarrollar nuevas características que proporcionen información significativa sobre la cinemática de los movimientos humanos, con el fin de lograr modelos más precisos. La formulación de estas características es esencial, ya que un análisis adecuado previo puede prevenir la necesidad de realizar estudios complejos que demanden etapas de procesamiento sofisticadas. Esto, a su vez, podría obstaculizar la aplicabilidad de estos modelos en un entorno del mundo real, como en el diseño de nuevos dispositivos portátiles para la clasificación de actividades.

Por lo tanto, este estudio se centra en extraer una nueva característica estrechamente relacionada con la dinámica del movimiento: el radio de curvatura. Esta característica en el dominio del tiempo se calcula segmentando las señales de acelerometría en ventanas, realizando una doble integración para derivar los datos de posición, y posteriormente estimando una circunferencia basada en los datos de posición obtenidos dentro de cada ventana, a lo largo de los tres planos de movimiento (coronal, sagital, transversal), lo que permite que los algoritmos de los sistemas HAR se ejecuten con éxito. De este modo, se mantiene la simplicidad computacional en los algoritmos y se reduce la necesidad de transformaciones de datos complejas.

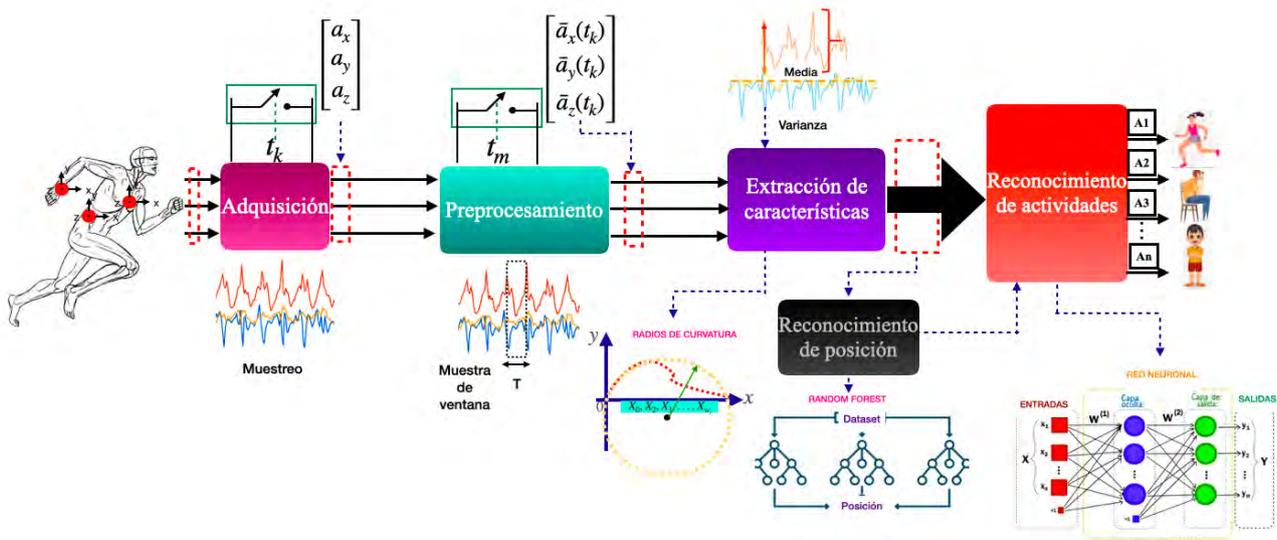


Figura 1.5: Esquema propuesto

En este trabajo se evalúa la efectividad del esquema de clasificación propuesto, siguiendo los pasos del proceso de los sistemas HAR, Figura 1.5. Adicionalmente se realiza la detección de la posición del acelerómetro para determinar el modelo de clasificación a utilizar. Finalmente, se comparan los resultados obtenidos en cada posición, proporcionando así referencias útiles para el desarrollo de nuevas y eficientes metodologías para la ejecución de sistemas HAR.

## 1.4. Objetivo General

- Desarrollar un modelo basado en redes neuronales capaz de clasificar actividades físicas humanas, mediante la conversión de señales de acelerometría en datos sobre actividades

---

físicas, y que funcione eficazmente en múltiples posiciones del sensor.

#### 1.4.1. Objetivos Específicos

- Implementar un sistema inalámbrico para capturar señales de acelerómetros colocados en el pecho, la cadera y la muñeca de un grupo de participantes.
- Crear y preprocesar bases de datos a partir de la información recolectada por los tres acelerómetros.
- Desarrollar características que faciliten la extracción de información útil para los algoritmos de clasificación de actividades.
- Desarrollar un algoritmo basado en redes neuronales que clasifique un conjunto de actividades físicas a partir de señales de acelerometría, utilizando un solo acelerómetro.
- Diseñar un esquema de clasificación de actividades físicas que integre la detección de la posición del sensor y la clasificación de las actividades.
- Validar el esquema de clasificación propuesto utilizando los datos adquiridos y comparar los resultados con bases de datos disponibles en la literatura.

#### 1.5. Metas

- Diseño y construcción de un sistema electrónico portátil compuesto por tres módulos independientes para la adquisición de señales de acelerometría.
- Creación de las bases de datos con las señales de acelerometría recolectadas, que serán utilizadas para entrenar los modelos.
- Implementación de un algoritmo de clasificación basado en redes neuronales, capaz de identificar el tipo de actividad física realizada.
- Incorporación de la detección de la posición del sensor en el algoritmo de clasificación de actividades.
- Evaluación del sistema de clasificación desarrollado mediante la validación en diferentes bases de datos.

#### 1.6. Justificación

Todo sistema vivo consume energía en el proceso de crecimiento y desempeño de actividades, en los humanos se convierte en un paradigma de investigación, donde se busca determinar la interacción del hombre con su entorno, por tal motivo los sistemas HAR han sido un tema central de investigación especialmente en los relacionados con la salud, debido a que la inactividad física constituye el cuarto factor de riesgo (por detrás de la hipertensión, el consumo de tabaco, y la hiperglucemia) más importante de mortalidad en todo el mundo [World Health Organization et al., 2010], es uno de los factores de riesgo más prevalentes de enfermedades no

---

transmisibles en todo el mundo. Por tal motivo, el seguimiento de la AF es de gran interés para estudios de nutrición, desempeño deportivo y salud en general, debido a que permite determinar el comportamiento de un individuo a diferentes tipos de estímulos y determinar su nivel de AF.

Por esta razón, es importante dar un seguimiento a la clasificación de la AF, tomando en cuenta los desafíos y tendencias existentes en este campo de estudio que benefician a numerosas aplicaciones, como el control de la salud, el fitness, el hogar inteligente, etc. Los sistemas HAR se han convertido en un área de investigación popular en el reconocimiento de patrones y el aprendizaje automático. Áreas fundamentales para el análisis de los datos relacionados con la actividad humana, ya que permiten identificar patrones significativos y mejorar la interpretación de las señales. El análisis de estos datos es esencial [Ghasemi et al., 2017], especialmente para la evaluación a largo plazo de parámetros biomecánicos y variables fisiológicas.

Pero todavía existen muchos problemas y desafíos que motivan el desarrollo de nuevas técnicas de reconocimiento de actividad para mejorar la precisión en condiciones más realistas. La llegada de las nuevas tecnologías portátiles y dispositivos móviles ha permitido aplicaciones novedosas pero con muchos problemas abiertos por abordar.

Numerosos estudios han utilizado múltiples acelerómetros ubicados en distintas partes del cuerpo para clasificar las AF [Clevenger et al., 2020a], [Bao and Intille, 2004], [White et al., 2019]. Otros, por su parte, combinan acelerómetros con sensores que miden variables como la frecuencia cardíaca, temperatura o la respuesta galvánica de la piel [Catal and Akbulut, 2018], [Lu et al., 2018], [Kang et al., 2021]. Sin embargo, estos enfoques suelen requerir que el usuario mantenga un patrón de uso fijo, lo cual no resulta práctico en situaciones de vida cotidiana, donde no se supervisa el uso del dispositivo. Además, estos sistemas tienden a tener una baja precisión cuando los sensores no se colocan en la posición predeterminada. En [Khan et al., 2008], por ejemplo, se alcanzó una precisión del 99% para la clasificación de AF, pero solo cuando el sensor estaba colocado en el pecho. Al probarse en otras posiciones, la precisión disminuyó a un 47%.

Aunque se han realizado trabajos donde se realiza el HAR considerando diferentes posiciones de los sensores [Henpraserttae et al., 2011], [Bharti et al., 2018], [Ustev et al., 2013], [Khan et al., 2010], y también se utilizan acelerómetros en conjunto con otros sensores, estos enfoques presentan limitaciones prácticas. En particular, la necesidad de usar múltiples sensores y ajustar la posición de los mismos en el cuerpo del usuario genera complejidad y reduce la viabilidad del sistema para su uso cotidiano. Además, la detección automática de la posición del sensor representa una oportunidad clave para mejorar la practicidad de estos sistemas, permitiendo el desarrollo de modelos específicos que se adapten a la ubicación detectada del sensor y que puedan ser probados con éxito en condiciones reales.

Como se ha señalado previamente, una de las principales tendencias actuales en la clasificación de actividades humanas es el desarrollo de modelos basados en RNAs que adopten un enfoque integral y flexible para abordar los desafíos asociados con el reconocimiento de actividades. Este tipo de modelos buscan superar las limitaciones tradicionales de los enfoques que dependen de la posición fija del acelerómetro en el cuerpo del usuario.

En lugar de requerir una colocación específica del sensor, los modelos basados en RNAs pretenden ser capaces de reconocer las actividades físicas con precisión, independientemente de la ubicación en el que el acelerómetro se porte. Este enfoque tiene el potencial de hacer que los sistemas de monitoreo de actividades sean más prácticos y accesibles en escenarios del mundo real, donde las condiciones de uso pueden variar significativamente y no siempre es posible asegurar que el sensor esté en una posición predefinida, ver Figura 1.6.

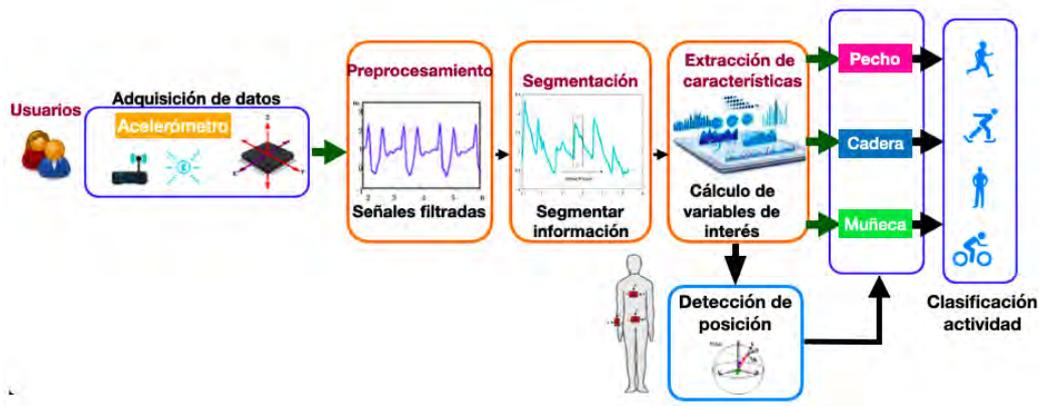


Figura 1.6: Esquema de clasificación de actividades propuesto

Esto puede permitir realizar el seguimiento de AF de manera exitosa, obteniendo resultados que mantengan buenos estándares en cuanto a precisión, sin entorpecer la movilidad del usuario; es el enfoque de investigación principal en este tema de tesis.

## 1.7. Alcance

Generar un esquema de clasificación de actividad física humana, que será validado mediante la comparación con otros modelos reportados en la literatura; se generará una metodología que pueda ser empleada para extraer una nueva característica estrechamente relacionada con el movimiento del cuerpo, la cual será utilizada para entrenar los modelos de clasificación de actividades y detección de posición del sensor. El modelo propuesto será validado por medio de simulación en términos de métricas de reconocimiento de actividades.

## 1.8. Contribución

La propuesta principal y la contribución de este trabajo es la adaptación de características estadísticas temporales bien conocidas combinadas con una nueva característica, que se obtiene a partir del cálculo del radio de curvatura basado en posiciones obtenidas en los tres planos de movimiento, generando trayectorias curvilíneas de los puntos de posición registrados en diferentes posiciones del cuerpo. Posteriormente, se hace uso de la pseudo-inversa para calcular la circunferencia que mejor aproxime a esta trayectoria de puntos por cada intervalo de tiempo, con radio  $r$  y centro  $h, k$ . Lo que resulta en una característica cinemática-antropométrica valiosa, estrechamente relacionada con los patrones de movimiento que las personas realizan durante la actividad física, permitiendo que los algoritmos de reconocimiento de actividades humanas (HAR) se ejecuten con éxito, manteniendo al mismo tiempo la simplicidad computacional en

---

los algoritmos y reduciendo la necesidad de transformaciones de datos complejas. Para clasificar las actividades se utilizó la red neuronal tipo feedforward.

# Capítulo 2

## Marco Teórico

### 2.1. Introducción

El reconocimiento de actividad física mediante acelerometría ha emergido como un campo de investigación de gran relevancia, impulsado por el rápido avance en tecnologías de sensores y análisis de datos. Los acelerómetros, al registrar las aceleraciones en múltiples ejes, ofrecen una ventana detallada al comportamiento y patrón de movimiento de los individuos. Este campo no solo tiene implicaciones significativas para la salud y la ciencia del deporte, sino que también está transformando la tecnología portátil al permitir un monitoreo más preciso y continuo de la actividad física.

Este trabajo de tesis no solo contribuye al avance en el reconocimiento de actividad física mediante la innovación en la extracción de características, sino que también ofrece un marco valioso para futuras investigaciones en la intersección de la tecnología portátil y el análisis de datos de movimiento. En esta sección, se explorarán los conceptos importantes para el entendimiento del trabajo desarrollado.

### 2.2. Cadena de Reconocimiento de Actividad Humana

El desafío del reconocimiento de actividades humanas implica diversas tareas, tales como el modelado de las actividades, la monitorización del comportamiento, el procesamiento de los datos obtenidos y la identificación de patrones. Para diseñar y evaluar un sistema HAR, es necesario seguir una serie de pasos específicos que permiten extraer la información relacionada con la actividad a partir de los sensores utilizados. Esta secuencia de pasos es conocida como la Cadena de reconocimiento de actividad, como se muestra en la Figura 2.1, [Cruciani et al., 2018].

Primero se lleva a cabo la recopilación de datos, centrándose en determinar los detalles del proceso de adquisición de datos, esto incluye la selección del tipo de sensor, el diseño de los experimentos para recopilar datos representativos, y la configuración del sensor para registrar las señales de manera continua o en intervalos específicos. Es necesario considerar aspectos importantes de la adquisición de la señal, como la frecuencia de muestreo. En el contexto de la captura del movimiento del cuerpo humano, la mayoría de su energía, concretamente el 99%, se concentra por debajo de los 15 Hz [Karantonis et al., 2006]. Por tanto, una frecuencia de muestreo superior a 30 Hz es suficiente para captar información interesante, [Banos et al.,

---

2014b, Yang, 2009, Fridolfsson et al., 2019].

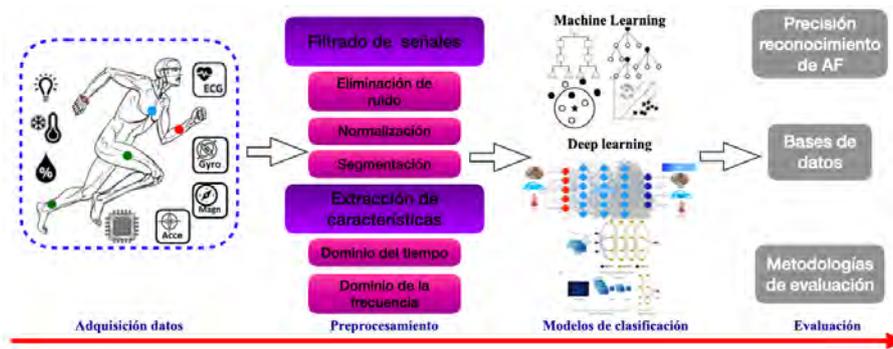


Figura 2.1: Cadena de reconocimiento de actividad

Una vez que se han recopilado los datos, el siguiente paso es el preprocesamiento. Esta etapa implica la limpieza y preparación de los datos para el análisis. Las tareas comunes en esta fase incluyen la eliminación de ruido y artefactos, el filtrado de señales, la normalización de datos, etc. El objetivo es asegurar que los datos sean precisos y estén en un formato adecuado para el análisis posterior.

Después del preprocesamiento de datos y antes de la extracción de características se ejecuta la segmentación de las señales, que tiene como objetivo dividir las señales de datos continuos en segmentos más manejables, cada uno representando un período específico de tiempo conocidas como ventanas [Dehghani et al., 2019].

Con los datos preprocesados, se procede a la extracción de características. Este paso consiste en identificar y calcular las variables y métricas relevantes que describen los patrones de actividad física. La extracción de características puede clasificarse en dos dominios principales: el dominio del tiempo y el dominio de la frecuencia, siendo el dominio del tiempo el más utilizado debido a su simplicidad de cálculo, [Shoab et al., 2015]. Las características pueden ser estadísticas (como media, varianza), o también espectrales (como transformadas de Fourier). La selección de características adecuadas es fundamental para la eficacia del modelo de reconocimiento. Aplicar técnicas complejas de extracción de características puede mejorar el éxito de la clasificación, pero esto puede traer un aumento en los requerimientos de procesamiento [Preece et al., 2008].

Con las características extraídas, se elige y entrena un modelo de clasificación. En esta etapa, se selecciona el algoritmo más adecuado para el reconocimiento de actividades, como redes neuronales artificiales, máquinas de soporte vectorial o árboles de decisión, [Wang et al., 2019]. Siendo los modelos RNAs los que han mejorado el rendimiento y la solidez de HAR, [Sharifani and Amini, 2023].

El entrenamiento del modelo implica ajustar los parámetros del algoritmo para que pueda aprender a clasificar las actividades físicas basándose en las características extraídas. Esta fase a menudo requiere la división de los datos en conjuntos de entrenamiento y prueba para evaluar el desempeño del modelo.

---

Y finalmente se realiza la evaluación del modelo, donde se examina la precisión del modelo en términos de métricas de reconocimiento de actividad, como precisión, recall, F1-score y exactitud, [Mekruksavanich et al., 2022a, Ihianle et al., 2020]. Se realizan pruebas adicionales para validar la robustez y la generalización del modelo en diferentes escenarios o con datos nuevos. Los resultados de esta evaluación proporcionan información sobre la efectividad del sistema y ayudan a identificar áreas para posibles mejoras.

### 2.2.1. Adquisición de Señales

La adquisición de señales es la primera etapa crucial en los sistemas HAR y en la mayoría de los sistemas de monitoreo y análisis de datos. Esta etapa se centra en la recopilación de datos del sensor que son fundamentales para la detección y clasificación de las actividades físicas, la cual implica la ejecución de diferentes tareas, como se describe a continuación.

- Selección de Sensores: En el contexto de sistemas HAR los sensores portátiles son los más utilizados, debido a su popularidad, facilidad de uso y asequibilidad [Sunny et al., 2015, Bulling et al., 2014b], algunos de ellos son:
  - Acelerómetros: Miden la aceleración en una o más direcciones (ejes), proporcionando datos sobre la aceleración y, indirectamente, sobre la velocidad y la posición.
  - Giroscopios: Miden la velocidad angular o la rotación alrededor de uno o más ejes, útiles para detectar cambios en la orientación.
  - Sensores de inclinación: Miden el ángulo de inclinación respecto a la gravedad, a menudo utilizados en combinación con acelerómetros.
- Configuración de sensores: Una vez seleccionado el sensor, se debe configurar para que cumpla con los requisitos del estudio. Ajustar los parámetros de los sensores asegura una adquisición adecuada de datos. Esto incluye parámetros como:
  - Frecuencia de muestreo: La tasa a la que el sensor toma muestras de los datos. Una frecuencia de muestreo más alta puede capturar cambios más rápidos en la actividad.
  - Rango de medición: El intervalo máximo y mínimo de valores que el sensor puede medir sin saturarse.
  - Resolución: La precisión de las mediciones, que determina la menor variación que puede ser detectada.
- Instalación de sensores: La ubicación del sensor es crucial para obtener datos precisos y representativos. Análisis como los presentados en [Altini et al., 2014] muestran cómo la capacidad de clasificación y el rendimiento del modelo se ven directamente afectados por el número y la combinación de posiciones de acelerómetro utilizados. Estos pueden ser colocados en:
  - En el entorno: Capturan datos sobre el entorno que los rodea, pueden medir diferentes tipos de variables ambientales, en algunos casos, los sensores se colocan para capturar datos sobre la interacción del individuo con su entorno como en superficies

---

de contacto. Aunque estos suelen requerir una costosa instalación para un monitoreo eficaz, [Xu et al., 2018].

- En el cuerpo: Los sensores pueden colocarse en distintas partes del cuerpo, como muñecas, tobillos, cintura o incluso en la ropa. Gracias a esto, los sistemas de monitoreo tienen la capacidad de registrar información importante sobre el usuario en cualquier lugar, [Zeng et al., 2014].
- **Recolección de datos:** Con el sensor configurado y colocado, se inicia la captura de datos. Este proceso implica la recolección continua o periódica de señales del sensor, que se registran en forma de datos crudos. Estas señales generadas por los sensores son representativas de las actividades humanas ejecutadas. Algunos de los datos pueden ser:
  - Datos de aceleración: Información sobre las fuerzas aplicadas en las direcciones de los ejes del sensor.
  - Datos de velocidad angular: Información sobre la velocidad de rotación o inclinación.
  - Datos de posición: Información sobre las trayectorias de posición generadas al ejecutar diferentes movimientos.
- **Transmisión y almacenamiento de datos:** Los datos capturados deben ser transmitidos y almacenados. Los datos adquiridos se deben guardar en un formato adecuado para su posterior procesamiento y análisis. Esto puede hacerse a través de:
  - Conexiones inalámbricas: Como Bluetooth o Wi-Fi, que permiten la transmisión de datos en tiempo real a dispositivos de almacenamiento o servidores.
  - Conexiones alámbricas: La transmisión de datos a través de conexiones cableadas, como  $I^2C$  o SPI hacia sistemas de procesamiento o control, donde los datos se almacenan en la memoria interna del dispositivo hasta que se descargan.
- **Verificación de calidad de los datos:** Antes de proceder con el análisis, es esencial verificar la calidad de los datos adquiridos. Esto implica:
  - Verificación de integridad: Asegurarse de que no haya pérdidas de datos o interrupciones en la captura.
  - Validación de precisión: Comprobar que los datos son precisos y representan adecuadamente las señales del sensor.
- **Preparación para el preprocesamiento:** Los datos adquiridos deben estar preparados para el preprocesamiento, que incluirá la limpieza, el filtrado y la segmentación, alistando así los datos para el análisis y la extracción de características que servirán como información de entrada en los modelos de clasificación.

Considerando lo anterior, se puede enfatizar como la etapa de adquisición de señales es fundamental en el proceso de HAR, esta debe ser ejecutada cuidadosamente debido a que los datos recopilados son la base sobre la cual se realiza todo el análisis y la clasificación de actividades, así mismo, la calidad y precisión de los datos adquiridos afectan directamente la efectividad y precisión del sistema.

---

## 2.2.2. Procesamiento de Señales

El procesamiento de señales en el contexto de sistemas HAR, es fundamental para mejorar la calidad y precisión de los datos recolectados por los sensores seleccionados. La presencia de ruido y sus efectos negativos en los modelos de clasificación se mitigan en la etapa de preprocesamiento, haciéndolos adecuados para la extracción de características [Ciuti et al., 2015]. Algunos de los pasos a ejecutar en esta etapa son:

- Filtrado de señales: El principal objetivo del filtrado de señales en sistemas HAR es eliminar el ruido y las interferencias no deseadas que pueden distorsionar los datos de los sensores, asegurando que las señales sean limpias y representativas de las actividades que se requieren clasificar.

Existe una variedad amplia de filtros que pueden ser empleados en esta etapa con el objetivo de reducir el ruido y mejorar la calidad de las señales, como los filtros (pasa-bajo, pasa-alto, pasa-banda, media móvil, Kalman). Sin embargo, según [Fridolfsson et al., 2019] un filtro paso-bajo ajustado a una (frecuencia de corte de 10 Hz) permite capturar toda la aceleración relevante para la actividad física a la vez que se minimiza el impacto del ruido, permitiendo que solo las frecuencias más bajas (que corresponden a la variación de la actividad) pasen a través del filtro, debido a esto, se convierte en el filtro más utilizado en HAR. El proceso de filtrado se puede dividir en diferentes etapas:

- Configuración del filtro: Definir el tipo de filtro a utilizar y establecer sus parámetros para adaptarse a las características de la señal y el tipo de actividad que se está midiendo. Como la frecuencia de corte para filtros pasa-bajo y pasa-alto, o el rango de frecuencias para filtros pasa-banda.
  - Aplicación del filtro: Aplicar el filtro a las señales adquiridas para eliminar el ruido y las interferencias. Este proceso implica el uso de técnicas de filtrado digital para procesar las señales en tiempo real o en post-procesamiento.
  - Revisión y ajuste: Evaluar la señal filtrada para asegurarse de que el filtrado ha sido efectivo y que la señal resultante es adecuada (no hay pérdida de información) para la extracción de características y clasificación.
- Segmentación: Es la división de la señal continua en segmentos o ventanas de tiempo, [Dehghani et al., 2019]. Por lo tanto, la etapa de segmentación es crucial para estructurar los datos recogidos por los sensores en unidades manejables, lo que permite analizar y clasificar las señales de manera más efectiva, cada ventana contiene una secuencia de datos sobre un periodo específico. Esto facilita el análisis de las características de las señales dentro de intervalos definidos y permite la clasificación de actividades basadas en estas características. La segmentación consiste en:
    - Definición de la ventana de tiempo: Se establece una duración fija para cada ventana de tiempo (tamaño), que puede variar desde unos pocos segundos hasta minutos, dependiendo de la actividad y la frecuencia de muestreo, en la mayoría de los estudios realizados de sistemas HAR, la longitud de las ventanas varía entre (1-10 s), [Preece et al., 2008]. El tamaño de la ventana debe ser lo suficientemente largo para capturar características representativas de la actividad, pero lo suficientemente corto para distinguir entre diferentes actividades.

- Aplicación de la ventana de tiempo: Una vez definida la duración de la ventana, la señal es dividida en segmentos consecutivos que abarcan la duración de la ventana. En algunos casos, las ventanas de tiempo pueden solaparse parcialmente para asegurar que se capturen transiciones entre actividades y evitar la pérdida de información, lo que ha demostrado mejoras significativas en los sistemas HAR, [Lara and Labrador, 2012].

El solapamiento puede ayudar a mejorar la precisión de los modelos de clasificación, pero también puede incrementar la complejidad computacional. El grado de solapamiento debe ser ajustado para optimizar el balance entre precisión y eficiencia.

- Normalización: Asegura que los datos sean comparables y estén en una escala uniforme, lo que mejora la precisión y la eficacia de los modelos de aprendizaje automático, facilitando la comparación y el análisis.

Durante la etapa de preprocesamiento de datos se ejecutan diversos procesos, todos importantes para asegurar que los datos provenientes de los sensores sean claros y útiles. Como organizar los datos en fragmentos que pueden ser analizados de manera más eficiente, Figura 2.2 facilitando la identificación de patrones y características dentro de cada ventana, lo que mejora la capacidad para detectar y analizar eventos específicos dentro de una señal continua.

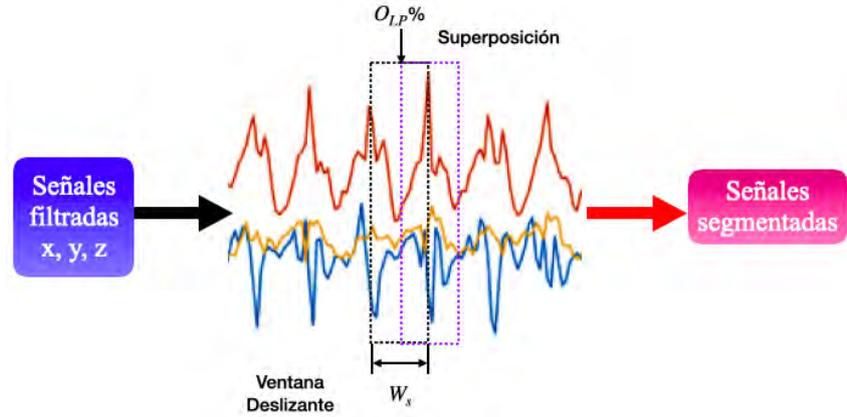


Figura 2.2: Preprocesamiento de señales

De acuerdo a lo anterior, segmentar las señales implica dividir la serie temporal de datos (lecturas del acelerómetro a lo largo del tiempo) en intervalos más pequeños (ventanas), el número de ventanas se puede determinar a partir de la siguiente expresión:

$$K = \left\lfloor \frac{N - M}{R} \right\rfloor + 1 \quad (2.1)$$

donde:  $K$  es el número de ventanas,  $N$  longitud de señal,  $M$  tamaño de la ventana,  $R$  factor de overlap.

El número de muestras de overlap se determina como:

$$X_{OL} = S_R * W_S \left\lfloor \frac{O_{LP}}{100} \right\rfloor \quad (2.2)$$

donde:  $X_{OL}$  número total de muestras overlap,  $S_R$  frecuencia de muestreo (Hz)  $W_S$  tamaño de ventana (s),  $O_{LP}$  porcentaje de overlap.

Por lo tanto, el preprocesamiento de señales en sistemas HAR es fundamental para mejorar la calidad de los datos, facilitar su análisis y comparación, preparar los datos para la extracción de características y optimizar el rendimiento general de los sistemas de reconocimiento de actividades.

### 2.2.3. Extracción y Selección de Características

La extracción de características se enfoca en reducir la complejidad de los datos al convertir las señales crudas en características significativas que describen las propiedades relevantes de las actividades. Estas características son las entradas que los algoritmos de aprendizaje automático utilizan para clasificar las actividades. Es fundamental transformar los datos preprocesados en un formato que pueda ser empleado por los modelos de aprendizaje automático y reconocer actividades. Para ello, es necesario realizar lo siguiente:

- Extracción de características: Es el proceso de derivar atributos significativos de los datos, de manera que reflejen las características relevantes de las actividades. Este proceso convierte los datos complejos y multidimensionales en un formato que es más fácil de analizar y utilizar para los algoritmos de clasificación. Estos enfoques transforman las señales de entrada hacia y desde diferentes dominios de representación [Preece et al., 2008].

En cada dominio existen métodos específicos para abstraer datos, es posible clasificar las técnicas de extracción de características en: el dominio del tiempo, de frecuencia y representación discreta. Como se ilustra en la Figura 2.3

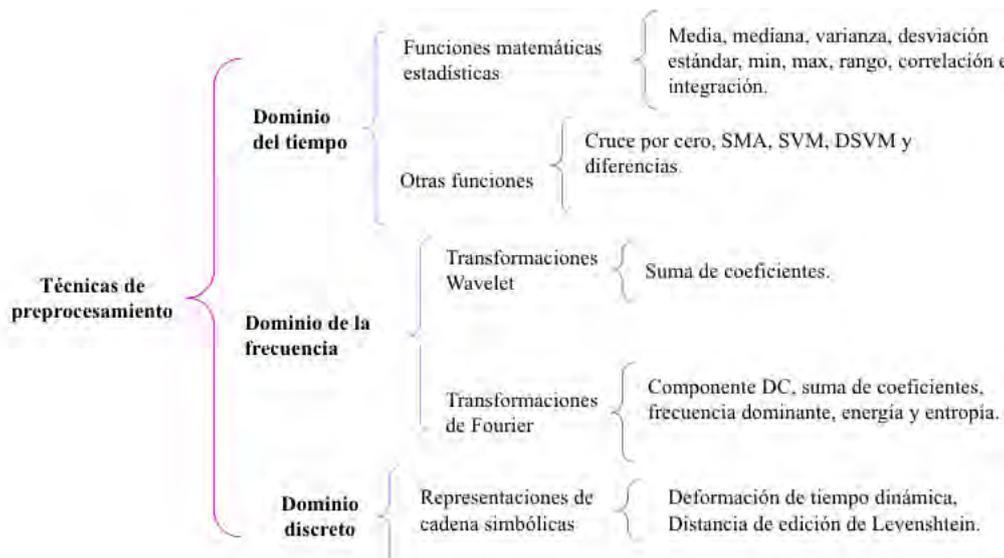


Figura 2.3: Dominios de extracción de características

Las características que son una versión compacta que proporcionan información de mayor utilidad, capturan la esencia de la actividad que se está evaluando, pueden estar en

diferentes dominios como se muestra en la Figura 2.3, sin embargo, algunas de las más usadas se muestran en las Figuras 2.4, 2.5.

		<i>Característica</i>	<i>Descripción</i>
<b>Ejes individuales</b>	<b>Dominio del tiempo</b>	Media	El valor promedio de una ventana de muestras
		Varianza	Mide la cantidad de variación o dispersión de la media
		Desviación estándar	La raíz cuadrada de la varianza
		Mínimo	El valor mínimo en una ventana de muestras
		Máximo	El valor máximo en una ventana de muestras
		Rango	La diferencia entre valores máximo y mínimo en una ventana de muestras
		Media absoluta	Promedio de valores absolutos
		Coefficiente de variación	Medida de la dispersión de la señal
		Curtosis	Mide el grado de la distribución de la ventana de muestras
		Cuartiles	Mide la distribución general de las muestras de señal en la ventana
		Rango intercuartil	La diferencia entre el 3 cuartil superior y el 1 cuartil inferior de la ventana de muestras
		Tasa media de cruce	Mide el número de veces que la señal cruza el valor medio
		Frecuencia dominante	Se calcula como la relación entre el coeficiente FFT de mayor magnitud y la suma de las magnitudes de todos los coeficientes FFT
<b>Dominio de frecuencia</b>	Entropía	Captura la impureza en los datos medidos. La entropía de la información de los valores normalizados de la magnitud del coeficiente FFT	$FD_{entropia} = - \sum_{i=1}^{L/2} Fni \log_2(Fni)$
	Energía	Es una medida de la energía total en todas las frecuencias. La suma de las magnitudes de los componentes FFT discretos al cuadrado	$FD_{energia} = - \sum_{i=1}^{L/2} Fi^2$

Figura 2.4: Características monoaxiales

		<i>Característica</i>	<i>Descripción</i>
<b>Múltiples ejes</b>	<b>Dominio del tiempo</b>	Correlación: (X, Y) (X, Z) (Y, Z)	Mide la relación de dependencia entre dos ejes de la señal del acelerómetro
		Área total absoluta	Suma de las áreas absolutas de los tres ejes
		Magnitud total del área	Magnitud de la señal del acelerómetro en los tres ejes, promediada durante la ventana de tiempo

Figura 2.5: Características multiaxiales

Identificar las características más importantes que contribuyen significativamente a la clasificación de actividades es crucial para construir modelos efectivos y eficientes. Por ello, se tiene que realizar una evaluación continua, como se muestra en el proceso presentado en la Figura 2.6, el cual ayuda a asegurar que las características seleccionadas sean las más relevantes y contribuyan significativamente a los modelos de clasificación.

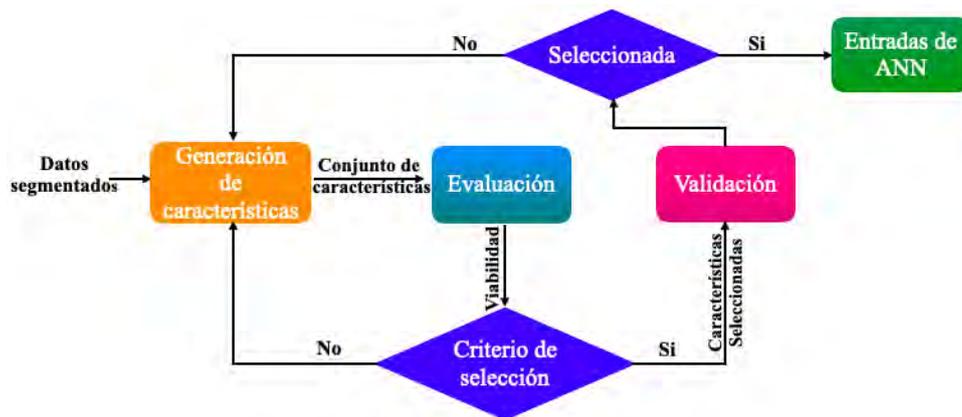


Figura 2.6: Proceso de selección de características

#### 2.2.4. Modelos de Clasificación en HAR

El objetivo principal de esta etapa es usar algoritmos de aprendizaje automático para predecir a qué clase (o actividad) pertenece cada segmento de datos. En el contexto de sistemas HAR, esto significa identificar qué tipo de actividad humana (como caminar, correr, sentarse, etc.) se está realizando en base a las características extraídas de los datos recolectados.

Elegir el algoritmo de clasificación adecuado que se ajuste a la naturaleza de los datos y al problema específico es crucial en la obtención de buenos resultados. Los modelos pueden variar desde enfoques simples como la regresión logística hasta métodos más complejos como redes neuronales profundas. Entre los modelos más utilizados se encuentran:

- Máquinas de Soporte Vectorial: Encuentra el hiperplano que mejor separa las clases en un espacio de características.
- Árboles de Decisión y Random Forest: Crean modelos basados en decisiones jerárquicas y combinan múltiples árboles para mejorar la precisión.
- Regresión Logística: Utiliza una función sigmoide para modelar la probabilidad de que un segmento de datos pertenezca a una clase específica.
- Redes Neuronales: Modelos basados en redes de nodos interconectados que pueden capturar patrones complejos y no lineales en los datos.
- K-Vecinos más Cercanos: Clasifica un dato en función de la mayoría de los votos de sus vecinos más cercanos en el espacio de características.

Una vez seleccionado el modelo de clasificación a utilizar se procede a ejecutar la etapa de entrenamiento y prueba, proceso en el cual el modelo es ajustado a los datos de entrenamiento. Según [Nguyen et al., 2021], una división del conjunto de datos de entrenamiento y prueba de 70/30 se determinó como la relación más efectiva para entrenar y validar modelos de aprendizaje automático. Durante el entrenamiento, el modelo aprende a partir de las características extraídas y sus etiquetas correspondientes para reconocer patrones asociados con cada actividad. En esta fase es importante considerar los siguientes puntos:

- 
- División de datos: Los datos se dividen en conjuntos de entrenamiento y de prueba para evaluar el rendimiento del modelo.
  - Ajuste de parámetros: Los parámetros del modelo (hiperparámetros) se ajustan para optimizar el rendimiento en el conjunto de entrenamiento.
  - Entrenamiento: El modelo se ajusta a los datos de entrenamiento mediante algoritmos de optimización, aprendiendo a clasificar correctamente las actividades.

### 2.2.5. Evaluación de Modelos HAR

En esta etapa se mide el rendimiento del modelo utilizando métricas que indiquen qué tan bien clasifica los datos en las diferentes categorías de actividades. Para evaluar el rendimiento final de clasificación se pueden emplear las siguientes métricas:

- Precisión (Accuracy): Indica la proporción de predicciones correctas (tanto positivas como negativas) sobre el total de predicciones realizadas, para cada clase. Esta métrica se puede expresar mediante la siguiente ecuación:

$$\text{Precisión} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.3)$$

donde  $TP$  (verdaderos positivos) representa el número de casos correctamente clasificados como positivos,  $TN$  (verdaderos negativos) es el número de casos correctamente clasificados como negativos,  $FP$  (falsos positivos) es el número de casos incorrectamente clasificados como positivos, y  $FN$  (falsos negativos) es el número de casos incorrectamente clasificados como negativos.

- Precisión (Precision): Mide la exactitud de las predicciones positivas realizadas por el modelo. Se calcula como:

$$\text{Precisión} = \frac{TP}{TP + FP} \quad (2.4)$$

- Exhaustividad (Recall): Muestra la proporción de casos positivos que el modelo ha identificado correctamente para cada clase. Esta métrica se expresa como:

$$\text{Exhaustividad} = \frac{TP}{TP + FN} \quad (2.5)$$

- Puntuación F1 (F1-score): Es la media armónica entre la precisión y la exhaustividad, proporcionando una métrica que equilibra ambas medidas. Se puede calcular mediante la siguiente fórmula:

$$\text{Puntuación F1} = 2 \times \frac{\text{Precisión} \times \text{Exhaustividad}}{\text{Precisión} + \text{Exhaustividad}} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (2.6)$$

---

También se encuentran las técnicas de validación cruzada como la evaluación LOSO (Leave-One-Subject-Out) utilizada en problemas de aprendizaje automático, especialmente en contextos donde los datos están organizados por sujetos individuales y se tiene un conjunto de datos pequeño [Gholamiangonabadi et al., 2020]. Es común adoptar el método LOSO para evaluar el rendimiento del algoritmo de clasificación.

En lugar de dividir los datos en particiones aleatorias, LOSO realiza la validación cruzada dejando fuera un sujeto completo en cada iteración. Esto es particularmente útil cuando los datos están relacionados con características individuales de los sujetos. El proceso de evaluación LOSO puede ser descrito como se muestra a continuación:

- División de datos: Los datos se organizan de manera que cada sujeto esté en su propio grupo, por lo tanto, habrá tantos grupos como número de participantes.
- Selección del sujeto para prueba: En cada iteración del proceso de validación, se selecciona un sujeto diferente para ser el conjunto de prueba. Todos los datos del sujeto seleccionado se utilizan para probar el modelo.
- Selección sujetos para entrenamiento: Los datos de todos los demás sujetos (sin contar el de prueba) se utilizan para entrenar el modelo.
- Evaluación del modelo: Se evalúa el modelo utilizando los datos del sujeto que se dejó fuera, de cada uno de los grupos. Se calcula el rendimiento del modelo utilizando métricas como precisión, recall, F1-score, etc.

Al evaluar el modelo en datos de un sujeto no visto durante el entrenamiento, LOSO proporciona una estimación de cómo el modelo generaliza a nuevos sujetos, lo que es crucial en aplicaciones prácticas donde el modelo se enfrentará a datos de nuevos usuarios. El enfoque de dejar fuera a un sujeto evita el sobreajuste, lo que asegura que el modelo es probado en todos los contextos posibles en el conjunto de datos.

Basado en los resultados de la evaluación, el modelo puede ser ajustado para mejorar su rendimiento. Esto puede incluir ajustes de hiperparámetros, reentrenamiento con más datos, o modificaciones en la estructura del modelo.

## 2.3. Radio de Curvatura

El radio de curvatura (RC) puede definirse como el radio del círculo que mejor se ajusta a la curva en un punto dado [Piaggio, 1943]. Cuanto más aguda sea la curva, menor será el RC, Figura 2.7. El radio del círculo asociado a cada punto de la curva se llama RC en ese punto, este es un buen indicador de saber qué tanto la curva se curva en cada punto.

El RC de una curva en un punto dado puede calcularse utilizando la ecuación de la circunferencia. Para una circunferencia, el RC es constante. La ecuación estándar de una circunferencia en el plano cartesiano es:

$$(x - h)^2 + (y - k)^2 = r^2 \tag{2.7}$$

donde:  $(h, k)$  son las coordenadas del centro de la circunferencia,  $(x, y)$  las coordenadas del punto en el plano y  $r$  es el radio de la circunferencia.

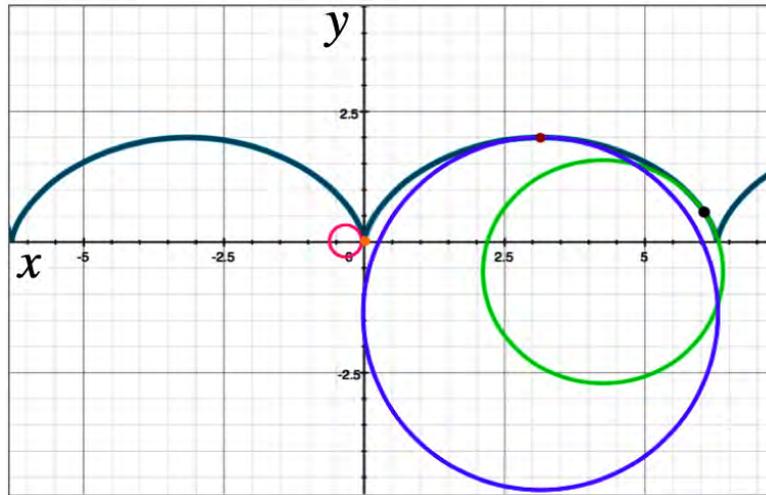


Figura 2.7: RC asociados a diferentes puntos

Por lo tanto, RC es un concepto que puede ser utilizado en la clasificación de patrones de movimiento, especialmente en el análisis de trayectorias y movimientos complejos. Este hace referencia a la medida de la curvatura de una trayectoria en un punto específico.

Tomando en cuenta que una recta es igual a una circunferencia con Radio  $\infty$  y que su curvatura se define como:

$$C = \frac{1}{R} \quad (2.8)$$

La curvatura de una recta es igual a:

$$C_r = \frac{1}{\infty} = 0 \quad (2.9)$$

donde  $C$  : es la curvatura,  $C_r$  : es la curvatura de una recta,  $R$  : radio de una circunferencia.

En la clasificación de patrones de movimiento, el RC puede proporcionar información crucial sobre la naturaleza del movimiento. Por ejemplo:

- Movimientos con un RC pequeño pueden indicar giros bruscos, como en deportes o actividades dinámicas.
- Un RC grande puede asociarse con movimientos más suaves o estáticos.

El análisis del RC puede ayudar a extraer características relevantes para la clasificación. Por ejemplo, se puede utilizar junto con otros parámetros (como velocidad y aceleración) para identificar y diferenciar actividades específicas. En el contexto de aprendizaje automático, el RC se puede usar como una característica en modelos de clasificación para mejorar la precisión en el reconocimiento de actividades, proporcionando información adicional sobre la dinámica

del movimiento. Además de su aplicación en la clasificación de actividades, en deportes como el baloncesto o el fútbol, el RC puede ayudar a identificar diferentes tipos de dribles o giros. En rehabilitación, puede ser útil para evaluar la movilidad de los pacientes.

Por lo tanto, el RC es una herramienta valiosa en la clasificación de patrones de movimiento, ya que proporciona información sobre la naturaleza y complejidad de las trayectorias, lo que puede mejorar la precisión en el reconocimiento de actividades y la comprensión del comportamiento humano.

## 2.4. Redes Neuronales Artificiales

Las RNAs son una importante rama de la inteligencia artificial, definidas como modelos inspirados en la estructura y función del cerebro humano [Sathyanarayana et al., 2018], ya que se asemejan a los procesos interactivos del cerebro y permiten estudiar fenómenos no lineales muy complejos. Estas han demostrado ser eficaces en una amplia gama de tareas. Reconocimiento de caracteres, imágenes y voz, generación de texto, traducción de idiomas, predicción de mercados financieros, detección de fraudes, pronóstico de enfermedades, clasificación, entre otras, son algunas de las aplicaciones donde son empleadas. Así mismo, en sistemas HAR, ya que tienen la capacidad de aprender patrones en los datos y extraer características discriminativas, lo que resulta en una poderosa herramienta [Nweke et al., 2018].

La complejidad de estos sistemas esta definida por la interacción de elementos más simples, que trabajan en conjunto y están interconectados, en el caso de una RNA, a cada uno de estos elementos se le denomina neurona. Cuando muchas neuronas se encuentran interconectadas, pueden formar toda una red de comunicación que pueden resolver problemas muy complejos [Acevedo et al., 2017].

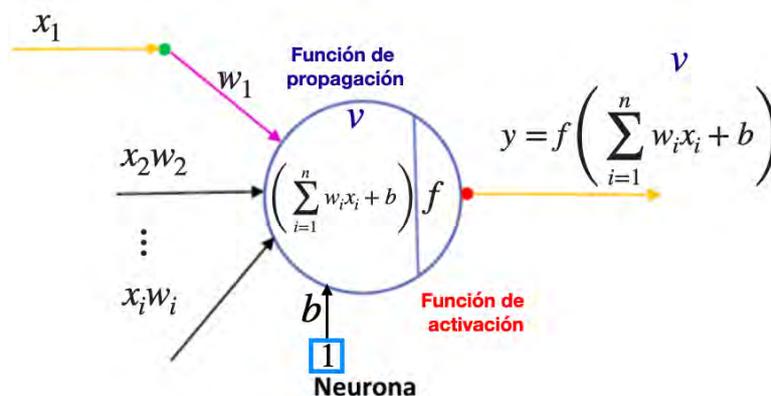


Figura 2.8: Estructura neurona artificial

De manera análoga a una neurona biológica, una neurona artificial posee conexiones de entrada a través de las cuales recibe estímulos independientes, es decir, entradas que no se conocen  $(x_1, x_2, \dots, x_i)$ , como se muestra en la Figura 2.8. Tomando los valores de entrada, la neurona será capaz de procesar la información y se producirá un valor ponderado de salida  $y$ , dado por la combinación lineal de las entradas y los pesos sinápticos  $(w_1, w_2, \dots, w_i)$ . La ecuación

---

2.10 muestra el modelo de la neurona artificial:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right), \quad y : \mathbb{R}^n \rightarrow \mathbb{R}, (w, x, f, i) \rightarrow y(w, x, f, i) : x \in \mathbb{R}^n \quad (2.10)$$

donde  $x_i$  : son los valores de entrada,  $w_i$  : *pesos* y  $b$  : *sesgo* que son parámetros de ponderación,  $f$  : es una función de activación acotada,  $y$  : es el valor de salida de la neurona.

Para esto es importante remarcar que la función de propagación, hace referencia al proceso de calcular la salida de una neurona mediante una combinación lineal de las entradas (ponderadas) y el sesgo, antes de aplicar la función de activación. Y la función de activación introduce no linealidad en la red neuronal, permitiendo que la red aprenda funciones complejas la cual se aplica a la salida de la combinación lineal de entradas.

Así como se ilustra en la ecuación 2.10 y en la Figura 2.8, una neurona puede modelar no linealidades o mantener un comportamiento lineal a través de una expresión matemática conocida como función de activación. En una neurona biológica, la comunicación con otras neuronas ocurre a través de señales eléctricas, un proceso que se denomina sinapsis. De manera similar, una neurona artificial se comunica con otras neuronas artificiales mediante un parámetro ponderado denominado peso sináptico. Estos pesos sinápticos se optimizan usando algoritmos de entrenamiento. Gracias a la flexibilidad y la implementación relativamente sencilla de las RNAs, estas pueden adaptarse a diversas tareas. Es decir, sin importar el propósito o área específica, una RNA buscará adaptarse para alcanzar el objetivo para el cual fue diseñada, ajustando sus pesos sinápticos a través de un proceso de entrenamiento [Asanza and Olivo, 2018, Olabe, 1998].

### 2.4.1. Funciones de Activación

Las funciones de activación en las RNAs son funciones matemáticas que se aplican a la salida de cada neurona para introducir no linealidades en el modelo, para esto se define una función de activación no lineal que su primera derivada también sea continua para asegurar que el proceso de aprendizaje y la optimización sean efectivos y estables. Estas funciones son fundamentales para que las redes neuronales puedan aprender y modelar relaciones complejas en los datos, a continuación, se presentan algunas de las funciones de activación comúnmente empleadas:

- Tangente hiperbólica (tanh): Esta función es frecuentemente utilizada debido a su rango centrado alrededor de cero, lo que puede ayudar a la convergencia del entrenamiento, la función y su primera derivada es continua en todo su dominio, su rango esta dado entre  $(-1, 1)$ , donde los valores grandes y positivos tienden de manera asintótica a 1 y los valores pequeños y negativos tienden de manera asintótica a -1, ver Figura 2.9.

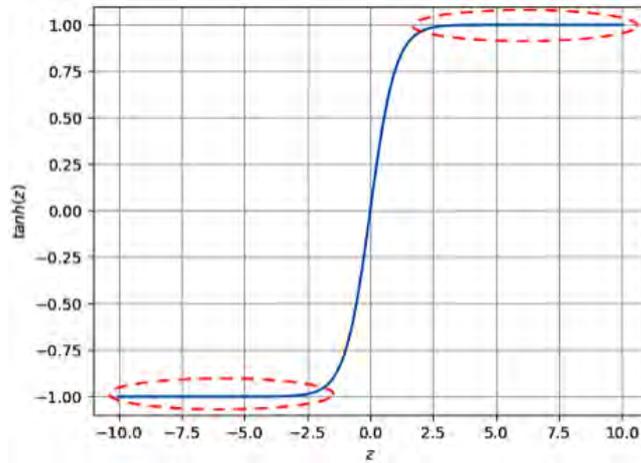


Figura 2.9: Función de activación tanh

La expresión matemática de la función  $\tanh(z)$ , está dada por:

$$f(z) = \tanh(z) = \frac{1 - e^{-2z}}{1 + e^{-2z}} \quad (2.11)$$

- ReLu: La función transforma los valores introducidos anulando los valores negativos tendiendo de manera asintótica a 0 y dejando los positivos tal y como entran, su derivada es continua en todos los puntos excepto en  $x = 0$ , donde hay un cambio abrupto, su rango está dado entre  $[0, \infty)$ . Ver Figura 2.10.

$$ReLU(z) = \max(0, z) \quad (2.12)$$

$$ReLU(z) = \begin{cases} 0, & z \leq 0 \\ z, & z > 0 \end{cases}$$

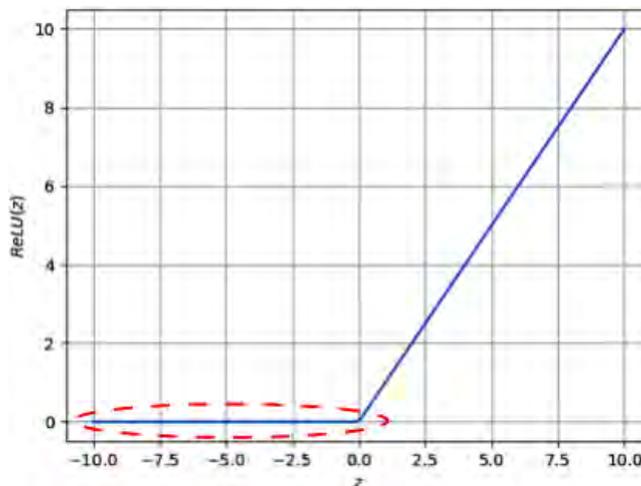


Figura 2.10: Función de activación ReLu

- SoftMax: La función transforma las salidas a una representación en forma de probabilidades, de tal manera que el sumatorio de todas las probabilidades de las salidas es 1. Es comúnmente utilizada en la capa de salida de RNAs para clasificación múltiple, su rango está dado entre (0, 1), como se muestra en la Figura 2.11.

$$\text{SoftMax}(y_z) = \frac{e^{y_z}}{\sum_{k=1}^N e^{y_k}} \quad (2.13)$$

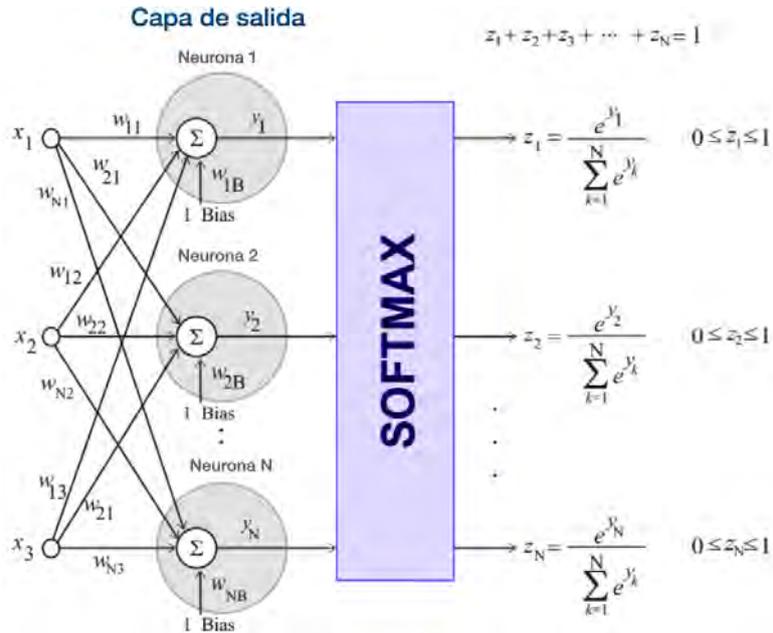


Figura 2.11: Función de activación SoftMax

donde  $y$  es un vector de entrada de tamaño igual al número de neuronas de la capa y  $N$  el número de clases diferentes.

Cada función de activación tiene sus características, ventajas y desventajas, y la elección de cuál utilizar depende del problema específico y del diseño de la red. Funciones como ReLU y sus variantes suelen ser preferidas por su eficiencia en el entrenamiento y la capacidad para manejar la no linealidad sin problemas de saturación. En tareas de clasificación, la función softmax es utilizada para convertir las salidas de la red en probabilidades interpretables.

### 2.4.2. Redes Neuronales Multicapa

Las redes neuronales feedforward (RNaf) son una clase fundamental de RNAs en las cuales la información se propaga en una única dirección: desde las neuronas de la capa de entrada hacia las neuronas de la capa de salida a través de una o más capas ocultas, sin ciclos ni bucles. Es una de las estructuras de RNAs más utilizadas en una amplia variedad de aplicaciones debido a su simplicidad y eficacia en la modelización de datos, [Hemeida et al., 2020, Bhaskar and Singh, 2012, Gayathri et al., 2022].

---

En una RNAf, las neuronas o perceptrones están organizadas en secciones denominadas capas. Los nodos en la capa de entrada proporcionan la información sobre los patrones que se desean reproducir (vector de entrada). Esta información se transmite a la siguiente capa (la primera capa oculta) a través de ponderaciones realizadas por los pesos sinápticos. Las salidas de la capa oculta sirven como entradas para la segunda capa, y las salidas de esta segunda capa se convierten en entradas para la tercera capa, y así sucesivamente, hasta llegar a la capa de salida. Esta comunicación entre las capas de la red neuronal es conocido como aprendizaje jerarquizado, [Nosratabadi et al., 2020]. La función de cada capa es ajustar los pesos específicos que se establecerán al final del proceso de aprendizaje.

La salida de cada neurona incluye una función de activación que es la suma de todos los pesos de entrada, mientras que la entrada de la neurona es la suma de todos los pesos junto con el sesgo (bias). El sesgo es una constante utilizada para ajustar la salida y la suma ponderada de las entradas de la neurona, mientras que las funciones de activación son fundamentales para el funcionamiento de las redes neuronales, [Zhang et al., 2020, Ochoa-Estopier et al., 2013]. Las actualizaciones de los pesos en el proceso de retropropagación se realizan para obtener los gradientes, utilizando múltiples capas ocultas.

A través de diferentes investigaciones como en [Emmert-Streib et al., 2020] se ha abordado la discusión sobre las arquitecturas de redes neuronales, enfatizando que la estructura RNAf es la más simple y fundamental. Pero se subraya la importancia de definir una función de error y un algoritmo de optimización para minimizar el error durante el entrenamiento, lo que es esencial para el funcionamiento efectivo de las RNAfs.

La Figura 2.12 ilustra una RNA de tres capas ocultas con  $J$  neuronas en la primer capa oculta  $K$  neuronas en la siguiente capa oculta y  $M$  neuronas en la última capa oculta, siendo esta una RNA multicapa con  $i$  entradas y  $n$  salidas.

Matemáticamente se representa como en la siguiente expresión:

$$y_n = f \left( \sum_{j=1}^J V_{mj} \left( \sum_{p=1}^n V_{jp} x_p + b_j \right) + l_m \right), \quad m = 1, 2, \dots, K \quad (2.14)$$

Definiendo  $z_k$  como la señal de salida de cada neurona de la primer capa oculta permite que el modelo se simplifique de tal forma que:

$$z_k = f \left( \sum_{p=1}^n V_{jp} x_p + b_j \right), \quad j = 1, 2, \dots, J \quad (2.15)$$

$$y_i = f \left( \sum_{j=1}^J V_{mj} z_k + l_m \right), \quad m = 1, 2, \dots, K \quad (2.16)$$

Existen diversas configuraciones y arquitecturas de redes neuronales recurrentes, en las cuales la información se transmite desde la primera capa hasta la última o, en algunos casos, a la penúltima capa. Independientemente de la ubicación de la retroalimentación, la esencia de una red neuronal recurrente radica en que la información siempre se distribuye en una sola dirección [Haykin, 2009].

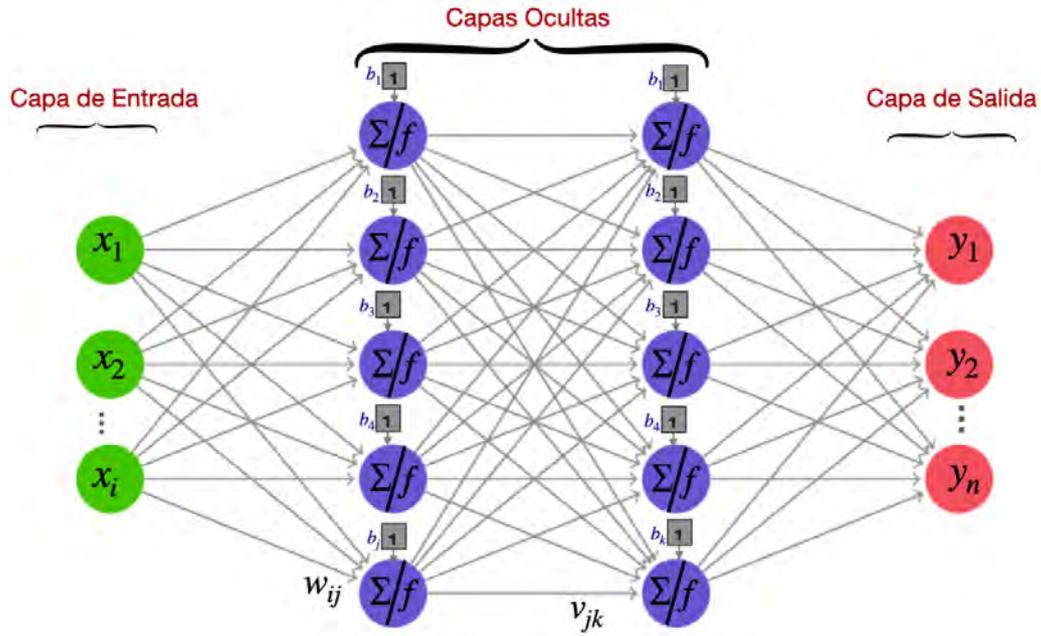


Figura 2.12: Red FFNN tipo densa con  $j - m$  neuronas,  $i$  entradas y  $n$  salidas

Las RNAs densas, también conocidas como redes neuronales totalmente conectadas son una variante de las RNAf, en las que cada neurona está conectada a todas las neuronas de la capa siguiente. Estas redes han demostrado ser eficaces en una amplia gama de tareas, incluida la clasificación de la actividad física, [Shoab et al., 2016]. La RNAf puede describirse matemáticamente de la siguiente manera:

Dada una red neuronal con  $L$  capas, donde  $L - 1$  capas son capas ocultas y la última capa es la capa de salida. Para cada capa  $l = 1, 2, \dots, L$ , se definen los siguientes términos:

$z^{[l]}$  : Vector de activación de la capa  $l$ .

$a^{[l]}$  : Vector de salida de la capa  $l$  ( $a^{[l]} = f(z^{[l]})$  donde  $f$  es la función de activación).

$W^{[l]}$  : Matriz de pesos de la capa  $l$ .

$b^{[l]}$  : Vector de sesgos de la capa  $l$ .

La propagación hacia adelante en una red neuronal densa puede describirse como sigue. Para la capa de entrada  $l = 1$ :

$$a^{[1]} = x, \text{ donde } x \text{ es el vector de características de entrada.}$$

Para cada capa  $l = 1, 2, \dots, L$ :

$$z^{[l]} = W^{[l]} \cdot a^{[l-1]} + b^{[l]}$$

$$a^{[l]} = f(z^{[l]}), \text{ donde } f \text{ es la función de activación.}$$

Para la capa de salida  $l = L$ :

$$\hat{y} = a^{[L]}, \text{ donde } \hat{y} \text{ es la salida predecida por la RNA}$$

---

La estructura matemática se basa en la propagación hacia adelante, a través de las capas de una red neuronal densa, utilizando matrices de pesos, vectores de sesgo y funciones de activación para calcular las salidas de cada capa. En la última capa se produce la salida final de la red neuronal.

### 2.4.3. Entrenamiento de Redes Neuronales

Sin lugar a dudas, una de las propiedades más relevantes de las RNAs es su capacidad para adaptarse a su entorno a través del aprendizaje, ajustando de manera precisa los pesos sinápticos. Este proceso de aprendizaje implica modificar los pesos al comparar la salida obtenida con la salida deseada, con el objetivo de minimizar el error. Así, los parámetros de la red se optimizan mediante simulaciones o interacciones con el entorno en el que se implementa [Haykin, 1998]. Este proceso de ajuste puede realizarse de dos maneras:

- **Aprendizaje supervisado:** En este el modelo se entrena utilizando un conjunto de datos etiquetados. Esto significa que cada entrada en el conjunto de datos tiene una etiqueta o valor de salida asociado, que la red neuronal debe aprender a predecir. La RNA es expuesta al conjunto de entrenamiento, y sus parámetros (pesos sinápticos) se ajustan en función de una señal de error, que representa la discrepancia entre la salida actual de la RNA y la salida deseada.
- **Aprendizaje no supervisado:** En el aprendizaje no supervisado, el modelo se entrena utilizando un conjunto de datos que no tiene etiquetas. El objetivo es encontrar patrones o estructuras subyacentes en los datos. Minimizando la función objetivo lo que significa que la RNA debe asignar un valor a cada comparación que realiza.

### 2.4.4. Función de Pérdida, Entropía Cruzada Categórica

La función de pérdida (o función de costo) es una herramienta fundamental en el aprendizaje automático, que mide la discrepancia entre las predicciones de un modelo y los valores reales (verdaderos). Asigna un valor que representa el “Sesgo” de hacer una predicción en comparación con el valor real.

Esta forma de la función de pérdida se utiliza comúnmente en algoritmos de aprendizaje automático, especialmente en clasificación multcategórica [Gordon-Rodriguez et al., 2020], donde la salida del modelo se obtiene típicamente aplicando la función Softmax.

La función de pérdida Entropía Cruzada Categórica sobre un conjunto de  $N$  ejemplos, se puede expresar como:

$$\mathcal{L}(\mathbf{y}, \hat{\mathbf{y}}) = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(\hat{y}_{ij}) \quad (2.17)$$

Donde:

- $\mathcal{L}(\mathbf{y}, \hat{\mathbf{y}})$ : es la función de pérdida total (entropía cruzada).
- $N$ : número total de ejemplos en el conjunto de datos.

- 
- $C$ : número de clases.
  - $y_{ij}$ : valor de la etiqueta verdadera para el ejemplo  $i$  y la clase  $j$ . Este valor es 1 si el ejemplo  $i$  pertenece a la clase  $j$  (one-hot encoding) y 0 en caso contrario.
  - $\hat{y}_{ij}$ : probabilidad predicha para el ejemplo  $i$  y la clase  $j$ .

Por lo tanto, para cada ejemplo  $i$ , se suma la contribución de todas las clases  $j$  al costo total. Solo la clase correcta donde  $y_{ij} = 1$  contribuye a la suma, ya que los términos donde  $y_{ij} = 0$  no afectan el resultado.

La división por  $N$  asegura que la pérdida sea un promedio sobre todos los ejemplos, lo que permite comparaciones consistentes entre conjuntos de datos de diferentes tamaños. Proceso que se ejecuta en la fase de entrenamiento del modelo, donde el objetivo es minimizar esta función de pérdida para mejorar la precisión de las predicciones.

### 2.4.5. Algoritmo de Optimización Adam

Los algoritmos de optimización son cruciales en el entrenamiento de RNAs, ya que se encarga de ajustar los parámetros del modelo (pesos sinápticos) para mejorar su rendimiento, adaptando las tasas de aprendizaje y manejando la variabilidad de los gradientes. Esto permite que la red aprenda de manera efectiva a partir de los datos proporcionados. Los métodos convencionales suelen emplear derivadas de primer orden, mientras que otros utilizan la segunda derivada de su función objetivo. La idea detrás del optimizador es encontrar los parámetros que minimizan la función de pérdida (o costo). Esta función mide cuán bien se está desempeñando el modelo al hacer predicciones en comparación con los valores reales.

El optimizador Adam (Adaptive Moment Estimation) es un algoritmo de optimización estocástica que combina las ventajas de dos métodos: AdaGrad y RMSProp. Su estructura matemática se basa en el cálculo de momentos de primer y segundo orden de los gradientes. En [Kingma, 2014] se describe el optimizador Adam, que es ampliamente utilizado en el entrenamiento de modelos de aprendizaje automático. Su estructura matemática se puede desglosar de la siguiente manera:

#### Estructura matemática del optimizador Adam:

- **Momentos del gradiente**

- Primer momento (media):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \tag{2.18}$$

- Segundo momento (varianza):

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \tag{2.19}$$

Aquí,  $g_t$  es el gradiente de la función de pérdida respecto a los parámetros en el tiempo  $t$ , y  $\beta_1$  y  $\beta_2$  son coeficientes de decaimiento (típicamente  $\beta_1 = 0.9$  y  $\beta_2 = 0.999$ ).

---

- **Corrección de sesgo**

Se introducen correcciones para los momentos, que ayudan a compensar el sesgo inicial debido a la inicialización en cero:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (2.20)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (2.21)$$

- **Actualización de parámetros**

La actualización de los parámetros se realiza mediante:

$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (2.22)$$

Donde  $\theta_t$  son los parámetros del modelo,  $\alpha$  es la tasa de aprendizaje, y  $\epsilon$  es un pequeño valor para evitar divisiones por cero (comúnmente  $10^{-8}$ ).

## 2.5. Clasificador de Bosques Aleatorios

Los Clasificadores de Bosques Aleatorios (RF) son un método de aprendizaje automático basado en árboles de decisión que se utiliza para tareas de clasificación y regresión, propuesto por [Breiman, 2001]. Es bien conocido que los árboles de decisión clásicos son sensibles al sobreajuste. Para superar este problema se han propuesto métodos de conjunto que equilibran los resultados de múltiples árboles de decisión entrenados en diferentes partes de los datos de entrenamiento. Por lo tanto, un bosque aleatorio se compone de múltiples árboles de decisión, que se generan a partir de diferentes subconjuntos de datos de entrenamiento. Cada árbol proporciona una "votación" para determinar la clase o el valor de salida. Un clasificador de bosques aleatorios se construye de la siguiente manera:

El modelo se entrena a partir de las características obtenidas en el vector de características propuesto. Supongamos que tenemos  $N$  ejemplos de entrenamiento, donde cada ejemplo tiene  $D$  características. Las características se representan como un vector  $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ , para cada ejemplo  $i$ . Las etiquetas de clase correspondientes se representan como un vector  $Q_i$  para cada ejemplo  $i$ .

$$D = \{(x_i, Q_i)\}_{i=1}^N \quad (2.23)$$

donde  $x_i$  son las entradas y  $Q_i$  las salidas de clase.

Básicamente el algoritmo de entrenamiento RF aplica la técnica general de agregación (bootstrap, o bagging) a los árboles de aprendizaje, el cual consiste en tomar muestras aleatorias de características en lugar de tomar todas las características disponibles al construir el modelo. Dado un conjunto de entrenamiento  $x_i = x_{1i}, \dots, x_{iD}$  con respuestas  $Q_i = Q_{1i}, \dots, Q_{iD}$ , el bagging selecciona repetidamente ( $B$  veces) una muestra aleatoria con reemplazo del conjunto de entrenamiento y ajusta árboles a estas muestras:

Para  $b = 1 \dots B$

1. Muestra, con reemplazo,  $N$  ejemplos de entrenamiento de  $x_i, Q_i$ ; llamados  $X_b, Y_b$ .
2. Entrena un árbol de clasificación  $f_b$  en  $X_b, Y_b$ .

Después del entrenamiento, las predicciones para las muestras no vistas  $x'$  pueden hacerse promediando las predicciones de todos los árboles de regresión individuales sobre  $x'$ :

$$\hat{f}(x') = \frac{1}{B} \sum_{b=1}^B f_b(x') \quad (2.24)$$

En este proceso, el bootstrapping optimiza el rendimiento del modelo al reducir su varianza sin incrementar el sesgo. Esto implica que, aunque las predicciones de un solo árbol sean altamente sensibles al ruido en su conjunto de entrenamiento, el promedio de las predicciones de múltiples árboles se vuelve más robusto, siempre que los árboles no presenten correlación entre sí.

El resultado de clasificación de un modelo RF se determina contando las predicciones de clase de cada árbol de decisión y seleccionando la clase más frecuente como predicción final.

$$y_{pred} = \underset{i}{\operatorname{argmax}} \left( \sum_{i=1}^M \alpha(Q_i) \right) \quad (2.25)$$

donde  $y_{pred}$  es la salida predicha,  $M$  es el número de árboles y  $\alpha(Q_i)$  es una función indicadora que devuelve 1 si la predicción del árbol  $i$  es igual a la clase  $Q_i$ , y 0 en caso contrario.

A continuación podemos visualizar la estructura del clasificador RF, constituido por múltiples árboles de decisión, ver Figura 2.13.

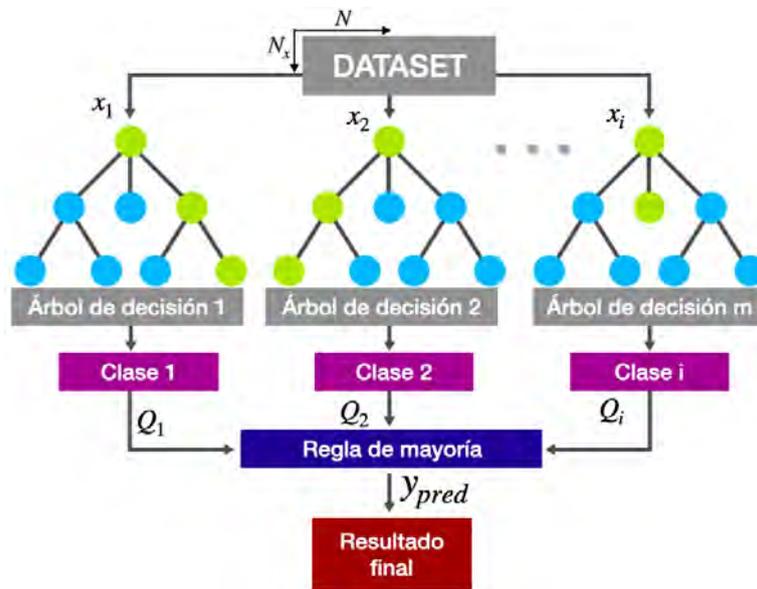


Figura 2.13: Estructura clasificador RF

El clasificador de bosques aleatorios es un método poderoso y versátil en el aprendizaje automático que aprovecha la combinación de múltiples árboles de decisión para lograr un mejor rendimiento.

---

### 2.5.1. Detección de Posición del Transductor

La idea principal detrás de la detección de posición del sensor en el cuerpo es analizar los datos de aceleración cuando el usuario está realizando diversas actividades y detectar esas variaciones. Estudios previos indicaron que la información de la posición aumenta la precisión del reconocimiento de actividades [Coskun et al., 2015]. Por lo tanto, se han propuesto enfoques alternativos para desarrollar múltiples modelos capaces de clasificar la actividad física en diferentes ubicaciones del sensor en el cuerpo, [Mannini et al., 2015, Fujinami and Kouchi, 2012, Durmaz Incel, 2015, Kunze and Lukowicz, 2008].

Dado que la mayoría de los métodos dependen de la ubicación del sensor en el cuerpo, el modelo de predicción o los parámetros varían según cada posición. Al identificar correctamente la posición del sensor, es posible desarrollar modelos específicos para cada ubicación. Esto permite una mejor calibración y adaptación del modelo a las características únicas de los datos obtenidos desde esa posición, aumentando así la precisión del reconocimiento de actividades. La misma actividad puede ser confundida con otra si se analiza desde diferentes posiciones del cuerpo. Por ejemplo, la actividad de caminar puede tener un patrón distinto si el sensor está en la muñeca en comparación con pecho o cadera, Figura 2.14.

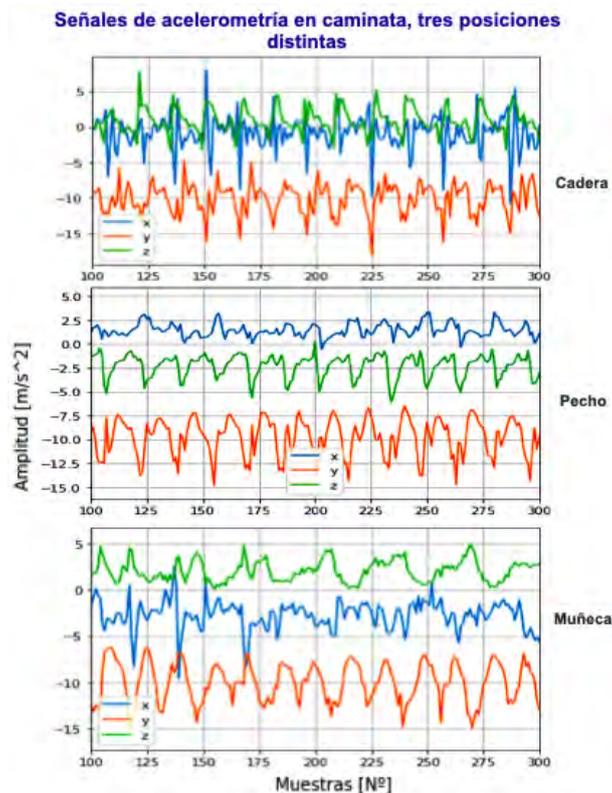


Figura 2.14: Señales de acelerometría en diferentes posiciones

Detectar automáticamente la posición del sensor permite que los sistemas HAR funcionen de manera más fluida y sin intervención del usuario. Esto es esencial para aplicaciones en tiempo real, donde la comodidad y la usabilidad son cruciales. Dotando al usuario de más libertad de elección, lo que aumenta la probabilidad de éxito del sistema HAR y mejora el rendimiento

---

de los modelos [Kurban and Yildirim, 2019, Clevenger et al., 2020b, Bao and Intille, 2004].

Como se ha mencionado uno de los sensores más efectivos en aplicaciones de sistemas HAR es el acelerómetro. Dado los avances en la tecnología de circuitos integrados, puede llevarse de forma continua durante días o incluso semanas, lo que presenta una solución práctica a las limitaciones relacionadas con el consumo de energía y la comodidad del usuario. Los sistemas HAR que utilizan acelerómetros usan estos sensores para detectar y clasificar actividades humanas mediante el análisis de patrones de movimiento. Los acelerómetros miden directamente los movimientos del cuerpo humano, respondiendo a factores como la frecuencia, la intensidad y la inclinación [Garnotel et al., 2019]. Esto permite un monitoreo preciso de las actividades físicas en tiempo real.

Considerando la captura de las aceleraciones en los planos sagital, coronal y transversal, el acelerómetro puede capturar información de manera precisa desde cualquier plano de movimiento del cuerpo humano, ofreciendo una perspectiva completa y detallada. Como se ilustra en la Figura 2.15.

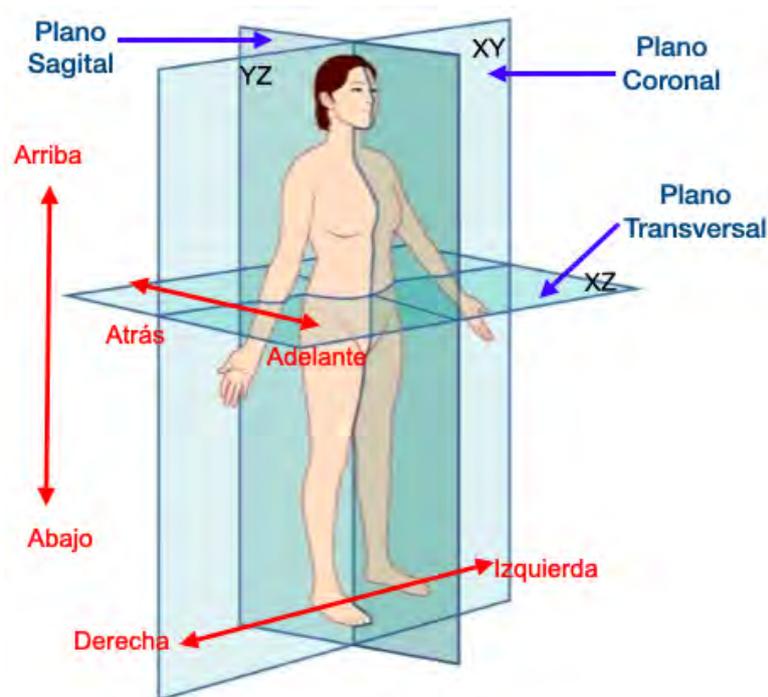


Figura 2.15: Planos de movimiento

Análisis como los presentados en [Altini et al., 2014] muestran cómo la capacidad de clasificación y el rendimiento del modelo se ven directamente afectados por el número y la combinación de posiciones donde se porta el acelerómetro. Portar varios acelerómetros simultáneamente en sistemas HAR no siempre se traduce en mejores resultados, ya que esto puede resultar en consecuencias negativas como elevación de costos, reducción de la comodidad y la generación de conjuntos de datos más grandes y complejos [Bao and Intille, 2004].

Por lo tanto, determinar la posición del acelerómetro facilita la adaptación de los sistemas

---

HAR a diferentes configuraciones corporales. Una contribución significativa de este trabajo es que la detección de la posición del sensor permite el desarrollo de modelos de aprendizaje profundo específicos que mejoran la precisión y la fiabilidad de la clasificación.

### 2.5.2. Importancia de la Detección de Posición del Transductor

La detección precisa de la posición del sensor en el cuerpo es un factor clave para mejorar la precisión y la fiabilidad de los sistemas HAR. El lugar donde se coloca el sensor influye de manera significativa en los patrones de aceleración registrados, lo que puede alterar el desempeño del modelo de clasificación. De hecho, diversos estudios han demostrado que la información sobre la ubicación del sensor es esencial para una correcta interpretación de los datos y para la creación de modelos adaptativos que sean sensibles a las variaciones individuales de cada usuario [Coskun et al., 2015, Mannini et al., 2015].

Los sistemas HAR dependen de la capacidad de identificar y diferenciar patrones específicos de movimiento según la ubicación del sensor en el cuerpo. Como los acelerómetros, que son los sensores más utilizados en este tipo de aplicaciones, capturan información sobre la aceleración del cuerpo humano en diferentes planos de movimiento. Sin embargo, la misma actividad realizada puede generar señales completamente diferentes. Las características de la aceleración serán distintas dependiendo de la posición del sensor [Fujinami and Kouchi, 2012, Durmaz Incel, 2015]. Esta variabilidad se debe a la dinámica del cuerpo humano y la forma en que las distintas partes del cuerpo responden al movimiento, lo que hace fundamental la identificación precisa de la ubicación del sensor.

Un enfoque comúnmente utilizado para abordar este reto es el desarrollo de modelos de clasificación específicos para cada ubicación del sensor. Al identificar la posición del sensor en tiempo real, los sistemas HAR pueden seleccionar el modelo más adecuado para procesar los datos de aceleración obtenidos desde esa ubicación particular, lo que permite una clasificación más precisa. Además, esto facilita la calibración del sistema, ajustando los parámetros y los algoritmos de acuerdo con las características específicas de cada ubicación del sensor. Esta adaptabilidad resulta crucial en aplicaciones donde el usuario puede llevar el sensor en diferentes partes del cuerpo o cambiar la ubicación del dispositivo a lo largo del tiempo, como ocurre en el caso de los dispositivos portátiles de monitoreo de salud o fitness [Kunze and Lukowicz, 2008].

Sin embargo, la implementación de sistemas que detecten la posición del sensor presenta ciertos desafíos, como la necesidad de contar con algoritmos de aprendizaje automático que sean lo suficientemente robustos para manejar las variaciones en los datos. También es necesario considerar que el uso de múltiples sensores en distintas ubicaciones puede generar conjuntos de datos más complejos, lo que puede implicar una mayor carga computacional y un aumento en el tamaño de los datos a procesar [Bao and Intille, 2004]. A pesar de estas limitaciones, la detección precisa de la posición sigue siendo un factor crítico para mejorar el rendimiento global de los sistemas de HAR.

Por lo tanto, la detección de la posición del sensor juega un papel crucial en la mejora de los sistemas de clasificación de actividades humanas. Al identificar la ubicación del sensor, es posible personalizar y optimizar los modelos de clasificación, lo que lleva a una mayor preci-

---

sión y confiabilidad. Además, este enfoque permite que los sistemas HAR sean más flexibles y adaptables a las necesidades y preferencias de los usuarios, contribuyendo a su éxito en aplicaciones reales. La detección automática de la posición no solo mejora la experiencia del usuario, sino que también abre nuevas posibilidades para el desarrollo de soluciones más avanzadas y personalizadas en el ámbito del monitoreo de la actividad física y la salud.

# Capítulo 3

## Propuesta Metodológica para la Clasificación de Actividades Humanas

La arquitectura general del sistema HAR utilizado en este trabajo se muestra en la Figura 3.1. El esquema propuesto abarca el preprocesamiento y la transformación de datos, así como el uso de un modelo de clasificador RF para detectar la posición del sensor en el cuerpo; por último, la clasificación de actividades se realiza utilizando modelos redes neuronales tipo RNaf, seleccionados en función de la posición detectada. Por lo tanto, se han desarrollado tres modelos diferentes para calcular HAR. Dado que los datos de aceleración en bruto de los sensores portátiles experimentan variaciones considerables a lo largo del tiempo, clasificar estos datos basándose únicamente en información de un solo punto se vuelve imposible [Lara and Labrador, 2012]. Por lo tanto, los métodos HAR se basan en una serie de datos recopilados a lo largo de un intervalo de tiempo determinado [Sztylek and Stuckenschmidt, 2016]; en este trabajo, se seleccionan períodos de 20s para realizar la tarea de clasificación.

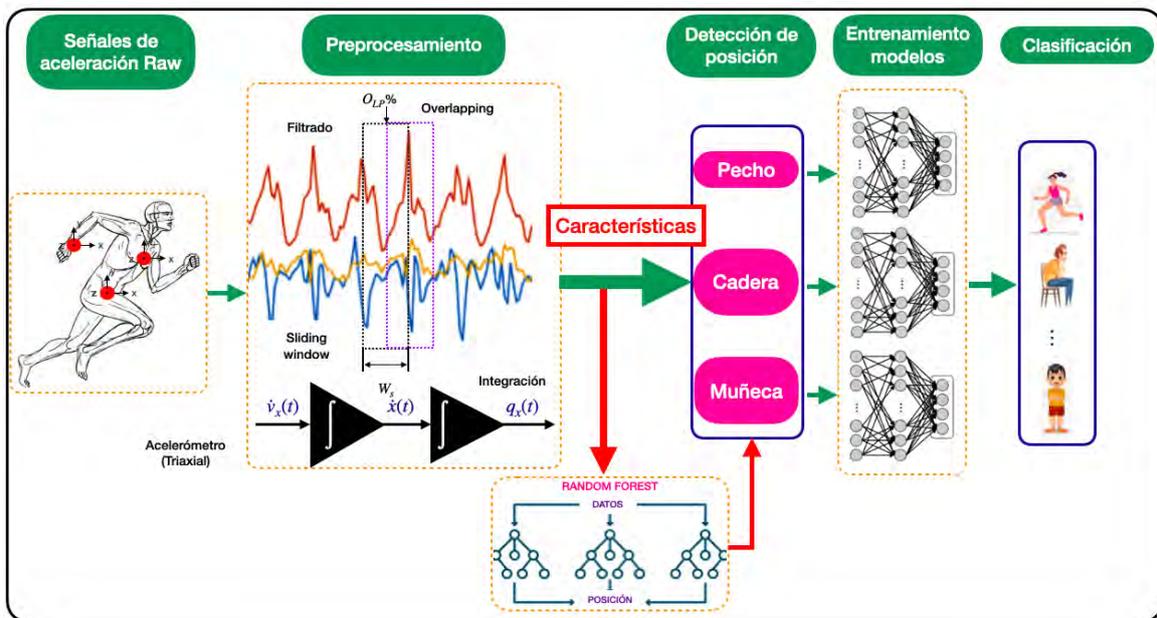


Figura 3.1: Estructura del esquema propuesto

---

### 3.1. Adquisición de Datos

El procedimiento de adquisición de señales es una etapa fundamental en la recopilación de datos para el desarrollo y validación de modelos de detección de posición y clasificación de actividades. En este trabajo, se implementó el uso de acelerómetros para registrar las aceleraciones experimentadas por un grupo de participantes mientras realizaban un conjunto de actividades consideradas cotidianas. Este enfoque permite capturar de manera precisa y en tiempo real las dinámicas de movimiento asociadas a cada actividad.

Los acelerómetros, son dispositivos sensibles a las variaciones en la aceleración, se colocaron en diferentes posiciones del cuerpo de los participantes para obtener una visión integral de sus movimientos. Durante la etapa de adquisición, los participantes realizaron actividades específicas, como caminar, correr, sentarse, etc., lo que permitió la creación de un conjunto de datos diverso y representativo.

El principal objetivo de este procedimiento fue familiarizarse con los patrones de las señales de aceleración obtenidas al ejecutar las diferentes actividades físicas, lo que propició un mejor entendimiento del fenómeno estudiado y del análisis del impacto que generan las diversas condiciones de adquisición de datos en los resultados obtenidos. Además, se buscó generar un dataset que permitiera mostrar más de un escenario de validación de los modelos propuestos, tanto en la detección de posición del sensor como en la clasificación de actividades. Esto permite comprobar la robustez y la capacidad de generalización efectiva de los modelos en diferentes contextos.

#### 3.1.1. Dataset Generado ACTDATA

La difusión de conjuntos de datos ha impulsado significativamente la investigación en campos de interés como el reconocimiento y la clasificación de actividades. Estos conjuntos de datos, por lo general, se diseñan para adaptarse a escenarios específicos, jugando un papel fundamental que propicia el avance de la investigación y el desarrollo tecnológico.

Para fines de este trabajo, se generó el conjunto de datos ACTDATA, este conjunto de datos se distingue por contener exclusivamente señales de acelerometría, generadas a partir de la ejecución de 10 actividades físicas consideradas comunes. Estas fueron cuidadosamente recolectadas a través de tres acelerómetros posicionados estratégicamente en el pecho, la cadera y la muñeca derecha de un grupo de 11 participantes, que desempeñaron las actividades dentro de un laboratorio, sin restricciones sobre la forma en que debían ejecutarse, con la excepción de que el sujeto debía esforzarse al máximo al ejecutarlas.

Las señales fueron muestreadas a una frecuencia de 35 Hz, que de acuerdo a [Karantonis et al., 2006] en el contexto de la captura del movimiento del cuerpo humano, la mayoría de su energía, concretamente el 99 %, se concentra por debajo de los 15 Hz. Por lo tanto, de acuerdo al Teorema de Nyquist [Zahniser and Brenner, 1985], que establece que una condición necesaria para la reconstrucción, en el dominio temporal, de una señal adquirida: la frecuencia de muestreo debe ser al menos 2 veces mayor que la frecuencia mas alta de la señal que se quiere reconstruir.

---

De acuerdo a lo anterior, 35 Hz se considera suficiente para captar la actividad de este conjunto de actividades. Para este caso de estudio, la adquisición de señales se ejecutó considerando el marco de referencia que se muestra en la Figura 3.2.

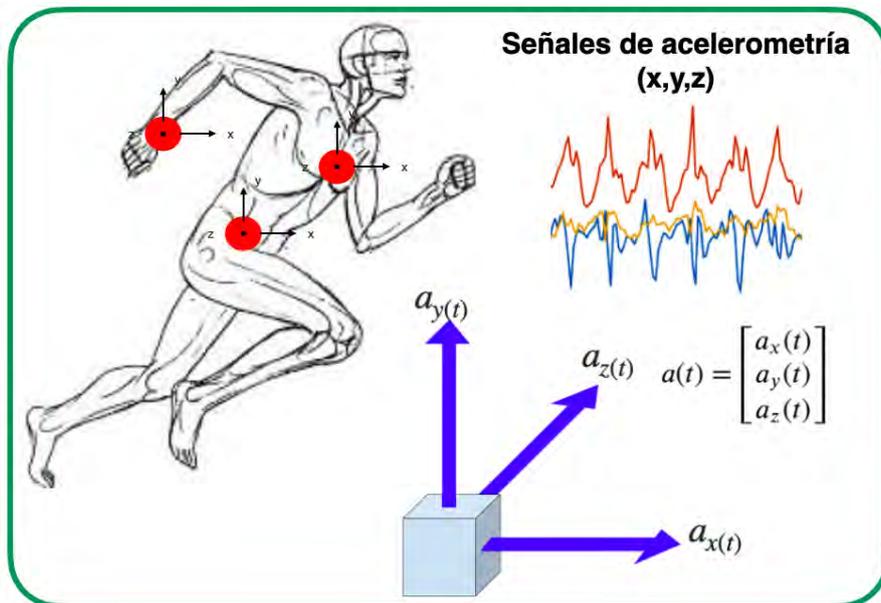


Figura 3.2: Marco de referencia ejes x,y,z

### 3.1.2. Conjunto de Actividades Propuestas

Se presenta el grupo de actividades ejecutadas por los participantes, así como su duración y las etiquetas asignadas a cada actividad. Esta información es esencial para la correcta organización y análisis de las señales adquiridas durante el registro. Las actividades seleccionadas abarcan una variedad de comportamientos cotidianos, lo que permite crear un conjunto de datos representativo que refleja las dinámicas de movimiento de personas en situaciones reales.

Cada actividad fue cuidadosamente etiquetada, facilitando la separación de las señales en función de la actividad y del sujeto. Este proceso de etiquetado es crucial, ya que permite la decodificación adecuada de las señales, asegurando que se puedan asignar correctamente a las categorías correspondientes. La separación de señales por actividad no solo simplifica el análisis posterior, sino que también es fundamental para el desarrollo de modelos precisos.

El conjunto consta de 10 actividades diferentes a la que se les ha asignado su respectiva etiqueta (Label), donde también se considera el uso de la clase Nula, que en el tratamiento del Dataset es un aspecto crucial que impacta significativamente la clasificación de actividades. Esta clase representa situaciones en las que no se está realizando ninguna de las actividades predefinidas o cuando los datos son irrelevantes o inconsistentes.

Durante la fase de validación, tener una clase Nula permite evaluar cómo el modelo maneja situaciones en las que no se deben generar predicciones, pues se permite al modelo distinguir entre momentos de inactividad y actividades reconocibles, mejorando así su capacidad para

---

manejar ambigüedades.

En la Tabla 3.1 se muestran los detalles del Dataset generado en este trabajo de tesis, considerando que la adquisición se realizó de manera simultánea en las tres posiciones propuestas.

Tabla 3.1: Actividades y etiquetas utilizadas en la base de datos (ACTDATA)

Label	Actividad	Duración
L0	Nula	1 min
L1	Parado	1 min
L2	Sentado y Relajado	1 min
L3	Acostado Boca Arriba	20x
L4	Elevación de Brazos	20x
L5	Dobla Cintura Adelante	20x
L6	Sentadilla	20x
L7	Saltar	30x
L8	Caminar	1 min
L9	Trotar	1 min
L10	Correr	1 min

*En la columna "Duración", Nx es el número de repeticiones de la actividad.*

Este conjunto de datos resulta adecuado para reflejar actividades cotidianas debido a la amplia variedad de partes del cuerpo involucradas en cada una de ellas. Por ejemplo, abarca desde acciones que implican la parte superior del cuerpo como la elevación frontal de los brazos hasta aquellas que se centran en la parte inferior como sentadillas. Además, aborda la diversidad en la intensidad de las acciones, como la comparación entre brincar y sentarse, así como la variabilidad en la velocidad de ejecución o dinamismo, representada por actividades que van desde correr hasta permanecer en reposo.

### 3.1.3. Participantes

Se realizaron pruebas de acelerometría a un grupo de personas sanas, estudiantes de entre (18 - 24) años, 7 hombres y 4 mujeres que han dado su autorización para portar los sensores y ser monitoreados. El conjunto de datos recopilados contiene grabaciones del movimiento corporal de los 11 voluntarios de perfil diverso, mientras desempeñan el conjunto de 10 actividades físicas descrito anteriormente, detalles sobre los participantes se muestra en la Tabla 3.2.

El nivel de actividad física se considera sedentaria en las personas que tienen actividad física nula, baja a las personas que tiene al menos 2 sesiones de 30 min de actividad física por semana, media a las personas que tienen al menos 3 sesiones y alta para personas que tienen más de 5 sesiones de actividad por semana.

### 3.1.4. Configuración Antropométrica de los Acelerómetros

Para la captura de señales se utilizaron tres módulos de acelerómetros modelo MPU6050, colocados en el pecho, la cadera y la muñeca de los participantes. La selección de la ubicación antropométrica para los tres módulos de adquisición es fundamental para garantizar la eficacia

Tabla 3.2: Características participantes (ACTDATA)

Participante	Edad	Altura (m)	Peso (kg)	IMC	Sexo	Nivel de AF
Sujeto 1	24	1.77	92	29.36	H	Sedentaria
Sujeto 2	19	1.52	55	23.80	M	Sedentaria
Sujeto 3	18	1.58	53	21.23	M	Sedentaria
Sujeto 4	18	1.56	59	24.24	M	Baja
Sujeto 5	18	1.62	51	19.43	M	Media
Sujeto 6	22	1.80	77	23.76	H	Media
Sujeto 7	20	1.76	76	24.53	H	Baja
Sujeto 8	19	1.80	86	26.54	H	Alta
Sujeto 9	19	1.68	90	31.88	H	Sedentaria
Sujeto 10	19	1.85	100	29.21	H	Media
Sujeto 11	19	1.79	68	21.22	H	Media

en la captura de datos de movimiento [Haskell and Kiernan, 2000], en este caso se seleccionaron, Figura 3.3.

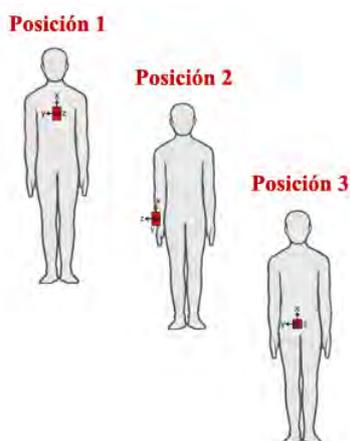


Figura 3.3: Ubicación antropométrica acelerómetros

Cada una de estas posiciones fue elegida cuidadosamente, considerando factores biomecánicos, funcionales y prácticos, que son descritos a continuación:

- El módulo colocado en el pecho proporciona una referencia central y estable para el movimiento del torso. Esta ubicación es crucial porque el torso es el centro de gravedad del cuerpo y su movimiento influye en las dinámicas de las extremidades. Además, al registrar datos desde esta posición, se pueden captar patrones de movimiento relacionados con la postura y la inclinación del cuerpo, lo que es especialmente útil para actividades que implican movimientos de todo el cuerpo, como caminar o correr.
- La cadera es otra ubicación clave, ya que es el punto de anclaje de las piernas y está involucrada en la mayoría de los movimientos dinámicos. Al colocar un módulo en la cadera, se pueden registrar de manera efectiva las fuerzas generadas durante actividades

---

como el levantamiento, la marcha y las actividades de balanceo. Esta ubicación también permite un seguimiento más cercano de la mecánica de la marcha, lo que es esencial para estudios relacionados con la movilidad y la rehabilitación.

- La elección de la muñeca como posición de adquisición permite capturar movimientos específicos de las extremidades superiores y su interacción con el entorno. Dado que muchas actividades cotidianas involucran el uso de las manos, un módulo en la muñeca proporciona datos valiosos sobre la dinámica de la manipulación y el alcance. Además, esta ubicación permite registrar movimientos relacionados con la coordinación, aspectos que son importantes para diferenciar eficientemente ciertas actividades.

La elección de estas tres ubicaciones maximiza la cobertura del cuerpo en términos de movimiento. Al combinar la información de diferentes segmentos del cuerpo, se obtienen insights más completos sobre la mecánica del movimiento y las interacciones entre distintas partes del cuerpo. La Figura 3.4, muestra como se incorporan y fijan los módulos, utilizando bandas elásticas que fueron atadas al cuerpo de cada uno de los participantes.



Figura 3.4: Distribución antropométrica de los módulos

---

### 3.1.5. Módulo de Adquisición de Señales

Se desarrollaron tres módulos de adquisición, cada uno diseñado para ubicarse en posiciones específicas del cuerpo: pecho, cadera y muñeca. Cada módulo sigue la configuración detallada en el esquema de la Figura 3.5, lo que facilita la comunicación inalámbrica. Esta característica posibilita la libertad de movimiento al realizar las actividades, proporcionando flexibilidad y comodidad durante la ejecución de las mismas.

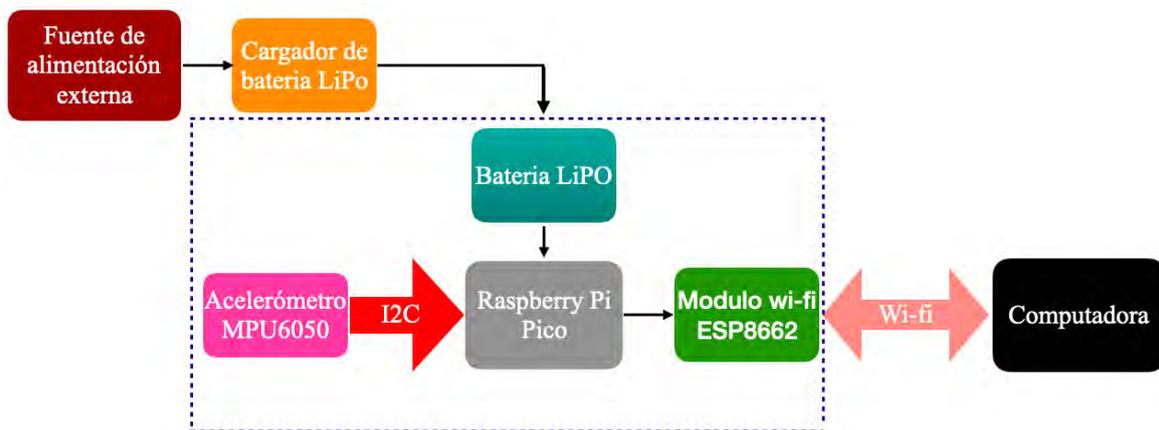


Figura 3.5: Estructura módulo de adquisición de señales

Cada módulo está alimentado por una batería LiPo, lo que garantiza una fuente de energía confiable y duradera para el sistema de adquisición. Internamente, cada módulo cuenta con un acelerómetro MPU6050, que mide la aceleración en tres ejes (x, y, z). La comunicación entre el acelerómetro y la Raspberry Pi Pico se establece a través del protocolo I2C, lo que facilita la conexión y permite la transmisión eficiente de datos. Además, cada módulo está vinculado a un módulo WiFi ESP-6082 que se conecta a una computadora que actúa como servidor. Esta configuración permite la transmisión inalámbrica de los datos recopilados, eliminando la necesidad de cables y aumentando la movilidad del usuario.

Durante la construcción de cada módulo, se llevó a cabo un proceso de soldadura para unir los componentes, que fueron cuidadosamente ubicados dentro de una caja de 4x4x2 cm, como se muestra en la Figura 3.6.



Figura 3.6: Estructura interna módulo de adquisición

Además, se incorporó un interruptor on/off en cada módulo, proporcionando la capacidad de activar y desactivar la lectura de datos según fuera necesario. En conjunto, estos módulos de adquisición están diseñados para facilitar un registro efectivo y preciso de las señales, contribuyendo al éxito del estudio y a la calidad de los datos recolectados.

### 3.1.6. Protocolo de Adquisición (TCP)

Se realizó la adquisición de las señales de acelerometría basadas en el protocolo de comunicación TCP, considerando una estructura cliente-servidor, como se muestra en la Figura 3.7. Este enfoque permite una comunicación eficiente y confiable entre los módulos de adquisición y la computadora designada como servidor.

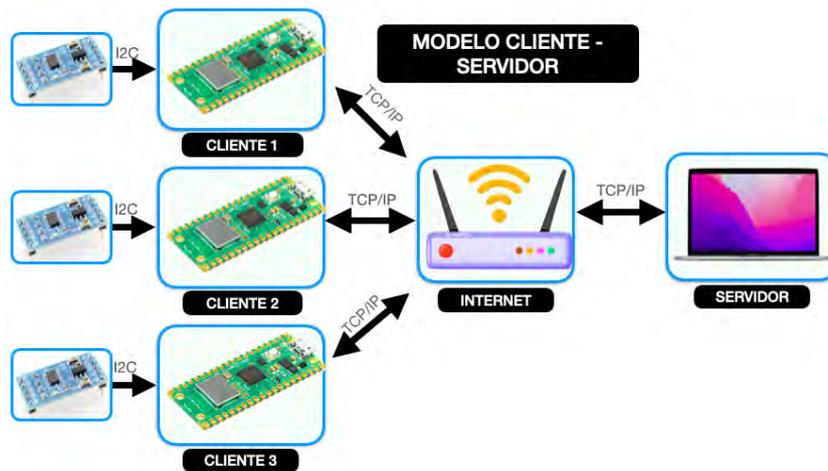


Figura 3.7: Protocolo de adquisición de datos

La arquitectura cliente-servidor facilita la captura y visualización de las aceleraciones en tiempo real a través de una aplicación desarrollada en Python. Esta aplicación no solo permite monitorear los datos a medida que se registran, sino que también ofrece herramientas para configurar los módulos de adquisición, ajustar parámetros de muestreo y gestionar la conexión entre el cliente y el servidor, la interfaz realizada se muestra en la Figura 3.8.

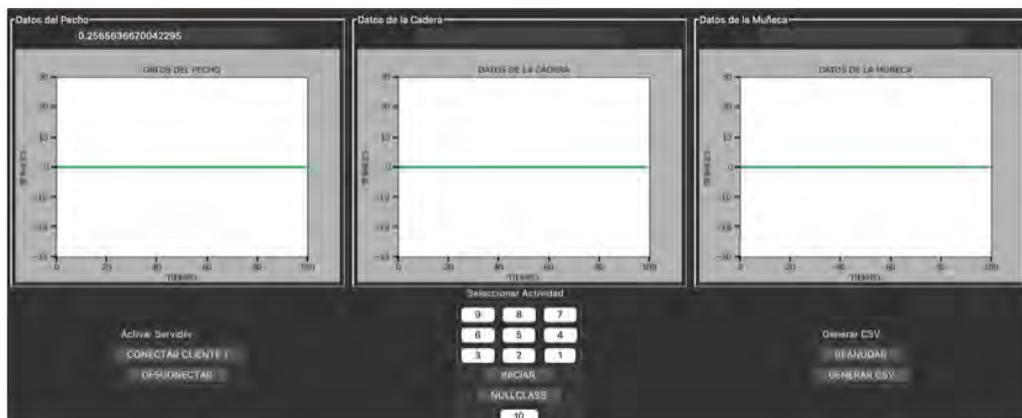


Figura 3.8: Aplicación desarrollada en Python

---

Los datos recolectados durante las sesiones de adquisición son almacenados en un archivo con extensión .csv, lo que asegura que se mantenga un formato estándar y fácilmente accesible para su posterior análisis y tratamiento. Este formato permite una manipulación sencilla de los datos utilizando diversas herramientas de análisis de datos y programación, permitiendo una posterior limpieza, segmentación y análisis de los datos. Esto es crucial para la preparación de los datos antes de aplicar algoritmos de clasificación.

Por último, es importante enfatizar que la capacidad de comunicación inalámbrica es una característica clave que proporciona libertad de movimiento durante la ejecución de las actividades. Esto no solo mejora la comodidad del usuario, sino que también permite una mayor flexibilidad en la recopilación de datos, ya que los participantes pueden moverse libremente sin estar restringidos por conexiones físicas.

### **3.2. Procesamiento de Señales**

El preprocesamiento de señales es una etapa fundamental los sistemas HAR y en la detección de la posición de sensores. Esta fase se encarga de transformar los datos en bruto, provenientes de dispositivos como acelerómetros en formatos más útiles y significativos para el análisis posterior. La importancia de un preprocesamiento adecuado radica en su capacidad para mejorar la calidad de los datos, eliminar ruido y facilitar la extracción de características relevantes, lo que, a su vez, influye directamente en el rendimiento de los algoritmos.

Un aspecto adicional importante en el preprocesamiento es el etiquetado de datos, que organiza el conjunto de datos según el número de participantes o las actividades realizadas. Este etiquetado es crucial para garantizar que los modelos aprendan de manera efectiva y generalicen bien nuevas situaciones, la idea conceptual ejecutada durante este proceso, se ilustra en la Figura 3.9. Una técnica común utilizada en esta fase es la codificación one-hot, que convierte las etiquetas categóricas en vectores binarios. Esta representación permite que los algoritmos de machine learning interpreten correctamente las diferentes clases de actividades.

Este enfoque de preprocesamiento propicia que los conjuntos de datos completos puedan discriminar entre información útil, adecuando el dataset y descartando señales que no corresponden a las actividades de interés. Al centrarse en los datos relevantes, se mejora la calidad de los modelos de clasificación y se aumenta su capacidad para generalizar en situaciones del mundo real.

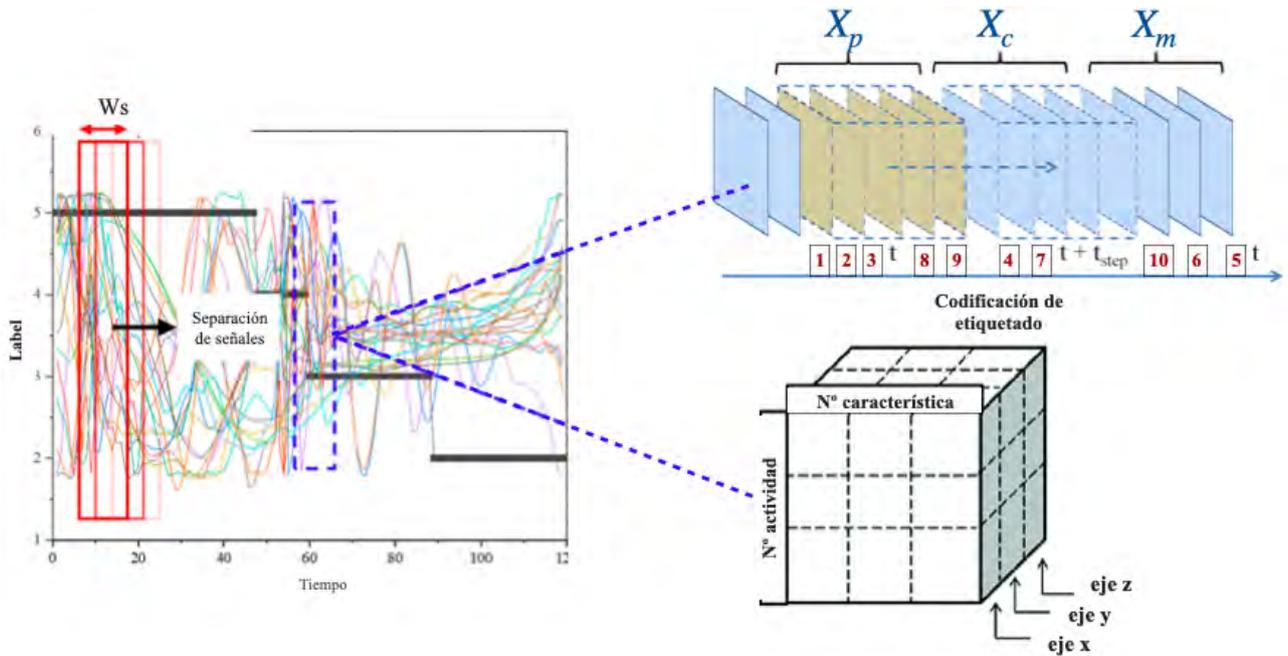


Figura 3.9: Procesamiento base de datos

### 3.2.1. Filtrado de Señales

El filtrado de las señales de acelerometría es un paso crucial en el procesamiento de datos, ya que permite mejorar la calidad de las señales registradas y eliminar el ruido no deseado que puede afectar los análisis posteriores. En este estudio, se aplicó un filtro Butterworth pasabajo, que es conocido por su capacidad para proporcionar una respuesta suave y uniforme en la banda de paso, lo que resulta en un filtrado efectivo de las señales.

El filtro Butterworth pasabajo se diseñó para permitir el paso de frecuencias por debajo de un umbral específico mientras atenúa las frecuencias más altas, así mismo elimina el ruido y las interferencias que pueden comprometer la integridad de los datos.

Después de realizar un análisis de correspondiente a las señales de acelerometría, utilizando la transformada discreta de Fourier (DFT) que se utiliza para calcular el espectro de frecuencias de una señal  $x$  de datos discretos, matemáticamente expresado como:

$$X(f) = \sum_{i=0}^{N-1} x_i e^{-j2\pi fi/N} \quad (3.1)$$

La ecuación puede reescribirse como:

$$X(f) = \sum_{i=0}^{N-1} a_i + jb_i \quad (3.2)$$

Considerando:  $a_i = x_i \cos(\frac{2\pi fi}{N})$ ,  $b_i = x_i \sen(\frac{2\pi fi}{N})$ .

---

Donde:  $x(f)$  : f-ésima componente de salida del espectro de frecuencias,  $N$  : número de muestras de la secuencia de entrada,  $f_i$  : coeficiente f-ésimo de Fourier en el dominio de la frecuencia,  $x_i$  : secuencia de entrada de muestras,  $i$  : es el índice en el dominio del tiempo de las muestras de entrada.

Análisis del cual se observó que las frecuencias fundamentales de las actividades más dinámicas, como correr o saltar, se encuentran por debajo de los 8 Hz. Así mismo, se considera lo propuesto en previas investigaciones, como en [Fridolfsson et al., 2019] donde menciona que un filtro paso-bajo ajustado a una (frecuencia de corte de 10 Hz) permite capturar toda la aceleración relevante para la actividad física a la vez que se minimiza el impacto del ruido. Lo que respalda la decisión de utilizar un filtro pasa-bajo con una frecuencia de corte de 10 Hz.

Un filtro pasabajo de tipo Butterworth se caracteriza por su respuesta en frecuencia suave y se puede definir en términos de su función de transferencia. Para un filtro Butterworth de orden  $n$  con una frecuencia de corte  $f_c$ , la función de transferencia  $H(s)$  en el dominio de Laplace se puede expresar como:

$$H(s) = \frac{1}{1 + \left(\frac{s}{\omega_c}\right)^{2n}} \quad (3.3)$$

donde:  $s$  es la variable compleja de Laplace, la frecuencia angular de corte es  $\omega_c = 2\pi f_c$ .

Para el caso en que  $f_c = 10\text{Hz}$ , tenemos:

$$\omega_c = 2\pi \cdot 10 \approx 62.83 \text{ rad/s} \quad (3.4)$$

Para un filtro de primer orden ( $n = 1$ ), la función de transferencia se simplifica a:

$$H(s) = \frac{1}{1 + \frac{s}{\omega_c}} \quad (3.5)$$

Al implementar un filtro digital, se suele usar la transformación bilineal para discretizar el filtro. La función de transferencia discreta se puede expresar como:

$$H(z) = \frac{b_0}{1 - a_1 z^{-1}} \quad (3.6)$$

donde  $b_0$  y  $a_1$  son coeficientes que dependen de la frecuencia de muestreo  $f_s$  y de la frecuencia de corte  $\omega_c$ .

Los coeficientes  $b_0$  y  $a_1$  se pueden calcular utilizando las siguientes fórmulas:

$$b_0 = \frac{\omega_c}{\omega_c + f_s} \quad (3.7)$$

$$a_1 = \frac{f_s - \omega_c}{f_s + \omega_c} \quad (3.8)$$

Para este caso de estudio en específico, se ha considerado una frecuencia de muestreo  $f_s = 35$  Hz y una frecuencia de corte  $f_c = 10$  Hz, por lo tanto:

- Cálculo de  $\omega_c$ :

$$\omega_c = 2\pi \cdot 10 \approx 62.83 \text{ rad/s} \quad (3.9)$$

- Cálculo del coeficiente  $b_0$ :

$$b_0 = \frac{62.83}{62.83 + 35} \approx \frac{62.83}{97.83} \approx 0.641 \quad (3.10)$$

- Cálculo del coeficiente  $a_1$ :

$$a_1 = \frac{35 - 10}{35 + 10} = \frac{25}{45} \approx 0.556 \quad (3.11)$$

Estos coeficientes se utilizaron para implementar el filtro digital en la fase de procesamiento de señales. En la Figura 3.10 se puede ver un ejemplo del resultado obtenido al aplicar el filtro a las señales de acelerometría provenientes de la muñeca.

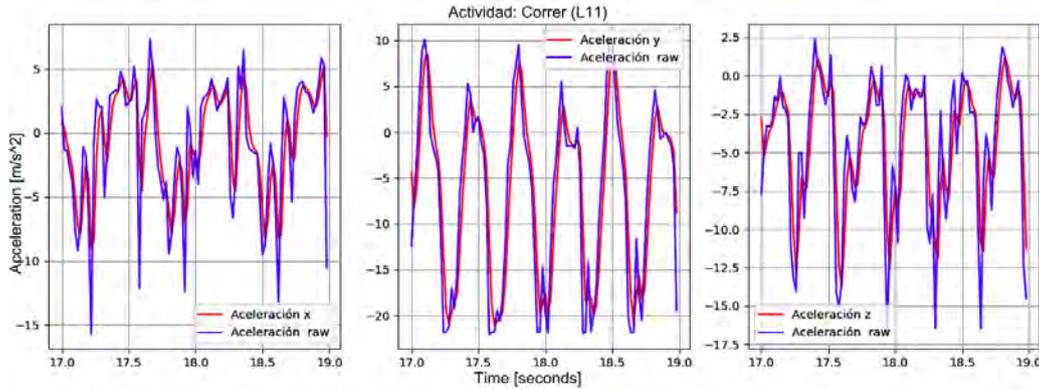


Figura 3.10: Aplicación del filtro pasa-bajo

### 3.2.2. Enventanado de Señales

Durante esta etapa, las señales se dividen en segmentos de tiempo específicos, lo que facilita el análisis de patrones temporales y la identificación de eventos significativos. Se realiza el preprocesamiento de los datos, tomando en cuenta ventanas de tiempo de 2 s y un overlapping del 50%, considerando una frecuencia de muestreo de 35 Hz, Figura 3.11, posteriormente se realiza la extracción de características, donde se calculan métricas como la media, la varianza y otras características propuestas que ayudan a describir el movimiento, las cuales contienen la información necesaria para entrenar los modelos.

De acuerdo a lo anterior y considerando lo detallado en la Sección 2.2.2, el número de ventanas que se obtienen en cada periodo se determina como:

$$K = \left\lfloor \frac{N - M}{R} \right\rfloor + 1 \quad (3.12)$$

$$K = \left\lfloor \frac{700 - 70}{50} \right\rfloor + 1 = 14$$

donde:  $K$  es el número de ventanas,  $N$  longitud de señal (nº muestras),  $M$  tamaño de la ventana (nº muestras),  $R$  factor de overlap (%).

El número de muestras de overlap se determina como:

$$X_{OL} = S_R * W_S \left\lceil \frac{O_{LP}}{100} \right\rceil \quad (3.13)$$

$$X_{OL} = 35 * 2 \left\lceil \frac{50}{100} \right\rceil = 35$$

donde:  $X_{OL}$  número total de muestras overlap,  $S_R$  frecuencia de muestreo (Hz)  $W_S$  tamaño de ventana (s),  $O_{LP}$  porcentaje de overlap.

El enfoque de sliding window es el método predominante utilizado en la etapa de segmentación del HAR. En este método, las señales de los sensores se dividen en ventanas de un tamaño fijo. Cuando las ventanas adyacentes se superponen, se denomina ventana deslizante superpuesta. En este trabajo, la segmentación de datos se lleva a cabo utilizando la técnica de ventana deslizante, considerando un tamaño de ventana de 2 s y una superposición del 50 %, como se muestra anteriormente.

Los resultados obtenidos anteriormente son representados gráficamente en la Figura 3.11. En este contexto, el segmentado de señales se lleva a cabo en las diferentes representaciones de aceleración, velocidad y posición, lo que permite una preparación eficaz de los datos para la extracción de características.

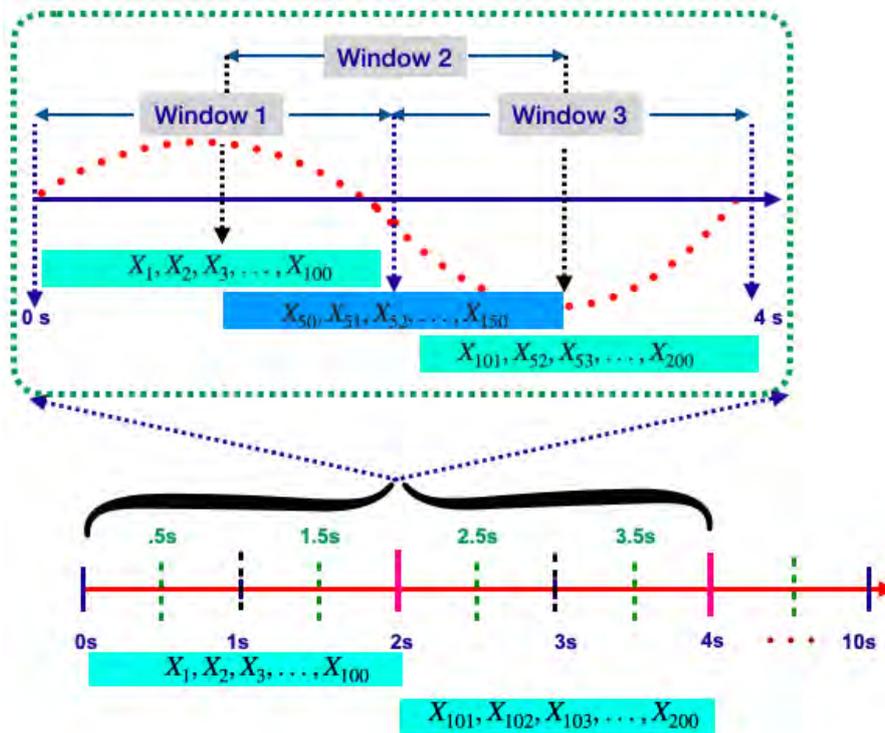


Figura 3.11: Enventanado y superposición de señales de aceleración, velocidad y posición

### 3.2.3. Conversión de Aceleración a Posición

Cada ventana de tiempo se transforma en un vector de características, que es la entrada en los modelos de detección de posición y clasificación de actividades. En particular, nuestra metodología consiste en transformar las señales de acelerometría en diferentes tipos de representaciones, como velocidad y posición, a partir de las cuales se extraen las características. Por lo tanto, para llevar a cabo este proceso de transformación, se realiza inicialmente una doble integración utilizando el método de Euler en las señales de aceleración triaxiales, obteniendo señales de posición a partir de las aceleraciones capturadas por el acelerómetro, como se muestra en la Figura 3.12

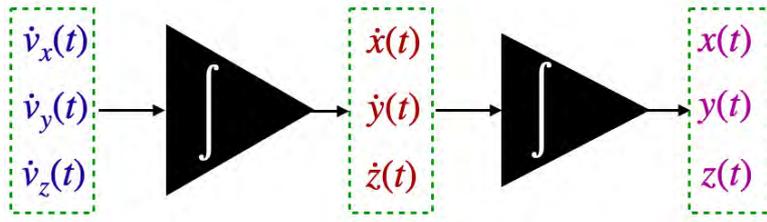


Figura 3.12: Integración de señales de aceleración

Por lo tanto, la cinemática de la posición, velocidad y aceleración se puede expresar para cada componente de la siguiente manera:

- Componente eje X, donde  $a_x(t)$ ,  $v_x(t)$ ,  $x(t)$  son las aceleraciones, velocidades y posiciones instantáneas respectivamente:

$$\Sigma_{Kx} : \begin{cases} \dot{v}_x(t) = a_x(t) \\ \dot{x}(t) = v_x(t) \\ q_x(t) = [v_x(t), x(t)]^T \end{cases} \quad (3.14)$$

- Componente eje Y, donde  $a_y(t)$ ,  $v_y(t)$ ,  $y(t)$  son las aceleraciones, velocidades y posiciones instantáneas respectivamente:

$$\Sigma_{Ky} : \begin{cases} \dot{v}_y(t) = a_y(t) \\ \dot{y}(t) = v_y(t) \\ q_y(t) = [v_y(t), y(t)]^T \end{cases} \quad (3.15)$$

- Componente eje Z, donde  $a_z(t)$ ,  $v_z(t)$ ,  $z(t)$  son las aceleraciones, velocidades y posiciones instantáneas respectivamente:

$$\Sigma_{Kz} : \begin{cases} \dot{v}_z(t) = a_z(t) \\ \dot{z}(t) = v_z(t) \\ q_z(t) = [v_z(t), z(t)]^T \end{cases} \quad (3.16)$$

Utilizando el método de doble integración de Euler en cada uno de las componentes de aceleración y considerando las siguientes condiciones iniciales:  $x(t_1)$ ,  $v_x(t_1)$ ,  $y(t_1)$ ,  $v_y(t_1)$ ,  $z(t_1)$ ,  $v_z(t_1) = 0$ , se expresa matemáticamente a continuación:

- Componente eje X:

$$v_x(t_{k+1}) = v_x(t_k) + \frac{1}{w_s} a_x(t_k) \quad (3.17)$$

$$x(t_{k+1}) = x(t_k) + \frac{1}{w_s} v_x(t_k); \quad k = 0, 2, \dots w_s \quad (3.18)$$

- Componente eje Y:

$$v_y(t_{k+1}) = v_y(t_k) + \frac{1}{w_s} a_y(t_k) \quad (3.19)$$

$$y(t_{k+1}) = y(t_k) + \frac{1}{w_s} v_y(t_k); \quad k = 0, 2, \dots w_s \quad (3.20)$$

- Componente eje Z:

$$v_z(t_{k+1}) = v_z(t_k) + \frac{1}{w_s} a_z(t_k) \quad (3.21)$$

$$z(t_{k+1}) = z(t_k) + \frac{1}{w_s} v_z(t_k); \quad k = 0, 2, \dots w_s \quad (3.22)$$

donde  $w_s$  es el tamaño de la ventana.

Una vez que se han obtenido las posiciones, velocidades y aceleraciones en los ejes (x, y, z) en cada ventana, como se muestra en la Figura 3.13, el cual corresponde a un ejemplo de la actividad correr, del acelerómetro posicionado en el pecho, posteriormente se lleva a cabo la extracción de características.

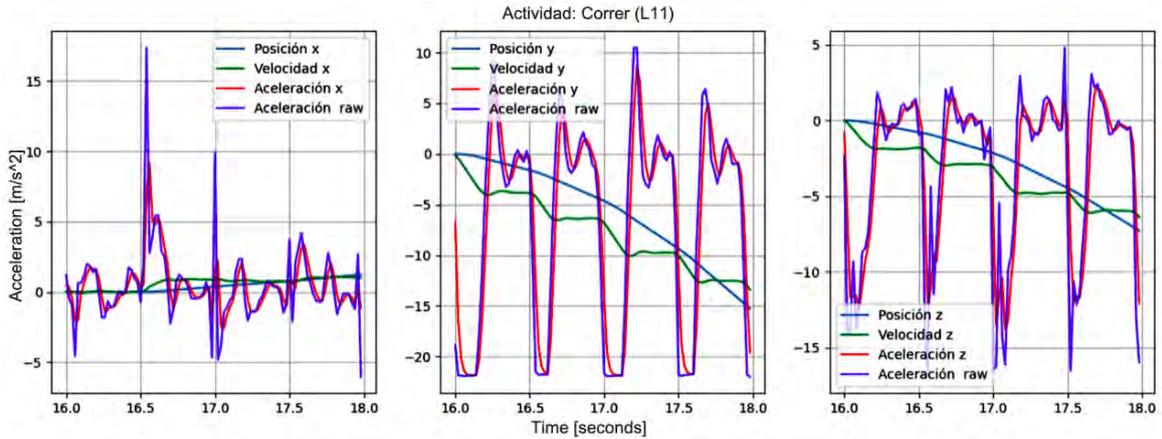


Figura 3.13: Señales de aceleración, velocidad y posición en x,y,z

### 3.3. Propuesta de la Nueva Característica

En el ámbito del HAR, la extracción de características relevantes es crucial para mejorar la precisión de los modelos de clasificación. En el enfoque abordado en este tema de tesis la característica propuesta, que es derivada del radio de curvatura, ofrece una representación geométrica de los patrones de movimiento. Esto se basa en la idea de que los movimientos humanos

pueden ser representados como trayectorias en el espacio, donde la curvatura de estas trayectorias proporciona información valiosa sobre la dinámica del movimiento.

El radio de curvatura se calcula analizando la forma de la trayectoria en diferentes planos de movimiento, lo que permite capturar variaciones sutiles en la actividad. Al considerar tanto el plano coronal, el plano sagital como el plano transversal, esta característica se adapta a una amplia gama de movimientos, desde caminatas y giros hasta actividades más complejas.

La inclusión del radio de curvatura en algoritmos de clasificación aporta varias ventajas. Primero, mejora la discriminación entre diferentes tipos de actividades al ofrecer una dimensión adicional que encapsula la complejidad del movimiento. Además, ayuda a reducir la sobrecarga de información al enfocarse en características que realmente reflejan el comportamiento del usuario, lo que puede resultar en modelos más eficientes y precisos.

Por lo tanto, el radio de curvatura no solo enriquece el conjunto de características disponibles, sino que también optimiza el rendimiento de los algoritmos de clasificación, contribuyendo a una mejor comprensión y reconocimiento de las actividades humanas.

### 3.3.1. Cálculo del Radio de Curvatura Plano Coronal

Se realiza la estimación de la posición cartesiana de un punto equidistante a un grupo de puntos (Radio de Curvatura), considerando la ecuación de la circunferencia, tomando en cuenta inicialmente el plano coronal, que corresponde a los ejes  $(x, y)$  como se observa en la Figura 3.14.

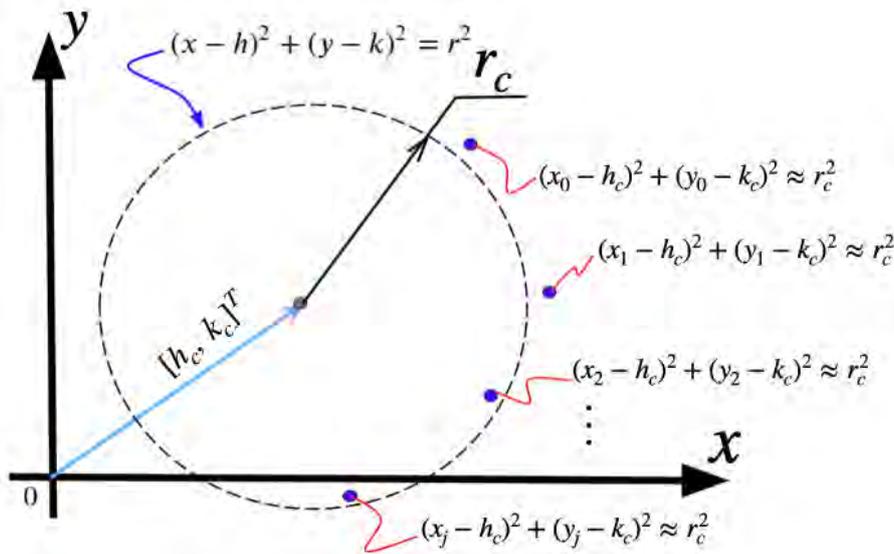


Figura 3.14: Gráfica del punto  $[h_c, k_c]^T$  y el RC, plano coronal

Se desea calcular un punto cuya coordenada o vector de posición se denota por el vector  $[h_c, k_c]^T$ , dicho punto se encuentra aproximadamente equidistante al número de puntos que contiene el tamaño de ventana seleccionada ( $w_s$ ), considerando  $[x_0, y_0]^T, \dots, [x_j, y_j]^T$  a una distancia

$r$ , es decir:

$$(x_j - h_c)^2 + (y_j - k_c)^2 = r_c^2, \quad j = 0, 1, \dots, w_s; \quad (3.23)$$

Al resolver el sistema de ecuaciones se obtiene las coordenadas del punto  $[h_c, k_c]^T$  (centro del círculo resultante). Como se muestra a continuación:

Para solucionar el punto  $[h_c, k_c]^T$ , es necesario reexpresar estas ecuaciones en notación vectorial, nótese que se pueden expresar como sigue:

$$[x_j - h_c, \quad y_j - k_c] \begin{bmatrix} x_j - h_c \\ y_j - k_c \end{bmatrix} \cong r_c^2, \quad j = 0, 1, \dots, w_s; \quad (3.24)$$

como:

$$\begin{bmatrix} x_j - h_c \\ y_j - k_c \end{bmatrix} = \begin{bmatrix} x_j \\ y_j \end{bmatrix} - \begin{bmatrix} h_c \\ k_c \end{bmatrix} \quad (3.25)$$

entonces:

$$([x_j \quad y_j] - [h_c, \quad k_c]) \left( \begin{bmatrix} x_j \\ y_j \end{bmatrix} - \begin{bmatrix} h_c \\ k_c \end{bmatrix} \right) \cong r_c^2, \quad j = 0, 1, \dots, w_s; \quad (3.26)$$

las manipulaciones algebraicas generan lo siguiente:

$$[x_j \quad y_j] \begin{bmatrix} x_j \\ y_j \end{bmatrix} - [h_c \quad k_c] \begin{bmatrix} x_j \\ y_j \end{bmatrix} - [x_j \quad y_j] \begin{bmatrix} h_c \\ k_c \end{bmatrix} + [h_c \quad k_c] \begin{bmatrix} h_c \\ k_c \end{bmatrix} \cong r_c^2 \quad (3.27)$$

o bien:

$$[x_j \quad y_j] \begin{bmatrix} x_j \\ y_j \end{bmatrix} - 2 [x_j \quad y_j] \begin{bmatrix} h_c \\ k_c \end{bmatrix} \cong r_c^2 - [h_c \quad k_c] \begin{bmatrix} h_c \\ k_c \end{bmatrix} \quad (3.28)$$

si se define que:

$$p_j := \begin{bmatrix} x_j \\ y_j \end{bmatrix} \quad (3.29)$$

entonces:

$$p_j^T p_j - 2 p_j^T \begin{bmatrix} h_c \\ k_c \end{bmatrix} \cong r_c^2 - [h_c \quad k_c] \begin{bmatrix} h_c \\ k_c \end{bmatrix}, \quad j = 0, 1, \dots, w_s; \quad (3.30)$$

En resumen, se tiene un número de ecuaciones igual al número de puntos que se encuentran dentro de una ventana  $w_s$ , estas ecuaciones expresan la misma diferencia cuadrática, por tanto, se pueden formular  $w_s$  equivalencias entre sí, esto es:

$$p_0^T p_0 - 2 p_0^T \begin{bmatrix} h_c \\ k_c \end{bmatrix} \cong p_i^T p_i - 2 p_i^T \begin{bmatrix} h_c \\ k_c \end{bmatrix}, \quad i = 1, 2, \dots, w_s; \quad (3.31)$$

se pueden construir 100 ecuaciones ( $w_s$ ) dejando los términos afines del lado izquierdo:

$$-2 (p_0^T - p_i^T) \begin{bmatrix} h_c \\ k_c \end{bmatrix} \cong p_i^T p_i - p_0^T p_0, \quad i = 1, 2, \dots, w_s; \quad (3.32)$$

de manera matricial en una sola ecuación:

$$-2 \begin{bmatrix} p_0^T - p_1^T \\ p_0^T - p_2^T \\ \vdots \\ p_0^T - p_{w_s}^T \end{bmatrix} \begin{bmatrix} h_c \\ k_c \end{bmatrix} \cong \begin{bmatrix} p_1^T p_1 - p_0^T p_0 \\ p_2^T p_2 - p_0^T p_0 \\ \vdots \\ p_{w_s}^T p_{w_s} - p_0^T p_0 \end{bmatrix} \quad (3.33)$$

Finalmente, el punto al que se refieren las 100 ecuaciones queda calculado como sigue:

$$\begin{bmatrix} h_c \\ k_c \end{bmatrix} \cong -\frac{1}{2} \begin{bmatrix} p_0^T - p_1^T \\ p_0^T - p_2^T \\ \vdots \\ p_0^T - p_{w_s}^T \end{bmatrix}^+ \cdot \begin{bmatrix} p_1^T p_1 - p_0^T p_0 \\ p_2^T p_2 - p_0^T p_0 \\ \vdots \\ p_{w_s}^T p_{w_s} - p_0^T p_0 \end{bmatrix}, \quad (3.34)$$

donde el simbolismo  $[\cdot]^+$  es conocido como la pseudoinversa de  $[\cdot]$

Al realizar la manipulación algebraica de las ecuaciones anteriores, se limita a dar la el valor numérico de la posición  $[h_c, k_c]^T$ , y no necesariamente del valor de la distancia aproximadamente equidistante  $\hat{r}_c$ , un criterio para calcular la distancia equidistante es el siguiente:

$$\hat{r}_c = \frac{1}{w_s} \sum_{j=0}^{w_s} \sqrt{(x_j - h_c)^2 + (y_j - k_c)^2}, \quad j = 0, 1, \dots, w_s; \quad (3.35)$$

En este trabajo, las señales se segmentan en períodos de 2 s, lo que significa que  $w_s$  es igual a los puntos que se encuentran dentro de este periodo. La Figura 3.15 muestra un ejemplo del resultado gráfico después de aplicar nuestra metodología, donde el valor de  $\hat{r}_c$  fue calculado a partir de las posiciones en la trayectoria de 100 puntos de color naranja, mismos que se obtienen por ventana.

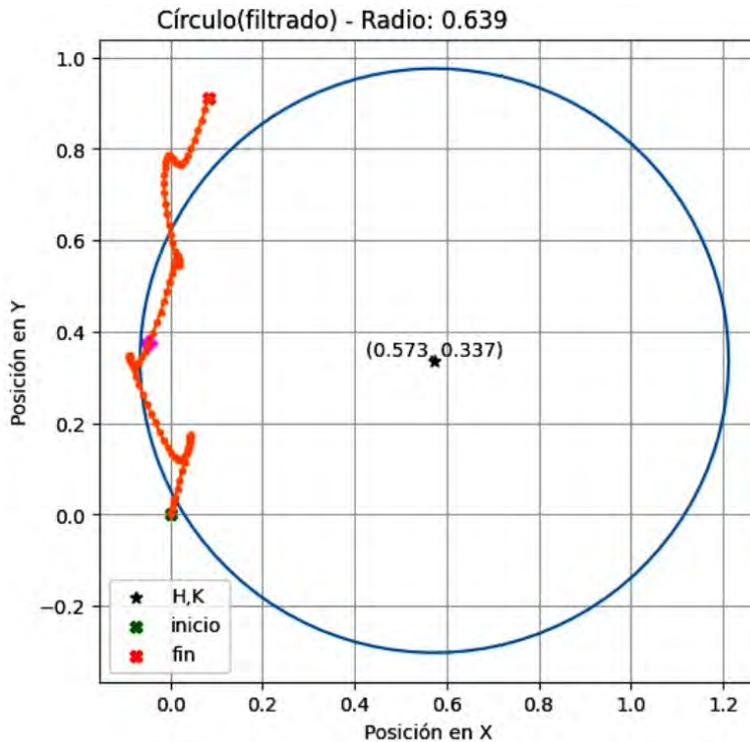


Figura 3.15: RC obtenido en la actividad correr, plano coronal

Por lo tanto, se puede observar que, a partir de la trayectoria de posición obtenida en el plano coronal durante una ventana de dos segundos, se registra un movimiento ascendente con ligeras

desviaciones laterales. Este patrón corresponde directamente a la dinámica del movimiento de carrera de una persona. Además, la circunferencia calculada con el algoritmo propuesto demuestra su eficiencia, ya que se ajusta bien a la mayoría de los puntos de la trayectoria obtenida. Finalmente, también se muestra el valor del radio de curvatura calculado ( $\hat{r}_c$ ).

### 3.3.2. Cálculo del Radio de Curvatura Plano Sagital

Se realiza la estimación de la posición cartesiana de un punto equidistante a un grupo de puntos (Radio de Curvatura), considerando la ecuación de la circunferencia, tomando en cuenta inicialmente el plano coronal, que corresponde a los ejes ( $y, z$ ) como se observa en la Figura 3.16.

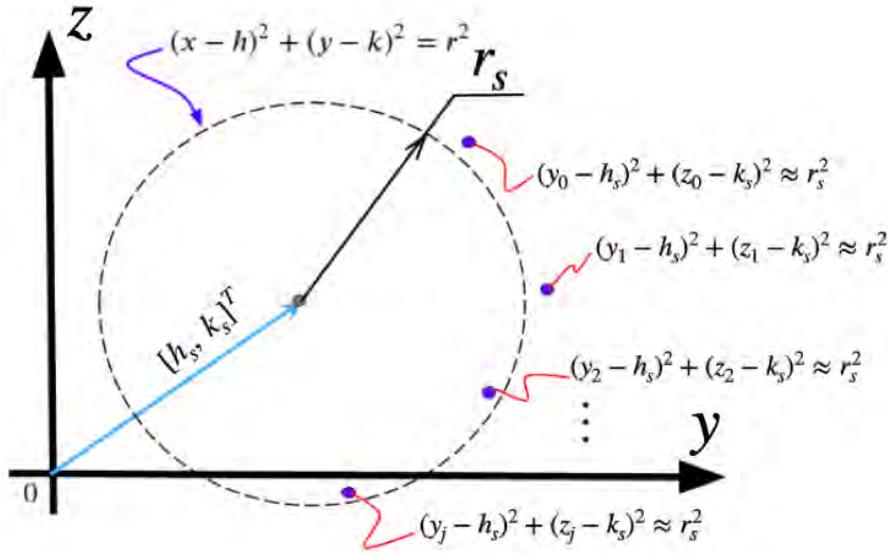


Figura 3.16: Gráfica del punto  $[h_s, k_s]^T$  y el RC, plano sagital

Se desea calcular un punto cuya coordenada o vector de posición se denota por el vector  $[h_s, k_s]^T$ , dicho punto se encuentra aproximadamente equidistante al número de puntos que contiene el tamaño de ventana seleccionada ( $w_s$ ), considerando  $[y_0, z_0]^T, \dots, [y_j, z_j]^T$  a una distancia  $r$ , es decir:

$$(y_j - h_s)^2 + (z_j - k_s)^2 = r_s^2, \quad j = 0, 1, \dots, w_s; \quad (3.36)$$

Al resolver el sistema de ecuaciones se obtiene las coordenadas del punto  $[h_s, k_s]^T$  (centro del círculo resultante). Como se muestra a continuación:

Para solucionar el punto  $[h_s, k_s]^T$ , es necesario reexpresar estas ecuaciones en notación vectorial, nótese que se pueden expresar como sigue:

$$[y_j - h_s, \quad z_j - k_s] \begin{bmatrix} y_j - h_s \\ z_j - k_s \end{bmatrix} \cong r_s^2, \quad j = 0, 1, \dots, w_s; \quad (3.37)$$

como:

$$\begin{bmatrix} y_j - h_s \\ z_j - k_s \end{bmatrix} = \begin{bmatrix} y_j \\ z_j \end{bmatrix} - \begin{bmatrix} h_s \\ k_s \end{bmatrix} \quad (3.38)$$

entonces:

$$([y_j \ z_j] - [h_s \ k_s]) \left( \begin{bmatrix} y_j \\ z_j \end{bmatrix} - \begin{bmatrix} h_s \\ k_s \end{bmatrix} \right) \cong r_s^2, \quad j = 0, 1, \dots, w_s; \quad (3.39)$$

las manipulaciones algebraicas generan lo siguiente:

$$[y_j \ z_j] \begin{bmatrix} y_j \\ z_j \end{bmatrix} - [h_s \ k_s] \begin{bmatrix} y_j \\ z_j \end{bmatrix} - [y_j \ z_j] \begin{bmatrix} h_s \\ k_s \end{bmatrix} + [h_s \ k_s] \begin{bmatrix} h_s \\ k_s \end{bmatrix} \cong r_s^2 \quad (3.40)$$

o bien:

$$[y_j \ z_j] \begin{bmatrix} y_j \\ z_j \end{bmatrix} - 2 [y_j \ z_j] \begin{bmatrix} h_s \\ k_s \end{bmatrix} \cong r_s^2 - [h_s \ k_s] \begin{bmatrix} h_s \\ k_s \end{bmatrix} \quad (3.41)$$

si se define que:

$$p_j := \begin{bmatrix} y_j \\ z_j \end{bmatrix} \quad (3.42)$$

entonces:

$$p_j^T p_j - 2p_j^T \begin{bmatrix} h_s \\ k_s \end{bmatrix} \cong r_s^2 - [h_s \ k_s] \begin{bmatrix} h_s \\ k_s \end{bmatrix}, \quad j = 0, 1, \dots, w_s; \quad (3.43)$$

En resumen, se tiene un número de ecuaciones igual al número de puntos que se encuentran dentro de una ventana  $w_s$ , estas ecuaciones expresan la misma diferencia cuadrática, por tanto, se pueden formular  $w_s$  equivalencias entre sí, esto es:

$$p_0^T p_0 - 2p_0^T \begin{bmatrix} h_s \\ k_s \end{bmatrix} \cong p_i^T p_i - 2p_i^T \begin{bmatrix} h_s \\ k_s \end{bmatrix}, \quad i = 1, 2, \dots, w_s. \quad (3.44)$$

se pueden construir 100 ecuaciones dejando los términos afines del lado izquierdo:

$$-2 (p_0^T - p_i^T) \begin{bmatrix} h_s \\ k_s \end{bmatrix} \cong p_i^T p_i - p_0^T p_0, \quad i = 1, 2, \dots, w_s; \quad (3.45)$$

de manera matricial en una sola ecuación:

$$-2 \begin{bmatrix} p_0^T - p_1^T \\ p_0^T - p_2^T \\ \vdots \\ p_0^T - p_{w_s}^T \end{bmatrix} \begin{bmatrix} h_s \\ k_s \end{bmatrix} \cong \begin{bmatrix} p_1^T p_1 - p_0^T p_0 \\ p_2^T p_2 - p_0^T p_0 \\ \vdots \\ p_{w_s}^T p_{w_s} - p_0^T p_0 \end{bmatrix} \quad (3.46)$$

Finalmente, el punto al que se refieren las 100 ecuaciones queda calculado como sigue:

$$\begin{bmatrix} h_s \\ k_s \end{bmatrix} \cong -\frac{1}{2} \begin{bmatrix} p_0^T - p_1^T \\ p_0^T - p_2^T \\ \vdots \\ p_0^T - p_{w_s}^T \end{bmatrix}^+ \cdot \begin{bmatrix} p_1^T p_1 - p_0^T p_0 \\ p_2^T p_2 - p_0^T p_0 \\ \vdots \\ p_{w_s}^T p_{w_s} - p_0^T p_0 \end{bmatrix}, \quad (3.47)$$

donde el simbolismo  $[\cdot]^+$  es conocido como la pseudoinversa de  $[\cdot]$

Al realizar la manipulación algebraica de las ecuaciones anteriores, se limita a dar la el valor numérico de la posición  $[h_s, k_s]^T$ , y no necesariamente del valor de la distancia aproximadamente equidistante  $\hat{r}_s$ , un criterio para calcular la distancia equidistante es el siguiente:

$$\hat{r}_s = \frac{1}{w_s} \sum_{j=0}^{w_s} \sqrt{(y_j - h_s)^2 + (z_j - k_s)^2}, \quad j = 0, 1, \dots, w_s; \quad (3.48)$$

### 3.3.3. Cálculo del Radio de Curvatura Plano Transversal

Se realiza la estimación de la posición cartesiana de un punto equidistante a un grupo de puntos (Radio de Curvatura), considerando la ecuación de la circunferencia, tomando en cuenta inicialmente el plano coronal, que corresponde a los ejes (x, z) como se observa en la Figura 3.17.

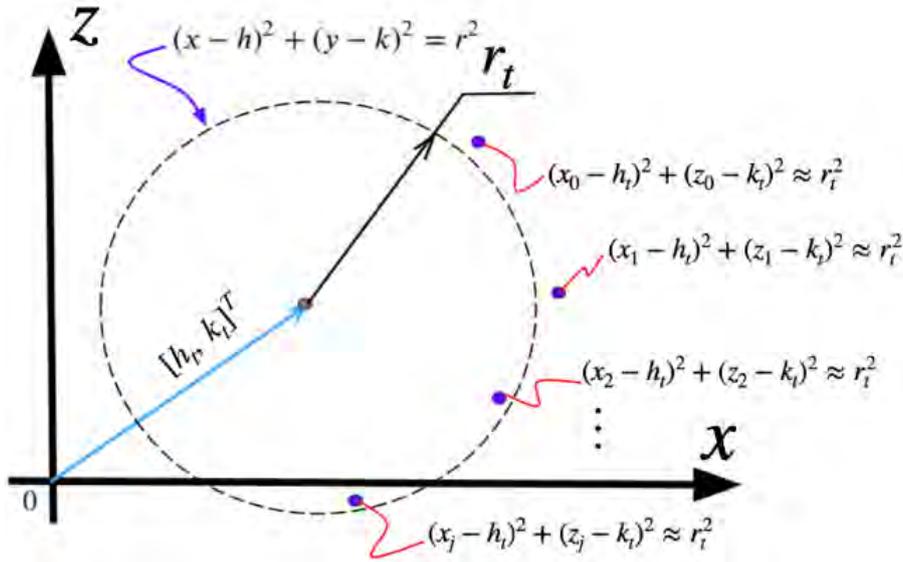


Figura 3.17: Gráfica del punto  $[h, k]$  y el RC, plano transversal

Se desea calcular un punto cuya coordenada o vector de posición se denota por el vector  $[h_t, k_t]^T$ , dicho punto se encuentra aproximadamente equidistante al número de puntos que contiene el tamaño de ventana seleccionada ( $w_s$ ), considerando  $[x_0, z_0]^T, \dots, [x_j, z_j]^T$  a una distancia  $r$ , es decir:

$$(x_j - h_t)^2 + (z_j - k_t)^2 = r_t^2, \quad j = 0, 1, \dots, w_s; \quad (3.49)$$

Al resolver el sistema de ecuaciones se obtiene las coordenadas del punto  $[h_t, k_t]^T$  (centro del círculo resultante). Como se muestra a continuación:

Para solucionar el punto  $[h_t, k_t]^T$ , es necesario reexpresar estas ecuaciones en notación vectorial, nótese que se pueden expresar como sigue:

$$[x_j - h_t, \quad z_j - k_t] \begin{bmatrix} x_j - h_t \\ z_j - k_t \end{bmatrix} \cong r_t^2, \quad j = 0, 1, \dots, w_s; \quad (3.50)$$

como:

$$\begin{bmatrix} x_j - h_t \\ z_j - k_t \end{bmatrix} = \begin{bmatrix} x_j \\ z_j \end{bmatrix} - \begin{bmatrix} h_t \\ k_t \end{bmatrix} \quad (3.51)$$

entonces:

$$([x_j \ z_j] - [h_t \ k_t]) \left( \begin{bmatrix} x_j \\ z_j \end{bmatrix} - \begin{bmatrix} h_t \\ k_t \end{bmatrix} \right) \cong r_t^2, \quad j = 0, 1, \dots, w_s; \quad (3.52)$$

las manipulaciones algebraicas generan lo siguiente:

$$[x_j \ z_j] \begin{bmatrix} x_j \\ z_j \end{bmatrix} - [h_t \ k_t] \begin{bmatrix} x_j \\ z_j \end{bmatrix} - [x_j \ z_j] \begin{bmatrix} h_t \\ k_t \end{bmatrix} + [h_t \ k_t] \begin{bmatrix} h_t \\ k_t \end{bmatrix} \cong r_t^2 \quad (3.53)$$

o bien:

$$[x_j \ z_j] \begin{bmatrix} x_j \\ z_j \end{bmatrix} - 2[x_j \ z_j] \begin{bmatrix} h_t \\ k_t \end{bmatrix} \cong r_t^2 - [h_t \ k_t] \begin{bmatrix} h_t \\ k_t \end{bmatrix} \quad (3.54)$$

si se define que:

$$p_j := \begin{bmatrix} x_j \\ z_j \end{bmatrix} \quad (3.55)$$

entonces:

$$p_j^T p_j - 2p_j^T \begin{bmatrix} h_t \\ k_t \end{bmatrix} \cong r_t^2 - [h_t \ k_t] \begin{bmatrix} h_t \\ k_t \end{bmatrix}, \quad j = 0, 1, \dots, w_s; \quad (3.56)$$

En resumen, se tiene un número de ecuaciones igual al número de puntos que se encuentran dentro de una ventana  $w_s$ , estas ecuaciones expresan la misma diferencia cuadrática, por tanto, se pueden formular  $w_s$  equivalencias entre sí, esto es:

$$p_0^T p_0 - 2p_0^T \begin{bmatrix} h_t \\ k_t \end{bmatrix} \cong p_i^T p_i - 2p_i^T \begin{bmatrix} h_t \\ k_t \end{bmatrix}, \quad i = 1, 2, \dots, w_s. \quad (3.57)$$

se pueden construir 100 ecuaciones dejando los términos afines del lado izquierdo:

$$-2(p_0^T - p_i^T) \begin{bmatrix} h_t \\ k_t \end{bmatrix} \cong p_i^T p_i - p_0^T p_0, \quad i = 1, 2, \dots, w_s; \quad (3.58)$$

de manera matricial en una sola ecuación:

$$-2 \begin{bmatrix} p_0^T - p_1^T \\ p_0^T - p_2^T \\ \vdots \\ p_0^T - p_{w_s}^T \end{bmatrix} \begin{bmatrix} h_t \\ k_t \end{bmatrix} \cong \begin{bmatrix} p_1^T p_1 - p_0^T p_0 \\ p_2^T p_2 - p_0^T p_0 \\ \vdots \\ p_{w_s}^T p_{w_s} - p_0^T p_0 \end{bmatrix} \quad (3.59)$$

Finalmente, el punto al que se refieren las 100 ecuaciones queda calculado como sigue:

$$\begin{bmatrix} h_t \\ k_t \end{bmatrix} \cong -\frac{1}{2} \begin{bmatrix} p_0^T - p_1^T \\ p_0^T - p_2^T \\ \vdots \\ p_0^T - p_{w_s}^T \end{bmatrix}^+ \cdot \begin{bmatrix} p_1^T p_1 - p_0^T p_0 \\ p_2^T p_2 - p_0^T p_0 \\ \vdots \\ p_{w_s}^T p_{w_s} - p_0^T p_0 \end{bmatrix}, \quad (3.60)$$

donde el simbolismo  $[\cdot]^+$  es conocido como la pseudoinversa de  $[\cdot]$

---

Al realizar la manipulación algebraica de las ecuaciones anteriores, se limita a dar el valor numérico de la posición  $[h_t, k_t]^T$ , y no necesariamente del valor de la distancia aproximadamente equidistante  $\hat{r}_t$ , un criterio para calcular la distancia equidistante es el siguiente:

$$\hat{r}_t = \frac{1}{w_s} \sum_{j=0}^{w_s} \sqrt{(x_j - h_t)^2 + (z_j - k_t)^2}, \quad j = 0, 1, \dots, w_s; \quad (3.61)$$

### 3.3.4. Vector de Características Propuesto

La selección de características es un aspecto crítico en el desarrollo de modelos de redes neuronales artificiales. Al elegir cuidadosamente características relevantes extraídas únicamente del dominio del tiempo, racionalizamos la complejidad del modelo mientras aseguramos una precisión de clasificación robusta en el HAR.

Siguiendo este enfoque, el vector de características propuesto se compone considerando que la estimación del radio de curvatura para cada uno de los tres planos de movimiento (sagital, coronal y transversal), esto implica aplicar el método descrito (Sección 3.3.1). Además, se calculan la media y la varianza de las señales de aceleración, velocidad y posición de los tres ejes, por lo tanto, el vector de características es conformado como se muestra en la Tabla 3.3.

<b>Vector de Características</b>
Radio de curvatura plano coronal $\hat{r}_c$
Radio de curvatura plano sagital $\hat{r}_s$
Radio de curvatura plano transversal $\hat{r}_t$
Promedio de aceleración en (x,y,z)
Promedio de velocidad en (x,y,z)
Promedio de posición en (x,y,z)
Varianza de aceleración en (x,y,z)
Varianza de velocidad en (x,y,z)
Varianza de posición en (x,y,z)

Tabla 3.3: Tabla de características.

Además de los radios de curvatura en los múltiples planos, se extraen otras 342 características, correspondientes al cálculo de la media y la varianza de las señales de posición, velocidad y aceleración a lo largo de los ejes (x, y, z).

Finalmente, en total se extrae un vector de 399 características por actividad, las cuales son utilizadas como entradas en los modelos de detección de posición del sensor, mediante el uso del algoritmo Random Forest y en los modelos de clasificación de actividad donde se utilizan redes neuronales tipo RNaf.

## 3.4. Modelo de Detección de Posición

En el contexto del HAR, la detección precisa de la posición de un sensor es esencial para entender el comportamiento del usuario. Un enfoque eficaz para esta tarea es el uso de algoritmos de Random Forest, permiten clasificar datos en diferentes clases. Este modelo se basa en

características derivadas de los radios de curvatura en los tres planos de movimiento, así como dos medidas estadísticas (promedio y varianza) en las diferentes representaciones propuestas (aceleración, velocidad y posición) lo que proporciona una representación geométrica robusta.

Una de las ventajas significativas de este enfoque es que no requiere un poder de procesamiento demandante. Los modelos de RF son inherentemente eficientes y escalables, lo que los hace ideales para aplicaciones en tiempo real. Además, utilizan técnicas como el bootstrapping para evitar el sobreajuste, generando múltiples subconjuntos de datos para entrenar los árboles de decisión. Esta característica no solo mejora la generalización del modelo, sino que también proporciona una robustez considerable ante variaciones en los datos.

La estructura del esquema de detección de posición mediante el uso del modelo RF utilizado en este trabajo se presenta a continuación, Figura 3.18. En este esquema, se observan tres opciones de colocación del acelerómetro: pecho, cadera y muñeca. Esta flexibilidad en la ubicación del sensor proporciona al usuario una mayor libertad en su uso, sin comprometer el rendimiento del modelo de clasificación de actividades. Además, este diseño no solo mejora la experiencia del usuario, sino que también potencia la efectividad del sistema.

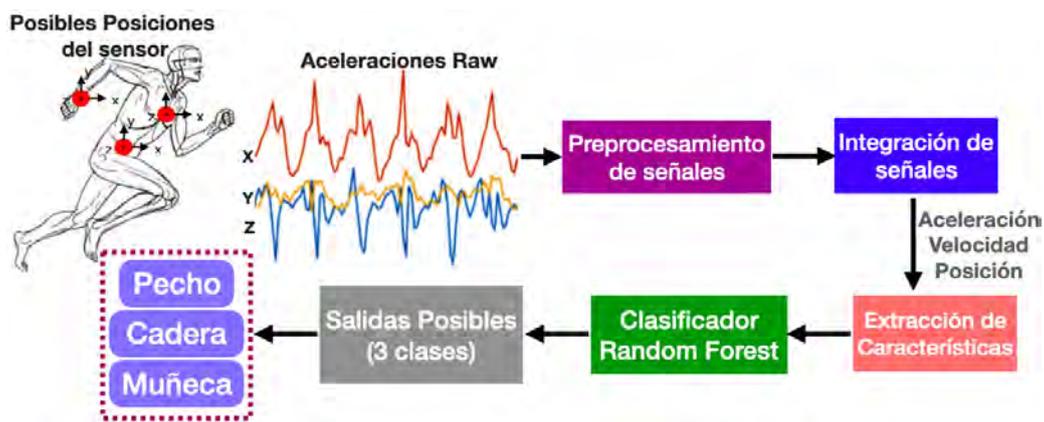


Figura 3.18: Estructura detección de posición

La detección de posición se ejecuta antes de la clasificación de actividades, lo que permite establecer un contexto adecuado para el análisis posterior. El resultado de esta etapa inicial no solo determina la posición del sensor, sino que también sirve como base para seleccionar automáticamente el modelo de RNA correspondiente, asegurando que el modelo de clasificación sea específico para la posición en la que se encuentra el sensor, optimizando así la precisión de las predicciones.

### 3.4.1. Algoritmo de Bosques Aleatorios

En esta sección, se presenta la estructura matemática del modelo Random Forest aplicado a la detección de la posición de sensores, específicamente en las clases de pecho, cadera y muñeca. Utilizando un conjunto de datos compuesto por ejemplos de diferentes participantes.

Se detallará cómo se estructuran las características de entrada y salida, el proceso de construcción de los árboles, y el método de predicción que utiliza el conteo de las clasificaciones

---

emitidas por cada árbol. A través de esta descripción matemática, se busca proporcionar una comprensión clara del funcionamiento interno del modelo y su capacidad para realizar predicciones precisas en el contexto del reconocimiento de actividades humanas.

El modelo se compone de 1000 árboles de decisión, cada uno construido a partir de un subconjunto de datos obtenidos mediante técnicas de bootstrapping. Este es entrenado a partir de las características obtenidas en el preprocesamiento.

Supongamos que tenemos  $N$  ejemplos de entrenamiento, donde cada ejemplo tiene  $D$  características. Las características se representan como un vector  $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ , para cada ejemplo  $i$ . Las etiquetas de clase correspondientes se representan como un vector  $Q_i$  para cada ejemplo  $i$ .

$$D = \{(x_i, Q_i)\}_{i=1}^N \quad (3.62)$$

$$x_i = \begin{bmatrix} x_{pecho} \\ x_{cadera} \\ x_{muñeca} \end{bmatrix}; \quad Q_i = [Q_p, Q_c, Q_m]^T$$

Donde:

$x_i$  = entradas, características extraídas en (x, y, z) de las 3 posiciones

$Q_i$  = salidas, clase correspondiente a la posición detectada (pecho, cadera, muñeca).

Considerando que el conjunto de datos que se compone de 10 participantes, se realiza una división del 70-30 para entrenar y probar el modelo, Se divide el conjunto de datos  $D$  en un conjunto de entrenamiento  $D_{train}$  y un conjunto de prueba  $D_{test}$ :

- $D_{train} = 0.7(10) = 7$  participantes que se utilizan para el entrenamiento.
- $D_{test} = 0.3(10) = 3$  participantes que se utilizan para prueba.

Se construyen  $M = 1000$  árboles de decisión, cada uno entrenado sobre un subconjunto de los datos de entrenamiento  $D_{train}$ , utilizando técnicas de bootstrapping.

Cada árbol  $A_t$  se entrena para hacer predicciones basadas en un subconjunto de características aleatorias. Para una nueva instancia  $x_i$ , cada árbol  $A_t$  emite una predicción de clase  $Q_i$ .

Para obtener la salida de clasificación de un modelo Random Forest, se realiza un conteo de las predicciones de clase emitidas por cada árbol y se selecciona la clase más frecuente como la predicción final.

$$y_{pred} = argmax\left(\sum_{i=1}^M \alpha(Q_i)\right) \quad (3.63)$$

Donde:

$y_{pred}$  : salida predecida (pecho, cadera o muñeca.)

$M$ : 1000, número de árboles

$\alpha(Q_i)$ : función indicadora 1 si la predicción del árbol  $i$  es igual a la clase  $Q$  y 0 en caso contrario.

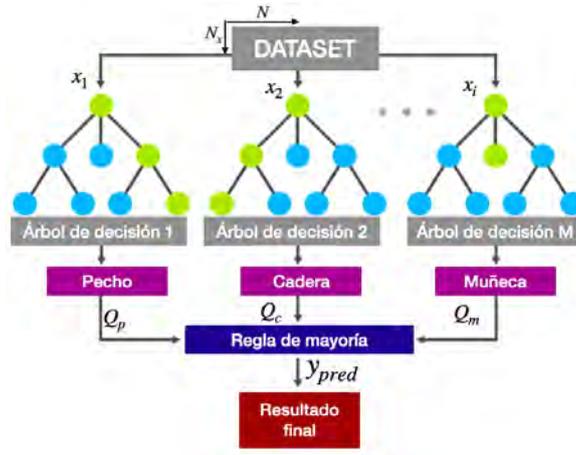


Figura 3.19: Estructura del RF propuesto

Una vez entrenado el modelo RF propuesto con la estructura mostrada en la Figura 3.19, el modelo se evalúa utilizando el conjunto de prueba  $D_{test}$ . La precisión se calcula como:

$$Exactitud = \frac{\text{Número predicciones correctas}}{n_{test}} \quad (3.64)$$

Donde  $n_{test}$  es el número total de instancias en el conjunto de prueba, que corresponde a los 3 participantes no utilizados en el entrenamiento.

Este enfoque permite que el modelo RF realice predicciones robustas y precisas para la detección de la posición del sensor, aprovechando la diversidad de los árboles y la información contenida en las características extraídas. La combinación de múltiples árboles ayuda a mitigar el riesgo de sobreajuste y a mejorar la generalización del modelo en nuevas instancias.

### 3.5. Clasificación de Actividades

En esta sección, se explorarán los modelos de clasificación de actividades basados en Redes Neuronales Artificiales (RNAs), que se implementan tras la fase de detección de posición. Este enfoque permite clasificar de manera eficiente las actividades humanas, aprovechando la información obtenida sobre la ubicación del sensor.

Para este propósito, se ha diseñado un esquema que consiste en tres modelos de Redes Neuronales Feedforward (RNAf), cada uno con tres capas ocultas. Estos modelos utilizan el mismo vector de características que se empleó en el modelo de Random Forest, que incluye los radios de curvatura en los tres planos de movimiento, así como el promedio y la varianza de las señales de aceleración, velocidad y posición.

Se muestra la implementación de estos modelos, así como de su efectividad en la clasificación de actividades en contextos reales. Este enfoque no solo mejora la precisión del sistema, sino que también resalta el potencial de las RNAs en el reconocimiento de patrones complejos en datos de movimiento.

### 3.5.1. Diseño y Selección del Esquema de Red Neuronal

La selección y el diseño del esquema de la red neuronal son fundamentales para optimizar el rendimiento del modelo, ya que determinan la capacidad del sistema para captar las complejidades inherentes a los datos de movimiento. Al elegir la arquitectura adecuada, se busca maximizar la precisión en la clasificación y mejorar la generalización a datos no vistos.

En este caso, se crearon tres modelos de clasificación distintos basados en la estructura de una RNAf, cada uno correspondiente a la posición del sensor: pecho, cadera y muñeca. Esta diferenciación permite que cada modelo se especialice en las características específicas de las señales de aceleración capturadas por cada sensor, lo que puede resultar en un rendimiento más eficiente y preciso. Por lo tanto, el esquema general de clasificación de actividades bajo este enfoque se conforma como se muestra en la Figura 3.20.

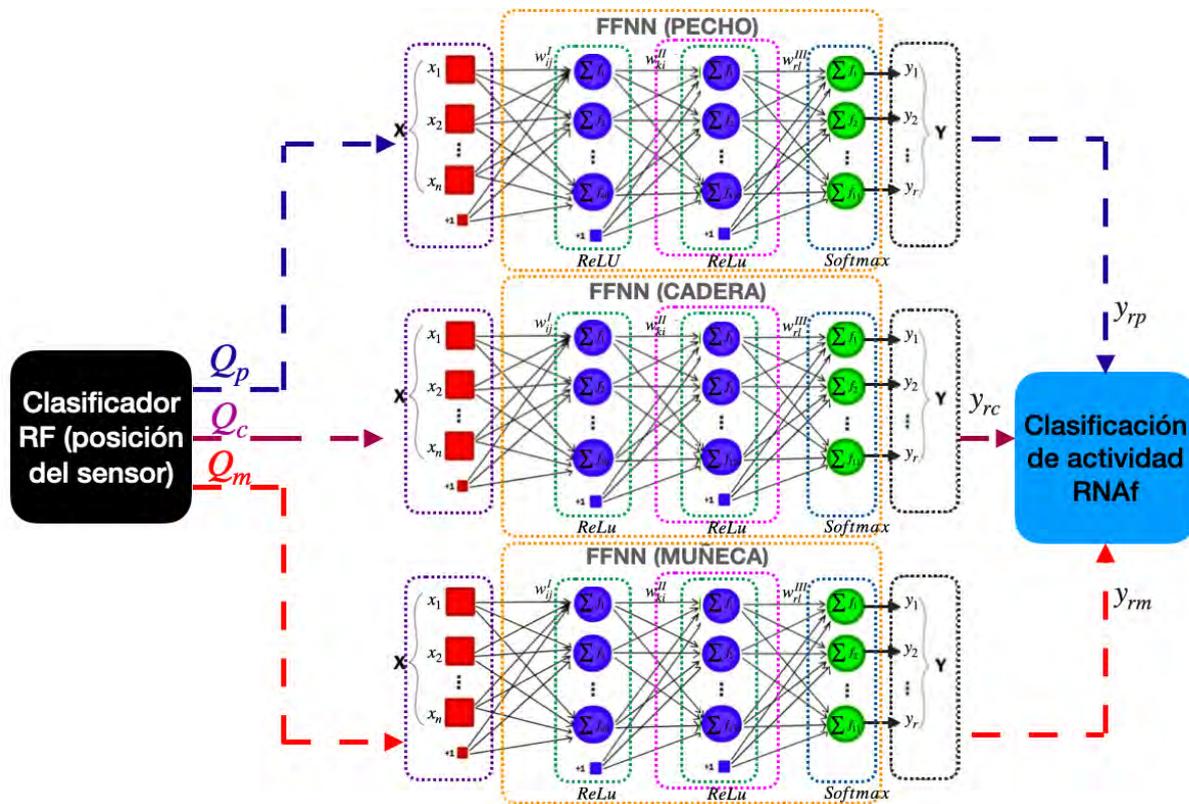


Figura 3.20: Estructura del sistema HAR propuesto

La estructura descriptiva general de cada modelo se describe a continuación:

- Capa de Entrada: Cada modelo comienza con una capa de entrada que recibe las características del vector de entrada (vector de características propuesto).
- Capas Ocultas: Los modelos incluyen varias capas ocultas, diseñadas para aprender representaciones complejas. Las neuronas en estas capas aplican funciones de activación, como ReLU, para introducir no linealidades en el aprendizaje.

- 
- **Capa de Salida:** La capa final de cada modelo está configurada para emitir una probabilidad de pertenencia a cada una de las clases de actividad, utilizando la función de activación Softmax.

### 3.5.2. Estructura del Modelo de RNaf del Pecho

La arquitectura de la RNA diseñada para procesar las señales del acelerómetro colocado en el pecho está basada en el enfoque de RNaf. La cual cuenta con la siguiente estructura:

- **Capa de entrada:** 399 neuronas
  - *Función de activación:* ReLU
- **Primera capa oculta:** 798 neuronas
  - *Función de activación:* ReLU
- **Segunda capa oculta:** 3000 neuronas
  - *Función de activación:* ReLU
- **Tercera capa oculta:** 2000 neuronas
  - *Función de activación:* ReLU
- **Cuarta capa oculta:** 1000 neuronas
  - *Función de activación:* ReLU
- **Capa de salida:** 13 neuronas
  - *Función de activación:* Softmax

Matemáticamente hablando la **Propagación hacia adelante** Para cada capa  $l$  de la red, donde  $l = 0, 1, 2, 3, 4, 5$  (entrada, primera capa oculta, segunda capa oculta, tercera capa oculta, cuarta capa oculta y salida), se define como:

**Capa de entrada** ( $l = 0$ ):

$$a^{(0)} = \mathbf{x} \quad (\text{vector de entrada de dimensión 399})$$

**Primera capa oculta** ( $l = 1$ ):

$$z_j^{(1)} = \sum_{i=1}^{399} w_{ji}^{(1)} a_i^{(0)} + b_j^{(1)}$$

$$a_j^{(1)} = \text{ReLU}(z_j^{(1)}) \quad \text{para } j = 1, 2, \dots, 798$$

**Segunda capa oculta** ( $l = 2$ ):

$$z_j^{(2)} = \sum_{i=1}^{798} w_{ji}^{(2)} a_i^{(1)} + b_j^{(2)}$$

---


$$a_j^{(2)} = \text{ReLU}(z_j^{(2)}) \quad \text{para } j = 1, 2, \dots, 3000$$

**Tercera capa oculta** ( $l = 3$ ):

$$z_j^{(3)} = \sum_{i=1}^{3000} w_{ji}^{(3)} a_i^{(2)} + b_j^{(3)}$$

$$a_j^{(3)} = \text{ReLU}(z_j^{(3)}) \quad \text{para } j = 1, 2, \dots, 2000$$

**Cuarta capa oculta** ( $l = 4$ ):

$$z_j^{(4)} = \sum_{i=1}^{2000} w_{ji}^{(4)} a_i^{(3)} + b_j^{(4)}$$

$$a_j^{(4)} = \text{ReLU}(z_j^{(4)}) \quad \text{para } j = 1, 2, \dots, 1000$$

**Capa de Salida** ( $l = 5$ ):

$$z_k^{(5)} = \sum_{j=1}^{1000} w_{kj}^{(5)} a_j^{(4)} + b_k^{(5)}$$

$$a_k^{(5)} = \text{Softmax}(z_k^{(5)}) \quad \text{para } k = 1, 2, \dots, 13$$

donde:  $w_{ji}^{(l)}$  : representa el peso de la conexión entre la neurona  $i$  de la capa anterior  $l-1$  y la neurona  $j$  de la capa  $l$ ,  $z_j^{(l)}$  : es la suma ponderada de las entradas para la neurona  $j$  de la capa  $l$ , que incluye los pesos y las activaciones de la capa anterior, además de un término de sesgo,  $b_j^{(l)}$  : es el sesgo asociado a la neurona  $j$  en la capa  $l$  y  $a_j^{(l)}$  : representa la activación de la neurona  $j$  en la capa  $l$ , que se obtiene aplicando una función de activación (como ReLU o Softmax).

Dado que se emplea la **entropía cruzada categórica** para la clasificación multiclase, la entropía cruzada, en términos generales, mide la diferencia entre distribuciones de probabilidad. Este enfoque es adecuado para modelos de RNAs cuya salida está representada por probabilidades, como ocurre en la clasificación categórica cuando se utiliza la función de activación Softmax. En este caso, la función de pérdida se define como:

$$L(\mathbf{y}, \hat{\mathbf{y}}) = -\frac{1}{399} \sum_{i=1}^{399} \sum_{k=1}^{13} y_k \log(a_k^{(5)}) \quad (3.65)$$

donde:  $y_k$  es la etiqueta verdadera (one-hot encoded) y  $a_k^{(5)}$  es la salida predicha de la red,  $N = 399$  es el número total de ejemplos en el conjunto de datos y  $C = 13$  el número de clases en el problema de clasificación.

### 3.5.3. Estructura del modelo de RNaf de la cadera

La arquitectura de la RNA diseñada para procesar las señales del acelerómetro colocado en el pecho está basada en el enfoque de RNaf. La cual cuenta con la siguiente estructura:

- **Capa de entrada:** 399 neuronas

- 
- *Función de activación:* ReLU
  - **Primera capa oculta:** 798 neuronas
    - *Función de activación:* ReLU
  - **Segunda capa oculta:** 2200 neuronas
    - *Función de activación:* ReLU
  - **Tercera capa oculta:** 2500 neuronas
    - *Función de activación:* ReLU
  - **Cuarta capa oculta:** 1000 neuronas
    - *Función de activación:* ReLU
  - **Capa de salida:** 13 neuronas
    - *Función de activación:* Softmax

Matemáticamente hablando la **Propagación hacia adelante** Para cada capa  $l$  de la red, donde  $l = 0, 1, 2, 3, 4, 5$  (entrada, primera capa oculta, segunda capa oculta, tercera capa oculta, cuarta capa oculta y salida), se define como:

**Capa de entrada** ( $l = 0$ ):

$$a^{(0)} = \mathbf{x} \quad (\text{vector de entrada de dimensión 399})$$

**Primera capa oculta** ( $l = 1$ ):

$$z_j^{(1)} = \sum_{i=1}^{399} w_{ji}^{(1)} a_i^{(0)} + b_j^{(1)}$$

$$a_j^{(1)} = \text{ReLU}(z_j^{(1)}) \quad \text{para } j = 1, 2, \dots, 798$$

**Segunda capa oculta** ( $l = 2$ ):

$$z_j^{(2)} = \sum_{i=1}^{798} w_{ji}^{(2)} a_i^{(1)} + b_j^{(2)}$$

$$a_j^{(2)} = \text{ReLU}(z_j^{(2)}) \quad \text{para } j = 1, 2, \dots, 2200$$

**Tercera capa oculta** ( $l = 3$ ):

$$z_j^{(3)} = \sum_{i=1}^{2200} w_{ji}^{(3)} a_i^{(2)} + b_j^{(3)}$$

$$a_j^{(3)} = \text{ReLU}(z_j^{(3)}) \quad \text{para } j = 1, 2, \dots, 2500$$

---

**Cuarta capa oculta** ( $l = 4$ ):

$$z_j^{(4)} = \sum_{i=1}^{2500} w_{ji}^{(4)} a_i^{(3)} + b_j^{(4)}$$

$$a_j^{(4)} = \text{ReLU}(z_j^{(4)}) \quad \text{para } j = 1, 2, \dots, 1000$$

**Capa de salida** ( $l = 5$ ):

$$z_k^{(5)} = \sum_{j=1}^{1000} w_{kj}^{(5)} a_j^{(4)} + b_k^{(5)}$$

$$a_k^{(5)} = \text{Softmax}(z_k^{(5)}) \quad \text{para } k = 1, 2, \dots, 13$$

donde:  $w_{ji}^{(l)}$  : representa el peso de la conexión entre la neurona  $i$  de la capa anterior  $l-1$  y la neurona  $j$  de la capa  $l$ ,  $z_j^{(l)}$  : es la suma ponderada de las entradas para la neurona  $j$  de la capa  $l$ , que incluye los pesos y las activaciones de la capa anterior, además de un término de sesgo,  $b_j^{(l)}$  : es el sesgo asociado a la neurona  $j$  en la capa  $l$  y  $a_j^{(l)}$  : representa la activación de la neurona  $j$  en la capa  $l$ , que se obtiene aplicando una función de activación (como ReLU o Softmax).

Dado que se utiliza la **categorical crossentropy** para la clasificación multiclase, la entropía cruzada, en general, es una medida de la distancia entre distribuciones de probabilidad. Esta suele ser adecuada en modelos de RNAs cuya salida representa una probabilidad, como cuando se realiza una clasificación categórica con función de activación Softmax, la función de pérdida en este caso se define como:

$$L(\mathbf{y}, \hat{\mathbf{y}}) = -\frac{1}{399} \sum_{i=1}^{399} \sum_{k=1}^{13} y_k \log(a_k^{(5)}) \quad (3.66)$$

donde:  $y_k$  es la etiqueta verdadera (one-hot encoded) y  $a_k^{(5)}$  es la salida predicha de la red,  $N = 399$  es el número total de ejemplos en el conjunto de datos y  $C = 13$  el número de clases en el problema de clasificación.

### 3.5.4. Estructura del modelo de RNaf de la muñeca

La arquitectura de la RNA diseñada para procesar las señales del acelerómetro colocado en el pecho está basada en el enfoque de RNaf. La cual cuenta con la siguiente estructura:

- **Capa de entrada:** 399 neuronas
  - *Función de activación:* ReLU
- **Primera capa oculta:** 798 neuronas
  - *Función de activación:* ReLU
- **Segunda capa oculta:** 2500 neuronas
  - *Función de activación:* ReLU

- 
- **Tercera capa oculta:** 2000 neuronas
    - *Función de activación:* ReLU
  - **Cuarta capa oculta:** 1500 neuronas
    - *Función de activación:* ReLU
  - **Capa de salida:** 13 neuronas
    - *Función de activación:* Softmax

Matemáticamente hablando la **Propagación hacia adelante** Para cada capa  $l$  de la red, donde  $l = 0, 1, 2, 3, 4, 5$  (entrada, primera capa oculta, segunda capa oculta, tercera capa oculta, cuarta capa oculta y salida), se define como:

**Capa de entrada** ( $l = 0$ ):

$$a^{(0)} = \mathbf{x} \quad (\text{vector de entrada de dimensión } 399)$$

**Primera capa oculta** ( $l = 1$ ):

$$z_j^{(1)} = \sum_{i=1}^{399} w_{ji}^{(1)} a_i^{(0)} + b_j^{(1)}$$

$$a_j^{(1)} = \text{ReLU}(z_j^{(1)}) \quad \text{para } j = 1, 2, \dots, 798$$

**Segunda capa oculta** ( $l = 2$ ):

$$z_j^{(2)} = \sum_{i=1}^{798} w_{ji}^{(2)} a_i^{(1)} + b_j^{(2)}$$

$$a_j^{(2)} = \text{ReLU}(z_j^{(2)}) \quad \text{para } j = 1, 2, \dots, 2500$$

**Tercera capa oculta** ( $l = 3$ ):

$$z_j^{(3)} = \sum_{i=1}^{2500} w_{ji}^{(3)} a_i^{(2)} + b_j^{(3)}$$

$$a_j^{(3)} = \text{ReLU}(z_j^{(3)}) \quad \text{para } j = 1, 2, \dots, 2000$$

**Cuarta capa oculta** ( $l = 4$ ):

$$z_j^{(4)} = \sum_{i=1}^{2000} w_{ji}^{(4)} a_i^{(3)} + b_j^{(4)}$$

$$a_j^{(4)} = \text{ReLU}(z_j^{(4)}) \quad \text{para } j = 1, 2, \dots, 1500$$

**Capa de salida** ( $l = 5$ ):

$$z_k^{(5)} = \sum_{j=1}^{1500} w_{kj}^{(5)} a_j^{(4)} + b_k^{(5)}$$

---


$$a_k^{(5)} = \text{Softmax}(z_k^{(5)}) \quad \text{para } k = 1, 2, \dots, 13$$

donde:  $w_{ji}^{(l)}$  : representa el peso de la conexión entre la neurona  $i$  de la capa anterior  $l-1$  y la neurona  $j$  de la capa  $l$ ,  $z_j^{(l)}$  : es la suma ponderada de las entradas para la neurona  $j$  de la capa  $l$ , que incluye los pesos y las activaciones de la capa anterior, además de un término de sesgo,  $b_j^{(l)}$  : es el sesgo asociado a la neurona  $j$  en la capa  $l$  y  $a_j^{(l)}$  : representa la activación de la neurona  $j$  en la capa  $l$ , que se obtiene aplicando una función de activación (como ReLU o Softmax).

Dado que se utiliza la **categorical crossentropy** para la clasificación multiclase, la entropía cruzada, en general, es una medida de la distancia entre distribuciones de probabilidad. Esta suele ser adecuada en modelos de RNAs cuya salida representa una probabilidad, como cuando se realiza una clasificación categórica con función de activación Softmax, la función de pérdida en este caso se define como:

$$L(\mathbf{y}, \hat{\mathbf{y}}) = -\frac{1}{399} \sum_{i=1}^{399} \sum_{k=1}^{13} y_k \log(a_k^{(5)}) \quad (3.67)$$

donde:  $y_k$  es la etiqueta verdadera (one-hot encoded) y  $a_k^{(5)}$  es la salida predicha de la red,  $N = 399$  es el número total de ejemplos en el conjunto de datos y  $C = 13$  el número de clases en el problema de clasificación.

Para optimizar la red y minimizar la función de pérdida, en los tres casos de los respectivos modelos (pecho, cadera y muñeca) se utiliza el **optimizador Adam**, que combina el descenso de gradiente estocástico con momentos. Este optimizador calcula adaptivamente la tasa de aprendizaje para cada parámetro en función de las estimaciones de los primeros y segundos momentos (media y varianza) de los gradientes. Los parámetros de los pesos y sesgos se actualizan mediante las siguientes fórmulas:

$$w_{ji}^{(l)} \leftarrow w_{ji}^{(l)} - \eta \cdot \frac{\hat{m}_{ji}^{(l)}}{\sqrt{\hat{v}_{ji}^{(l)} + \epsilon}}$$

$$b_j^{(l)} \leftarrow b_j^{(l)} - \eta \cdot \frac{\hat{m}_j^{(l)}}{\sqrt{\hat{v}_j^{(l)} + \epsilon}}$$

donde:

- $\hat{m}$  y  $\hat{v}$  son estimaciones del primer y segundo momento (media y varianza).
- $\eta$  es la tasa de aprendizaje.
- $\epsilon$  es un pequeño valor para evitar divisiones por cero.

Este proceso de actualización ayuda a que el optimizador Adam converja de manera más rápida y estable, ajustando dinámicamente los parámetros del modelo de acuerdo con el comportamiento de los gradientes durante el entrenamiento.

### 3.5.5. Entrenamiento y Validación

El entrenamiento y la validación de modelos basados en RNA son pasos fundamentales en el desarrollo de sistemas de inteligencia artificial capaces de realizar tareas complejas, como la clasificación de actividades. En este proceso, las RNAs aprenden a partir de un conjunto de datos mediante la adaptación de sus parámetros internos, optimizando así su capacidad para hacer predicciones precisas, Figura 3.21.

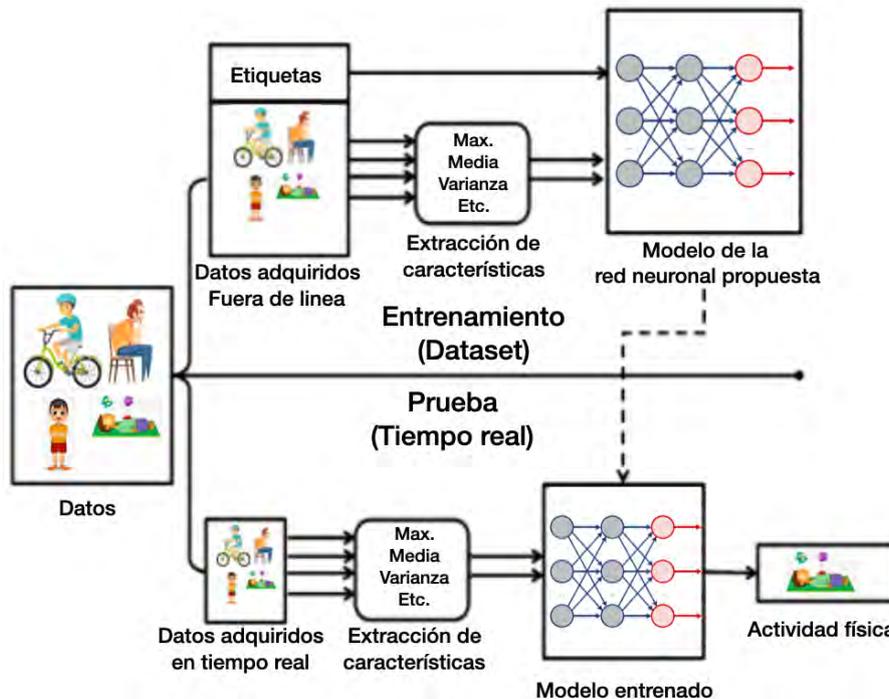


Figura 3.21: Proceso de entrenamiento-prueba en RNAs

Durante la fase de entrenamiento, el modelo se expone a un conjunto de datos de entrenamiento que incluye características relevantes y sus correspondientes etiquetas. Utilizando técnicas como el descenso de gradiente y funciones de pérdida, el modelo ajusta sus pesos y sesgos para minimizar el error en las predicciones. Este proceso se repite a través de múltiples épocas, permitiendo que el modelo refine su capacidad de generalización.

La validación es un componente crítico que se lleva a cabo para evaluar el rendimiento del modelo en datos no vistos. A través de un conjunto de validación, se mide la capacidad del modelo para generalizar y evitar el sobreajuste, lo que puede ocurrir si el modelo se adapta demasiado a los datos de entrenamiento. Métodos como la validación cruzada y el uso de métricas de rendimiento, como la precisión, el recall y la matriz de confusión, resulta fundamental en esta etapa, detalladas en la Sección 2.2.5. Estas métricas permiten no solo cuantificar el desempeño del modelo, sino también identificar en qué clases se producen errores, lo que puede guiar futuras mejoras en el diseño y la selección de características.

---

### 3.5.6. Base de Datos, Repositorio UCI (mHealth)

En el ámbito de la clasificación de actividades y la detección de la posición del sensor, la validación de resultados es fundamental para asegurar la robustez y aplicabilidad de los modelos propuestos. Para ello, se utilizará el conjunto de datos mHealth Dataset, [Banos et al., 2014b]. Este dataset, contiene registros de actividades cotidianas realizadas por sujetos equipados con sensores de smartphones, utilizar esta información permitirá evaluar la capacidad de los modelos para identificar distintas actividades y posiciones en un entorno realista.

Para capturar los datos de las señales de acelerometría, se utilizaron tres acelerómetros triaxiales. Se registraron las aceleraciones de los sensores colocados en el pecho, la muñeca derecha y el tobillo izquierdo de cada sujeto, fijados con correas elásticas para medir el movimiento experimentado por diferentes partes del cuerpo. Todas las actividades de detección se registraron a una tasa de muestreo de 50 Hz. Los datos se recopilaron en un entorno fuera del laboratorio, sin restricciones sobre cómo debían realizarse las actividades. El conjunto de datos incluye grabaciones del movimiento corporal de diez voluntarios con perfiles diversos, recopiladas mientras realizaban 12 actividades físicas, como se muestra en la Tabla 3.4.

Tabla 3.4: Base de datos mHealth

Label	Actividad	Duración
L1	Parado	1 min
L2	Sentado	1 min
L3	Acostado	1 min
L4	Caminar	1 min
L5	Subir Escaleras	1 min
L6	Doblar Cintura Adelante	20x
L7	Elevación Frontal de Brazos	20x
L8	Agacharse	20x
L9	Ciclismo	1 min
L10	Trotar	1 min
L11	Correr	1 min
L12	Saltar	20x

*En la columna "Duración",  $Nx$  es el número de repeticiones de la actividad.*

Este estudio, esta enfocado exclusivamente en las columnas del dataset que contienen las señales de acelerometría, ya que son las que nos permiten analizar y clasificar las actividades físicas considerando el sistema que fue diseñado en este trabajo de tesis.

Las columnas restantes, que incluyen información demográfica de los sujetos y otros datos no relevantes para el objetivo de nuestro trabajo, se han descartado, lo que permite simplificar el análisis y concentrar los esfuerzos en la interpretación de las señales de aceleración obtenidas de los sensores. Por lo tanto, de las 24 columnas disponibles solo se utilizan 11, las cuales se muestran a continuación en la Tabla 3.5.

Tabla 3.5: Estructura base de datos mHealth

Nº Columna	Nombre	Descripción
0	C:0	Aceleración pecho en x
1	C:1	Aceleración pecho en y
2	C:2	Aceleración pecho en z
5	C:5	Aceleración tobillo en x
6	C:6	Aceleración tobillo en y
7	C:7	Aceleración tobillo en z
14	C:14	Aceleración muñeca en x
15	C:15	Aceleración muñeca en y
16	C:16	Aceleración muñeca en z
23	Label	Número Actividad
24	Subject	Número Participante

Antes de utilizar los datos para el entrenamiento de modelos de clasificación, es esencial realizar un preprocesamiento adecuado. La Figura 3.22, es una muestra del estado inicial del dataset, esta muestra la naturaleza cruda de las señales de acelerometría obtenidas, las cuales contienen las señales de las tres posiciones de los acelerómetros en los diferentes ejes, correspondientes al participante 1.

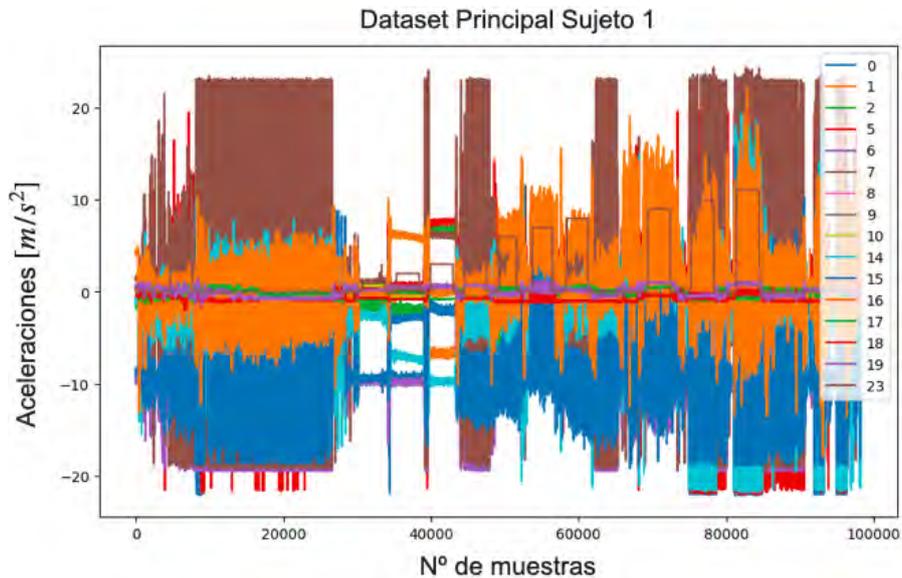


Figura 3.22: Base de datos inicial, sujeto 1

Posteriormente, se separan las señales de acuerdo a la posición del sensor, que en este caso pueden ser ubicados en (pecho, cadera o muñeca), por ejemplo en la Figura 3.23 se presenta el conjunto de datos correspondientes a las señales de aceleración en los ejes (x, y, z) de la posición del pecho del sujeto 1, con sus respectivas etiquetas.

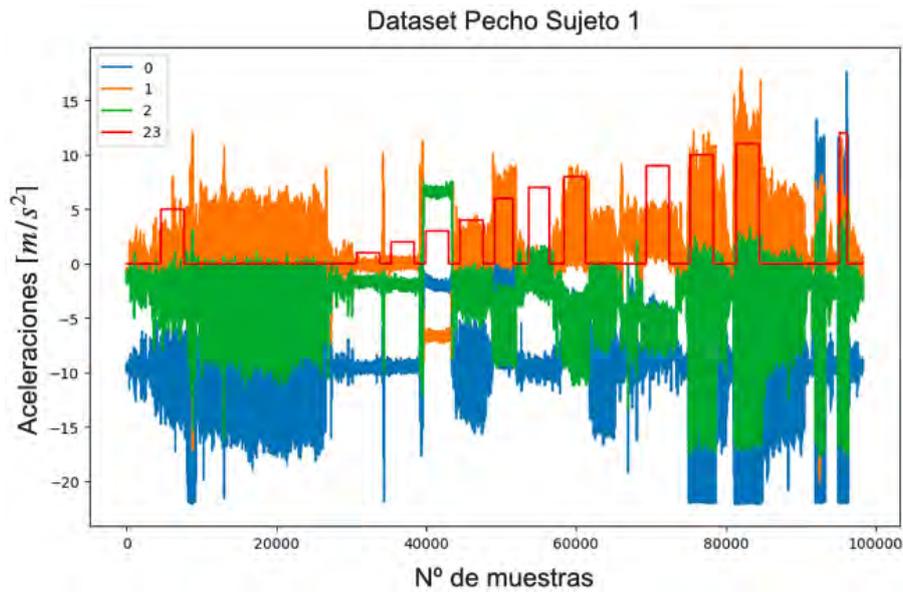


Figura 3.23: Base de datos sujeto 1, señales del pecho

Cada actividad se asocia con una etiqueta específica que permite al modelo identificar de manera efectiva la actividad realizada. Este etiquetado es crucial para el entrenamiento supervisado de los algoritmos propuestos. Las etiquetas indican los datos correspondientes a cada una de las 12 actividades registradas en esta base de datos, donde también se incluye una actividad nula (cuando no se ejecuta ninguna actividad), como se muestra en la Figura 3.24.

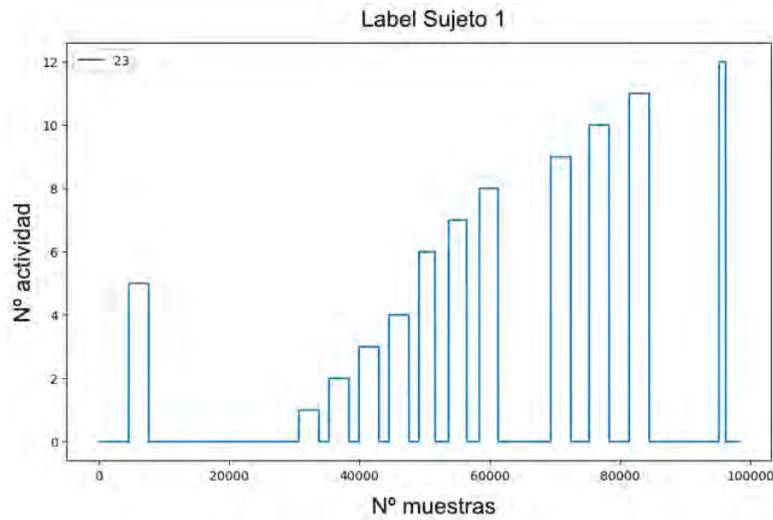


Figura 3.24: Etiquetas, sujeto 1

Finalmente, en la Figura 3.25, se presentan los resultados de la separación de las señales de acelerometría basadas en las Labels, de esta manera se pueden seleccionar los períodos en los que las señales son útiles, visualizar los patrones correspondientes a las diferentes actividades de la base de datos.

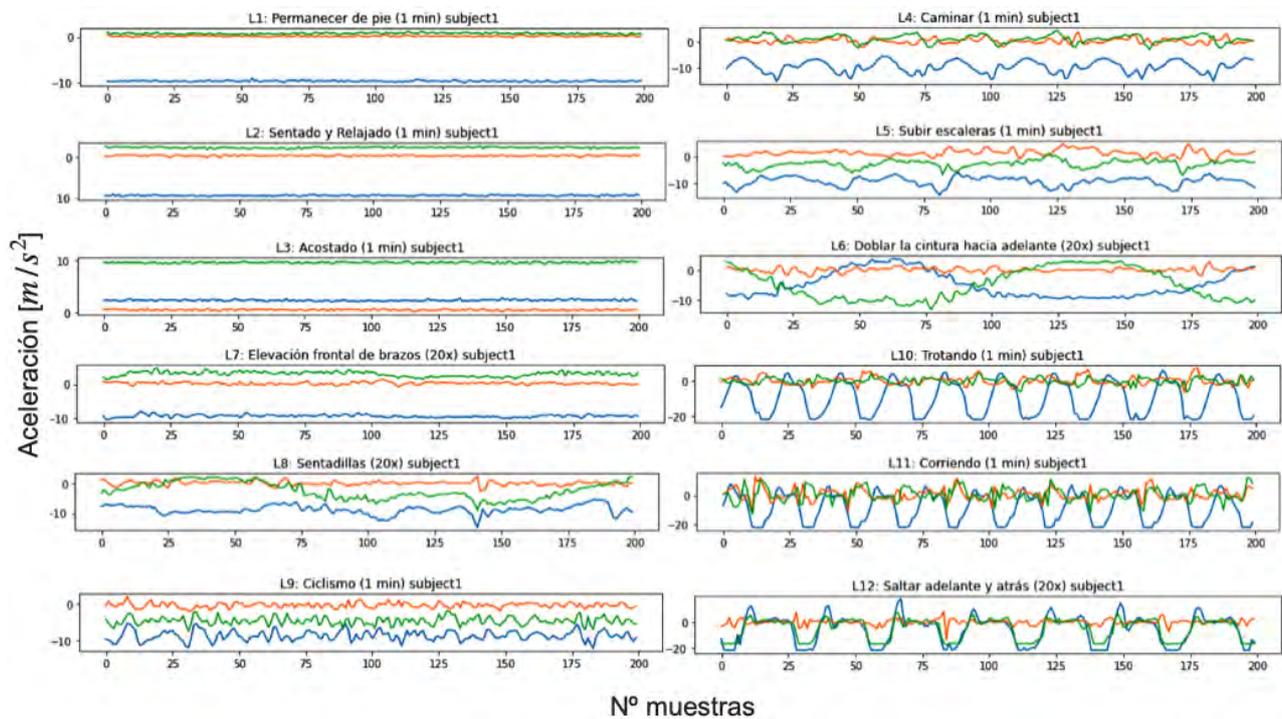


Figura 3.25: Separación de señales sujeto 1, base de datos mHealth

La importancia de contar con una comparativa que incluya diferentes datos radica en la necesidad de verificar la efectividad y generalización de los algoritmos. La variabilidad en las características de los datos, como el tipo de sensor, las condiciones de captura y la demografía de los sujetos, puede influir en el rendimiento de los modelos. De esta manera, se obtiene una visión más completa de la efectividad del enfoque, sino que también se puede identificar su adaptabilidad y resistencia a diferentes contextos.

# Capítulo 4

## Resultados de Implementación

### 4.1. Base de Datos Generada ACTDATA

La generación del dataset se realizó a partir de datos adquiridos por cada participante en un conjunto de actividades físicas, a una frecuencia de muestreo de 35 Hz. Para cada sujeto, se creó un archivo de registro individual, denominado *ACTDATA – sujeto.csv*, donde se almacenaron las señales de los tres acelerómetros utilizados en el estudio. Esto permite que cada archivo contenga de manera organizada y accesible los datos correspondientes a todas las actividades realizadas por el participante.

Cada archivo incluye una serie de muestras registradas por los acelerómetros, las cuales están organizadas en filas. Las columnas del archivo representan las aceleraciones medidas en los ejes (x, y, z) de cada uno de los tres sensores: uno colocado en el pecho, otro en la cadera y un tercero en la muñeca. Esta disposición facilita el análisis de cómo se mueve cada parte del cuerpo en diferentes situaciones. La estructura y el significado de cada una de las columnas se describe a continuación, en la Tabla 4.1.

Tabla 4.1: Estructura base de datos ACTDATA

Nº Columna	Nombre	Descripción
1	x1	Aceleración pecho en x
2	y1	Aceleración pecho en y
3	z1	Aceleración pecho en z
4	x2	Aceleración cadera en x
5	y2	Aceleración cadera en y
6	z2	Aceleración cadera en z
7	x3	Aceleración muñeca en x
8	y3	Aceleración muñeca en y
9	z3	Aceleración muñeca en z
10	Label	Número Actividad
11	Sujeto	Número Participante

Además, las etiquetas de actividad están diseñadas para identificar de manera clara cada tipo de actividad. Por ejemplo, la etiqueta correspondiente a la actividad de acostarse se identifica con el número 3. Esta codificación es fundamental para la etapa de clasificación, ya que

---

permite a los modelos de aprendizaje automático discernir entre las distintas actividades físicas registradas. En la Figura 4.1 se muestra como luce gráficamente la estructura de la base de datos generada por cada participante, señales que posteriormente son separadas y preprocesadas. Ya que en un solo conjunto de datos se tiene información correspondiente a los tres acelerómetros (pecho, cadera y muñeca).

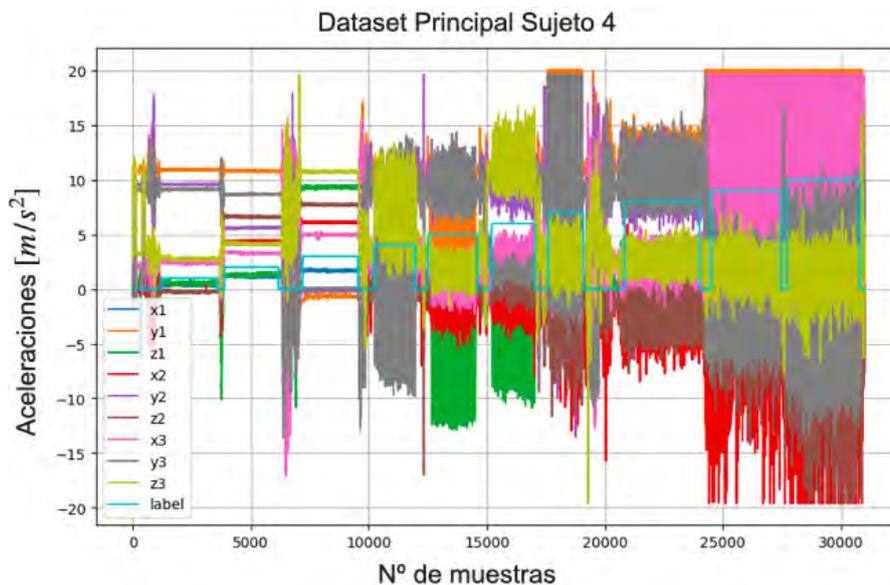


Figura 4.1: Base de datos inicial, sujeto 4

Posteriormente, se separan las señales de la base de datos considerando las diferentes posiciones del sensor, como se muestra en la Figura 4.2, donde se han separado las señales del acelerómetro colocado en el pecho del sujeto 4.

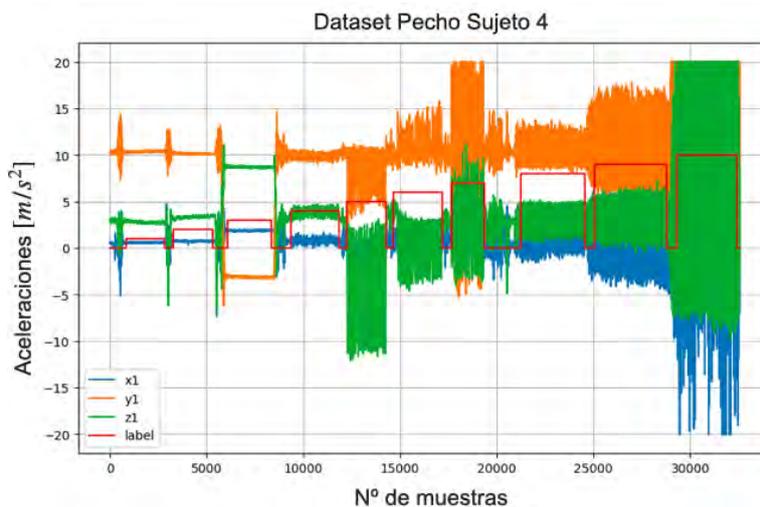


Figura 4.2: Señales pecho, sujeto 4

Con esta estructura se puede identificar las señales entre cada actividad, gracias a la etiqueta, donde se distinguen los periodos donde las señales realmente aportan información a la

clasificación. Esta identificación es fundamental para el entrenamiento efectivo de los modelos ya que permite enfocar el análisis en las secciones de datos que son relevantes y útiles para la tarea de clasificación. En la Figura 4.3 se pueden ver las etiquetas correspondientes a las 10 actividades del conjunto de datos.

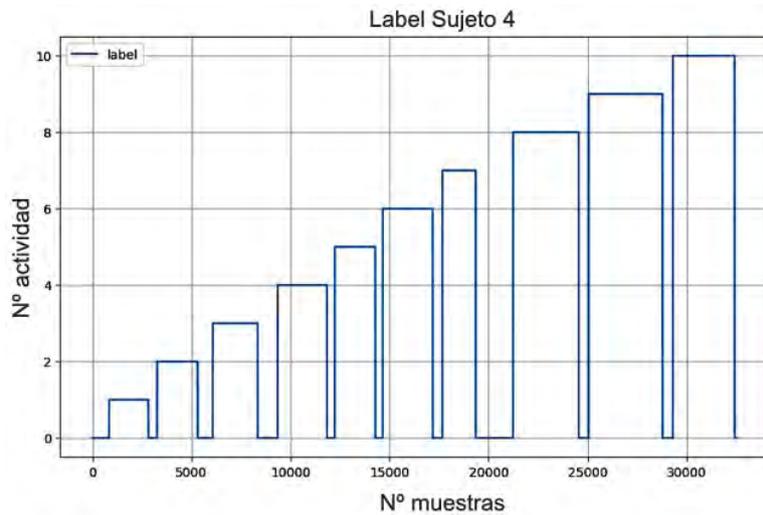


Figura 4.3: Etiquetas, sujeto 4

En la Figura 4.4 se pueden observar las señales de aceleraciones del pecho, separadas por actividad.

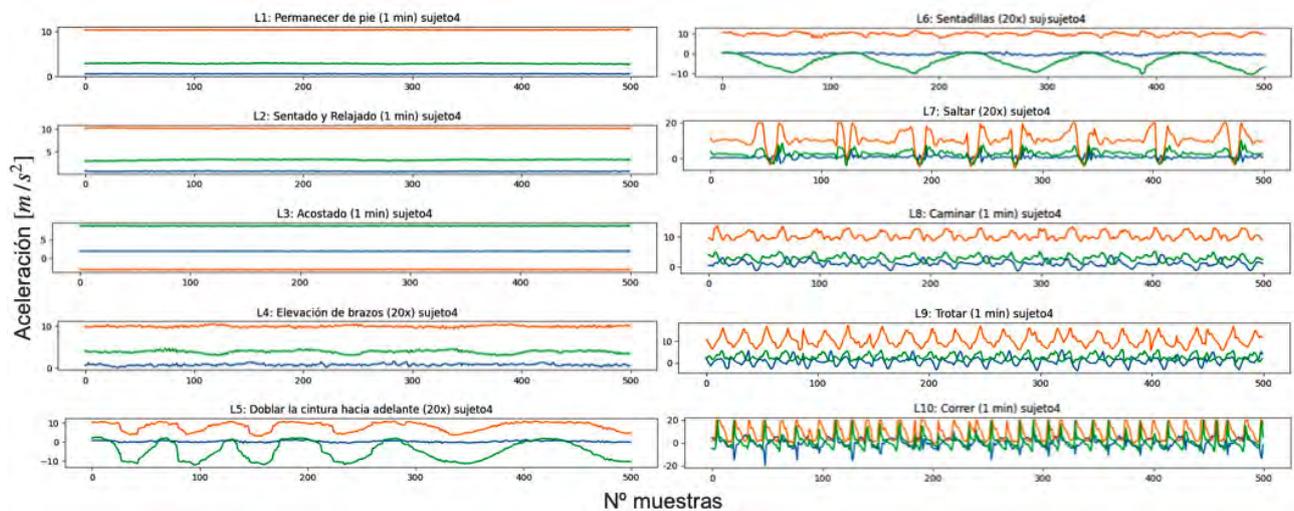


Figura 4.4: Separación de señales sujeto 4, base de datos ACTDATA

## 4.2. Resultados Detección de Posición, Base de Datos ACTDATA

Un clasificador RF es un algoritmo de aprendizaje automático supervisado. Su función principal es construir múltiples árboles de decisión durante el entrenamiento y combinar sus predicciones para obtener una predicción final más robusta y precisa. Cada árbol de decisión se construye utilizando un subconjunto aleatorio de características y un subconjunto aleatorio

de datos de entrenamiento.

Para la clasificación, cada árbol en el bosque genera una predicción de clase y, al final, se utiliza un voto mayoritario o un promedio de las predicciones para determinar la clase final asignada. El algoritmo RF se utilizó para determinar la ubicación del sensor en el cuerpo, dado un vector de características propuesto.

Para el caso del ACDATA, que es el dataset que fue generado a partir de las pruebas de adquisición realizadas en este trabajo, se obtuvieron los resultados en la detección de posición del sensor que se muestran a continuación en las Figuras 4.5 y 4.6.

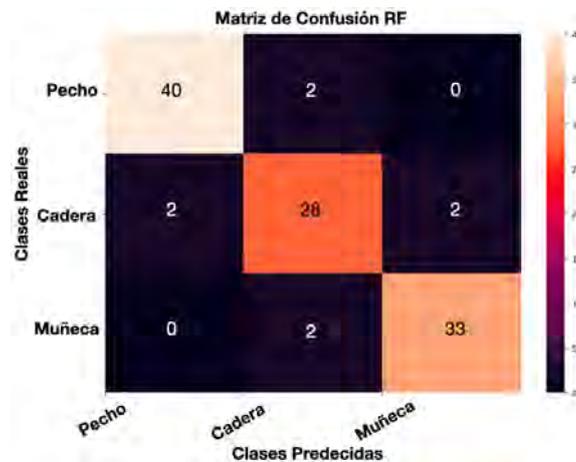


Figura 4.5: Matriz de confusión detección de posición ACTDATA

	Precisión	Recall	F1-score	Support
<b>Clase_Pecho</b>	0.97	0.93	0.95	42
<b>Clase_Cadera</b>	0.84	0.91	0.88	33
<b>Clase_Muñeca</b>	0.94	0.92	0.93	35
<b>accuracy</b>			0.93	109
<b>macro avg</b>	0.91	0.92	0.91	109
<b>weighted avg</b>	0.93	0.92	0.93	109

Figura 4.6: Métricas modelo detección de posición ACTDATA

Se puede deducir que la clase pecho muestra un excelente rendimiento, con una precisión de 0.97 y un F1-score de 0.95. que indica que el modelo es muy confiable. Así mismo, la clase muñeca tiene un buen rendimiento con una precisión de 0.94 y un F1-score de 0.93, lo que indica que el modelo clasifica esta actividad de manera efectiva. Sin embargo, en la posición de la cadera presenta métricas más bajas, con una precisión de 0.84 y un F1-score de 0.88. Esto sugiere que hay más confusión en esta posición, lo que podría deberse a variabilidad en los datos.

### 4.2.1. Resultados Detección de Posición, Repositorio UCI (mHealth)

Un alto rendimiento en la detección de posiciones abre la puerta a aplicaciones prácticas en el ámbito de la salud, el fitness y la rehabilitación, donde es crucial entender cómo se mueve el cuerpo en diferentes contextos. El rendimiento del modelo se muestra en la matriz de confusión de la Figura 4.7, a partir de la cual se pueden determinar algunos puntos importantes.

El uso de características basadas en el radio de curvatura ha demostrado ser un enfoque robusto para la detección de posiciones, lo que sugiere que esta característica es especialmente útil para capturar la dinámica de los movimientos, lo que ha permitido obtener precisiones de hasta 98 %. El modelo de señales de la muñeca, que alcanzó la menor precisión, indica que la elección de la fuente de datos puede influir significativamente en los resultados. Esto sugiere que otras partes del cuerpo o combinaciones de señales podrían también ser investigadas para optimizar aún más la precisión.

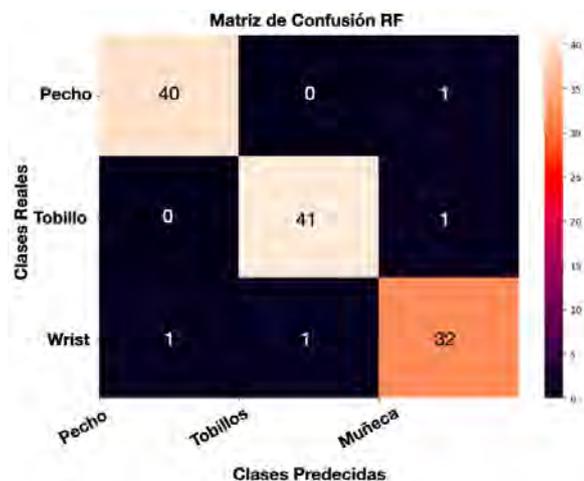


Figura 4.7: Matriz de confusión detección de posición mHealth

	Precisión	Recall	F1-score	Support
<b>Clase_Pecho</b>	0.98	0.98	0.98	41
<b>Clase_Tobillo</b>	0.98	0.98	0.98	42
<b>Clase_Muñeca</b>	0.94	0.94	0.94	34
<b>accuracy</b>			0.97	117
<b>macro avg</b>	0.96	0.96	0.96	117
<b>weighted avg</b>	0.97	0.97	0.97	117

Figura 4.8: Métricas modelo detección de posición mHealth

De acuerdo con la Figura 4.8, los resultados muestran que el modelo RF tiene un rendimiento excelente de forma generalizada, con una precisión, recuperación y F1-score superiores a 0.94 para todas las clases evaluadas, logrando una precisión total del 97 %. Las métricas de promedios macro y ponderado también son altas, lo que indica un rendimiento de clasificación

---

consistente y robusto en todas las clases.

Además, al probar la clasificación utilizando solo el radio de curvatura como característica de entrada, se alcanza una precisión del 70 %, lo que demuestra que esta característica proporciona la información más útil al modelo. Sin embargo, el modelo muestra un rendimiento ligeramente inferior para la clase de la muñeca (94 %) debido en parte, a la alta variabilidad en los movimientos de la mano.

### 4.3. Resultados Clasificación de Actividades, (ACTDATA)

Una vez que se ha determinado la posición del sensor, el siguiente paso es clasificar las 12 actividades previamente etiquetadas. Se utiliza un vector de características propuesto compuesto por 399 elementos como entrada para entrenar los modelos de reconocimiento de actividades, que incluye el radio de curvatura y estadísticas como la media y la varianza, cuyas características se detallan en la Sección 3.3.4.

Los resultados en modelos de RNAs para la clasificación de actividades pueden variar según diversos factores, como la calidad de los datos, la arquitectura de la red, la elección de hiperparámetros y el preprocesamiento de los datos. Por lo tanto, en este trabajo se construyeron tres estructuras diferentes de modelos de redes neuronales de tipo RNAf. En cualquiera de los tres casos, el vector de entrada tiene las mismas dimensiones; por lo tanto, la diferencia radica en los parámetros de la red neuronal aplicada en cada caso.

Los resultados mostrados a continuación el modelo de clasificación de actividad, basándose en los datos que fueron capturados en este trabajo. Para la posición del pecho, en las Figuras 4.9 y 4.10, El modelo tiene un accuracy del 92 %, los promedios macro 0.95 y ponderado 0.96 indican que, las actividades se clasifican bien.

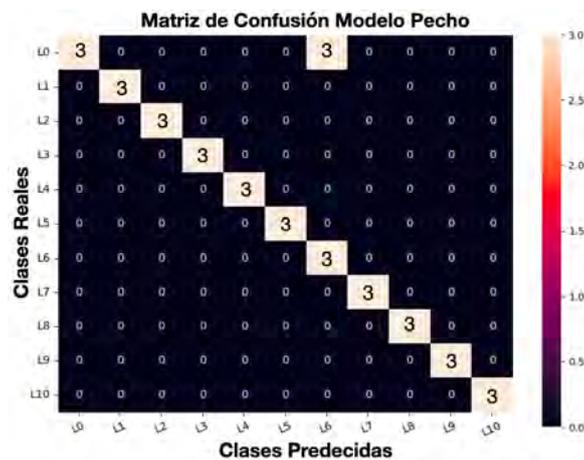


Figura 4.9: Matriz de confusión clasificación de AF del pecho, ACTDATA

El modelo muestra un rendimiento variado en las actividades. La Clase (Nula) tuvo una precisión de 0.50 y un recall de 0.67, indicando confusión en su clasificación. Las actividades (Parado), (Sentado y Relajado), (Acostado Boca Arriba), (Elevación de Brazos), (Dobla Cintura

Adelante), (Saltar), (Caminar), (Trotar) y (Correr) se clasificaron perfectamente, con precisiones y recalls de 1. Sin embargo, (Sentadilla) mostró una precisión de 0.50 y un recall de 1, lo que sugiere que aunque todos los ejemplos fueron identificados, hubo confusión con esa actividad.

	Precisión	Recall	F1-score	Support
clase_0	1	0.50	0.67	6
clase_1	1	1	1	3
clase_2	1	1	1	3
clase_3	1	1	1	3
clase_4	1	1	1	3
clase_5	1	1	1	3
clase_6	0.50	1	0.67	3
clase_7	1	1	1	3
clase_8	1	1	1	3
clase_9	1	1	1	3
clase_10	1	1	1	3
accuracy			0.92	36
macro avg	0.95	0.95	0.94	36
weighted avg	0.96	0.92	0.92	36

Figura 4.10: Métricas modelo clasificación de AF del pecho, ACTDATA

Los resultados del modelo de clasificación para la muñeca Figuras 4.11 y 4.12, muestran un rendimiento mayormente positivo en las actividades. La clase nula tuvo una precisión de 1, pero un recall de 0.50, lo que indica confusión en su identificación. Las actividades (Parado), (Sentado y Relajado), (Acostado Boca Arriba), (Elevación de Brazos), (Sentadilla), (Saltar), (Caminar), (Trotar) y (Correr) se clasificaron perfectamente, con precisiones y recalls de 1.00. Sin embargo, la actividad (Dobla Cintura Adelante) mostró una precisión de 0.50 y un recall de 1.00, sugiriendo problemas de confusión con otras clases. En general, el modelo obtuvo un accuracy del 92%, con promedios macro de 0.95 y ponderados de 0.96, reflejando un sólido desempeño en la mayoría de las actividades.

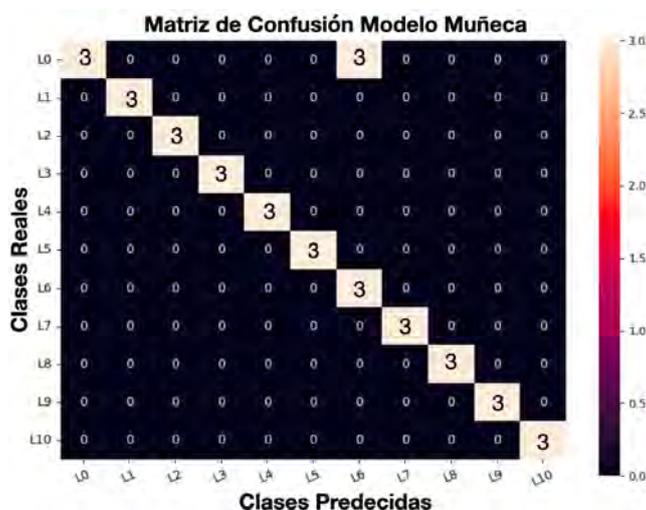


Figura 4.11: Matriz de confusión clasificación de AF de muñeca, ACTDATA

	Precisión	Recall	F1-score	Support
clase_0	1	0.50	0.67	6
clase_1	1	1	1	3
clase_2	1	1	1	3
clase_3	1	1	1	3
clase_4	1	1	1	3
clase_5	0.50	1	0.67	3
clase_6	1	1	1	3
clase_7	1	1	1	3
clase_8	1	1	1	3
clase_9	1	1	1	3
clase_10	1	1	1	3
accuracy			0.92	36
macro avg	0.95	0.95	0.94	36
weighted avg	0.96	0.92	0.92	36

Figura 4.12: Métricas modelo clasificación de AF de muñeca, ACTDATA

En el modelo de clasificación para la cadera Figuras 4.13 y 4.14 muestran un rendimiento mayormente positivo, aunque con algunas inconsistencias. La Clase Nula tuvo una precisión de 1, pero un recall de 0.50, indicando que no se identificaron correctamente todos los casos.

Las actividades (Parado), (Sentado y Relajado), (Acostado Boca Arriba), (Elevación de Brazos),(Saltar), (Caminar), (Trotar) y (Correr) fueron clasificadas sin errores, con precisiones y recalls de 1. La actividad (Dobla Cintura Adelante) presentó un desempeño más bajo, con una precisión de 0.40 y un recall de 0.67, lo que sugiere problemas en su identificación. En (Sentadilla) se mostró una precisión de 0.75 y un recall de 1, indicando que, aunque se identificó correctamente, hubo algunos errores. En general, el modelo alcanzó un accuracy del 90%, con promedios macro de 0.92 y ponderados de 0.93, lo que resalta un buen desempeño en la mayoría de las actividades, pero también indica la necesidad de mejorar en las clases con menor rendimiento.

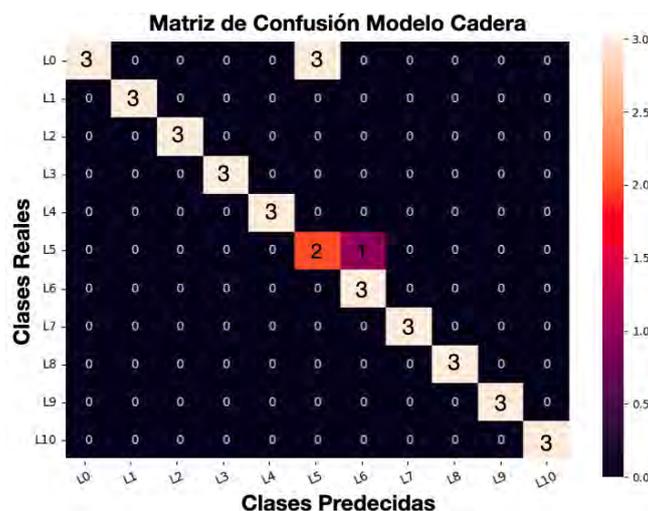


Figura 4.13: Matriz de confusión clasificación de AF de cadera, ACTDATA

	Precisión	Recall	F1-score	Support
clase_0	1	0.50	0.67	6
clase_1	1	1	1	3
clase_2	1	1	1	3
clase_3	1	1	1	3
clase_4	1	1	1	3
clase_5	0.40	0.67	0.50	3
clase_6	0.75	1	0.86	3
clase_7	1	1	1	3
clase_8	1	1	1	3
clase_9	1	1	1	3
clase_10	1	1	1	3
accuracy			0.90	36
macro avg	0.92	0.92	0.91	36
weighted avg	0.93	0.89	0.89	36

Figura 4.14: Métricas modelo clasificación de AF de cadera, ACTDATA

### 4.3.1. Validación LOSO, (ACTDATA)

La validación Leave-One-Subject-Out (LOSO) es una técnica crucial en el ámbito del aprendizaje automático, especialmente en aplicaciones relacionadas con el análisis de datos biométricos y el reconocimiento de actividades humanas. Su propósito principal es evaluar la capacidad de un modelo para generalizar a nuevos sujetos que no han sido utilizados durante el entrenamiento. En lugar de dividir los datos en conjuntos de entrenamiento y prueba de manera aleatoria, la validación LOSO se centra en dejar fuera un sujeto específico en cada iteración, utilizando los datos de los demás sujetos para entrenar el modelo.

Esto permite obtener una estimación más realista del rendimiento del modelo en situaciones del mundo real, donde es probable que se enfrente a datos de individuos no incluidos en el conjunto de entrenamiento, la Tabla 4.2 muestra los resultados de la evaluación LOSO, de la cual se determinan diferentes aspectos importantes.

Tabla 4.2: Resultados validación cruzada (LOSO), ACTDATA

Nº Sujeto	Pecho	Muñeca	Cadera
Sujeto 1	93.12 %	95.68 %	92.22 %
Sujeto 2	93.45 %	95.50 %	92.75 %
Sujeto 3	93.78 %	95.24 %	95.44 %
Sujeto 4	94.04 %	95.01 %	92.39 %
Sujeto 5	94.14 %	94.62 %	91.18 %
Sujeto 6	94.47 %	94.43 %	95.13 %
Sujeto 7	94.60 %	94.25 %	91.49 %
Sujeto 8	94.43 %	94.01 %	93.74 %
Sujeto 9	95.25 %	93.67 %	92.97 %
Sujeto 10	95.59 %	96.42 %	95.31 %
Sujeto 10	95.71 %	95.15 %	94.12 %

Se observa en la evaluación LOSO que las tasas de precisión para cada sujeto son bastante consistentes a lo largo de las diferentes ubicaciones de medición. Esto sugiere que el modelo es robusto y capaz de generalizar.

La muñeca muestra el mejor rendimiento en comparación con el pecho y la cadera, con el valor más alto alcanzando 96.42 %. Esto sugiere que la muñeca es el sitio más confiable para la medición en este contexto, aunque el pecho muestra resultados muy similares. La cadera presenta la menor precisión el porcentaje más bajo alcanzado fue de 91.18 %. Esto podría indicar que las mediciones en la cadera son menos consistentes. Evaluar factores como la calidad de los datos, el método de medición puede ser una opción para mejorar el rendimiento.

### 4.3.2. Resultados Clasificación de Actividades, (mHealth)

Según los resultados del modelo del pecho dadas en las Figuras 4.15 y 4.16, las actividades con un F1-score de 1, lo que indica el mejor rendimiento, son estar de pie (L1), sentarse y relajarse (L2), estar acostado (L3), caminar (L4), inclinarse hacia adelante (L6), elevación frontal de brazos (L7), flexión de rodillas (agacharse) (L8), andar en bicicleta (L9) y saltar hacia adelante y hacia atrás (L12). Esto muestra una precisión y recuperación perfectas para estas actividades. Las actividades con el rendimiento más bajo son subir escaleras (L5), trotar (L10) y correr (L11), que tienen F1-scores más bajos. En general, el modelo tiene una precisión del 95 %, lo que indica una fuerte capacidad de clasificación.

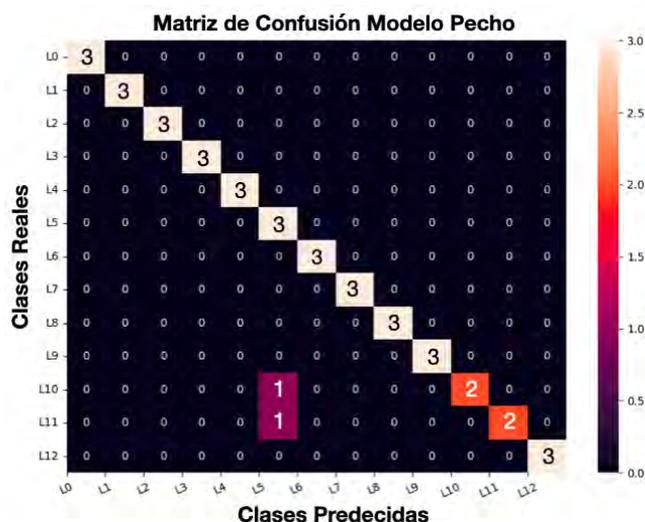


Figura 4.15: Matriz de confusión clasificación de AF en pecho, mHealth

	Precisión	Recall	F1-score	Support
clase_0	1	1	1	3
clase_1	1	1	1	3
clase_2	1	1	1	3
clase_3	1	1	1	3
clase_4	1	1	1	3
clase_5	0.60	1	0.75	3
clase_6	1	1	1	3
clase_7	1	1	1	3
clase_8	1	1	1	3
clase_9	1	1	1	3
clase_10	1	0.67	0.80	3
clase_11	1	0.67	0.80	3
clase_12	1	1	1	3
accuracy			0.95	39
macro avg	0.97	0.95	0.95	39
weighted avg	0.97	0.95	0.95	39

Figura 4.16: Métricas modelo clasificación de AF en pecho, mHealth

De acuerdo con los resultados para el modelo del tobillo, mostrados en las Figuras 4.17 y 4.18, actividades como estar de pie (L1), sentarse y relajarse (L2), estar acostado (L3), subir escaleras (L5), elevación frontal de brazos (L7), flexión de rodillas (agacharse) (L8), andar en bicicleta (L9), trotar (L10), correr (L11) y saltar hacia adelante y hacia atrás (L12) tienen precisiones y recuperaciones de 1, mostrando una clasificación perfecta. Actividades como caminar (L4) y los inclinaciones hacia adelante (L6) presentan precisiones y recuperaciones más bajas, de 0.67, lo que indica menos precisión. En general, el modelo logra una precisión del 95 %, demostrando un rendimiento sólido en la mayoría de los casos.

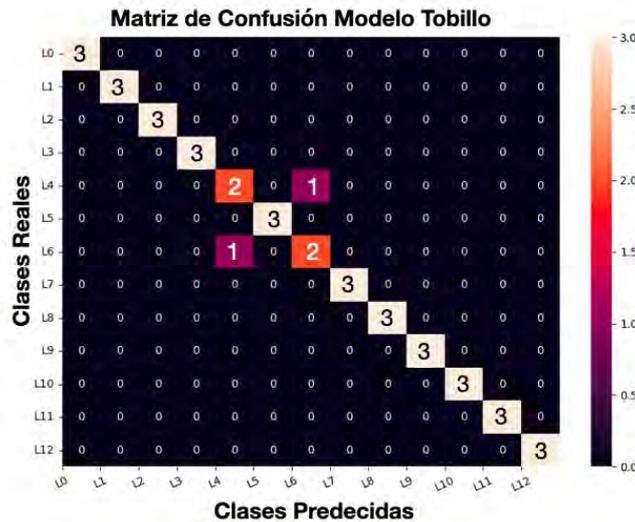


Figura 4.17: Matriz de confusión clasificación de AF en tobillo, mHealth

	Precisión	Recall	F1-score	Support
clase_0	1	1	1	3
clase_1	1	1	1	3
clase_2	1	1	1	3
clase_3	1	1	1	3
clase_4	0.67	0.67	0.67	3
clase_5	1	1	1	3
clase_6	0.67	0.67	0.67	3
clase_7	1	1	1	3
clase_8	1	1	1	3
clase_9	1	1	1	3
clase_10	1	1	1	3
clase_11	1	1	1	3
clase_12	1	1	1	3
accuracy			0.95	39
macro avg	0.95	0.95	0.95	39
weighted avg	0.95	0.95	0.95	39

Figura 4.18: Métricas modelo clasificación de AF en tobillo

Finalmente, para los resultados del modelo de muñeca, dados en las Figuras 4.19 y 4.20, las actividades con el mejor rendimiento, donde el modelo logra una clasificación perfecta sin errores, son estar de pie (L1), sentarse y relajarse (L2), estar acostado (L3), caminar (L4), inclinaciones hacia adelante (L6), elevación frontal de brazos (L7), andar en bicicleta (L9), trotar (L10), correr (L11) y saltar hacia adelante y hacia atrás (L12). La precisión para subir escaleras (L5) y la flexión de rodillas (agacharse) (L8) indica que el porcentaje de veces que el modelo predice la actividad es del 75 % y del 67 %, respectivamente, que son los más bajos. En general, este modelo alcanzó la mayor precisión, con un 97 %.

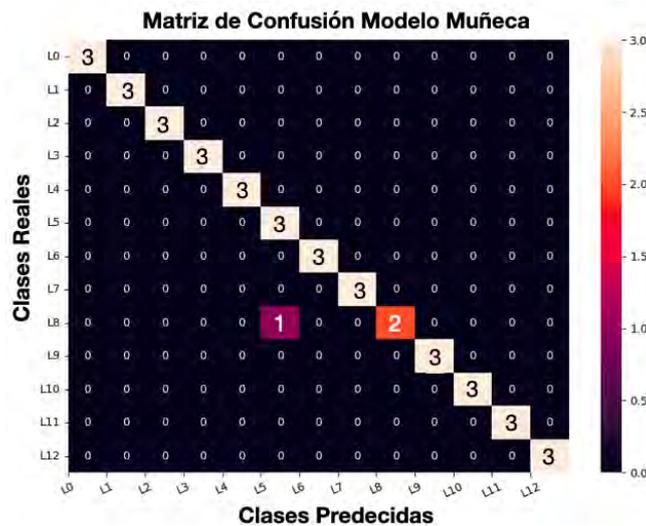


Figura 4.19: Matriz de confusión clasificación de AF en muñeca

	Precisión	Recall	F1-score	Support
clase_0	1	1	1	3
clase_1	1	1	1	3
clase_2	1	1	1	3
clase_3	1	1	1	3
clase_4	1	1	1	3
clase_5	0.75	1	0.86	3
clase_6	1	1	1	3
clase_7	1	1	1	3
clase_8	1	0.67	0.80	3
clase_9	1	1	1	3
clase_10	1	1	1	3
clase_11	1	1	1	3
clase_12	1	1	1	3
accuracy			0.97	39
macro avg	0.98	0.97	0.97	39
weighted avg	0.98	0.97	0.97	39

Figura 4.20: Métricas modelo clasificación de AF en muñeca, mHealth

Al utilizar solo el radio de curvatura para entrenar los modelos, las tasas de precisión son del 72 % para el pecho, 73 % para el tobillo y 77 % para la muñeca, lo que resalta la utilidad de esta característica.

### 4.3.3. Validación LOSO, (mHealth)

La evaluación LOSO se muestra en la Tabla 4.3 y revela una notable consistencia en las precisiones obtenidas; las variaciones entre sujetos son mínimas. Esto indica que el modelo es robusto frente a las diferencias individuales en los datos. Mientras que los sensores del pecho y de la muñeca muestran precisiones consistentemente altas, el sensor del tobillo presenta una ligera variabilidad. Esto sugiere que, aunque los sensores del pecho y de la muñeca ofrecen una mayor estabilidad en la clasificación, el sensor del tobillo puede estar sujeto a más ruido o variabilidad en los datos, debido al impacto del pie con el piso lo que influye en la precisión del modelo.

Tabla 4.3: Resultados validación cruzada (LOSO), mHealth

Nº Sujeto	Pecho	Muñeca	Tobillo
Sujeto 1	96.34 %	98.12 %	94.72 %
Sujeto 2	96.87 %	98.25 %	95.21 %
Sujeto 3	97.21 %	98.08 %	94.85 %
Sujeto 4	96.12 %	97.99 %	95.67 %
Sujeto 5	97.85 %	98.43 %	94.18 %
Sujeto 6	96.63 %	98.51 %	95.73 %
Sujeto 7	95.21 %	97.92 %	95.49 %
Sujeto 8	97.34 %	98.67 %	94.92 %
Sujeto 9	97.58 %	97.84 %	93.67 %
Sujeto 10	97.96 %	98.29 %	95.26 %

# Capítulo 5

## Conclusiones

El trabajo de clasificación de actividad y detección de posición está inspirado en este caso en un parámetro cinemático antropométrico, denominado radio de curvatura, aunque este concepto matemático es bien definido, no ha sido utilizado anteriormente en el análisis de movimientos humanos para la ejecución de sistemas HAR. The modelos of clasificación that are capaz to obtain a desempe o elevated o de un desempe nicamente con caracter sticas of naturaleza aritmética, nicamente complementándolo, nicamente with caracter sticas of naturaleza aritmética, lo son la varianza y la media.

Los resultados muestran que las características propuestas are adecuadas y efectivas para construir modelos robustos de clasificación de actividades físicas y de detección de posición del sensor, utilizando únicamente señales de acelerometría. Notablemente, el uso del radio de curvatura por sí solo alcanza una precisión de hasta el 77%. Esto resalta el papel significativo del radio de curvatura en los modelos HAR, proporcionando información crucial sobre la dinámica y las características de los movimientos humanos, considerando múltiples planos bidimensionales, lo que ha permitido tener una perspectiva completa de los mismos.

En el primer experimento, donde se utilizaron los datos adquiridos (ACTDATA), las tasas de precisión para el pecho varían entre 93.12% y 95.71%, con un promedio de alrededor de 94.2%. En el segundo experimento, que utiliza el dataset del repositorio UCI (mHealth), las precisiones para el pecho oscilan de 96.34% a 97.96%, con un promedio de aproximadamente 96.62%. Estos resultados indican que el uso de datos provenientes de la literatura ofrece un rendimiento superior. No obstante, esto también sugiere que puede haber problemas en los datos adquiridos, como pérdida de datos o ruido, ya que la variabilidad y las menores tasas de precisión indican que el modelo podría no estar funcionando a su máxima capacidad debido a la calidad inferior de los datos. Así mismo, esta doble validación permite comprobar la eficiencia de los modelos de clasificación considerando, ciertas variaciones en las condiciones de ejecución de las actividades.

Sin embargo, es crucial destacar que la adquisición de datos fue una etapa fundamental en el desarrollo de este trabajo. Aunque el objetivo no era generar una base de datos, esta fase desempeñó un papel clave al facilitar la adopción del concepto del radio de curvatura. A través del desarrollo y la interacción con el sistema de adquisición de datos, se realizó la inspección visual de los diferentes patrones de movimiento generados al ejecutar diversas actividades físicas. Este análisis no solo ayudó a familiarizarse con los diferentes patrones de movimiento,

---

sino que también inspiró la idea de que estas trayectorias podrían ser utilizadas para calcular circunferencias relacionadas con las diferentes dinámicas de movimientos realizados en las múltiples actividades físicas estudiadas.

Esta relación entre la adquisición de datos y la adopción del radio de curvatura subraya la importancia de esta etapa en el desarrollo del trabajo doctoral, demostrando cómo la observación directa y el análisis de los patrones de movimiento pueden enriquecer el enfoque de los sistemas HAR.

El modelo de RF muestra un rendimiento general bueno, alcanzando una precisión superior de hasta el 97 %, lo que indica su capacidad para clasificar correctamente la mayoría de las posiciones. Sin embargo, el modelo basado en las señales que provienen de la cadera presenta ciertas dificultades para realizar la detección de posición, lo que coincide con el desempeño observado en los modelos de clasificación de actividad, que tienen un accuracy general del 93 %. Esto sugiere que, de las tres posiciones seleccionadas, la que corresponde a la cadera es la que muestra menor efectividad. La precisión inferior en los modelos de señales provenientes de la cadera se atribuye principalmente a la dificultad de mantener el sensor en la posición adecuada, que debe coincidir con el punto de unión entre la cadera y la pierna. Esta falta de estabilidad impacta directamente en la consistencia de las señales, provocando ruido y variabilidad que afectan el rendimiento del modelo.

Finalmente, el uso de este enfoque, que emplea características simples pero directamente relacionadas con el comportamiento de la cinemática de los movimientos, permite alcanzar precisiones comparables a las de métodos que utilizan transformaciones complejas y requieren una considerable fuerza bruta de procesamiento. Esta simplicidad no solo facilita la implementación y optimización de los modelos, sino que también mejora su aplicabilidad en entornos del mundo real, donde la eficiencia y la rapidez son cruciales. Al reducir la complejidad del análisis, el enfoque ofrece una ventaja significativa, haciéndolo más accesible y práctico.

## 5.1. Discusión y Limitaciones

La ventaja de nuestra metodología radica en su capacidad para lograr alta precisión utilizando solo unas pocas características; esto ofrece beneficios en términos de simplicidad y eficiencia computacional. A diferencia de los métodos que emplean características en el dominio de la frecuencia o combinaciones de ambos dominios, nuestro enfoque evita transformaciones complejas, reduciendo así los requisitos de procesamiento y memoria.

Sin embargo, el cálculo del radio de curvatura es altamente dependiente de la dinámica del movimiento. En actividades con poca variación dinámica, la capacidad del modelo para extraer información útil puede verse disminuida. La sensibilidad del radio de curvatura a la falta de variabilidad en los datos puede limitar la efectividad del método, lo que sugiere que futuras investigaciones deberían abordar estos aspectos para optimizar aún más la precisión y aplicabilidad en diversos escenarios de monitoreo de actividad física.

A pesar de estos desafíos, la simplicidad y eficiencia de nuestro enfoque ofrecen un equilibrio muy favorable entre rendimiento y carga computacional. A diferencia de otras metodologías en

---

el ámbito del sistemas HAR, que requieren transformaciones complejas y costosas desde el punto de vista computacional como la extracción de características avanzadas , nuestro enfoque evita este tipo de procesos pesados. Estas metodologías complejas suelen necesitar grandes cantidades de datos y poder de procesamiento, lo que limita su implementación en sistemas portátiles y dispositivos con recursos limitados, como los wearables.

En contraste, nuestro modelo es más accesible para su implementación en tiempo real, lo que lo convierte en una opción ideal para aplicaciones de monitoreo de actividad física en dispositivos móviles, donde la eficiencia y el bajo consumo de recursos son esenciales. Así, mientras otros enfoques pueden tener una alta precisión en entornos controlados, el nuestro se distingue por su capacidad para operar de manera efectiva en condiciones más exigentes, sin comprometer el rendimiento y aprovechando al máximo las capacidades de los dispositivos portátiles.

## 5.2. Trabajos futuros

Los trabajos adicionales que se podrían realizar en un futuro a partir de este trabajo de tesis son:

- **Mejorar la extracción de características:** Investigar nuevas características adicionales o combinaciones de características que puedan complementarse con el radio de curvatura, especialmente en actividades con baja variabilidad dinámica, para mejorar la capacidad del modelo de extraer información útil.
- **Optimización del modelo:** Desarrollar y probar algoritmos de machine learning más avanzados o híbridos que puedan combinar efectivamente el radio de curvatura con otras métricas de movimiento, buscando mejorar la precisión y la robustez en diferentes escenarios de actividad física.
- **Análisis de variabilidad:** Realizar estudios que analicen la sensibilidad del modelo a la variabilidad de los datos. Esto podría incluir la recopilación de datos en un rango más amplio de condiciones y tipos de movimiento para evaluar el rendimiento en diversas situaciones.
- **Aplicaciones en dispositivos portátiles:** Investigar la implementación de los modelos desarrollados en dispositivos portátiles, enfocándose en la optimización de la eficiencia computacional y el consumo de energía, lo cual es crucial para su uso en tiempo real.
- **Validación en escenarios del mundo real:** Llevar a cabo estudios de validación en escenarios del mundo real, donde se evalúe la efectividad de los modelos en situaciones cotidianas y variadas, como deportes, ejercicios en casa, y actividades laborales.
- **Exploración de métodos complementarios:** Considerar la integración de métodos de análisis en el dominio de la frecuencia o enfoques multimodales que puedan proporcionar un contexto adicional sobre el comportamiento humano, potencialmente mejorando la precisión de la clasificación.

---

Los puntos anteriores mencionan algunas de las oportunidades que pueden dar seguimiento a esta investigación, no solo pueden abordar las limitaciones actuales, sino también expandir el impacto y la aplicabilidad de los modelos de clasificación de actividad física en diversas áreas y en la vida real.

# Bibliografía

- [Acevedo et al., 2017] Acevedo, E., Serna, A., and Serna, E. (2017). Principios y características de las redes neuronales artificiales. *Desarrollo e innovación en ingeniería*, 173.
- [Afshin et al., 2016] Afshin, A., Babalola, D., Mclean, M., Yu, Z., Ma, W., Chen, C.-Y., Arabi, M., and Mozaffarian, D. (2016). Information technology and lifestyle: a systematic evaluation of internet and mobile interventions for improving diet, physical activity, obesity, tobacco, and alcohol use. *Journal of the American Heart Association*, 5(9):e003058.
- [Alfonso Mantilla, 2017] Alfonso Mantilla, J. (2017). Uses of accelerometers in physiotherapy: A review of the literature. *REVISTA IBEROAMERICANA DE CIENCIAS DE LA ACTIVIDAD FISICA Y EL DEPORTE*, 6(2):38–45.
- [Alshorman et al., 2020] Alshorman, O., Alshorman, B., and Masadeh, M. S. (2020). A review of physical human activity recognition chain using sensors. *Indonesian Journal of Electrical Engineering and Informatics*, 8(3):560–573.
- [AlShorman et al., 2020] AlShorman, O., Alshorman, B., and Masadeh, M. S. (2020). A review of physical human activity recognition chain using sensors. *Indonesian Journal of Electrical Engineering and Informatics (IJEI)*, 8(3):560–573.
- [Altini et al., 2014] Altini, M., Penders, J., Vullers, R., and Amft, O. (2014). Estimating energy expenditure using body-worn accelerometers: a comparison of methods, sensors number and positioning. *IEEE journal of biomedical and health informatics*, 19(1):219–226.
- [Alzahrani and Kammoun, 2016] Alzahrani, M. and Kammoun, S. (2016). Human activity recognition: Challenges and process stages. *International Journal of Innovative Research in Computer and Communication Engineering*, 5:1111–1118.
- [Andreu-Perez et al., 2015] Andreu-Perez, J., Leff, D. R., Ip, H. M., and Yang, G.-Z. (2015). From wearable sensors to smart implants—toward pervasive and personalized healthcare. *IEEE Transactions on Biomedical Engineering*, 62(12):2750–2762.
- [Arvidsson et al., 2019] Arvidsson, D., Fridolfsson, J., and Börjesson, M. (2019). Measurement of physical activity in clinical practice using accelerometers. *Journal of internal medicine*, 286(2):137–153.
- [Asanza and Olivo, 2018] Asanza, W. R. and Olivo, B. M. (2018). Redes neuronales artificiales aplicadas al reconocimiento de patrones. *Editorial UTMACH*, 1(4):5.

- 
- [Atiq et al., 2019] Atiq, F., Mauser-Bunschoten, E. P., Eikenboom, J., van Galen, K. P., Meijer, K., de Meris, J., Cnossen, M. H., Beckers, E. A., Laros-van Gorkom, B. A., Nieuwenhuizen, L., et al. (2019). Sports participation and physical activity in patients with von willebrand disease. *Haemophilia*, 25(1):101–108.
- [Banos et al., 2014a] Banos, O., Galvez, J.-M., Damas, M., Pomares, H., and Rojas, I. (2014a). Window size impact in human activity recognition. *Sensors*, 14(4):6474–6499.
- [Banos et al., 2014b] Banos, O., Garcia, R., Holgado-Terriza, J. A., Damas, M., Pomares, H., Rojas, I., and Saez, A. (2014b). Villalonga, c. mhealthdroid: A novel framework for agile development of mobile health applications. In *Proceedings of the International Workshop on Ambient Assisted Living, Belfast, UK*, pages 2–5.
- [Bao and Intille, 2004] Bao, L. and Intille, S. S. (2004). Activity recognition from user-annotated acceleration data. In *International conference on pervasive computing*, pages 1–17. Springer.
- [Bennasar et al., 2022] Bennasar, M., Price, B. A., Gooch, D., Bandara, A. K., and Nuseibeh, B. (2022). Significant features for human activity recognition using tri-axial accelerometers. *Sensors*, 22(19):7482.
- [Benson et al., 2018] Benson, L. C., Clermont, C. A., Osis, S. T., Kobsar, D., and Ferber, R. (2018). Classifying running speed conditions using a single wearable sensor: Optimal segmentation and feature extraction methods. *Journal of biomechanics*, 71:94–99.
- [Bharti et al., 2018] Bharti, P., De, D., Chellappan, S., and Das, S. K. (2018). Human: Complex activity recognition with multi-modal multi-positional body sensing. *IEEE Transactions on Mobile Computing*, 18(4):857–870.
- [Bharti et al., 2019] Bharti, P., De, D., Chellappan, S., and Das, S. K. (2019). HuMAN: Complex activity recognition with multi-modal multi-positional body sensing. *IEEE Transactions on Mobile Computing*, 18(4):857–870.
- [Bhaskar and Singh, 2012] Bhaskar, K. and Singh, S. N. (2012). Awnn-assisted wind power forecasting using feed-forward neural network. *IEEE transactions on sustainable energy*, 3(2):306–315.
- [Biddle and Asare, 2011] Biddle, S. J. and Asare, M. (2011). Physical activity and mental health in children and adolescents: a review of reviews. *British journal of sports medicine*, 45(11):886–895.
- [Black et al., 2019] Black, N., Johnston, D. W., Propper, C., and Shields, M. A. (2019). The effect of school sports facilities on physical activity, health and socioeconomic status in adulthood. *Social Science & Medicine*, 220:120–128.
- [Breiman, 2001] Breiman, L. (2001). Random forests. *Machine learning*, 45:5–32.
- [Bulling et al., 2014a] Bulling, A., Blanke, U., and Schiele, B. (2014a). A tutorial on human activity recognition using body-worn inertial sensors. *ACM Computing Surveys*, 46(3):1–33.

- 
- [Bulling et al., 2014b] Bulling, A., Blanke, U., and Schiele, B. (2014b). A tutorial on human activity recognition using body-worn inertial sensors. *ACM Computing Surveys (CSUR)*, 46(3):1–33.
- [Cao, 2015] Cao, Z.-B. (2015). Physical activity levels and physical activity recommendations in japan. *Physical Activity, Exercise, Sedentary Behavior and Health*, pages 3–15.
- [Catal and Akbulut, 2018] Catal, C. and Akbulut, A. (2018). Automatic energy expenditure measurement for health science. *Computer methods and programs in biomedicine*, 157:31–37.
- [Chaix, 2018] Chaix, B. (2018). Mobile sensing in environmental health and neighborhood research. *Annual review of public health*, 39:367–384.
- [Chodzko-Zajko et al., 2009] Chodzko-Zajko, W. J., Proctor, D. N., Singh, M. A. F., Minson, C. T., Nigg, C. R., Salem, G. J., and Skinner, J. S. (2009). Exercise and physical activity for older adults. *Medicine & science in sports & exercise*, 41(7):1510–1530.
- [Ciuti et al., 2015] Ciuti, G., Ricotti, L., Menciacchi, A., and Dario, P. (2015). Mems sensor technologies for human centred applications in healthcare, physical activities, safety and environmental sensing: A review on research activities in italy. *Sensors*, 15(3):6441–6468.
- [Clevenger et al., 2020a] Clevenger, K. A., Pfeiffer, K. A., and Montoye, A. H. (2020a). Cross-generational comparability of hip- and wrist-worn ActiGraph GT3X+, wGT3X-BT, and GT9X accelerometers during free-living in adults. *Journal of Sports Sciences*, 00(00):1–9.
- [Clevenger et al., 2020b] Clevenger, K. A., Pfeiffer, K. A., and Montoye, A. H. (2020b). Cross-generational comparability of hip-and wrist-worn actigraph gt3x+, wgt3x-bt, and gt9x accelerometers during free-living in adults. *Journal of Sports Sciences*, 38(24):2794–2802.
- [Coskun et al., 2015] Coskun, D., Incel, O. D., and Ozgovde, A. (2015). Phone position/placement detection using accelerometer: Impact on activity recognition. In *2015 IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*, pages 1–6. IEEE.
- [Cosma and McGinnity, 2019] Cosma, G. and McGinnity, T. M. (2019). Feature extraction and classification using leading eigenvectors: applications to biomedical and multi-modal mhealth data. *IEEE Access*, 7:107400–107412.
- [Crouter et al., 2015] Crouter, S. E., Flynn, J. I., and Bassett Jr, D. R. (2015). Estimating physical activity in youth using a wrist accelerometer. *Medicine and science in sports and exercise*, 47(5):944.
- [Cruciani et al., 2018] Cruciani, F., Cleland, I., Nugent, C., McCullagh, P., Synnes, K., and Hallberg, J. (2018). Automatic annotation for human activity recognition in free living using a smartphone. *Sensors*, 18(7):2203.
- [Dehghani et al., 2019] Dehghani, A., Sarbishei, O., Glatard, T., and Shihab, E. (2019). A quantitative comparison of overlapping and non-overlapping sliding windows for human activity recognition using inertial sensors. *Sensors*, 19(22):5026.
-

- 
- [Dua et al., 2021] Dua, N., Singh, S. N., and Semwal, V. B. (2021). Multi-input cnn-gru based human activity recognition using wearable sensors. *Computing*, 103(7):1461–1478.
- [Durmaz Incel, 2015] Durmaz Incel, O. (2015). Analysis of movement, orientation and rotation-based sensing for phone placement recognition. *Sensors*, 15(10):25474–25506.
- [D’Arco et al., 2023] D’Arco, L., Wang, H., and Zheng, H. (2023). Deephar: a deep feed-forward neural network algorithm for smart insole-based human activity recognition. *Neural Computing and Applications*, 35(18):13547–13563.
- [Emmert-Streib et al., 2020] Emmert-Streib, F., Yang, Z., Feng, H., Tripathi, S., and Dehmer, M. (2020). An introductory review of deep learning for prediction models with big data. *Frontiers in Artificial Intelligence*, 3:4.
- [Fridolfsson et al., 2019] Fridolfsson, J., Börjesson, M., Buck, C., Ekblom, Ö., Ekblom-Bak, E., Hunsberger, M., Lissner, L., and Arvidsson, D. (2019). Effects of frequency filtering on intensity and noise in accelerometer-based physical activity measurements. *Sensors*, 19(9):2186.
- [Fujinami and Kouchi, 2012] Fujinami, K. and Kouchi, S. (2012). Recognizing a mobile phone’s storing position as a context of a device and a user. In *International Conference on Mobile and Ubiquitous Systems: Computing, Networking, and Services*, pages 76–88. Springer.
- [Gao et al., 2019] Gao, X., Luo, H., Wang, Q., Zhao, F., Ye, L., and Zhang, Y. (2019). A human activity recognition algorithm based on stacking denoising autoencoder and lightgbm. *Sensors*, 19(4):947.
- [Garnotel et al., 2019] Garnotel, M., Simon, C., and Bonnet, S. (2019). Physical activity estimation from accelerometry. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 6–10. IEEE.
- [Gayathri et al., 2022] Gayathri, J., Abraham, B., Sujarani, M., and Nair, M. S. (2022). A computer-aided diagnosis system for the classification of covid-19 and non-covid-19 pneumonia on chest x-ray images by integrating cnn with sparse autoencoder and feed forward neural network. *Computers in biology and medicine*, 141:105134.
- [Geravesh and Rupapara, 2023] Geravesh, S. and Rupapara, V. (2023). Artificial neural networks for human activity recognition using sensor based dataset. *Multimedia Tools and Applications*, 82(10):14815–14835.
- [Ghasemi et al., 2017] Ghasemi, V., Pouyan, A. A., and Sharifi, M. (2017). Human activity recognition in smart homes based on a difference of convex programming problem. *KSII Transactions on Internet and Information Systems (TIIS)*, 11(1):321–344.
- [Gholamiangonabadi et al., 2020] Gholamiangonabadi, D., Kiselov, N., and Grolinger, K. (2020). Deep neural networks for human activity recognition with wearable sensors: Leave-one-subject-out cross-validation for model selection. *Ieee Access*, 8:133982–133994.
- [Gil-Martin et al., 2020] Gil-Martin, M., San-Segundo, R., Fernandez-Martinez, F., and Ferreiros-López, J. (2020). Improving physical activity recognition using a new deep learning architecture and post-processing techniques. *Engineering Applications of Artificial Intelligence*, 92:103679.
-

- 
- [Gjoreski and Gams, 2011] Gjoreski, H. and Gams, M. (2011). Accelerometer data preparation for activity recognition. In *Proceedings of the International Multiconference Information Society, Ljubljana, Slovenia*, volume 1014, page 1014.
- [Gordon-Rodriguez et al., 2020] Gordon-Rodriguez, E., Loaiza-Ganem, G., Pleiss, G., and Cunningham, J. P. (2020). Uses and abuses of the cross-entropy loss: Case studies in modern deep learning.
- [Hafeez et al., 2023] Hafeez, S., Alotaibi, S. S., Alazeb, A., Al Mudawi, N., and Kim, W. (2023). Multi-sensor-based action monitoring and recognition via hybrid descriptors and logistic regression. *IEEE Access*, 11:48145–48157.
- [Hanai et al., 2009] Hanai, Y., Nishimura, J., and Kuroda, T. (2009). Haar-like filtering for human activity recognition using 3d accelerometer. In *2009 IEEE 13th Digital Signal Processing Workshop and 5th IEEE Signal Processing Education Workshop*, pages 675–678. IEEE.
- [Haskell and Kiernan, 2000] Haskell, W. L. and Kiernan, M. (2000). Methodologic issues in measuring physical activity and physical fitness when evaluating the role of dietary supplements for physically active people. *The American journal of clinical nutrition*, 72(2):541S–550S.
- [Haykin, 1998] Haykin, S. (1998). *Neural networks: a comprehensive foundation*. Prentice Hall PTR.
- [Haykin, 2009] Haykin, S. (2009). *Neural networks and learning machines, 3/E*. Pearson Education India.
- [Hemeida et al., 2020] Hemeida, A. M., Hassan, S. A., Mohamed, A.-A. A., Alkhalaf, S., Mahmoud, M. M., Senjyu, T., and El-Din, A. B. (2020). Nature-inspired algorithms for feed-forward neural network classifiers: A survey of one decade of research. *Ain Shams Engineering Journal*, 11(3):659–675.
- [Henpraserttae et al., 2011] Henpraserttae, A., Thiemjarus, S., and Marukatat, S. (2011). Accurate activity recognition using a mobile phone regardless of device orientation and location. In *2011 International Conference on Body Sensor Networks*, pages 41–46. IEEE.
- [Hu et al., 2019] Hu, C., Chen, Y., Peng, X., Yu, H., Gao, C., and Hu, L. (2019). A novel feature incremental learning method for sensor-based activity recognition. *IEEE Transactions on Knowledge and Data Engineering*, 31(6):1038–1050.
- [Hutabarat et al., 2023] Hutabarat, J. P., Ahmadi, N., and Adiono, T. (2023). Human activity recognition based on wearable devices and feedforward neural networks. In *2023 International Conference on Electrical Engineering and Informatics (ICEEI)*, pages 1–4. IEEE.
- [Ihianle et al., 2020] Ihianle, I. K., Nwajana, A. O., Ebenuwa, S. H., Otuka, R. I., Owa, K., and Orisatoki, M. O. (2020). A deep learning approach for human activities recognition from multimodal sensing devices. *IEEE Access*, 8:179028–179038.
- [Janssen and LeBlanc, 2010] Janssen, I. and LeBlanc, A. G. (2010). Systematic review of the health benefits of physical activity and fitness in school-aged children and youth. *International journal of behavioral nutrition and physical activity*, 7(1):1–16.
-

- 
- [Jantawong et al., 2021] Jantawong, P., Jitpattanakul, A., and Mekruksavanich, S. (2021). Enhancement of human complex activity recognition using wearable sensors data with inceptiontime network. In *2021 2nd International Conference on Big Data Analytics and Practices (IBDAP)*, pages 12–16. IEEE.
- [Jeon et al., 2007] Jeon, A., Kim, J., Kim, I., Jung, J., Ye, S., Ro, J., Yoon, S., Son, J., Kim, B., Shin, B., et al. (2007). Implementation of the personal emergency response system using a 3-axial accelerometer. In *2007 6th International Special Topic Conference on Information Technology Applications in Biomedicine*, pages 223–226. IEEE.
- [Kang et al., 2021] Kang, K. H., Shin, S. H., Jung, J., and Kim, Y. T. (2021). Estimation of a physical activity energy expenditure with a patch-type sensor module using artificial neural network. *Concurrency and Computation: Practice and Experience*, 33(2):e5455.
- [Kanjo et al., 2019] Kanjo, E., Younis, E. M., and Ang, C. S. (2019). Deep learning analysis of mobile physiological, environmental and location sensor data for emotion detection. *Information Fusion*, 49:46–56.
- [Karantonis et al., 2006] Karantonis, D. M., Narayanan, M. R., Mathie, M., Lovell, N. H., and Celler, B. G. (2006). Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE transactions on information technology in biomedicine*, 10(1):156–167.
- [Khan et al., 2008] Khan, A. M., Lee, Y.-K., and Kim, T.-S. (2008). Accelerometer signal-based human activity recognition using augmented autoregressive model coefficients and artificial neural nets. In *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 5172–5175. IEEE.
- [Khan et al., 2010] Khan, A. M., Lee, Y.-K., Lee, S., and Kim, T.-S. (2010). Accelerometer’s position independent physical activity recognition system for long-term activity monitoring in the elderly. *Medical & biological engineering & computing*, 48(12):1271–1279.
- [Kingma, 2014] Kingma, D. P. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [Krizhevsky et al., 2012] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25:1097–1105.
- [Kuncan et al., 2019] Kuncan, F., Kaya, Y., and Kuncan, M. (2019). A novel approach for activity recognition with down-sampling 1d local binary pattern. *Advances in Electrical and Computer Engineering*, 19(1):35–44.
- [Kunze and Lukowicz, 2008] Kunze, K. and Lukowicz, P. (2008). Dealing with sensor displacement in motion-based onbody activity recognition systems. In *Proceedings of the 10th international conference on Ubiquitous computing*, pages 20–29.
- [Kurban and Yildirim, 2019] Kurban, O. C. and Yildirim, T. (2019). Daily motion recognition system by a triaxial accelerometer usable in different positions. *IEEE Sensors Journal*, 19(17):7543–7552.
-

- 
- [Kutlay and Gagula-Palalic, 2016] Kutlay, M. A. and Gagula-Palalic, S. (2016). Application of machine learning in healthcare: Analysis on mhealth dataset. *Southeast Europe Journal of Soft Computing*, 4(2).
- [Lane et al., 2010] Lane, N. D., Miluzzo, E., Lu, H., Peebles, D., Choudhury, T., and Campbell, A. T. (2010). A survey of mobile phone sensing. *IEEE Communications magazine*, 48(9):140–150.
- [Lara and Labrador, 2012] Lara, O. D. and Labrador, M. A. (2012). A survey on human activity recognition using wearable sensors. *IEEE communications surveys & tutorials*, 15(3):1192–1209.
- [LeCun et al., 2015] LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.
- [Lee et al., 2003] Lee, S., Park, H., Hong, S., Lee, K., and Kim, Y. (2003). A study on the activity classification using a triaxial accelerometer. In *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439)*, volume 3, pages 2941–2943. IEEE.
- [Liandana et al., 2024] Liandana, M., Hostiadi, D. P., and Pradipta, G. A. (2024). A new approach for human activity recognition (har) using a single triaxial accelerometer based on a combination of three feature subsets. *International Journal of Intelligent Engineering & Systems*, 17(2).
- [Lohit et al., 2019] Lohit, S., Wang, Q., and Turaga, P. (2019). Temporal transformer networks: Joint learning of invariant and discriminative time warping. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 12426–12435.
- [Lu et al., 2018] Lu, K., Yang, L., Seoane, F., Abtahi, F., Forsman, M., and Lindecrantz, K. (2018). Fusion of heart rate, respiration and motion measurements from a wearable sensor system to enhance energy expenditure estimation. *Sensors*, 18(9):3092.
- [Mackintosh et al., 2016] Mackintosh, K. A., Montoye, A. H., Pfeiffer, K. A., and McNarry, M. A. (2016). Investigating optimal accelerometer placement for energy expenditure prediction in children using a machine learning approach. *IPEM, Physiological Measurement*, 37(10):1728–1740.
- [Maczák et al., 2021] Maczák, B., Vadai, G., Dér, A., Szendi, I., and Gingl, Z. (2021). Detailed analysis and comparison of different activity metrics. *Plos one*, 16(12):e0261718.
- [Mannini et al., 2015] Mannini, A., Sabatini, A. M., and Intille, S. S. (2015). Accelerometry-based recognition of the placement sites of a wearable sensor. *Pervasive and mobile computing*, 21:62–74.
- [Mehrang et al., 2018] Mehrang, S., Pietilä, J., and Korhonen, I. (2018). An activity recognition framework deploying the random forest classifier and a single optical heart rate monitoring and triaxial accelerometer wrist-band. *Sensors*, 18(2):613.
-

- 
- [Mekruksavanich et al., 2022a] Mekruksavanich, S., Hnoohom, N., and Jitpattanakul, A. (2022a). A hybrid deep residual network for efficient transitional activity recognition based on wearable sensors. *Applied Sciences*, 12(10):4988.
- [Mekruksavanich et al., 2022b] Mekruksavanich, S., Jitpattanakul, A., Sitthithakerngkiet, K., Youplao, P., and Yupapin, P. (2022b). Resnet-se: Channel attention-based deep residual network for complex activity recognition using wrist-worn wearable sensors. *IEEE Access*, 10:51142–51154.
- [Merglen et al., 2014] Merglen, A., Flatz, A., Bélanger, R. E., Michaud, P.-A., and Suris, J.-C. (2014). Weekly sport practice and adolescent well-being. *Archives of disease in childhood*, 99(3):208–210.
- [Mohammed and Tashev, 2017] Mohammed, S. and Tashev, I. (2017). Unsupervised deep representation learning to remove motion artifacts in free-mode body sensor networks. In *2017 IEEE 14th international conference on wearable and implantable body sensor networks (BSN)*, pages 183–188. IEEE.
- [Neverova et al., 2016] Neverova, N., Wolf, C., Lacey, G., Fridman, L., Chandra, D., Barbello, B., and Taylor, G. (2016). Learning human identity from motion patterns. *IEEE Access*, 4:1810–1820.
- [Nguyen et al., 2021] Nguyen, Q. H., Ly, H.-B., Ho, L. S., Al-Ansari, N., Le, H. V., Tran, V. Q., Prakash, I., and Pham, B. T. (2021). Influence of data splitting on performance of machine learning models in prediction of shear strength of soil. *Mathematical Problems in Engineering*, 2021(1):4832864.
- [Nosratabadi et al., 2020] Nosratabadi, S., Mosavi, A., Duan, P., Ghamisi, P., Filip, F., Band, S. S., Reuter, U., Gama, J., and Gandomi, A. H. (2020). Data science in economics: comprehensive review of advanced machine learning and deep learning methods. *Mathematics*, 8(10):1799.
- [Nweke et al., 2018] Nweke, H. F., Teh, Y. W., Al-Garadi, M. A., and Alo, U. R. (2018). Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: State of the art and research challenges. *Expert Systems with Applications*, 105:233–261.
- [Ochoa-Estopier et al., 2013] Ochoa-Estopier, L. M., Jobson, M., and Smith, R. (2013). Operational optimization of crude oil distillation systems using artificial neural networks. *Computers & chemical engineering*, 59:178–185.
- [Olabe, 1998] Olabe, X. B. (1998). Redes neuronales artificiales y sus aplicaciones. *Publicaciones de la Escuela de Ingenieros*.
- [OMS et al., 2010] OMS, W. H. O. et al. (2010). Recomendaciones mundiales sobre actividad física para la salud.
- [Ordóñez and Roggen, 2016] Ordóñez, F. J. and Roggen, D. (2016). Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, 16(1):115.
-

- 
- [Paraschiakos et al., 2020] Paraschiakos, S., de Sá, C. R., Okai, J., Slagboom, E. P., Beekman, M., and Knobbe, A. (2020). Rnns on monitoring physical activity energy expenditure in older people. *arXiv preprint arXiv:2006.01169*.
- [Piaggio, 1943] Piaggio, H. (1943). The definition of radius of curvature. *The Mathematical Gazette*, 27(274):77–79.
- [Preece et al., 2008] Preece, S. J., Goulermas, J. Y., Kenney, L. P., and Howard, D. (2008). A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data. *IEEE Transactions on Biomedical Engineering*, 56(3):871–879.
- [Ramanujam et al., 2021] Ramanujam, E., Perumal, T., and Padmavathi, S. (2021). Human activity recognition with smartphone and wearable sensors using deep learning techniques: A review. *IEEE Sensors Journal*, 21(12):13029–13040.
- [Ray et al., 2024] Ray, L. S. S., Geißler, D., Liu, M., Zhou, B., Suh, S., and Lukowicz, P. (2024). Als-har: Harnessing wearable ambient light sensors to enhance imu-based har. *arXiv preprint arXiv:2408.09527*.
- [Saha et al., 2018] Saha, J., Chowdhury, C., Roy Chowdhury, I., Biswas, S., and Aslam, N. (2018). An ensemble of condition based classifiers for device independent detailed human activity recognition using smartphones. *Information*, 9(4):94.
- [San-Segundo et al., 2016] San-Segundo, R., Montero, J. M., Barra-Chicote, R., Fernández, F., and Pardo, J. M. (2016). Feature extraction from smartphone inertial signals for human activity segmentation. *Signal Processing*, 120:359–372.
- [Sathyanarayana et al., 2018] Sathyanarayana, S., Satzoda, R. K., Sathyanarayana, S., and Thambipillai, S. (2018). Vision-based patient monitoring: a comprehensive review of algorithms and technologies. *Journal of Ambient Intelligence and Humanized Computing*, 9:225–251.
- [Sharifani and Amini, 2023] Sharifani, K. and Amini, M. (2023). Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal*, 10(07):3897–3904.
- [Shoaib et al., 2015] Shoaib, M., Bosch, S., Incel, O. D., Scholten, H., and Havinga, P. J. (2015). A survey of online activity recognition using mobile phones. *Sensors*, 15(1):2059–2085.
- [Shoaib et al., 2016] Shoaib, M., Bosch, S., Incel, O. D., Scholten, H., and Havinga, P. J. (2016). Complex human activity recognition using smartphone and wrist-worn motion sensors. *Sensors*, 16(4):426.
- [Strackiewicz et al., 2019] Strackiewicz, M., James, P., and Onnela, J.-P. (2019). A systematic review of smartphone-based human activity recognition for health research. *arXiv preprint arXiv:1910.03970*.
- [Sunny et al., 2015] Sunny, J. T., George, S. M., and Kizhakkethottam, J. J. (2015). Applications and Challenges of Human Activity Recognition using Sensors in a Smart Environment. *IJIRST –International Journal for Innovative Research in Science Technology*, 2(04):50–57.
-

- 
- [Sztyler and Stuckenschmidt, 2016] Sztyler, T. and Stuckenschmidt, H. (2016). On-body localization of wearable devices: An investigation of position-aware activity recognition. In *2016 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, pages 1–9. IEEE.
- [Ungurean and Brezilianu, 2017] Ungurean, L. and Brezilianu, A. (2017). An internet of things framework for remote monitoring of the healthcare parameters. *Advances in Electrical and Computer Engineering*, 17(2):11–16.
- [Ustev et al., 2013] Ustev, Y. E., Durmaz Incel, O., and Ersoy, C. (2013). User, device and orientation independent human activity recognition on mobile phones: Challenges and a proposal. In *Proceedings of the 2013 ACM conference on Pervasive and ubiquitous computing adjunct publication*, pages 1427–1436.
- [Valarezo et al., 2020] Valarezo, A. E., Rivera, L. P., Park, H., Park, N., and Kim, T.-S. (2020). Human activities recognition with a single wrist imu via a variational autoencoder and android deep recurrent neural nets. *Computer Science and Information Systems*, 17(2):581–597.
- [Van Kasteren et al., 2008] Van Kasteren, T., Noulas, A., Englebienne, G., and Kröse, B. (2008). Accurate activity recognition in a home setting. In *Proceedings of the 10th international conference on Ubiquitous computing*, pages 1–9.
- [Wang et al., 2019] Wang, J., Chen, Y., Hao, S., Peng, X., and Hu, L. (2019). Deep learning for sensor-based activity recognition: A survey. *Pattern recognition letters*, 119:3–11.
- [Wei and Wang, 2024] Wei, X. and Wang, Z. (2024). Tcn-attention-har: human activity recognition based on attention mechanism time convolutional network. *Scientific Reports*, 14(1):7414.
- [White et al., 2019] White, T., Westgate, K., Hollidge, S., Venables, M., Olivier, P., Wareham, N., and Brage, S. (2019). Estimating energy expenditure from wrist and thigh accelerometry in free-living adults: a doubly labelled water study. *International Journal of Obesity*, 43(11):2333–2342.
- [World Health Organization et al., 2010] World Health Organization, t. et al. (2010). *Global recommendations on physical activity for health*. World Health Organization.
- [Xu et al., 2018] Xu, T., Zhou, Y., and Zhu, J. (2018). New advances and challenges of fall detection systems: A survey. *Applied Sciences*, 8(3):418.
- [Yang, 2009] Yang, J. (2009). Toward physical activity diary: motion recognition using simple acceleration features with mobile phones. In *Proceedings of the 1st international workshop on Interactive multimedia for consumer electronics*, pages 1–10.
- [Zahniser and Brenner, 1985] Zahniser, D. J. and Brenner, J. F. (1985). *Signals and systems*, by av oppenheim, as willsky, and it young. prentice-hall, englewood cliffs, new jersey, 1983, 796 pages, hardbound.

- 
- [Zeng et al., 2014] Zeng, M., Nguyen, L. T., Yu, B., Mengshoel, O. J., Zhu, J., Wu, P., and Zhang, J. (2014). Convolutional neural networks for human activity recognition using mobile sensors. In *6th international conference on mobile computing, applications and services*, pages 197–205. IEEE.
- [Zhang et al., 2019] Zhang, H., Xiao, Z., Wang, J., Li, F., and Szczerbicki, E. (2019). A novel iot-perceptive human activity recognition (har) approach using multihead convolutional attention. *IEEE Internet of Things Journal*, 7(2):1072–1080.
- [Zhang et al., 2020] Zhang, Z., Cheng, Q. S., Chen, H., and Jiang, F. (2020). An efficient hybrid sampling method for neural network-based microwave component modeling and optimization. *IEEE Microwave and Wireless Components Letters*, 30(7):625–628.

# Anexos

# Apéndice A

## Producción Científica

Durante la culminación del trabajo de tesis se publicó un artículo de investigación en la revista *Mathematical and Computational Applications*, titulado **Human Activity Recognition from Accelerometry, Based on a Radius of Curvature Feature** donde se desglosa y valida el esquema del modelo para HAR. Se muestran los resultados de la simulación del modelo con datos personas, disponibles en la literatura y se demuestra la eficiencia del enfoque que integró la nueva característica propuesta, **el radio de curvatura**.

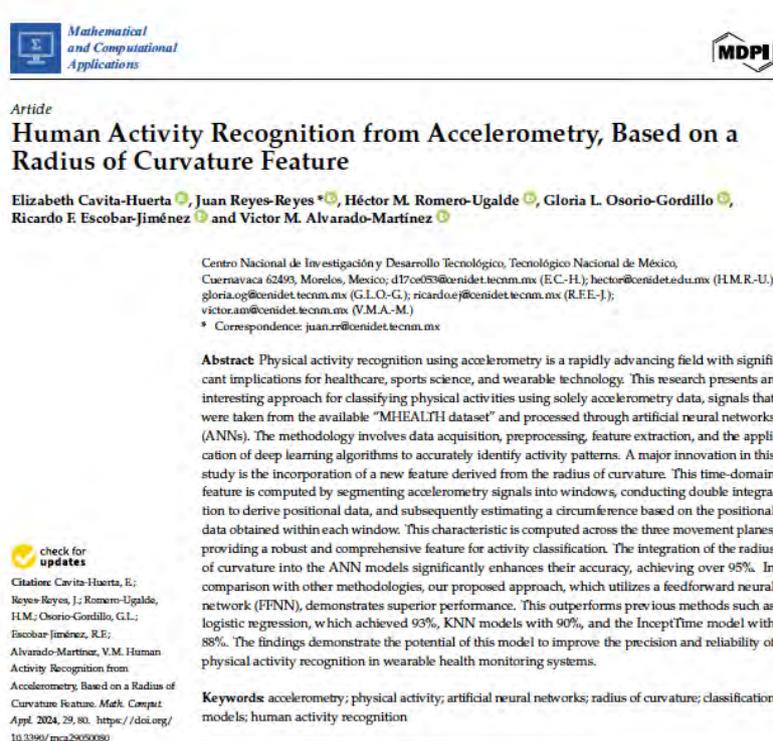


Figura A.1: Publicación realizada en *Mathematical and Computational Applications*

Así mismo, se realizó una publicación en una revista de divulgación científica que abordó un ejercicio de clasificación, titulado **Clasificación de actividad física mediante señales de acelerometría** donde se comparan los resultados de modelos en la Clasificación de Actividades tomando en cuenta diferentes posiciones del cuerpo.

Clasificación de actividad física mediante señales de acelerometría  
 Classification of physical activity by accelerometry signals

E. Cavita-Huerta <sup>1,2\*</sup>, J. Reyes-Reyes <sup>2</sup>

<sup>1</sup> *Cenadict, Interior Internado Palmira S/N, Palmira, 62493 Cuernavaca, Mor.*

**Resumen**

El presente trabajo aborda la problemática asociada con el reconocimiento de patrones usando únicamente señales de acelerometría para identificar y clasificar un grupo de actividades físicas. Por lo tanto, se desarrolló un modelo de Redes Neuronales Artificiales (ANN) del tipo feedforward (RNAF), que cuenta con una estructura 40-150-13 y es capaz de clasificar el conjunto de actividades. Además, se presenta una comparativa del desempeño de la red neuronal ante cuatro diferentes escenarios de clasificación. Las señales de acelerometría utilizadas fueron tomadas del conjunto de datos (mHealth Dataset), estas fueron recolectadas cuando un grupo de 10 personas ejecutaba un protocolo de 12 actividades y portaba acelerómetros en tres posiciones antropométricas distintas: pecho, muñeca derecha, tobillo izquierdo. En los primeros tres escenarios de clasificación se considera como información de entrada a la RNAF las señales de cada una de las posiciones individualmente, concluyendo que el pecho es la mejor posición, logrando 77% de precisión. En el cuarto escenario, se adopta un enfoque integral considerando las señales de los tres sensores simultáneamente, lo que aumenta significativamente la precisión, alcanzando un 90%.

*Palabras Clave:* Acelerometría, actividad física, redes neuronales artificiales, reconocimiento de actividad física.

**Abstract**

The present work addresses the problem associated with pattern recognition using only accelerometer signals to identify and classify a group of physical activities. Therefore, a model of Artificial Neural Networks (ANN) of the feedforward type (RNAF) was developed, with a structure of 40-150-13 capable of classifying the entire set of activities. Furthermore, a comparison of the neural network's performance under four different classification scenarios is presented. The accelerometer signals used were obtained from the mHealth Dataset, collected while a group of 10 individuals performed a protocol consisting of 12 activities while wearing accelerometers in three distinct anthropometric positions: chest, right wrist, and left ankle. In the first three classification scenarios, the input information for the RNAF consists of signals from each position individually, concluding that the chest provides the best accuracy at 77%. In the fourth scenario, an integrated approach considering signals from all three sensors simultaneously is adopted, significantly boosting accuracy to 90%.

*Keywords:* Accelerometry, physical activity, artificial neural networks, human activity recognition.

Figura A.2: Publicación realizada en Boletín de Ciencias Básicas e Ingeniería del ICBI