

# Reconocimiento de actividades físicas utilizando un dispositivo wearable

Ing. Geenkel Coss\* supervisor: Dr. Carlos Brito-Loeza \*

## Resumen

El proyecto de tesis que se describe en este documento consiste en diseñar un sistema de reconocimiento de actividades físicas que funcione en tiempo real en un dispositivo *wearable*. En la introducción se resume brevemente lo que se ha hecho en el área de reconocimiento de actividades y se resaltan los trabajos en los que se ha realizado la clasificación en dispositivos *wearables*. Se expondrá el objetivo general del proyecto y los objetivos particulares y en la sección metodología se explicará como se desarrollará el proyecto y que herramientas se utilizarán. Por último se mostrarán los avances del proyecto y el calendario de actividades propuesto.

AMS clasificacion: 68T05

Palabras clave: Wearable, Sistemas Embebidos, Aprendizaje supervisado, Reconocimiento de actividades.

## 1. Introducción

El problema del reconocimiento automático de actividades ha sido estudiado en una gran cantidad de trabajos que se pueden encontrar en la literatura. En la tabla 1, tomada de [Lara y Labrador, 2013] se resumen los tipos de actividades que se han detectado en la literatura junto con algunos ejemplos.

---

\*Laboratorio de Aprendizaje Automático y Visión Maestría en Ciencias de la Computación, Facultad de Matemáticas, Universidad Autónoma de Yucatán Emails: {mcoss002@gmail.com, carlos.brito@correo.uady.mx, Web: <http://www.clir-lab.org/>

Grupo	Actividades
Ambulación	Caminar, correr, permanecer sentado o de pie, subir o bajar escaleras.
Transporte	Usar el autobús, montar bicicleta, manejar.
Vida diara	Comer, beber, ver TV, lavarse los dientes, usar la PC, leer un libro.
Ejercicio	Abdominales, lagartijas, spinning.
Social	Platicar.

Tabla 1: Tipos de actividades que se han detectado [Lara y Labrador, 2013].

Para realizar la clasificación de actividades, se han utilizado datos de diferentes sensores. Los más comunes son los sensores inerciales, en especial los acelerómetros, ya que se ha visto que son los que proporcionan información más relevante sobre las actividades. También se han utilizado micrófonos [Choudhury et al, 2008] para detectar actividades como platicar con otra persona o ver la televisión. Se ha usado GPS [Reddy et al, 2010] para actividades de transporte como conducir o montar bicicleta. También se han usado cámaras de video [Joseph et al, 2010] pero que tienen la desventaja de que la persona debe estar siempre enfrente de la cámara y además requieren bastante poder computacional. Los sensores ambientales [Choudhury et al, 2008] que pueden ser sensores de temperatura, humedad o de luz ambiental se han utilizado para obtener información acerca de donde se realiza la actividad o si es de día o de noche.

En la mayoría de los trabajos de la literatura se han utilizado técnicas de aprendizaje supervisado para realizar la clasificación de las actividades ya que generalmente es fácil obtener muestras etiquetadas y se obtienen mejores resultados. Entre las técnicas utilizadas están Árboles de decisión, Clasificadores Bayesianos, Métodos basados en instancias, Redes Neuronales, Máquinas de soporte vectorial, Lógica difusa, Métodos de regresión o combinaciones de varios métodos.

Para realizar la detección de actividades en tiempo real se han utilizado computadoras portátiles [Jatoba, 2008], teléfonos celulares [Brezmes et al, 2009] y dispositivos wearables [Choudhury et al, 2008][Maurer et al, 2006].

Los dispositivos *wearables* o vestibles son aquellos dispositivos electrónicos que una persona puede llevar encima, en alguna parte de su cuerpo o la ropa, interactuando continuamente con él, sin afectar sus actividades normales. En general, estos dispositivos se caracterizan por ser pequeños, tener una capacidad computacional limitada y además funcionan con batería.

De manera comercial, ya se ha realizado el reconocimiento de actividades físicas utilizando este tipo de dispositivos. Por ejemplo, el *smartwatch* de samsung puede detectar las actividades de caminar, correr, montar bicicleta. Por otra parte en la literatura encontramos dos trabajos que han realizado la clasificación en dispositivos *wearables*. Sus características se resumen en la tabla 1.

Se pretende que el sistema de detección de actividades que se propone implementar en este proyecto sea capaz de reconocer un mayor número de actividades y que además pueda funcionar durante varios días con una batería de menor capacidad.

## 2. Objetivos

El objetivo general de la tesis será diseñar un sistema de clasificación de actividades físicas basado mediciones inerciales que opere en tiempo real en un dispositivo wearable. Entre los objetivos particulares está la creación de una base de datos con diferentes personas realizando diferentes actividades físicas, diseñar un sistema de clasificación de actividades eficiente, diseñar un dispositivo wearable e implementar el sistema de clasificación en él.

	ewatch [Maurer et al, 2006]	Mobile Sensing Plataform (MSP) [Choudhury et al, 2008]
Procesador	Microcontrolador de 32 bits Philips LPC2106 a 60Mhz.	Intel PXA271 de 32-bit en tarjeta iMote y Atmega128 de 8-bits en tarjeta de sensores.
Medidas	50mm x 48mm x 17.5mm	51mm x 36mm
Batería	Capacidad de 700 mAh y duración de 1 día.	Capacidad de 1800 mAh y duración de 10 horas.
Sensores	Acelerómetro de 2 ejes colocado en la muñeca.	Acelerómetro de 3 ejes colocado en la cintura.
Actividades	Caminar, correr, estar sentado o de pie, subir o bajar escaleras.	Caminar, estar sentado o de pie, subir o bajar escaleras, subir o bajar en un elevador, cepillarse los dientes.
Precisión	87.1 %	93.8 %

Tabla 2: Dispositivos *wearables* que realizan clasificación de actividades en tiempo real.

### 3. Metodología

#### 3.1. Dispositivo *wearable*

El primer paso de la tesis será el diseño y fabricación del dispositivo *wearable* ya que será necesario para obtener las muestras del sensor inercial con las que se construirán los vectores de características para formar la base de datos con la que se entrenarán los algoritmos de aprendizaje.

Debido a que se pretende que el dispositivo sea pequeño y tenga una larga duración de batería, se utilizaran componentes pequeños, de montaje superficial y que tengan un consumo de energía bajo. Se utilizará un microcontrolador MSP430 de Texas Instruments ya que se consideran de muy bajo consumo de corriente. El sensor inercial que se incluirá en el diseño para obtener las muestras será el MPU9150 de invensense que también es de bajo consumo. Este sensor puede medir aceleración y velocidad angular en los ejes  $x$ ,  $y$  y  $z$  ya que internamente cuenta con un acelerómetro y un giroscopio.

#### 3.2. Vector de características

Para la clasificación de actividades se utilizarán técnicas de aprendizaje supervisado debido a la facilidad de obtener muestras etiquetadas con las que se puede entrenar el algoritmo clasificador. En la literatura se ha visto que los sensores inerciales son los que proporcionan más información para realizar la clasificación de actividades por lo que se utilizará datos de un acelerómetro y un giroscopio para formar los vectores de características, que etiquetados conformarán el conjunto de entrenamiento.

Debido a que la aceleración y la velocidad angular medida en un instante de tiempo proporciona muy poca información acerca de alguna actividad física, se deberán utilizar características que tomen en cuenta secuencias o muestras consecutivas de estas mediciones como por ejemplo, la media o la varianza.

Como se desea que la clasificación se realice de manera eficiente debido a la limitante de recursos y energía, se realizarán pruebas con diferentes combinaciones de características para tratar de encontrar el mejor balance entre eficiencia y rendimiento del algoritmo.

### 3.3. Base de datos

Uno de los objetivos de la tesis será construir una base de datos de muestras inerciales de diferentes personas realizando actividades físicas. Esto es con el fin de entrenar al algoritmo clasificador con diferentes formas de realizar las actividades. De esta manera el clasificador será flexible y no dependerá de la persona que utiliza el dispositivo, por lo que no será necesario entrenar el algoritmo para cada persona que vaya a utilizar el dispositivo.

Para construir la base de datos se reclutarán de 15 a 20 voluntarios a los cuales se les colocará el dispositivo y se les pedirá que realicen distintas actividades físicas mientras se recolectan y almacenan las muestras.

### 3.4. Algoritmo clasificador

Como ya se había mencionado, para construir el clasificador de actividades se utilizarán técnicas de aprendizaje supervisado. Se revisará la literatura para encontrar cuales clasificadores tienen una mejor relación entre eficiencia y rendimiento. Se implementarán primero de manera *offline* en una PC para medir su rendimiento y posteriormente se implementarán en el dispositivo *wearable*.

## 4. Avances

Como avance se diseñó y fabricó un dispositivo *wearable* en el que se implementará el sistema de clasificación de actividades físicas. El dispositivo está compuesto por los siguientes módulos:

- Microcontrolador de Texas Instruments MSP430F5529.
- Sensor inercial MPU9150.
- Memoria F-RAM de 1-Mbit.
- Conector para memoria microSD.
- Botones y leds.
- Batería de 420 mAh.

Este dispositivo fue programado primero para obtener muestras del sensor inercial y almacenarlas en una memoria microSD etiquetadas con un número correspondiente a una actividad. Estos datos se utilizaron para crear el primer conjunto de entrenamiento para probar los algoritmos clasificadores K-NN y Red Neuronal Artificial.

Se recolectaron muestras de 6 actividades: correr, caminar, estar en reposo, saltar, realizar abdominales, realizar lagartijas. De estas muestras se construyó un conjunto de entrenamiento con 200 vectores de características de cada actividad.

Los vectores de características están conformados por 16 elementos. Los primeros 8 son los 3 ejes de aceleración, los 3 ejes del giroscopio, el módulo del vector de aceleración y el módulo del vector del giroscopio. Las demás características se calculan tomando los módulos de  $N$  muestras consecutivas. Estos son el máximo, el mínimo, la media y la varianza de los módulos de aceleración y del giroscopio.

El primer algoritmo que se probó utilizando el conjunto de entrenamiento construido fue el de *K vecinos más cercanos* ( $K$ -NN). Éste fue implementado en MATLAB. Fijando el número  $N$  de muestras consecutivas para formar el vector de características a 10 se probó K-NN variando el número  $K$  y se encontró que el rendimiento del algoritmo no cambia significativamente cuando aumenta el número de vecinos, por lo que se seleccionó el caso más simple cuando  $K = 1$ . Después, fijando  $K = 1$  se varió el número  $N$  y se encontró que el rendimiento va aumentando conforme aumenta  $N$ , sin embargo, también aumenta la complejidad de la clasificación. Se logró un 97% de precisión utilizando  $K = 1$  y  $N = 17$ .

El otro algoritmo que se probó fue la Red Neuronal Artificial. Se realizaron pruebas con diferentes topologías utilizando validación cruzada y la función tangente hiperbólica como función de activación. También se probó variando  $N$  y se encontró que a partir de  $N=10$  se logra un 100% de precisión.

## 5. Plan de trabajo

1. Revisión en la literatura acerca de los métodos de aprendizaje supervisado.
2. Realizar pruebas clasificando diferentes actividades físicas.
3. Recolección de muestras con diferentes personas para construir base de datos.
4. Implementar clasificadores en la computadora y medir su rendimiento.
5. Selección de características que conformarán el vector.
6. Implementación en tiempo real del algoritmo clasificador en el dispositivo wearable.
7. Escribir documento de tesis y artículo científico.

Actividad	Jun	Jul	Ago	sep	oct	nov	dic	ene	feb	mar	abr	may	jun	jul
1	x	x	x	x										
2		x	x											
3			x	x										
4				x	x									
5						x								
6							x	x						
7						x	x	x	x	x	x	x	x	x

Tabla 3: Calendario de actividades.

## Referencias

- [1] N. Bicocchi, M. Mamei, and F. Zambonelli, “Detecting activities from body-worn accelerometers via instance-based algorithms,” *Pervasive and Mobile Computing*, vol. 6, no. 4, pp. 482–495, 2010.
- [2] K. Altun, B. Barshan, and O. Tunçel, “Comparative study on classifying human activities with miniature inertial and magnetic sensors,” *Pattern Recognition*, vol. 43, no. 10, pp. 3605–3620, 2010.
- [3] H. Junker, O. Amft, P. Lukowicz, and G. Tröster, “Gesture spotting with body-worn inertial sensors to detect user activities,” *Pattern Recognition*, vol. 41, no. 6, pp. 2010–2024, 2008.
- [4] A. Mannini and A. M. Sabatini, “Machine learning methods for classifying human physical activity from on-body accelerometers.,” *Sensors (Basel, Switzerland)*, vol. 10, pp. 1154–75, jan 2010.
- [5] C.-C. Yang and Y.-L. Hsu, “A review of accelerometry-based wearable motion detectors for physical activity monitoring.,” *Sensors (Basel, Switzerland)*, vol. 10, pp. 7772–88, jan 2010.
- [6] O. D. Lara and M. A. Labrador, “A survey on human activity recognition using wearable sensors,” *IEEE Communications Surveys Tutorials*, vol. 15, pp. 1192–1209, Third 2013.
- [7] U. Maurer, A. Smailagic, D. P. Siewiorek, and M. Deisher, “Activity recognition and monitoring using multiple sensors on different body positions,” in *International Workshop on Wearable and Implantable Body Sensor Networks (BSN’06)*, pp. 4 pp.–116, April 2006.
- [8] S. Reddy, M. Mun, J. Burke, D. Estrin, M. Hansen, and M. Srivastava, “Using mobile phones to determine transportation modes,” *ACM Trans. Sen. Netw.*, vol. 6, pp. 13:1–13:27, Mar. 2010.

- [9] C. N. Joseph, S. Kokulakumaran, K. Srijevantham, A. Thusyantham, C. Gunasekara, and C. D. Gamage, "A framework for whole-body gesture recognition from video feeds," in *2010 5th International Conference on Industrial and Information Systems*, pp. 430–435, July 2010.
- [10] T. Brezmes, J.-L. Gorricho, and J. Cotrina, *Activity Recognition from Accelerometer Data on a Mobile Phone*, pp. 796–799. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009.
- [11] L. C. Jatoba, U. Grossmann, C. Kunze, J. Ottenbacher, and W. Stork, "Context-aware mobile health monitoring: Evaluation of different pattern recognition methods for classification of physical activity," in *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 5250–5253, Aug 2008.
- [12] T. Choudhury, G. Borriello, S. Consolvo, D. Haehnel, B. Harrison, B. Hemingway, J. Hightower, P. . Klasnja, K. Koscher, A. LaMarca, J. A. Landay, L. LeGrand, J. Lester, A. Rahimi, A. Rea, and D. Wyatt, "The mobile sensing platform: An embedded activity recognition system," *IEEE Pervasive Computing*, vol. 7, pp. 32–41, April 2008.