

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

E. Cavita-Huerta ^{a,*}, J. Reyes-Reyes ^a

^a Cenidet, 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.

1. Introducción

Aunque existen diferentes técnicas y modelos matemáticos para la realización de la clasificación de la actividad física (AF), los modelos basados en las Redes Neuronales Artificiales (ANN) han demostrado ser una herramienta eficiente y precisa que mejoran el desempeño de sistemas de clasificación de actividad, ya que eligiendo las características

y parámetros adecuados pueden obtener desempeños superiores al 95 % de precisión, en entornos no controlados (Freedson et al., 2011).

Otro punto de partida de las investigaciones de la medición de la AF basados en ANN, no es referente al desarrollo de nuevos modelos, sino respecto a la ubicación óptima del acelerómetro, en (Mackintosh et al., 2016) se valida y compara

*Autor para la correspondencia: d17ce053@cenidet.tecnm.mx

Correo electrónico: d17ce053@cenidet.tecnm.mx (Elizabeth Cavita-Huerta), juan.rr@cenidet.tecnm.mx (Juan Reyes-Reyes).

el desempeño de las ANN, a partir de acelerómetros usados en diversas posiciones anatómicas y combinaciones de estos.

Asimismo, 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 & Gams, 2011).

Si bien el uso de acelerómetros y ANN para la estimación de AF representa una poderosa herramienta, la posición del acelerómetro está limitada a una parte específica del cuerpo, ya que, si un algoritmo está diseñado para utilizarse en el pecho, brindando una precisión mayor al 90% y por alguna razón el acelerómetro es usado en otra posición del cuerpo, la precisión puede sufrir una disminución notable de más de un 50% (Khan et al., 2008).

Debido a que el seguimiento de la AF es una variable de gran interés, ya que permite evaluar el comportamiento de un individuo frente a diferentes tipos de estímulos, así como determinar su nivel de AF (Demrozi et al., 2020). La detección continua de movimiento del individuo o su monitorización requiere la incorporación de algún dispositivo en su vida diaria y de esta manera se realice la captura de la información de utilidad.

El desarrollo de dispositivos portátiles, como los teléfonos y relojes inteligentes, así como las pulseras de fitness, que incorporan diversos sensores como giroscopios, monitores de frecuencia cardíaca, termómetros, acelerómetros, podómetros, etc., y que son utilizados por muchas personas, ofrecen la mejor alternativa para evaluar la AF, ya que brindan nuevas oportunidades para la monitorización continua de actividades humanas, (Shcherbina, et al., 2017). Estos artefactos han de ser portátiles, es decir, ligeros y preferiblemente de un tamaño pequeño, de tal manera que al llevarlos puestos no interfieran en el desarrollo de las tareas diarias de una persona (Bulling et al., 2014).

Especialmente, los acelerómetros electrónicos son los sensores de movimiento más prometedores para evaluar la AF de las personas, 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). Considerando el estado actual de la tecnología de circuitos integrados, también existen buenas oportunidades para construir sistemas de acelerómetros muy pequeños y ligeros que puedan llevarse durante días o incluso semanas.

Este sensor de movimiento puede detectar la aceleración en los tres planos del espacio. Dependiendo del tipo de acelerómetro utilizado, la señal obtenida puede ser uniaxial, biaxial o triaxial, esta capacidad le permite capturar con precisión las señales de cualquier eje del cuerpo humano, proporcionando una visión completa y detallada del movimiento, Figura 1.

Sin embargo, es necesario establecer un método para poder modelar las señales procedentes de los sensores y así compararlas entre sí, con el fin de llevar a cabo el Reconocimiento de Actividades Humanas (HAR) utilizando únicamente las señales provenientes de acelerómetros.

El reconocimiento de patrones de señales provenientes de acelerómetros es una técnica fundamental en diversas áreas. Dentro del campo de la tecnología de la salud, como lo es la

aplicación del HAR, estos dispositivos registran los movimientos del cuerpo y pueden identificar patrones asociados con actividades específicas, como caminar, correr, dormir, etc. Esta información es invaluable para rastrear el estado físico, el nivel de actividad y para detectar anomalías que podrían indicar problemas de salud (Banos et al., 2015). Por ejemplo, en aplicaciones de seguridad y vigilancia para personas mayores, los acelerómetros pueden usarse para detectar patrones de comportamiento anómalos o actividades específicas, como una caída y alertar automáticamente a los servicios de emergencia.

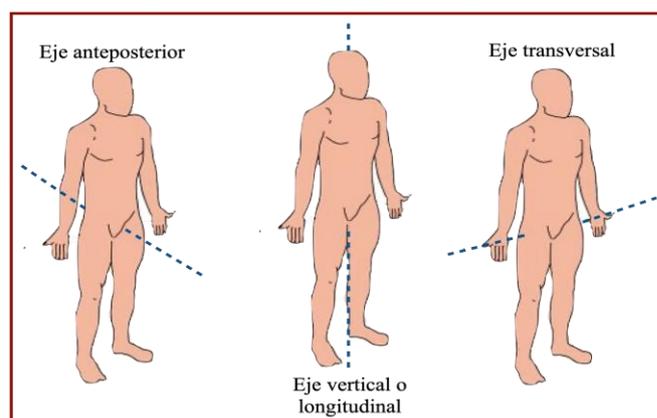


Figura 1: Distribución de ejes en el cuerpo humano.

En el sector industrial, el reconocimiento de patrones utilizando acelerómetros pueden ayudar a incrementar la productividad y realizar una correcta programación del mantenimiento predictivo. Los acelerómetros se utilizan para monitorear la vibración de maquinaria y equipos.

Los cambios en los patrones de vibración pueden indicar un desgaste o un mal funcionamiento, lo que permite la implementación de mantenimiento predictivo para evitar costosas averías y tiempos de inactividad no planificados (Windau, J., & Itti, L., 2018). Por lo tanto, el reconocimiento de patrones de señales provenientes de acelerómetros es esencial debido a su versatilidad y capacidad para proporcionar información valiosa dentro de una amplia gama de aplicaciones.

1.1. Acelerometría

El reconocimiento de actividades en los seres humanos es un problema que implica el modelado de actividades, la supervisión del comportamiento, el procesamiento de datos y el reconocimiento de patrones. Para diseñar y evaluar cualquier sistema HAR, tradicionalmente se deben seguir pasos o etapas específicas para recuperar información de actividad del sensor. Estos pasos se denominan, cadena de reconocimiento de actividad (Alshorman et al., 2020), Figura 2.

Sin embargo, existe una problemática que afecta directamente el HAR, cuando se utilizan acelerómetros. Los patrones de salida de las señales de acelerometría son cambiantes según la posición del cuerpo en la que se encuentren.

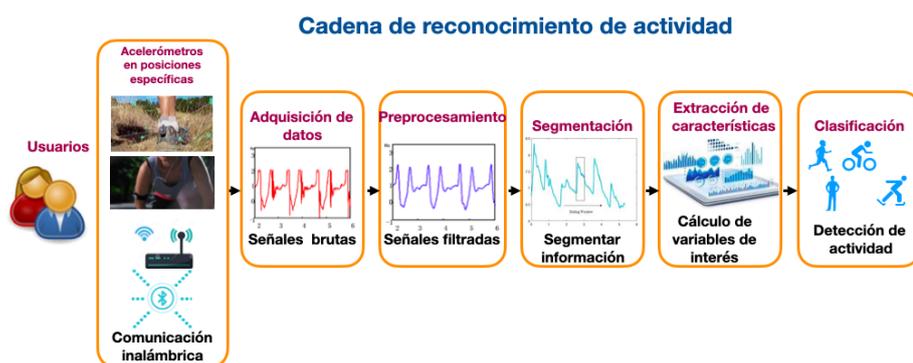


Figura 2: Cadena de reconocimiento de actividad.

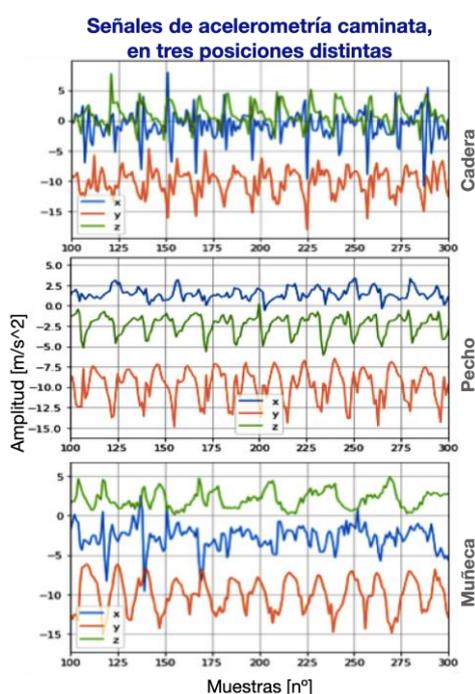


Figura 3: Señales de acelerometría caminata.

La Figura 3, muestra una comparativa de señales de acelerometría obtenidas en una prueba de laboratorio para la captura de señales de manera inalámbrica, como parte del desarrollo de un trabajo de tesis doctoral llevado a cabo en Cenidet. Las señales fueron muestreadas a 50 Hz, mediante una tarjeta Raspberry Pi, utilizando tres módulos IMU colocados en pecho, cadera y muñeca de una persona.

La mayoría de las investigaciones realizadas emplean varios acelerómetros en diferentes partes del cuerpo para realizar la clasificación de AF (Clevenger *et al.*, 2020), (Bao and Intille, 2004), (White *et al.*, 2019), mientras que otros utilizan acelerómetros en conjunto con sensores que miden otras variables, (Catal and Akbulut, 2018), (Lu *et al.*, 2018), (Kang *et al.*, 2021), tales limitan al usuario a lidiar con un patrón de uso fijo, que no es práctico y efectivo donde no existe supervisión de uso y además se debe considerar que entre más sensores se utilicen para la clasificación de AF mayor poder de procesamiento será necesario.

También otro punto importante a considerar es que estos modelos diseñados para realizar clasificación presentan un desempeño de precisión bajo al no utilizarse en la posición asignada por diseño, en (Khan *et al.*, 2008) se realizó la clasificación de la AF con una precisión mayor al 90 %, pero el sensor requería estar fijo al pecho, cuando se probó para el caso independiente de la posición, la precisión sufrió una disminución notable de más del 50 %.

1.2. Redes Neuronales Artificiales

Las ANN son algoritmos informáticos que se asemejan a los procesos interactivos del cerebro humano y permiten estudiar fenómenos no lineales muy complejos. La ventaja fundamental de estos métodos es su capacidad para hacer inferencias a nivel individual en lugar de a nivel de grupo (Carpenter *et al.*, 2015).

Los elementos base de una ANN son los nodos (elementos de procesamiento) y las conexiones. Cada nodo tiene su propia entrada, a partir de la cual recibe comunicaciones de otros nodos y/o del entorno, y su propia salida, a partir de la cual se comunica con otros nodos o con el entorno. Además, cada nodo tiene una función a través de la cual transforma su propia entrada global en una salida. Las conexiones entre los nodos pueden modificarse a lo largo del tiempo en un proceso de aprendizaje dinámico, lo que conduce a la identificación de nuevos patrones complejos entre entradas y salidas y a la predicción de estimaciones sobre datos desconocidos (Grossi and Buscema, 2007).

Debido a estas características, el uso de modelos basados en redes neuronales artificiales ANN resultan un poderoso enfoque de clasificación de AF, que proporcionan resultados satisfactorios (Gil-Martin *et al.*, 2020). Estos tienen la capacidad de aprender y determinar las relaciones ocultas entre entradas y salidas, posteriormente, la ANN es capaz de predecir la salida a partir de la entrada de nuevos datos, Figura 4. Una vez realizado el entrenamiento adecuado, las redes neuronales intentan predecir con mayor precisión que los análisis de clasificación o regresión convencionales (Disse, *et al.*, 2017).

Por lo tanto, en los modelos de ANN para clasificación de actividades el proceso de entrenamiento y prueba juega un papel crítico, este implica varios pasos fundamentales. A continuación, se describen de manera general:

1. Recopilación y Preprocesamiento de Datos:

Recopilación de Datos: Se recopilan conjuntos de datos que contienen ejemplos de entrada y salida deseados para la tarea específica.

Preprocesamiento de Datos: Los datos se procesan para eliminar ruido, normalizar escalas y realizar otras transformaciones que mejoren la calidad y eficacia del entrenamiento.

2. **División de datos:** Se divide el conjunto de datos, uno para entrenamiento y otro para prueba/validación. Esto permite evaluar la capacidad de generalización del modelo.
3. **Diseño del modelo:** Se elige la arquitectura de la red neuronal, incluyendo la cantidad de capas, el tipo de capas (densas, convolucionales, recurrentes, etc.), y la función de activación.
4. **Entrenamiento del modelo:** Se presenta el conjunto de entrenamiento a la red y se ajustan los pesos mediante el algoritmo de optimización minimizando la pérdida.
5. **Prueba del modelo:** Una vez entrenado, se evalúa el rendimiento del modelo utilizando el conjunto de prueba, que no ha sido visto durante el entrenamiento.

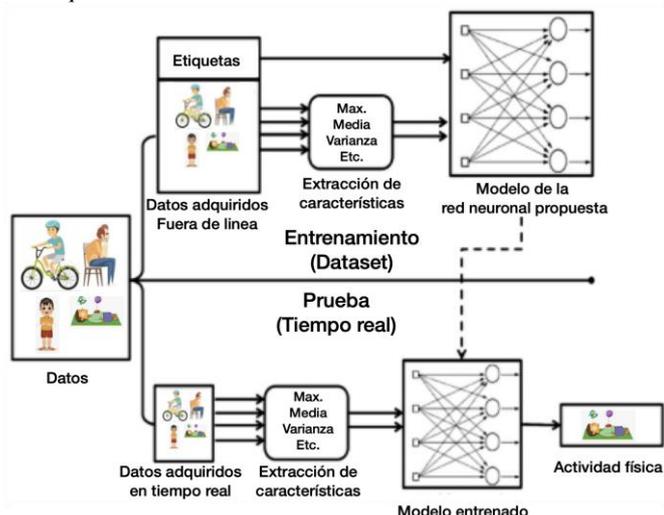


Figura 4: Proceso de entrenamiento y prueba de una ANN.

2. Cadena de reconocimiento de actividad

En este trabajo, se abordó el problema de HAR utilizando la metodología propuesta en la cadena de reconocimiento de actividad, Figura 2. Centrando la investigación en la influencia en la calidad del reconocimiento de actividades, cuando se utilizan señales provenientes de más de un acelerómetro.

2.1. Adquisición de datos

Para este ejercicio de clasificación se utilizaron señales que provienen de acelerómetros triaxiales, los cuales registran las aceleraciones en los ejes x,y,z. El conjunto de datos utilizado fue tomado de la literatura, mHealth *Dataset* (Banos *et al.*, 2014). Este consta de un conjunto de 12 actividades, consideradas comunes en la vida diaria de las personas: Parado (L1), Sentado y relajado (L2), Acostado boca arriba (L3), Caminar (L4), Subir escaleras (L5), Doblar cintura hacia adelante (L6), Elevación de brazos (L7), Sentadilla (L8),

Ciclismo (L9), Trotar (L10), Correr (L11) y Brincar adelante y atrás (L12), las etiquetas utilizadas sirven para identificar las actividades.

Los sensores utilizados para capturar los movimientos corporales se colocaron respectivamente en el pecho, la muñeca derecha y el tobillo izquierdo de 10 sujetos con perfiles diversos que desempeñan el protocolo de actividades propuesto, estos se fijaron mediante correas elásticas al cuerpo de los participantes, Figura 5.

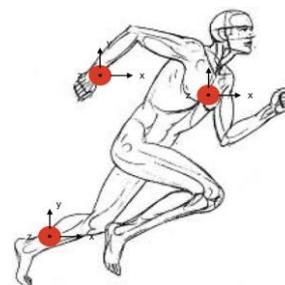


Figura 5: Ubicación de sensores.

En la recopilación de estos datos se utilizaron sensores portátiles *Shimmer2*. El sensor colocado en el pecho también proporciona mediciones de ECG de 2 derivaciones que no se utilizan para el desarrollo del modelo de reconocimiento, sino que se recogen para futuros trabajos.

Las actividades se llevaron a cabo en un entorno fuera del laboratorio sin restricciones sobre la forma en que debían ejecutarse, con la excepción de que el sujeto debía esforzarse al máximo al ejecutarlas. Todas las modalidades de detección se graban a una frecuencia de muestreo de 50 Hz, que se considera suficiente para captar la actividad humana.

2.2. Preprocesamiento de datos

En primer lugar, para que los datos sean aptos para el análisis, estos se analizan antes de que pasen por el resto de la cadena. 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.

En cada dominio existen métodos específicos para abstraer datos de señales sin procesar, es posible clasificar las técnicas de procesamiento en: el dominio del tiempo, de frecuencia y representación discreta, (Preece *et al.*, 2008).

En este caso, las señales se tratan en el dominio del tiempo, inicialmente se realizan las transformaciones pertinentes para normalizar las señales en el marco de referencia determinado, Figura 6.

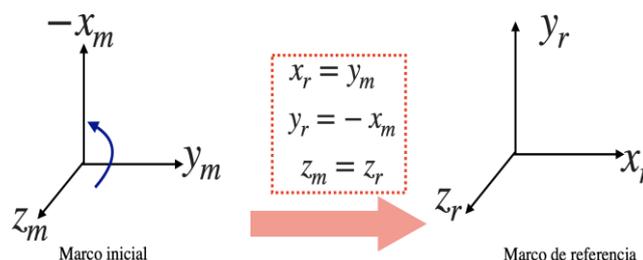


Figura 6: Normalización del marco de referencia

Considerando la siguiente expresión matemática, representativa de las modificaciones realizadas y aplicadas a las señales:

$$\begin{bmatrix} x_r \\ y_r \\ z_r \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} x_m \\ y_m \\ z_m \end{bmatrix} \quad (1)$$

donde:

- $[x_r, y_r, z_r]^T$ vector traspuesto de aceleraciones normalizadas.
- $[x_m, y_m, z_m]^T$ vector traspuesto de aceleraciones iniciales (raw).

Después de la normalización de los ejes de las señales de aceleración se procede a realizar la extracción de la componente gravitatoria de las señales de aceleración normalizadas, restando la media, como se muestra a continuación:

$$a_{lineal\{x|y|z\}} = a_{norm\{x|y|z\}} - \underline{a_{norm\{x|y|z\}}} \quad (2)$$

donde:

- $a_{lineal\{x|y|z\}}$ vector de aceleraciones sin la presencia de la componente gravitacional.
- $a_{norm\{x|y|z\}}$ vector de aceleraciones normalizadas.
- $\underline{a_{norm\{x|y|z\}}}$ promedio de las aceleraciones normalizadas.

Independientemente de cuál sea la actividad física, el problema de reconocimiento se puede abordar de una manera más elegante y precisa si se antepone el conocimiento de las señales de acelerometría en el desarrollo del modelo, al incorporar un enfoque proactivo hacia la comprensión y manipulación de estas señales, se establece una base sólida para la creación de un modelo HAR que no solo sea robusto y preciso en la fase de entrenamiento, sino que también demuestre alta capacidad para generalizar y adaptarse a situaciones diversas.

2.3. Segmentación de datos

El objetivo principal de la etapa de segmentación es buscar los segmentos que contienen datos valiosos sobre las actividades y reducir la cantidad de datos procesados (San-Segundo, *et al.*, 2016). Las técnicas de ventana deslizante son un ejemplo común de las técnicas utilizadas en esta etapa, la cual se implementó en este trabajo.

Por lo tanto, esto 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:

$$K = \left\lceil \frac{N-M}{R} \right\rceil + 1 \quad (3)$$

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:

$$X_{OL} = S_R \cdot W_S \left(\frac{O_{LP}}{100} \right) \quad (4)$$

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

Para este trabajo, cada ventana abarca un segmento de tiempo específico de 1 segundo y se desplaza a lo largo de la serie temporal, a medida que se avanza a través de la secuencia, la ventana se desliza (overlap) al 50%, lo que permite capturar la información de manera continua y asegura una cobertura adecuada de la secuencia completa, proceso que se ejemplifica en la Figura 7.

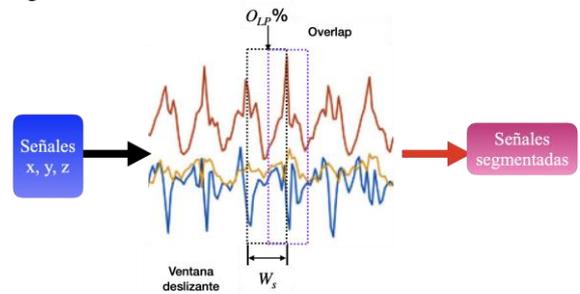


Figura 7: Segmentación de señales

La técnica de ventana deslizante es una estrategia clave en el procesamiento de datos, particularmente útil para tareas como el reconocimiento de patrones en series temporales, como las provenientes de sensores como el acelerómetro.

2.4. Extracción de características

La etapa de extracción de características se utiliza para encontrar una alta resolución de representación de datos para cada segmento (Van Nguyen, *et al.*, 2018), este es un paso crucial en el procesamiento de datos.

Especialmente en el ámbito de las ANN, se debe elegir un subconjunto relevante de características originales, considerando sólo las más informativas y deshacerse de aquellas que pueden introducir ruido o no contribuir significativamente, ya que algunas pueden tener más impacto en la clasificación que otras, en la Tabla 1 se muestran algunas de las características más comunes basadas en el tiempo y la frecuencia.

Tabla 1: Características comunes.

Dominio	Característica
Tiempo	Media
	Varianza
	Desviación estándar
	Mínimo
	Máximo
	Rango
	Media absoluta
	Coefficiente de variación
	Curtosis
	Cuartiles
Frecuencia	Rango intercuartil
	Tasa media de cruce
	Frecuencia dominante
	Entropía
	Energía

Tomando en cuenta que se utilizan las señales provenientes de tres acelerómetros, ubicados estratégicamente (en el pecho, la muñeca derecha y el tobillo izquierdo), se ha llevado a cabo la extracción de características exclusivamente en el dominio del tiempo, que es particularmente relevante en este contexto, ya que permite analizar directamente cómo las señales varían a lo largo del tiempo, posibilitando la identificación de patrones temporales, como la frecuencia de movimiento, la duración de las actividades y posiblemente la secuencia temporal de eventos.

Además, al limitarse al dominio del tiempo, se simplifica el proceso de extracción de características, lo que puede resultar beneficioso en términos de eficiencia computacional, simplicidad y menor uso de recursos. En este sentido las características empleadas en este trabajo son:

Tabla 2: Características utilizadas.

Promedio
Varianza
Moda
Desviación estándar
Mediana

Aunque el dominio del tiempo puede ser adecuado para ciertos escenarios, en otros casos podría ser beneficioso explorar técnicas en el dominio de la frecuencia o utilizar enfoques más avanzados.

En el contexto específico del reconocimiento de actividad física basada en señales de acelerometría, la extracción de características puede incluir la identificación de patrones específicos en las señales que son indicativos de ciertas actividades. Realizando una correcta evaluación y selección de características se puede mejorar la precisión de los modelos significativamente, ya que éstas alimentan a los modelos basados en ANN, como las entradas de información.

2.5. Clasificación

El aprendizaje profundo ha mejorado el rendimiento y la robustez de HAR, acelerando su adopción y aplicación a una amplia gama de aplicaciones basadas en sensores portátiles (Acevedo *et al.*, 2017).

En el contexto de modelos que hacen uso de acelerómetros, es común que las variables de entrada se definan como características derivadas de las señales capturadas por el sensor. Estas características se sitúan en la capa de entrada del modelo, donde cada una de ellas proporciona información específica sobre las dinámicas de movimiento registradas por los acelerómetros.

Las unidades ocultas, ubicadas en las capas intermedias del modelo, representan combinaciones ponderadas de las variables de entrada. La capacidad de las unidades ocultas para capturar relaciones no lineales y patrones más sofisticados es fundamental para mejorar la capacidad de adaptarse a una amplia variedad de datos de entrada. En cuanto a las categorías de la variable de salida, estas corresponden directamente con los diferentes tipos de actividades físicas que se pretenden clasificar. La capa de salida del modelo genera probabilidades o predicciones asociadas a cada categoría, indicando la probabilidad de que una observación pertenezca a una actividad específica.

En este caso, se ha utilizado una red neuronal densa, también conocida como red neuronal totalmente conectada o feedforward (RNAf), estas son una arquitectura de ANN 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 AF, ya que tienen la capacidad de aprender patrones complejos en los datos y extraer características discriminativas para una clasificación precisa (Shoaib *et al.*, 2016).

La arquitectura de la red está definida por tres capas, con 40-150-13 neuronas en cada capa respectivamente, Figura 8. En la capa de entrada se alimenta la ANN con el vector de características extraídas de las señales de acelerometría $[x_1, x_2, \dots, x_n]$, de los sensores colocados en (pecho, muñeca derecha y tobillo izquierdo) respectivamente. En la capa de salida se tienen las categorías de la variable de salida, el vector correspondiente a las 13 clases de actividades, que deben clasificarse $[y_1, y_2, \dots, y_r]$ para este caso.

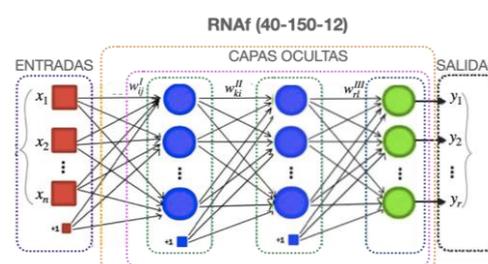


Figura 8: Arquitectura de la RNAf.

Los parámetros utilizados en el modelo de la RNAf son los siguientes:

Capas:

1. Capa densa con 40 neuronas y activación Tangente hiperbólica.
2. Capa densa con 150 neuronas y activación ReLU.
3. Capa densa con 13 neuronas y activación Softmax.

- Optimizador: Adam
- Función de pérdida: Entropía cruzada categórica.
- N° de épocas: 1500

3. Resultados

A continuación, se presentan los resultados obtenidos en el ejercicio de clasificación detallado en la sección 2. Estos resultados ofrecen una visión clara del impacto que tiene la implementación de un enfoque que involucra el uso de varios acelerómetros, estratégicamente ubicados en diferentes partes del cuerpo. Utilizando un esquema de modelo de clasificación basado en ANN.

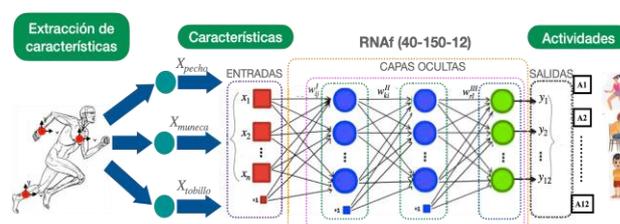


Figura 9: Esquema de clasificación.

El esquema general de la estructura del modelo fortalece la comprensión del enfoque implementado y resalta la contribución positiva de esta configuración en el rendimiento global del sistema de clasificación, Figura 9.

La incorporación de información de varios puntos de medición aumenta la capacidad del modelo para discernir entre diversas actividades, mejorando así su precisión y capacidad de generalización, ya que cuando se considera solo una posición como información de entrada, la precisión del modelo oscila entre el 69-77%, sin embargo, cuando se utiliza la información proveniente de los tres sensores de manera simultánea se alcanza un 90%, incrementándose de manera considerable la capacidad de clasificación, ver Tabla 3.

Tabla 3: Índices de reconocimiento de AF según la posición.

Posición	Precisión
Pecho	77%
Muñeca derecha	69%
Tobillo izquierdo	72%
Todos	90%

Los resultados presentados reflejan el impacto positivo de este enfoque multimodal en la clasificación de AF, cuando se realiza la combinación de información de varios acelerómetros se mejora la capacidad del modelo para realizar el proceso de clasificación. Comprobando lo sugerido en diferentes investigaciones como (Altini et al., 2014) y (Gjoreski and Gams, 2011), donde se determina que el uso de 3 acelerómetros es suficiente para incrementar la capacidad de clasificación en modelos basados en ANN en más de un 90%, considerando la distribución de los sensores tanto en la zona superior como inferior del cuerpo de las personas. De esta manera se logra detectar la dinámica de los movimientos del cuerpo humano ante diferentes AF con mayor eficiencia.

Conclusiones

Se presentaron índices de reconocimiento de actividades físicas según la posición del acelerómetro, los cuales reflejan la capacidad del modelo para discernir entre diversas actividades en diferentes ubicaciones del cuerpo. Es evidente que la precisión varía según la posición del acelerómetro, destacando la influencia significativa de la ubicación del sensor en la calidad de las predicciones del modelo.

El desempeño del modelo se destaca de manera individual en la posición del pecho, alcanzando una capacidad de clasificación del 77%, mientras que la muñeca y el tobillo presentan cifras algo inferiores. Esta variabilidad en el rendimiento según la posición del acelerómetro subraya la importancia de considerar la ubicación y la cantidad específica de sensores, que serán necesarios al diseñar sistemas de clasificación de AF. Análisis como los presentados en (Altini et al., 2014) muestran como la capacidad de clasificación es directamente afectada por el número y la combinación de las posiciones de los acelerómetros utilizados.

Finalmente, la evaluación global del modelo considerando la combinación de información de todos los acelerómetros, muestra un rendimiento sobresaliente con una capacidad de clasificación del 90% sobre el obtenido por un único sensor. Sin embargo, es evidente que aún se puede mejorar el

rendimiento del modelo, aplicando técnicas de extracción de características más complejas.

Referencias

- Acevedo, E., Serna, A., & Serna, E. (2017). Principios y características de las redes neuronales artificiales. *Desarrollo e innovación en ingeniería*, 173.
- AlShorman, O., Alshorman, B., & Masadeh, M. S. (2020). A review of physical human activity recognition chain using sensors. *Indonesian Journal of Electrical Engineering and Informatics (IJEEI)*, 8(3), 560-573.
- Altini, M., Penders, J., Vullers, R., & 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.
- Banos, O., Garcia, Rafael, and Saez, Alejandro. (2014). MHEALTH Dataset. UCI Machine Learning.
- Banos, O., Villalonga, C., Garcia, R., Saez, A., Damas, M., Holgado-Terriza, J. A., ... & Rojas, I. (2015). Design, implementation and validation of a novel open framework for agile development of mobile health applications. *Biomedical engineering online*, 14(2), 1-20.
- Bulling, A., Blanke, U., & Schiele, B. (2014). A tutorial on human activity recognition using body-worn inertial sensors. *ACM Computing Surveys (CSUR)*, 46(3), 1-33.
- Carpenter, A., Pencharz, P., & Mouzaki, M. (2015). Accurate estimation of energy requirements of young patients. *Journal of Pediatric Gastroenterology and Nutrition*, 60(1), 4-10.
- Demrozi, F., Pravadelli, G., Bihorac, A., & Rashidi, P. (2020). Human activity recognition using inertial, physiological and environmental sensors: A comprehensive survey. *IEEE access*, 8, 210816-210836.
- Disse, E., Ledoux, S., Bétry, C., Caussy, C., Maitrepierre, C., Coupaye, M., ... & Simon, C. (2018). An artificial neural network to predict resting energy expenditure in obesity. *Clinical Nutrition*, 37(5), 1661-1669.
- Freedson, P. S., Lyden, K., Kozey-Keadle, S., & Staudenmayer, J. (2011). Evaluation of artificial neural network algorithms for predicting METs and activity type from accelerometer data: validation on an independent sample. *Journal of Applied Physiology*, 111(6), 1804-1812.
- Garnotel, M., Simon, C., & Bonnet, S. (2019, July). Physical activity estimation from accelerometry. In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 6-10). IEEE.
- Gjoreski, H., Lustrek, M., & Gams, M. (2011). Accelerometer placement for posture recognition and fall detection. In 2011 Seventh International Conference on Intelligent Environments (pp. 47-54). IEEE.
- Grossi, E., & Buscema, M. (2007). Introduction to artificial neural networks. *European journal of gastroenterology & hepatology*, 19(12), 1046-1054.
- 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.
- Mackintosh, K. A., Montoye, A. H. K., Pfeiffer, K. A., & McNarry, M. A. (2016). Investigating optimal accelerometer placement for energy expenditure prediction in children using a machine learning approach. *Physiological measurement*, 37(10), 1728.
- Preece, S. J., Goulermas, J. Y., Kenney, L. P., & 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.
- San-Segundo, R., Montero, J. M., Barra-Chicote, R., Fernández, F., & Pardo, J. M. (2016). Feature extraction from smartphone inertial signals for human activity segmentation. *Signal Processing*, 120, 359-372.
- Shcherbina, A., Mattsson, C. M., Waggott, D., Salisbury, H., Christle, J. W., Hastie, T., ... & Ashley, E. A. (2017). Accuracy in wrist-worn, sensor-based measurements of heart rate and energy expenditure in a diverse cohort. *Journal of personalised medicine*, 7(2), 3.
- Shoab, M., Bosch, S., Incel, O. D., Scholten, H., & Havinga, P. J. (2016). Complex human activity recognition using smartphone and wrist-worn motion sensors. *Sensors*, 16(4), 426.
- Van Nguyen, N. H., Pham, M. T., Dai Ung, N., & Tachibana, K. (2018). Human activity recognition based on weighted sum method and combination of feature extraction methods. *International Journal of Intelligent Information Systems*, 7(1), 9.
- Windau, J., & Itti, L. (2018, May). Inertial machine monitoring system for automated failure detection. In 2018 IEEE International Conference on Robotics and Automation (ICRA) (pp. 93-98). IEEE.