





VT-T00063-SSI

Don. - 2014





CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS  
DEL INSTITUTO POLITÉCNICO NACIONAL

Laboratorio de Tecnologías de Información,  
CINVESTAV-Tamaulipas

**Reconocimiento de Actividades Físicas de un  
Usuario Móvil a través de un Acelerómetro  
Tri-axial Incorporado en un Smartphone**

Tesis que presenta:

**Andrés Álvarez Landero**

Para obtener el grado de:

**Maestro en Ciencias  
en Computación**

Director de la Tesis:  
Dr. César Torres Huitzil

**CINVESTAV  
IPN  
ADQUISICION  
LIBROS**

Cd. Victoria, Tamaulipas, México

Octubre, 2013



CLASIF..	UT 00063
ADQUIS..	UT-T00063-SS1
FECHA:	21-10-2014
PROCED..	Don-2014
	\$

ID: 216275-1001



© Derechos reservados por  
Andrés Álvarez Landero  
2013



La tesis presentada por Andrés Álvarez Landero fue aprobada por:

---

Dr. José Juan García Hernández

---

Dr. Hiram Galeana Zapién

---

Dr. César Torres Huitzil, Director

Cd. Victoria, Tamaulipas, México, 24 de Octubre de 2013



Dedicado a toda mi familia

# Agradecimientos

- ▶ Agradezco a Dios por haberme acompañado y guiado a lo largo de mis estudios de maestría, por ser mi fortaleza en los momentos de debilidad y por la salud que nunca me faltó.
- ▶ Agradezco a mis padres Andrés Álvarez y Bartola Landero por el apoyo brindado en todo momento, por sus sabios consejos, por los valores que me han inculcado y sobre todo por ser un ejemplo de vida a seguir.
- ▶ Agradezco al Dr. César Torres Huitzil por su acertada dirección y el apoyo brindado en la realización de este trabajo de tesis, pero sobre todo por su paciencia y sus buenos consejos.
- ▶ A mis revisores, Dr. José Juan García Hernández y Dr. Hiram Galeana Zapién por el tiempo dedicado en revisar este documento de tesis, por sus comentarios y las sugerencias realizadas para enriquecer este trabajo.
- ▶ Al CINVESTAV por todo el apoyo académico brindado, los cuales hicieron posible el cumplimiento de esta maestría.
- ▶ A todos los investigadores del Laboratorio de Tecnología de Información del CINVESTAV Tamaulipas por su apoyo, confianza y el tiempo dedicado para transmitir sus conocimientos durante la realización de mis estudios.
- ▶ A todos mis compañeros de generación por todos los momentos compartidos durante la realización de mis estudios, así como el deseo de superación personal y profesional.
- ▶ Al CONACYT por otorgarme el apoyo económico el cual permitió concluir mis estudios de maestría.



# Índice General

<b>Índice General</b>	<b>I</b>
<b>Índice de Figuras</b>	<b>v</b>
<b>Índice de Tablas</b>	<b>vii</b>
<b>Índice de Algoritmos</b>	<b>ix</b>
<b>Resumen</b>	<b>xi</b>
<b>Abstract</b>	<b>xiii</b>
<b>Nomenclatura</b>	<b>xv</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Antecedentes y motivación	1
1.2. Planteamiento del problema	3
1.3. Pregunta de investigación	6
1.4. Objetivos	6
1.5. Metodología	7
1.6. Organización de la tesis	9
<b>2. Marco teórico y estado del arte</b>	<b>11</b>
2.1. Marco teórico	11
2.1.1. Técnicas de preprocesamiento de datos	12
2.1.1.1. Técnicas para la remoción de ruido	12
2.1.1.2. Uniformización de datos	13
2.1.2. Extracción de características	14
2.1.2.1. Dominio del tiempo	14
2.1.2.2. Dominio de la frecuencia	15
2.1.3. Análisis de componentes principales	17
2.1.4. Métodos de clasificación	19
2.1.5. Fundamento de redes neuronales	21
2.1.5.1. Red perceptrón	22
2.1.5.2. Red <i>feedforward</i>	23
2.2. Estado del arte	26
2.3. Resumen	32



<b>3. Sistema de reconocimiento de actividades físicas</b>	<b>35</b>
3.1. Panorama general	35
3.2. Preprocesamiento de datos	37
3.2.1. Eliminación de ruido	37
3.2.2. Interpolación de datos	39
3.3. Segmentación de datos	40
3.4. Extracción y selección de características	42
3.4.1. Modelo autorregresivo	43
3.4.2. Cálculo de los percentiles	45
3.4.3. Construcción del vector de características	46
3.5. Obtención de los componentes principales	47
3.6. Clasificación de las actividades	48
3.6.1. Distribución de las clases	49
3.6.2. Esquema de clasificación jerárquico	51
3.7. Resumen	52
<b>4. Experimentación y resultados</b>	<b>55</b>
4.1. Recopilación de datos por el acelerómetro	55
4.2. Parametrización del esquema jerárquico	59
4.2.1. Estimación del número de coeficientes autorregresivos	59
4.2.2. Selección del número de componentes principales	61
4.2.3. Topología de las redes	62
4.3. Evaluación del enfoque propuesto	63
4.3.1. Técnicas y métricas de evaluación	63
4.3.2. Precisión y exactitud del clasificador	65
4.3.3. Robustez del sistema respecto a cambios de usuario	66
4.3.4. Comparación con otros clasificadores	68
4.4. Implementación en un smartphone .	69
4.4.1. Tiempos de ejecución	69
4.4.2. Estimación del consumo de energía	71
4.4.3. Aplicación de prueba de concepto	72
4.5. Resumen	74
<b>5. Conclusiones y trabajo futuro</b>	<b>75</b>
5.1. Conclusiones	75
5.2. Trabajo futuro	77
<b>A. Diseño de la aplicación móvil y el sistema web</b>	<b>79</b>
A.1. Componentes de una aplicación móvil en Android	79
A.2. Módulo 1: Recolección de datos	81
A.3. Módulo 2: Reconocimiento fuera de línea	82
A.4. Módulo 3: Reconocimiento en línea	84
A.5. Módulo 4: Proceso de notificación	84







# Índice de Figuras

1.1.	Ubicaciones donde el usuario coloca el smartphone	3
1.2.	Señal de la aceleración cuando un usuario camina sobre una superficie sólida y el pasto	5
1.3.	Perfiles de la aceleración cuando se realiza una misma actividad física	6
1.4.	Diagrama general de un sistema de reconocimiento de actividades físicas	8
2.1.	Arquitectura delno perceptrón simple	23
2.2.	Arquitectura de una red <i>feedforward</i> .	25
2.3.	Posiciones del smartphone consideradas en el trabajo [1].	28
2.4.	Diseño de la red neuronal propuesta en el trabajo [2].	30
3.1.	Etapas de la solución propuesta para el reconocimiento de actividades físicas	36
3.2.	Remoción de la gravedad a través de un filtro pasa altas.	38
3.3.	Señal suavizada a partir un filtro promedio de orden tres.	39
3.4.	Ejemplificación de la frecuencia de muestreo no regular	40
3.5.	División del conjunto de datos en segmentos de tamaño $k$	41
3.6.	Ejemplificación de una señal segmentada cada 200 muestras.	42
3.7.	Señales generadas al caminar, subir y bajar escaleras	46
3.8.	Proceso de extracción de características.	47
3.9.	Proyección del espacio de características sobre los CPs	47
3.10.	Diagrama general para la obtención de los CPs.	48
3.11.	Distribución de las clases empleando la media y la desviación estándar	49
3.12.	Ilustración de las clases linealmente separables y las no separables	50
3.13.	Esquema jerárquico propuesto para el reconocimiento de actividades físicas	52
4.1.	Bolsillos y orientaciones consideradas de como portar el smartphone	56
4.2.	Organización de los datos recolectados.	58
4.3.	Estimación de los coeficientes autorregresivos	60
4.4.	Estimación de una señal a partir de los coeficientes autorregresivos	60
4.5.	Perfiles de la energía consumida por tres dispositivos móviles	72
4.6.	Esquema de notificación entre el GCM, la aplicación móvil y el sistema web.	73
A.1.	Módulo 1 diseñado para la recolección de datos	82
A.2.	Módulo de reconocimiento fuera de línea	83
A.3.	Módulo de Clasificación en línea.	85
A.4.	Interfaz empleada para el proceso de clasificación en línea.	86
A.5.	Módulo de notificación	87
A.6.	Interfaz gráfica del sistema Web.	89



# Índice de Tablas

2.1. Características del dominio del tiempo . . . . .	16
2.2. Características del dominio de la frecuencia . . . . .	17
2.3. Clasificadores reportados en la literatura . . . . .	19
2.4. Resultados de la evaluación de las SVMs diseñadas en el trabajo [1] . . . . .	28
2.5. Evaluación de características a partir de los clasificadores . . . . .	29
2.6. Características evaluadas con diferentes clasificadores en el trabajo [3] . . . . .	31
2.7. Modos de portabilidad considerados en el trabajo [4] . . . . .	32
2.8. Resumen de los trabajos revisados en el estado del arte . . . . .	32
3.1. Tamaños de ventanas considerados en la literatura. . . . .	41
3.2. Características seleccionadas para el reconocimiento de actividades físicas . . . . .	43
4.1. Datos recolectados por un usuario. . . . .	58
4.2. CPs seleccionados a partir de su varianza . . . . .	61
4.3. Configuración de las redes empleadas en el esquema jerárquico . . . . .	62
4.4. Matriz de confusión empleada para dos clases. . . . .	64
4.5. Medidas utilizadas para la evaluación del clasificador. . . . .	64
4.6. Ejemplos utilizados para validar y evaluar el clasificador . . . . .	65
4.7. Resultados de la evaluación del esquema de clasificación jerárquico. . . . .	66
4.8. Porcentajes de reconocimiento obtenido al evaluar a otros usuarios . . . . .	67
4.9. Obtención de la velocidad de caminar por diferentes usuarios . . . . .	67
4.10. Parametrización de los clasificadores. . . . .	68
4.11. Resultados obtenidos de los clasificadores evaluados . . . . .	69
4.12. Características de los diferentes smartphones utilizados. . . . .	70
4.13. Estimación de los tiempos de ejecución . . . . .	70
4.14. Estimación del consumo de energía en tres diferentes dispositivos . . . . .	71



# Índice de Algoritmos

1. Algoritmo de filtrado para la remoción de la gravedad 38
2. Algoritmo de Burg para la obtención de los coeficientes de un modelo autorregresivo 44



## **Reconocimiento de Actividades Físicas de un Usuario Móvil a través de un Acelerómetro Tri-axial Incorporado en un Smartphone**

por

**Andrés Álvarez Landero**

Laboratorio de Tecnologías de Información, CINVESTAV-Tamaulipas  
Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, 2013  
Dr. César Torres Huitzil, Director

La aceptación de los teléfonos móviles inteligentes (smartphones) por los usuarios se incrementa cada día más, gracias a la diversidad de aplicaciones y servicios de comunicación de banda ancha, cómputo y sensado que éstos ofrecen. Aprovechando la infraestructura de sensado de los smartphones es factible desarrollar aplicaciones que utilicen información de la movilidad y/o contexto del usuario. Por ejemplo, el sistema de posicionamiento global (GPS) es usado en diversas soluciones en el mercado para desarrollar aplicaciones móviles basadas en la ubicación y mediante el análisis de la señal del acelerómetro ha hecho posible reconocer gestos e inferir las actividades físicas realizadas por un usuario. Sin embargo, el reconocimiento de actividades a través de un smartphone no es una tarea sencilla debido a que existen diferentes factores que dificultan su desarrollo: el uso del dispositivo móvil en ambientes no controlados, la variación de la aceleración respecto a su posición y orientación y las capacidades limitadas del dispositivo. El objetivo de este trabajo de tesis es desarrollar un sistema de reconocimiento de actividades físicas de un usuario móvil, mediante el uso de un acelerómetro tri-axial independiente de la posición y orientación del smartphone. Para el reconocimiento se consideran las actividades de correr, caminar, subir escaleras, bajar escaleras y estático, cuando el dispositivo se ubica en los bolsillos frontales y posteriores de un pantalón. La solución propuesta emplea características del dominio del tiempo (estadísticas y coeficientes autorregresivos), análisis de componentes principales y un esquema de clasificación jerárquico basado en redes neuronales. Bajo este enfoque se obtuvo una exactitud del 93.3 % en el reconocimiento de las actividades físicas. El sistema de reconocimiento fue



implementado en un smartphone con sistema operativo Android permitiendo el monitoreo continuo durante 10 horas aproximadamente y tiempos de respuestas aproximados de 0.6 segundos. Finalmente se muestra su utilidad en una aplicación móvil de prueba de concepto, la cual se comunica con un sistema web bajo un esquema de comunicación cliente-servidor, para registrar y notificar un resumen del historial de las actividades físicas realizadas por un usuario



## **Mobile User Physical Activity Recognition using a Tri-axial accelerometer embedded in a smartphone.**

by

**Andrés Álvarez Landero**

Information Technology Laboratory, CINVESTAV-Tamaulipas

Research Center for Advanced Study from the National Polytechnic Institute, 2013

Dr. César Torres Huitzil, Advisor

The acceptance of smart mobile devices (smartphones) by users increases every day, thanks to the diversity of applications and broadband communication, computing and sensing services that they offer. Leveraging smartphones sensing infrastructure is feasible to develop applications that use information about the mobility and/or user context. For example, the Global Positioning System (GPS) is used in various market solutions to develop mobile applications based on location and by analyzing the accelerometer signal it is possible to recognize gestures and infer the physical activities performed by a user. However, the recognition of activities through a smartphone is not a simple task, because there are various factors that hinder their development: the use of the device in uncontrolled environments, acceleration measurements are position and orientation dependent and the device limited capacities. The objective of this thesis work is to develop a recognition system of physical activities of a mobile user, using a tri-axial accelerometer independently of position and orientation of the smartphone. For activity recognition, running, walking, up stairs, down stairs and static, are considered in different positions in the front and back trousers pockets. The proposed solution is based on time domain characteristics, principal component analysis and a hierarchical classification scheme based on neural networks. Under this approach, an accuracy of 93.3% was obtained. The recognition system was fully implemented in Android capable smartphones allowing continuous monitoring during 10 hours and time response of 0.6 seconds on average. Finally, a mobile application, which communicates with a web service under a client-server scheme, was developed as a proof-of-concept to record and report a summary of physical activities history for a user.



# Nomenclatura

<b>GPS</b>	Sistema de posicionamiento global
<b>SVM</b>	Máquinas de vector soporte
<b>K-NN</b>	$K$ vecinos más cercanos
<b>NB</b>	Naïve Bayes
<b>SMA</b>	Área de la magnitud de la señal
<b>RMS</b>	Raíz cuadrada media
<b>WT</b>	Transformada wavelet
<b>FFT</b>	Transformada rápida de fourier
<b>LDA</b>	Análisis discriminante lineal
<b>RMS</b>	Raíz cuadrada media
<b>SO</b>	Sistema operativo
<b>RNA</b>	Redes neuronales artificiales
<b>DT</b>	Árboles de decisión
<b>ACP</b>	Análisis de componentes principales
<b>CPs</b>	Componentes principales
<b>API</b>	Interfaz de programación de aplicaciones
<b>XML</b>	Lenguaje de marca extensible
<b>GCM</b>	<i>Google Cloud Messaging</i>
<b>GAE</b>	<i>Google App Engine</i>



# 1

## Introducción

### 1.1 Antecedentes y motivación

Con el desarrollo de las nuevas tecnologías microelectrónicas, aplicadas al diseño de los teléfonos móviles inteligentes también conocidos como smartphones, las dimensiones físicas de éstos son cada vez menores. Gracias a la diversidad de aplicaciones, servicios de comunicación, cómputo y sensado que ofrecen los smartphones, su adopción por los usuarios aumenta cada día más desempeñando un papel importante dentro de sus vidas. Algunos de los servicios más sofisticados que proporcionan los smartphones son: localización basada en el sistema de posicionamiento global (GPS), acceso a conexiones inalámbricas de área local (Wi-Fi) y redes celulares de banda ancha (LTE, evolución a largo plazo), internet móvil, televisión, radio, multimedia, aplicaciones de navegación y redes sociales, así como las tareas de telefonía. Otra de las características atractivas que poseen los smartphones es la capacidad de percibir su entorno a través de sus sensores integrados tales como el micrófono, la cámara, el GPS y los sensores inerciales: acelerómetro, giroscopio y brújula [5].



En el caso de los sensores inerciales, su incorporación en los smartphones tenía como objetivo mejorar la interacción con el usuario, de forma que al cambiar la orientación del smartphone de forma automática permitiese al usuario visualizar fácilmente la información. También es posible realizar aplicaciones para el reconocimiento de gestos [6, 7, 8], realidad aumentada [9], juegos, etcétera a partir del análisis de los datos proporcionados por el acelerómetro asociado a los movimientos o gestos realizados por el smartphone. Otra de las aplicaciones factibles de desarrollar con los datos del acelerómetro, es el reconocimiento de actividades físicas que un usuario realiza. Por ejemplo: correr, caminar, andar en bicicleta, estar de pie, sentado, acostado [5, 10, 11] o incluso la detección de caídas de un usuario [12, 13, 14].

A pesar de las restricciones que presentan los sistemas de reconocimiento de actividades físicas reportados en la literatura, se han intentado realizar sistemas complejos [14, 15, 16], pero debido a las restricciones que presentan (el uso de más de un acelerómetro, ajustados a una sola posición, etcétera) no son factibles de realizarse en escenarios reales. Sin embargo, disponer de un sistema capaz de reconocer las actividades físicas considerando posiciones de portabilidad más realistas, permitiría desarrollar sistemas o aplicaciones móviles más complejas: en el ámbito de la salud sería posible implementar un sistema de monitoreo y notificación que con base al historial de las actividades físicas realizadas en un intervalo de tiempo dado, fuese capaz de deducir tendencias o hábitos asociados a la condición física de un usuario [16, 17]. También sería factible construir sistemas dependientes del contexto, los cuales permiten personalizar el comportamiento del smartphone según la actividad física que se esté realizando tales como desactivar servicios (GPS, Wi-Fi, Bluetooth), cambiar perfiles de sonido, reproducir música, etcétera [16, 18]. Otra aplicación asociada al reconocimiento de actividades físicas es el desarrollo de un sistema de recomendación y notificación publicitaria a diferentes usuarios según el lugar y la actividad física que estén realizando, por ejemplo, si un usuario está corriendo notificarle acerca de bebidas energéticas, marcas de zapatos y/o ropa deportiva, entre otras [16, 18].



Puesto que existe una gran variedad de aplicaciones que se pueden realizar a partir de un sistema de reconocimiento de actividades físicas implementado en un smartphone y considerando escenarios más realistas, en este trabajo de tesis se ha desarrollado dicho sistema partiendo del análisis de los datos proporcionados por un acelerómetro tri-axial de un smartphone. El sistema es capaz de discriminar entre las siguientes actividades: correr, caminar, subir/bajar escaleras y estáticas (de pie, sentado y acostado). Una de las características importantes de este sistema, es que permite el reconocimiento de las actividades cuando el dispositivo móvil se ubica en diferentes posiciones y orientaciones de portabilidad, tal como se ilustra en la Figura 1.1.




Figura 1.1: Ubicaciones consideradas donde el usuario puede colocar el smartphone.

## 1.2 Planteamiento del problema

El problema abordado en este trabajo de tesis puede verse desde la perspectiva del paradigma de reconocimiento de patrones, por lo cual se plantea formalmente de la siguiente manera:



Dado  $\vec{X} = \{x_1, x_2, \dots, x_k\}$  un vector de características obtenido de una secuencia de mediciones  $\{\vec{a}_1, \vec{a}_2, \dots, \vec{a}_n\}$  proporcionadas por un acelerómetro tri-axial, determinar a que actividad física del conjunto  $\mathbf{A} = \{A_1, A_2, \dots, A_m\}$  pertenece.

Donde  $\vec{a} = (a_x, a_y, a_z)$  es el vector de aceleración proporcionado por un acelerómetro tri-axial,  $a_x, a_y, a_z$  las componentes de la aceleración medidas en el marco de referencia del smartphone,  $k$  es el número de características,  $n$  el número de datos en crudo y  $k < n$ .

Básicamente el problema de reconocimiento de actividades consiste en extraer las características más representativas y en diseñar un esquema de clasificación para discriminar entre las diferentes clases, con la condición de que el clasificador sea de bajo costo computacional debido a que se implementa en un smartphone. Desarrollar un sistema de reconocimiento de actividades físicas a través de un smartphone no es una tarea fácil de resolver, debido a que la señal de la aceleración capturada por el acelerómetro tri-axial se ve influenciada por los siguientes problemas:

- ▶ Las mediciones capturadas por el acelerómetro dependen de la posición y orientación en la que el usuario coloque el smartphone.
- ▶ El ambiente (superficie) sobre el cual se mueve el usuario no es el mismo.
- ▶ La vestimenta (calzado, pantalón, etcétera) usada por los usuarios es variable.
- ▶ Existen variaciones en las señales obtenidas por el acelerómetro entre usuarios, al realizar una misma actividad física.
- ▶ Los dispositivos móviles están limitados en recursos (hardware y software).

En efecto, existen múltiples ambientes donde el usuario puede realizar alguna actividad física, los cuales provocan que el acelerómetro capture diferentes mediciones de la aceleración. Por ejemplo, en la Figura 1.2 se ilustran distintas señales al realizar una misma actividad (caminar) sobre una superficie sólida y una superficie con pasto Figura 1.2 a) y 1.2 b), respectivamente (por simplicidad



en las Figuras 1.2 y 1.3 solo se ilustra la magnitud del vector de la aceleración). Por otro lado, el hecho de que no exista un marco de referencia único que determine la manera en la que el usuario lleve el smartphone, ocasiona que el acelerómetro capture diferentes perfiles de la aceleración para una misma actividad física. Un ejemplo de esto se puede ver en las mediciones ilustradas en las gráficas de las Figura 1.3 a) y 1.3 b) al portar el smartphone en dos posiciones diferentes (Figura 1.3 c)) y realizar una misma actividad física (caminar).

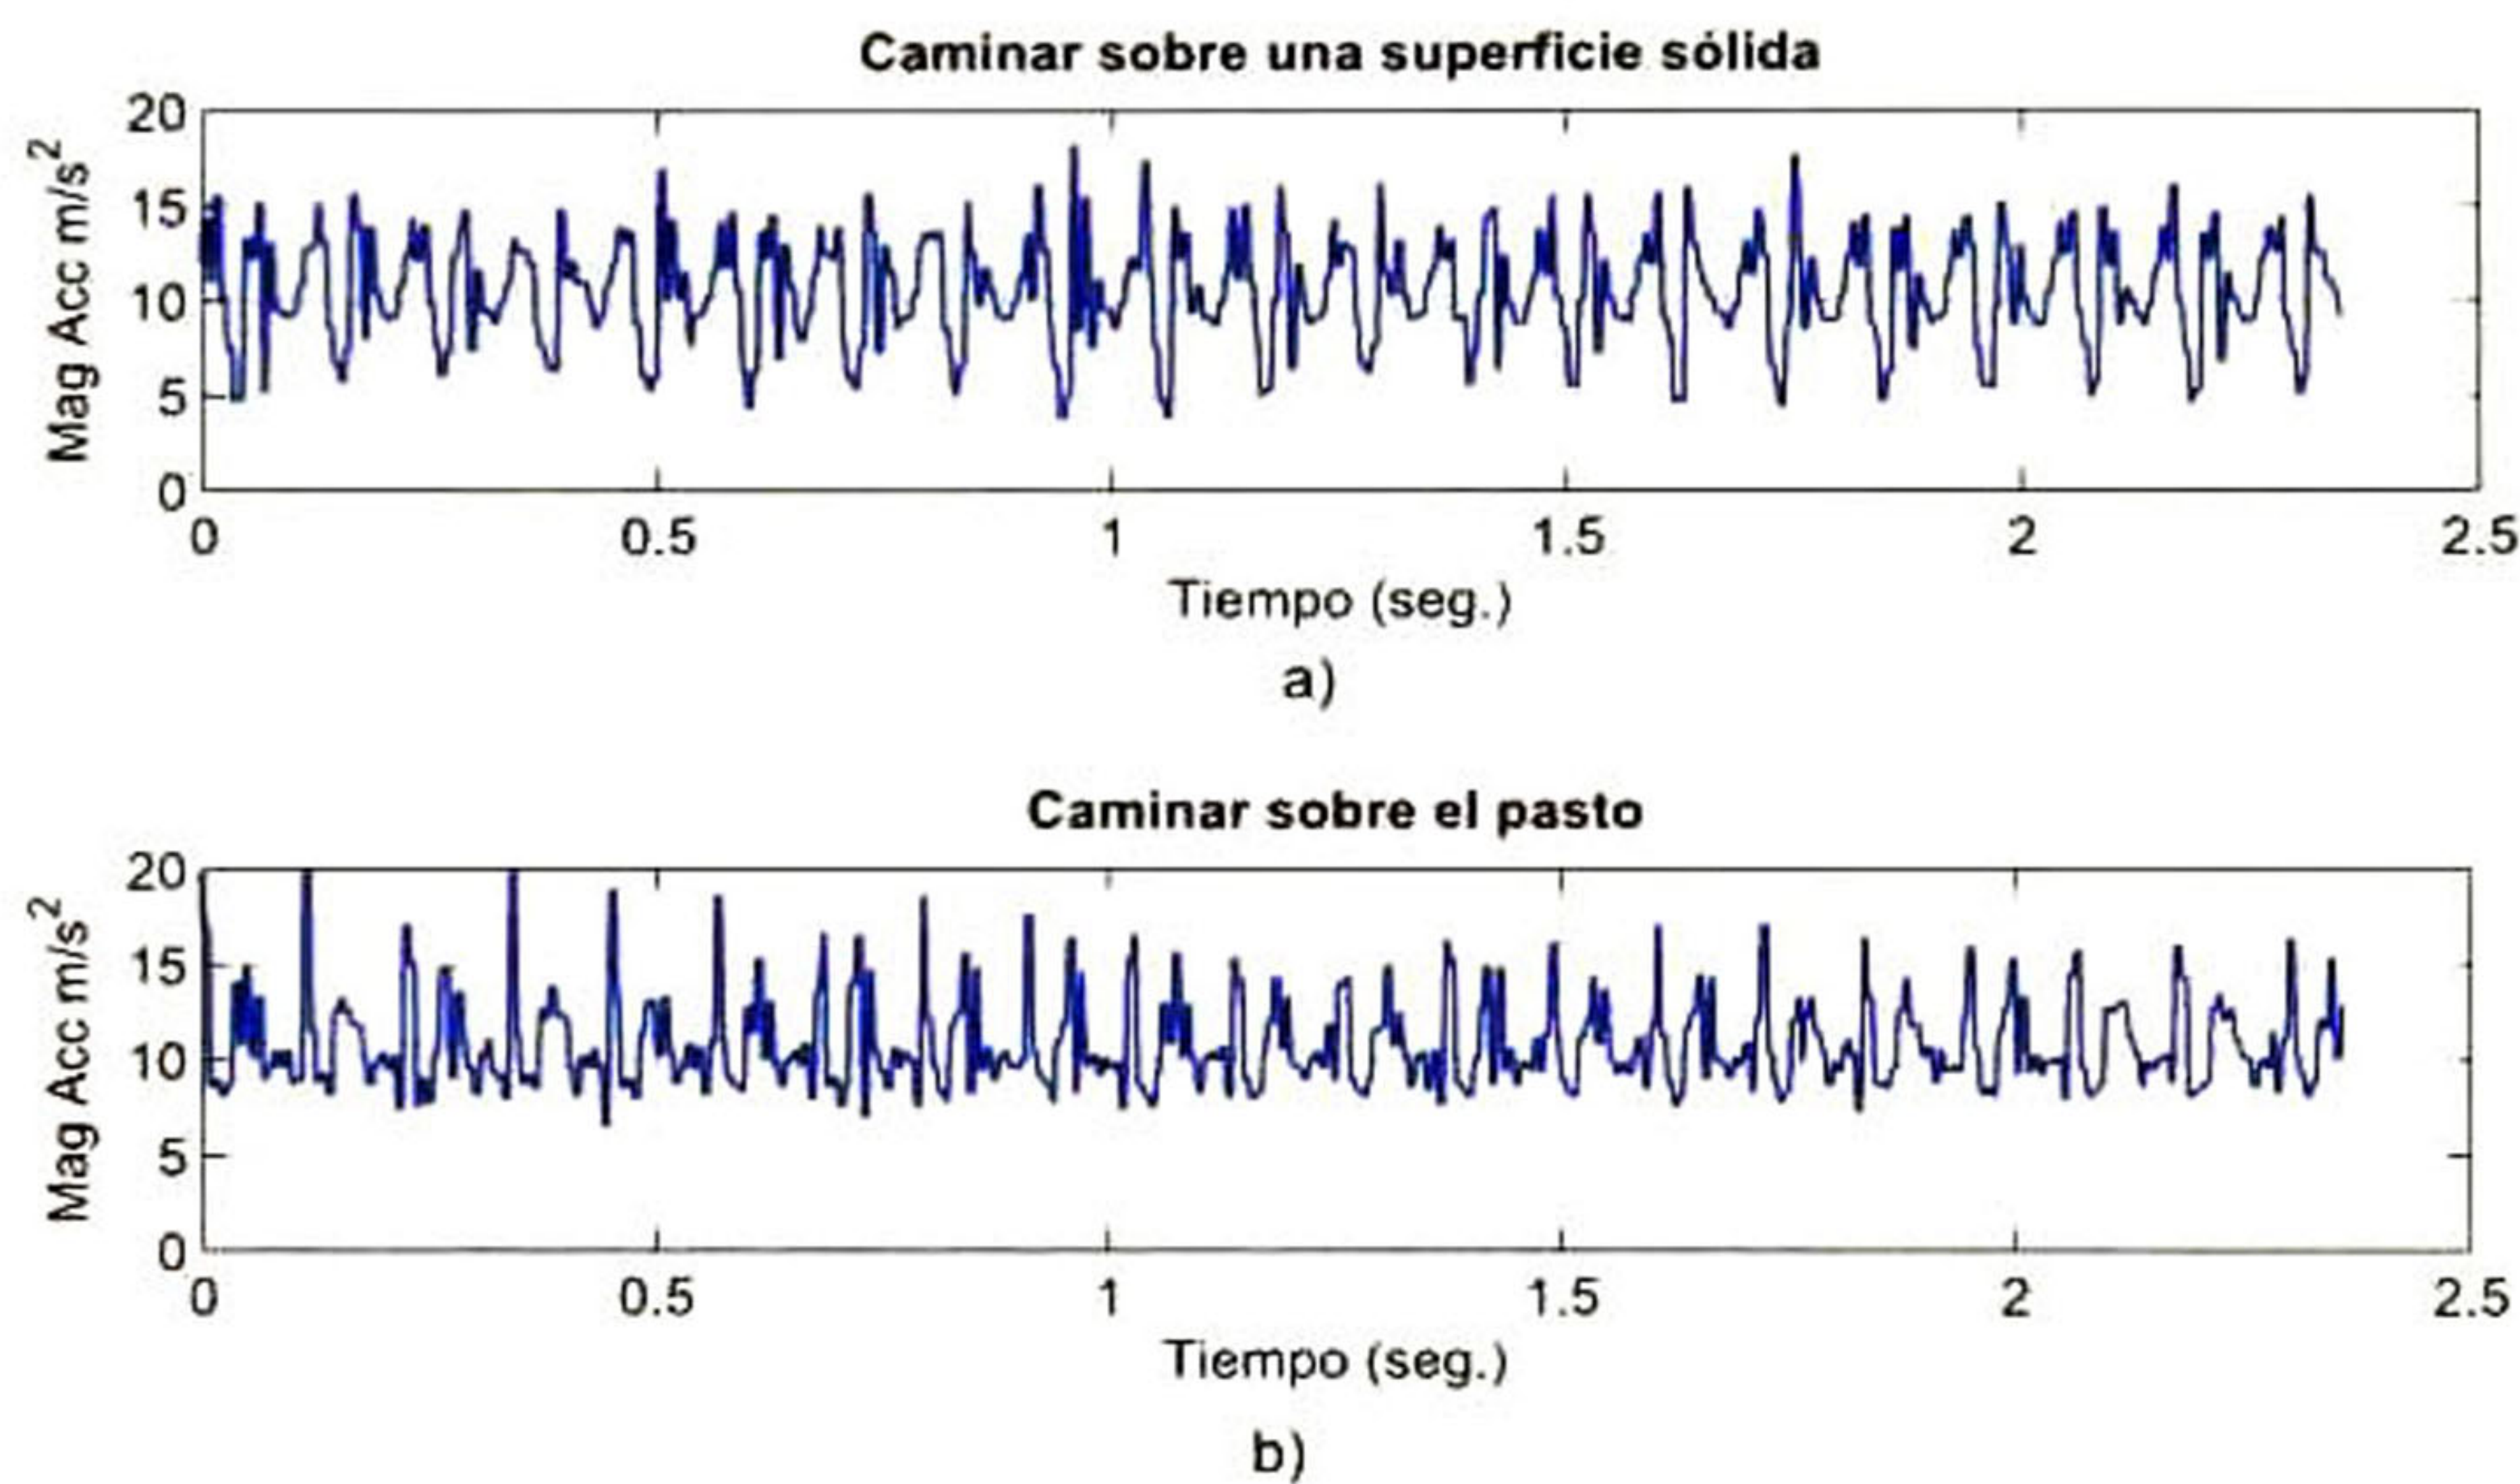


Figura 1.2: Señales de la aceleración cuando un usuario camina sobre una superficie sólida a) y el pasto b).

Respecto a las limitaciones que presentan los smartphones, su sistema operativo es una de ellas debido a que no ha sido concebido para realizar tareas específicas tales como la captura constante de muestras por el acelerómetro. Por ejemplo, esto ocasiona que en un intervalo de tiempo dado, no se capture el mismo número de muestras por el acelerómetro. Para ilustrar este inconveniente en la Figura 1.3 a) y 1.3 b) se observa que el número de muestras es de 1000 y 980, respectivamente cuando se realiza la misma actividad en un tiempo de 25 segundos. Por otro lado, los recursos de energía, almacenamiento y procesamiento de un smartphone son limitados lo cual restringe el uso de algoritmos complejos para el reconocimiento de las actividades, debido a que requieran de un mayor costo de computacional.



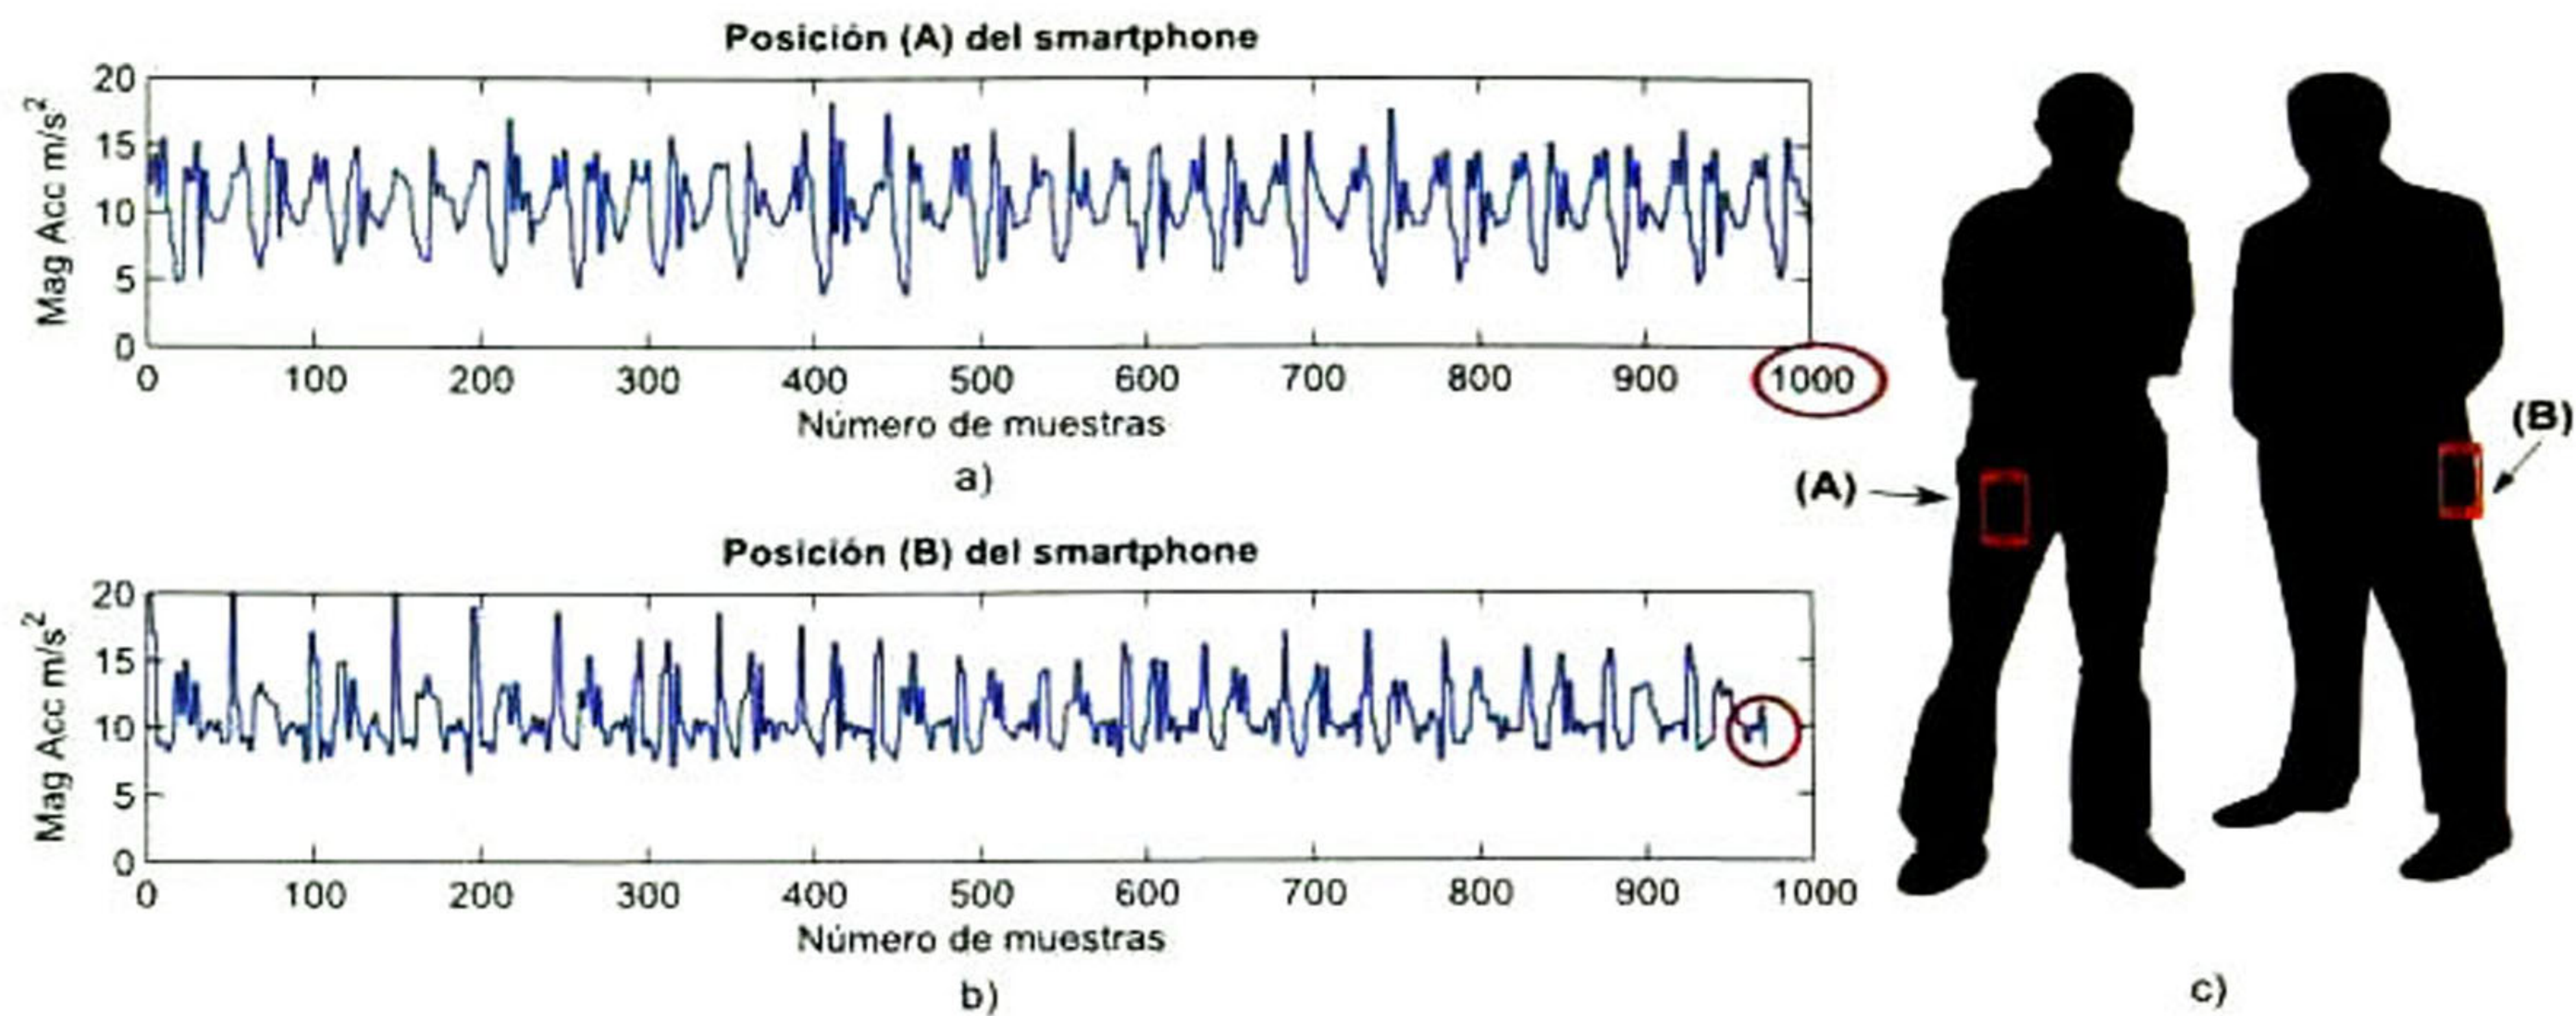


Figura 1.3: Perfiles de la aceleración cuando se realiza una misma actividad física (caminar) y llevar el smartphone en posiciones diferentes. Adicionalmente se ilustra con los círculos rojos la frecuencia de muestreo no regular.

## 1.3 Pregunta de investigación

En este trabajo de tesis se plantea la siguiente pregunta de investigación:

¿Es posible reconocer las actividades físicas realizadas por un usuario portando el smartphone en diferentes posiciones utilizando características en el dominio del tiempo, empleando un clasificador de bajo costo computacional y de precisión competitiva?

## 1.4 Objetivos

El objetivo principal de este trabajo de tesis es:

- Diseñar un sistema de reconocimiento de actividades físicas realizadas por un usuario móvil a través de un acelerómetro tri-axial incorporado en un smartphone.

Los objetivos específicos que se han establecido son los siguientes:



- ▶ Identificar las características que sean más relevantes, independientes de la posición y orientación y de bajo costo computacional, a partir de las muestras extraídas de un acelerómetro tri-axial.
- ▶ Determinar un método de clasificación que sea de bajo costo computacional para su implementación en el dispositivo móvil y pueda clasificar de manera precisa, las actividades físicas realizadas por el usuario.
- ▶ Diseñar una aplicación móvil que interactúe con un sistema web basado en un esquema de comunicación cliente-servidor, para monitorear y notificar al usuario el historial de las actividades físicas realizadas.

## 1.5 Metodología

La metodología seguida para el desarrollo de este trabajo de tesis se ilustra en el diagrama de la Figura 1.4. Como primer paso se realiza la recopilación de un conjunto de datos, posteriormente se aplica un preprocesamiento a los datos recolectados, se extraen las características apropiadas y finalmente se diseña un esquema de clasificación que discrimine entre las actividades.

Para la recolección de los datos se diseñó una aplicación móvil en un smartphone con sistema operativo (SO) Android, la cual almacena automáticamente los datos proporcionados por el acelerómetro. A fin de tener un control sobre los datos recolectados, la aplicación permite configurar algunos parámetros como: el tipo de actividad física, el tiempo de captura, la posición y orientación del smartphone. Se ha seleccionado Android como plataforma móvil para la validación y prototipado del sistema de reconocimiento debido a que es el más adoptado con respecto a otros SO móviles. Según [19, 20] Android abarca aproximadamente el 75.13% del mercado internacional y el resto es distribuido en otros SO móviles tales como *iOS*, *Symbian*, *Windows Phone*, etcétera.



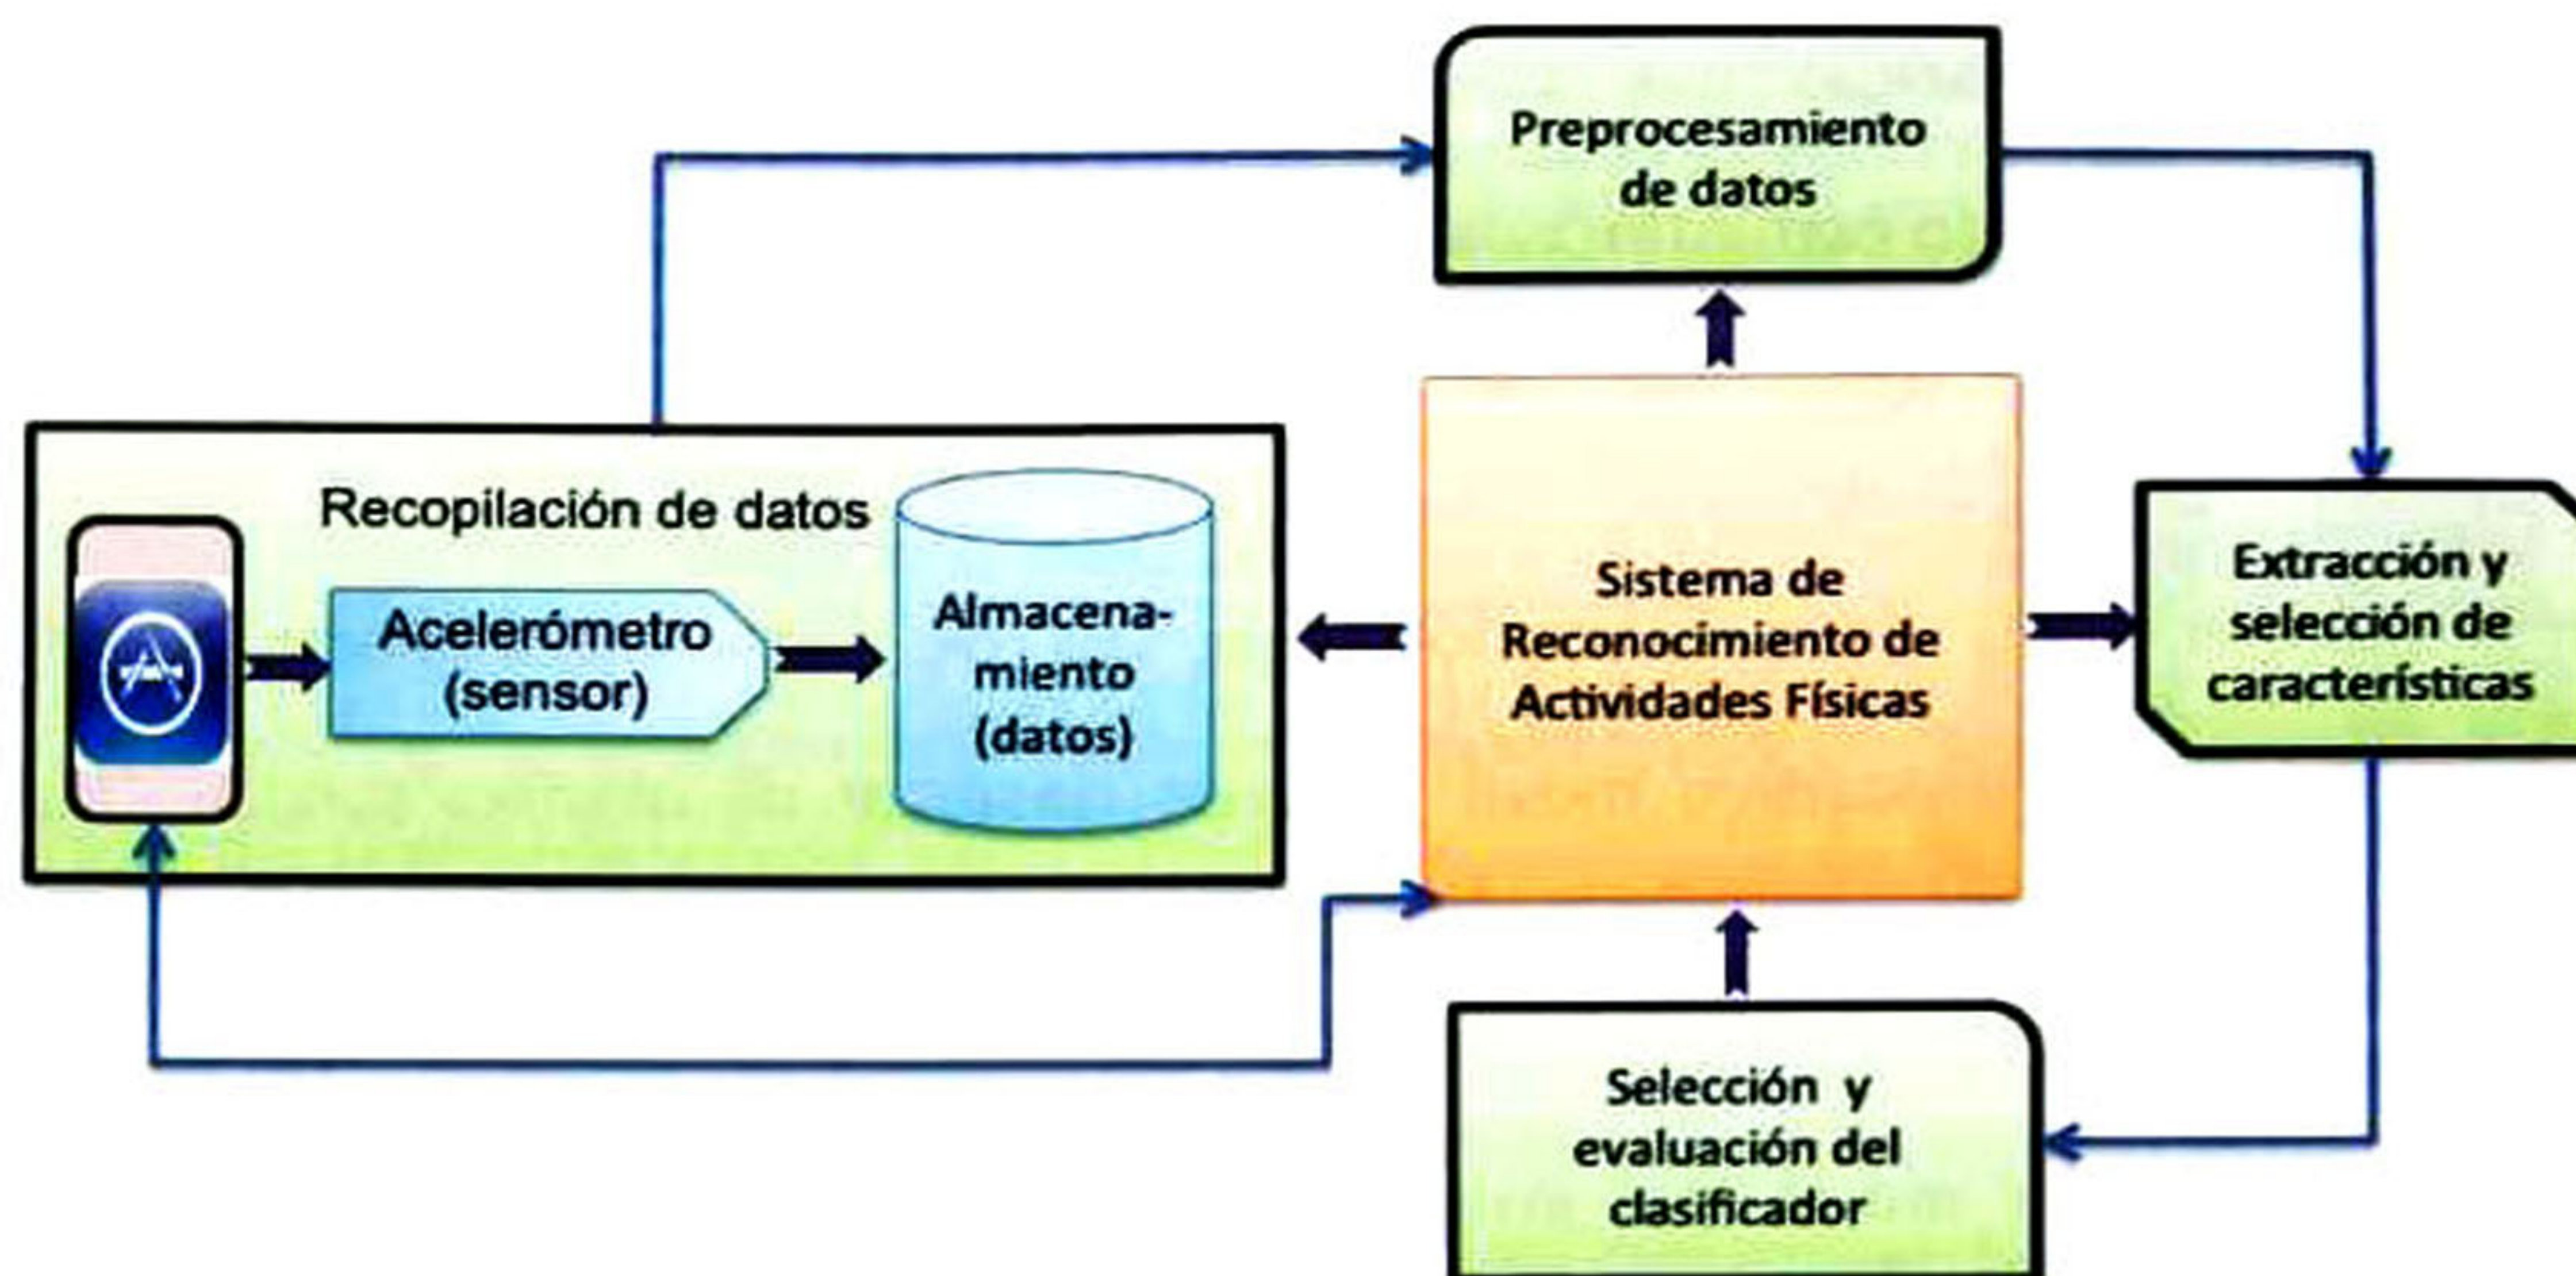


Figura 1.4: Diagrama general de un sistema de reconocimiento de actividades físicas, basado en el paradigma de reconocimiento de patrones

En la etapa de preprocesamiento de datos, se remueven aquellas variaciones indeseables de la aceleración, tales como la gravedad y el ruido generado por las vibraciones (*jittering*) generalmente capturadas por el acelerómetro [11, 21]. Para ello, se aplican técnicas de suavizado de datos como el filtro pasa altas de primer orden y el filtro promedio móvil (*moving average*). Como parte complementaria se aplicó un método de interpolación lineal que solventara el problema de la frecuencia de muestreo no regular.

Otras de las tareas realizadas fue la determinación de características, las cuales fueron seleccionadas con base en la revisión del estado del arte y experimentaciones. Se encontró que las características estadísticas [10] como la media, la desviación estándar, los percentiles y el uso de coeficientes autorregresivos proporcionan una buena representación de las señales generadas por el acelerómetro. Adicionalmente se empleó el análisis de componentes principales (ACP) con la finalidad de reducir el número de características y por lo tanto el costo computacional.

En la etapa de clasificación y evaluación, se diseña un esquema jerárquico basado en redes neuronales (*perceptrón* y *feedforward*) [5, 22, 23] y se realizó una comparación con algunos de los clasificadores reportados en la literatura para el reconocimiento de actividades físicas (máquinas de



vectores de soporte (SVM), Naïve Bayes (NB) y  $k$  vecinos más cercanos (K-NN)) [5, 22, 23]. De los resultados obtenidos se observó que el porcentaje de precisión de la enfoque propuesto es superior a los otros métodos. Una vez diseñado y validado el esquema de clasificación, éste se implementó en el dispositivo y se evaluaron el tiempo de ejecución y el consumo de energía.

Finalmente se desarrolla una aplicación sobre una plataforma móvil (Android), la cual interactúa con un sistema web bajo un esquema de comunicación cliente-servidor. La aplicación web que se diseñó monitorea y notifica al usuario el historial de las actividades físicas realizadas.

## 1.6 Organización de la tesis

El resto del presente documento de tesis está estructurado como se indica a continuación: en el Capítulo 2 se describe el marco teórico, terminología y conceptos asociados al contexto de esta investigación. También se describen y analizan algunos de los trabajos relacionados al reconocimiento de actividades físicas.

En el Capítulo 3 se presenta el sistema de reconocimiento de actividades físicas propuesto en este trabajo. En primer lugar se describen y justifican las técnicas de preprocesamiento aplicado a los datos. Posteriormente se extraen y seleccionan las características que mejor representan las propiedades de cada actividad física y se describe el método del ACP para reducir el número de características seleccionado. Por último se muestra el esquema de clasificación propuesto, el cual básicamente consta de un esquema jerárquico basado en redes neuronales (perceptrón y *feedforward*).

El proceso de experimentación y evaluación se presenta en el Capítulo 4, en éste se describe la evaluación del esquema de clasificación propuesto, la robustez del sistema respecto a cambios de usuarios, los tiempos de ejecución y la estimación del consumo de energía por el sistema de reconocimiento en el dispositivo móvil.



En el Capítulo 5 se presentan las conclusiones derivadas de este trabajo de tesis. Adicionalmente se discuten algunos trabajos de interés que puedan mejorar o enriquecer el sistema de reconocimiento de actividades, con la finalidad de dar pie a nuevas investigaciones.

Finalmente se muestra un Apéndice donde se describe brevemente cada uno de los módulos de la aplicación móvil y el desarrollo del sistema web.



# 2

## Marco teórico y estado del arte

*En este capítulo se presenta el marco teórico sobre el cual se desarrolla la investigación presentada. También se analizan algunos trabajos reportados en la literatura, los cuales están relacionados al reconocimiento de actividades físicas a través de un acelerómetro tri-axial.*

### 2.1 Marco teórico

Como se planteó en la metodología presentada en la Figura 1.4, las etapas generales para realizar un sistema de reconocimiento de actividades físicas son: preprocesamiento, extracción de características y clasificación. A continuación se analizarán algunos aspectos básicos relacionados a cada una de estas etapas.



### 2.1.1 Técnicas de preprocesamiento de datos

El preprocesamiento de datos consiste en transformar los datos en información significativa, para realizar acciones o tomar decisiones que se estimen convenientes. En este trabajo se aplican técnicas de filtrado para disminuir o remover aquellas señales que no sean de interés, por ejemplo, la gravedad y el *jittering*. También se describe el método de interpolación para solventar el problema de la frecuencia de muestreo no regular. Estas técnicas y métodos se describen brevemente a continuación:

#### 2.1.1.1. Técnicas para la remoción de ruido

**Filtro pasa alta.** Un filtro pasa altas se encarga de atenuar las frecuencia bajas y permite el paso de las frecuencias altas. Un ejemplo de este filtro utilizado para remover la gravedad en plataformas móviles [24, 25] se establece en la Ecuación (2.1).

$$f(x_i) = \begin{cases} a_i & \text{if } i = 0 \\ \alpha * f(a_{i-1}) + \alpha * (a_i - a_{i-1}) & \text{if } 0 < i \leq n \end{cases} \quad (2.1)$$

Donde  $f$  es la señal filtrada,  $a$  es la señal del acelerómetro,  $\alpha$  es el factor del filtro definido entre 0 y 1 el cual representa el umbral que permitirá el paso de las frecuencias consideradas como altas, y  $n$  el número total de muestras.

**Filtro promedio móvil.** Permite reducir las variaciones abruptas de una señal y es aplicado sobre ventanas de tamaño definido. Este tipo de filtro es utilizado para remover el *jittering* [11, 21] y se calcula de acuerdo a la Ecuación (2.2).

$$y_i = \frac{1}{k} \sum_{j=0}^k a(i+j) \quad (2.2)$$

Donde  $y$  es la señal filtrada y  $k$  es el tamaño de la ventana.



Existen otros tipos de filtros para la remoción de ruido, los cuales han sido utilizados en la literatura, algunos de ellos son:

**Filtro pasa baja.** Es aquel que permite el paso de las frecuencias más bajas y atenúa las frecuencias más altas. Un ejemplo de como aplicar un filtro pasa baja de primer orden [25] se indica en la Ecuación (2.3).

$$f(a_i) = \begin{cases} a_i & \text{if } i = 0 \\ a_i * \alpha + [f(a_{i-1}) * (1 - \alpha)] & \text{if } 0 < i \leq n \end{cases} \quad (2.3)$$

Donde  $f$  es la señal filtrada,  $a$  es la señal del acelerómetro,  $\alpha$  es el factor del filtro definido entre 0 y 1 el cual representa el umbral que permitirá el paso de las frecuencias consideradas como bajas y  $n$  el número total de muestras.

**Filtro de la mediana.** Consiste en obtener la mediana de un conjunto de datos ordenados en una ventana determinada y el elemento central es reemplazado por ésta. La mediana es considerada como el número medio en una lista ordenada si el número total de datos es impar, en caso contrario se toma el promedio del par de números centrales. Al igual que el filtro promedio también es aplicado en ventanas de tamaño fijo.

Una de las razones de emplear cualquiera de estas técnicas de filtrado es que no requieren de un alto costo computacional, lo cual hace factible su implementación sobre dispositivos móviles, aunado a ésto en el estado del arte se muestra el uso de estos tipos de filtro.

#### 2.1.1.2. Uniformización de datos

Uno de los inconvenientes presentes en algunas plataformas móviles como por ejemplo en Android, es la frecuencia de muestreo no regular, ocasionada por la pérdida de muestras o por que éstas no son capturadas en intervalos de tiempo constante. Uno de los métodos empleados para resolver este problema es la interpolación, la cual tiene como fin inferir un valor a partir de un conjunto de datos. Algunos de los métodos de interpolación más utilizados son [26, 27]:



**Interpolación lineal.** A partir de dos puntos  $(x_0, y_0)$ ,  $(x_1, y_1)$ , la interpolación lineal consiste en encontrar una estimación del valor  $y$  para un valor  $x$ , tal que  $x_0 < x < x_1$  y  $y_0 < y < y_1$ . Ésta se establece con base a la Ecuación (2.4).

$$y = y_0 + \frac{y_1 - y_0}{x_1 - x_0}(x - x_0) \quad (2.4)$$

**Interpolación cuadrática.** Ésta se aplica a partir de tres puntos  $(x_0, y_0)$ ,  $(x_1, y_1)$ ,  $(x_2, y_2)$  y con la Ecuación (2.5) es posible inferir el valor estimado.

$$y = y_0 \frac{(x - x_1)(x - x_2)}{(x_0 - x_1)(x_0 - x_2)} + y_1 \frac{(x - x_0)(x - x_2)}{(x_1 - x_0)(x_1 - x_2)} + y_2 \frac{(x - x_0)(x - x_1)}{(x_2 - x_0)(x_2 - x_1)} \quad (2.5)$$

Existen otros métodos de interpolación más complejos los cuales no son descritos en este documento.

## 2.1.2 Extracción de características

El proceso de extracción de características consiste en eliminar la redundancia de la información conservando la más representativa. En el reconocimiento de actividades físicas, algunos autores han utilizado diversas características tanto del dominio del tiempo como de la frecuencia [28]. A continuación se describen algunas de las características incluidas en cada dominio.

### 2.1.2.1. Dominio del tiempo

Las características del dominio del tiempo han sido utilizadas para el reconocimiento de actividades debido a que no requieren de un alto costo computacional para su extracción. En la Tabla 2.1 se muestran de manera general el nombre de cada una de ellas, su ecuación y las referencias donde se han empleado. A continuación se describen de manera breve algunas de las características incluidas en este dominio:



- ▶ **La media aritmética.** Es el valor obtenido al sumar todos los datos y dividir el resultado entre el número total de ellos. Es considerada como una característica global de la señal, la cual permite discriminar entre actividades dinámicas y estáticas.
- ▶ **La Desviación estándar.** Es una medida de centralización o dispersión que calcula cuánto tienden a alejarse los valores puntuales del promedio en una distribución.
- ▶ **Percentiles.** Los percentiles son una medida de posición que describen una determinada población, es decir, es el valor que supera un determinado porcentaje de los miembros de una población.
- ▶ **Coefficientes autorregresivos.** Parten de un modelo autorregresivo en el que la señal originada en un tiempo  $t$ , es estimada a partir de las observaciones de la señal en los períodos anteriores más un término de error (típicamente, ruido blanco).
- ▶ **La correlación cruzada.** Es una medida para la similitud entre dos señales y es comúnmente utilizada para buscar un patrón conocido en las señales.
- ▶ **Área de la magnitud de la señal.** Se calcula obteniendo la suma del área abarcada por la magnitud de cada uno de los tres ejes de las señales proporcionadas por el acelerómetro. Esta característica se puede utilizar para discriminar entre actividades dinámicas y estáticas.
- ▶ **Cruce por cero.** Esta definido como los puntos en una señal que pasan a través de un valor específico. La detección de cruces por cero puede realizarse a través de diferentes métodos, tales como la búsqueda exhaustiva, el método de bisección, y el método de Newton-Raphson.

#### 2.1.2.2. Dominio de la frecuencia

Otras de las características empleadas en el reconocimiento de actividades son las del dominio de la frecuencia, las cuales se han utilizado debido a que contribuyen a una mejor representación de las



Referencias	Nombre	Ecuación
[25, 28, 29]	Media aritmética	$\bar{x} = \frac{1}{n} \sum_{i=1}^n a_i$
[25, 28]	Desviación estándar	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - \bar{x})^2}$
[17, 30]	Percentiles	$P_k = \frac{n \cdot k}{100}$
[12, 31, 32, 33]	Coefficientes autorregresivos	$Y_t = \sum_{i=1}^P \phi_i Y_{t-i} + \varepsilon_t$
[28, 29]	Correlación cruzada	$Corr_{xy} = \max_{d=1}^{n-1} \left( \frac{1}{n} \sum_{i=1}^n x_i \cdot y_{i-d} \right)$
[25, 28, 32, 34, 35]	Área de la magnitud de la señal	$SMA = \frac{1}{t} \left( \int_0^t  x(t)  dt + \int_0^t  y(t)  dt + \int_0^t  z(t)  dt \right)$
[28, 36]	Raíz cuadrada media	$RMS(a) = \sqrt{\frac{a_1^2 + a_2^2 + \dots + a_n^2}{n}}$

Tabla 2.1: Características del dominio del tiempo reportadas en la literatura.

señales originadas por las actividades físicas, sin embargo requieren de un alto costo computacional para su extracción. Algunas de estas características se resumen en la Tabla 2.2. A continuación se hará una breve descripción de cada una de ellas.

- ▶ **La energía.** Es calculada como la suma del cuadrado de sus coeficientes espectrales, normalizados por el número de muestras. Esta característica ha sido utilizada para identificar el modo de transportarse de un usuario, por ejemplo caminar, correr, andar en bicicleta y en vehículo.
- ▶ **Información de la entropía.** Es la medida del desorden o de la incertidumbre de una fuente de información [28]. Esta característica ayuda a diferenciar entre las señales que tienen valores similares de energía, pero que correspondan a patrones de actividades diferentes.
- ▶ **La Transformada Wavelet (WT).** Se utiliza para examinar las características de tiempo-frecuencia de una señal. La transformada Wavelet está dada por la transformada Wavelet continua y la transformada Wavelet discreta, dos herramientas que permiten el análisis de señales de manera similar a la transformada de Fourier.



Algunos autores han utilizado la transformada Wavelet discreta para discriminar entre actividades tales como subir/bajar escaleras, caminar y detectar caídas [10, 37, 38].

Referencias	Nombre	Ecuación
[28]	Energía	$\sum_{i=1}^n (a_i)^2$
[28, 29, 39]	Información de la Entropía	$-\sum_{i=1}^n p(a_i) \log_2 p(a_i)$
[28]	Transformada Wavelet	$T_b^a(f) = \frac{1}{\sqrt{a}} \int f(t) \psi\left(\frac{t-b}{a}\right) dt$

Tabla 2.2: Características del dominio de la frecuencia reportadas en la literatura.

### 2.1.3 Análisis de componentes principales

El análisis de componentes principales (ACP) es una técnica estadística utilizada para reducir la dimensionalidad (número de variables) de un conjunto de datos. Básicamente el objetivo del ACP consiste en que dado un conjunto de datos con muchas variables (características), hay que reducirlas a un número menor perdiendo la mínima cantidad de información posible. Para estudiar las relaciones que se presentan entre variables correlacionadas (que miden información común) se puede transformar el conjunto original de variables en otro conjunto de nuevas variables incorreladas entre sí (que no tenga repetición o redundancia en la información) llamado conjunto de componentes principales (CPs). Las nuevas variables son combinaciones lineales de las anteriores y se van construyendo según el orden de importancia respecto a la variabilidad total que recogen de las muestras.

Para realizar el cálculo de las componentes principales se considera una serie de variables  $(x_1, x_2, \dots, x_p)$  de un conjunto de clases, y se trata de calcular a partir de ellas nuevas variables  $y_1, y_2, \dots, y_p$ , incorreladas entre sí, cuyas varianzas van decreciendo progresivamente. Cada  $y_i$  es una combinación lineal de las  $x_1, x_2, \dots, x_p$  originales. El primer CP  $z_1$ , es la combinación lineal con la varianza más grande, esto es  $z_1 = \mathbf{x}^T \mathbf{w}_1$ ; donde el vector coeficiente  $d$ -dimensional  $\mathbf{w}_1 = (w_{1,1}, w_{1,2}, \dots, w_{1,d})^T$  resuelve la Ecuación (2.6):



$$\mathbf{w}_1 = \arg \max_{\|\mathbf{w}=1\|} \text{Var}\{\mathbf{x}^T \mathbf{w}\} \quad (2.6)$$

El segundo CP es la combinación lineal con la segunda varianza mayor y ortogonal al primer CP, y así sucesivamente, de tal manera que existen tantas CPs como cantidad de variables originales. Para muchos conjuntos de datos las primeras CPs representan la mayoría de la varianza, de tal forma que el resto puede ser descartada con una pérdida mínima de información.

Asumiendo la estandarización de los datos (media igual a 0 y desviación estándar igual a 1) a partir de la matriz de covarianza denotada en la Ecuación (2.7):

$$\Sigma_{d \times d} = \frac{1}{n} X X^T \quad (2.7)$$

Se puede utilizar el teorema de descomposición espectral para escribir  $\Sigma$  como se muestra en la Ecuación (2.8):

$$\Sigma = U \Lambda U^T \quad (2.8)$$

Donde  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_d)$  es la diagonal de la matriz con los eigenvalores<sup>1</sup>  $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_d$  y  $U$  es la matriz ortogonal de tamaño  $d \times d$  que contiene los eigenvectores<sup>2</sup>

Las CPs están dadas por las  $d$  filas de la matriz  $S$  de tamaño  $d \times n$ , donde:

$$S = U^T X$$

<sup>1</sup>Los *eigenvalores*, son la suma de los cuadrados de los pesos de cada columna de la matriz factorial, los cuales indican la cantidad total de varianza que explica ese factor (columna) para las variables consideradas como grupo.

<sup>2</sup>Los *eigenvectores*, de una matriz cuadrada son los vectores distintos de cero, que después de ser multiplicados por la matriz, o bien permanecen proporcionales al vector original, es to es que solo hayan cambiado solo en magnitud pero no en dirección o se vuelven cero.



El subespacio generado por los primeros  $k$  eigenvectores tienen la desviación cuadrática media más pequeña de  $X$  entre todos los subespacios de dimensión  $k$ . Finalmente después de esta transformación lineal, se obtiene un espacio  $k$ -dimensional cuyas dimensiones son los eigenvectores, y las varianzas sobre esas nuevas dimensiones son igual a los eigenvalores.

### 2.1.4 Métodos de clasificación

La clasificación es una tarea que permite diferenciar entre dos o más tipos de clases con base a sus características y se realiza a través de algún método de clasificación que puede ser supervisado o no supervisado. Los clasificadores supervisados requiere de un conocimiento *a priori* de las clases a la que pertenecen los patrones de entrada, mientras que un no supervisado no lo requiere, ya que su objetivo es buscar grupos automáticamente en un conjunto de datos. En este trabajo de tesis se hizo énfasis en los clasificadores supervisados, ya que han sido empleados en la literatura para el reconocimiento de actividades físicas, algunos de estos clasificadores se muestran en la Tabla 2.3. A continuación se describe de manera general algunos métodos de clasificación supervisados descritos en[40]:

Referencias	Métodos de clasificación
[3, 33, 37, 41, 42]	Maquinas de soporte vectorial (SVM)
[2, 32, 35]	Redes neuronales artificiales
[3, 43]	Árboles de decisión
[3, 43]	$k$ : vecinos más cercanos (K-NN)
[3]	Naïve Bayes

Tabla 2.3: Clasificadores reportados en la literatura para el reconocimiento de actividades físicas.

- **Máquinas de soporte vectorial (SVM)**. Son un tipo de red neuronal que fueron originalmente diseñadas para la solución de problemas no lineales de clasificación, sin embargo recientemente se ha aplicado a problemas de regresión y predicción de series temporales. Esto se debe a su capacidad de generalización, la cual es función directa de su estructura y de la metodología utilizada para la estimación de sus parámetros. Se han encontrado



muchas aplicaciones como clasificación de imágenes, reconocimiento de caracteres, detección de proteínas, clasificación de patrones, identificación de funciones, etcétera.

- ▶ **Árboles de decisión (DT)**. Son una forma gráfica y analítica de representar todos los eventos (sucesos) que pueden surgir a partir de una decisión asumida en cierto momento. Los DT ayudan a tomar la decisión más acertada, desde un punto de vista probabilístico, ante un abanico de posibles decisiones. Se han considerado como una técnica de clasificación que van planteando una serie de cuestiones respecto al patrón a clasificar y en función de las respuestas se hacen otras preguntas. Después de pasar a través de diferentes cuestiones respecto al patrón, este queda clasificado.
- ▶  **$K$  vecinos más cercanos (K-NN)**. Es un método de clasificación supervisado que sirve para estimar la función de densidad  $f(x|C_j)$  de las variables predictivas  $x$  por cada clase  $C_j$ . Es considerado como un método no paramétrico, que estima el valor de la función de densidad de probabilidad o directamente la probabilidad a posteriori del cual un elemento  $x$  pertenezca a la clase  $C_j$ . No existe un modelo global asociado a los conceptos a aprender, las predicciones se realizan con base en los ejemplos más parecidos a los que hay que predecir. Es necesario especificar una métrica para poder medir la proximidad entre los patrones más cercanos, algunas medidas de distancias comúnmente empleadas son la distancia Euclidiana, Mahalanobis, Manhattan, Chebyshev, entre otras.
- ▶ **Naïve Bayes (NB)**. Es uno de los modelos probabilistas ampliamente utilizados como clasificador, el cual es empleado un conjunto de entrenamiento de tamaño medio o grande (por ejemplo, en minería de datos). Esta técnica de clasificación y predicción supervisada construye modelos que predicen la probabilidad de posibles resultados, los atributos que describen a los ejemplos son independientes entre sí con respecto al concepto que se pretende aprender. Se basan en la regla de Bayes para predecir la probabilidad condicional de los patrones dada la clase y la probabilidad a priori de la clase en el conjunto de entrenamiento.



- ▶ **Redes neuronales artificiales (RNA).** Están inspiradas en las redes neuronales biológicas del cerebro humano y constituidas por elementos que se comportan de forma similar a la neurona biológica en sus funciones más comunes. Estos elementos están organizados de una forma parecida a la que presenta el cerebro humano. Las RNA han sido aplicadas con gran éxito en el área del reconocimiento de patrones, debido al hecho que se ha demostrado que si se dispone de un conjunto de entradas seleccionadas correctamente, es posible llevar a cabo un procedimiento de aprendizaje para discernir cuál ha sido el criterio de clasificación y generalizarlo de forma tal que se consiga éxito en la clasificación de nuevas entradas que no fueron usadas durante el proceso de aprendizaje de la red.

Particularmente en este trabajo de tesis se ha empleado un esquema jerarquico el cual es similar a los DT que van planteando una serie de cuestiones respecto al patrón a clasificar y para tomar una decisión una red neuronal se ha diseñado en cada uno de los niveles de la jerarquía. Se han empleado redes neuronales debido a que tienen la característica de ser no lineales, lo cual permite que sea factible para discriminar entre clases linealmente no separables. A continuación se describen de manera general algunos fundamentos restringiendo a redes de tipo perceptrón y *feedforward*.

### 2.1.5 Fundamento de redes neuronales

Existe una gran variedad de modelos que representan a RNA, las cuales son caracterizadas por su capacidad de aprendizaje. Algunos ejemplos son: el perceptrón, las redes autoorganizadas, las redes de función de base radial, las redes *feedforward*, etcétera. El entrenamiento de las RNAs muestran algunos paralelismos con el desarrollo intelectual de los seres humanos. No obstante aun cuando parece que se ha conseguido entender el proceso de aprendizaje conviene ser moderado porque el aprendizaje de las RNA está limitado [44].



El objetivo del entrenamiento de una RNA es conseguir que una aplicación determinada, para un conjunto de entradas produzca el conjunto de salidas deseadas o mínimamente consistentes. El proceso de entrenamiento consiste en la aplicación secuencial de diferentes conjuntos o vectores de entrada para que se ajusten los pesos de las interconexiones según un procedimiento predeterminado. Durante el proceso de entrenamiento los pesos convergen gradualmente hacia los valores que hacen que cada entrada produzca el vector de salida deseado [45, 46]. En las siguientes subsecciones se describe de manera breve una red perceptrón y una red *feedforward*.

#### 2.1.5.1. Red perceptrón

El perceptrón es el primer modelo de red neuronal artificial desarrollada por Rosembat en 1958 [46]. Este tipo de red es capaz de clasificar patrones linealmente separables, es decir, patrones colocados en lados opuestos de un hiperplano. Básicamente el perceptrón se compone de una capa de entrada, una capa de salida, una neurona simple (compuesta por los pesos sinápticos  $\mathbf{w} = w_1, w_2, \dots, w_n$ ) y una constante o valor umbral denominado *bias* ( $b$ ) [44, 47]. La Figura 2.1 ilustra la topología de una red perceptrón.

El aprendizaje de una red perceptrón consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red, esto es, en función del error obtenido en la salida. El comportamiento del perceptrón está definido por los pares  $\{x_1, y_1\}, \{x_2, y_2\}, \dots, \{x_n, y_n\}$ , de tal forma que cuando el patrón de entrada  $x$  es aplicado a la red, la salida de la red es comparada con el valor esperado  $y$ . La neurona de salida realiza la suma pondera de las entradas con los pesos  $w$ , suma el *bias* y pasa el resultado a una función de transferencia *hardlim* [45, 48], ésto puede denotarse como se indica en la Ecuación (2.9). La regla de decisión es generar 1 si el patrón presentado pertenece a una clase A, o 0 si pertenece a una clase B.



$$y = f \left( \sum w_i x_i + b \right) = \text{hardlim} \left( \sum_i w_i x_i + b \right) \quad (2.9)$$

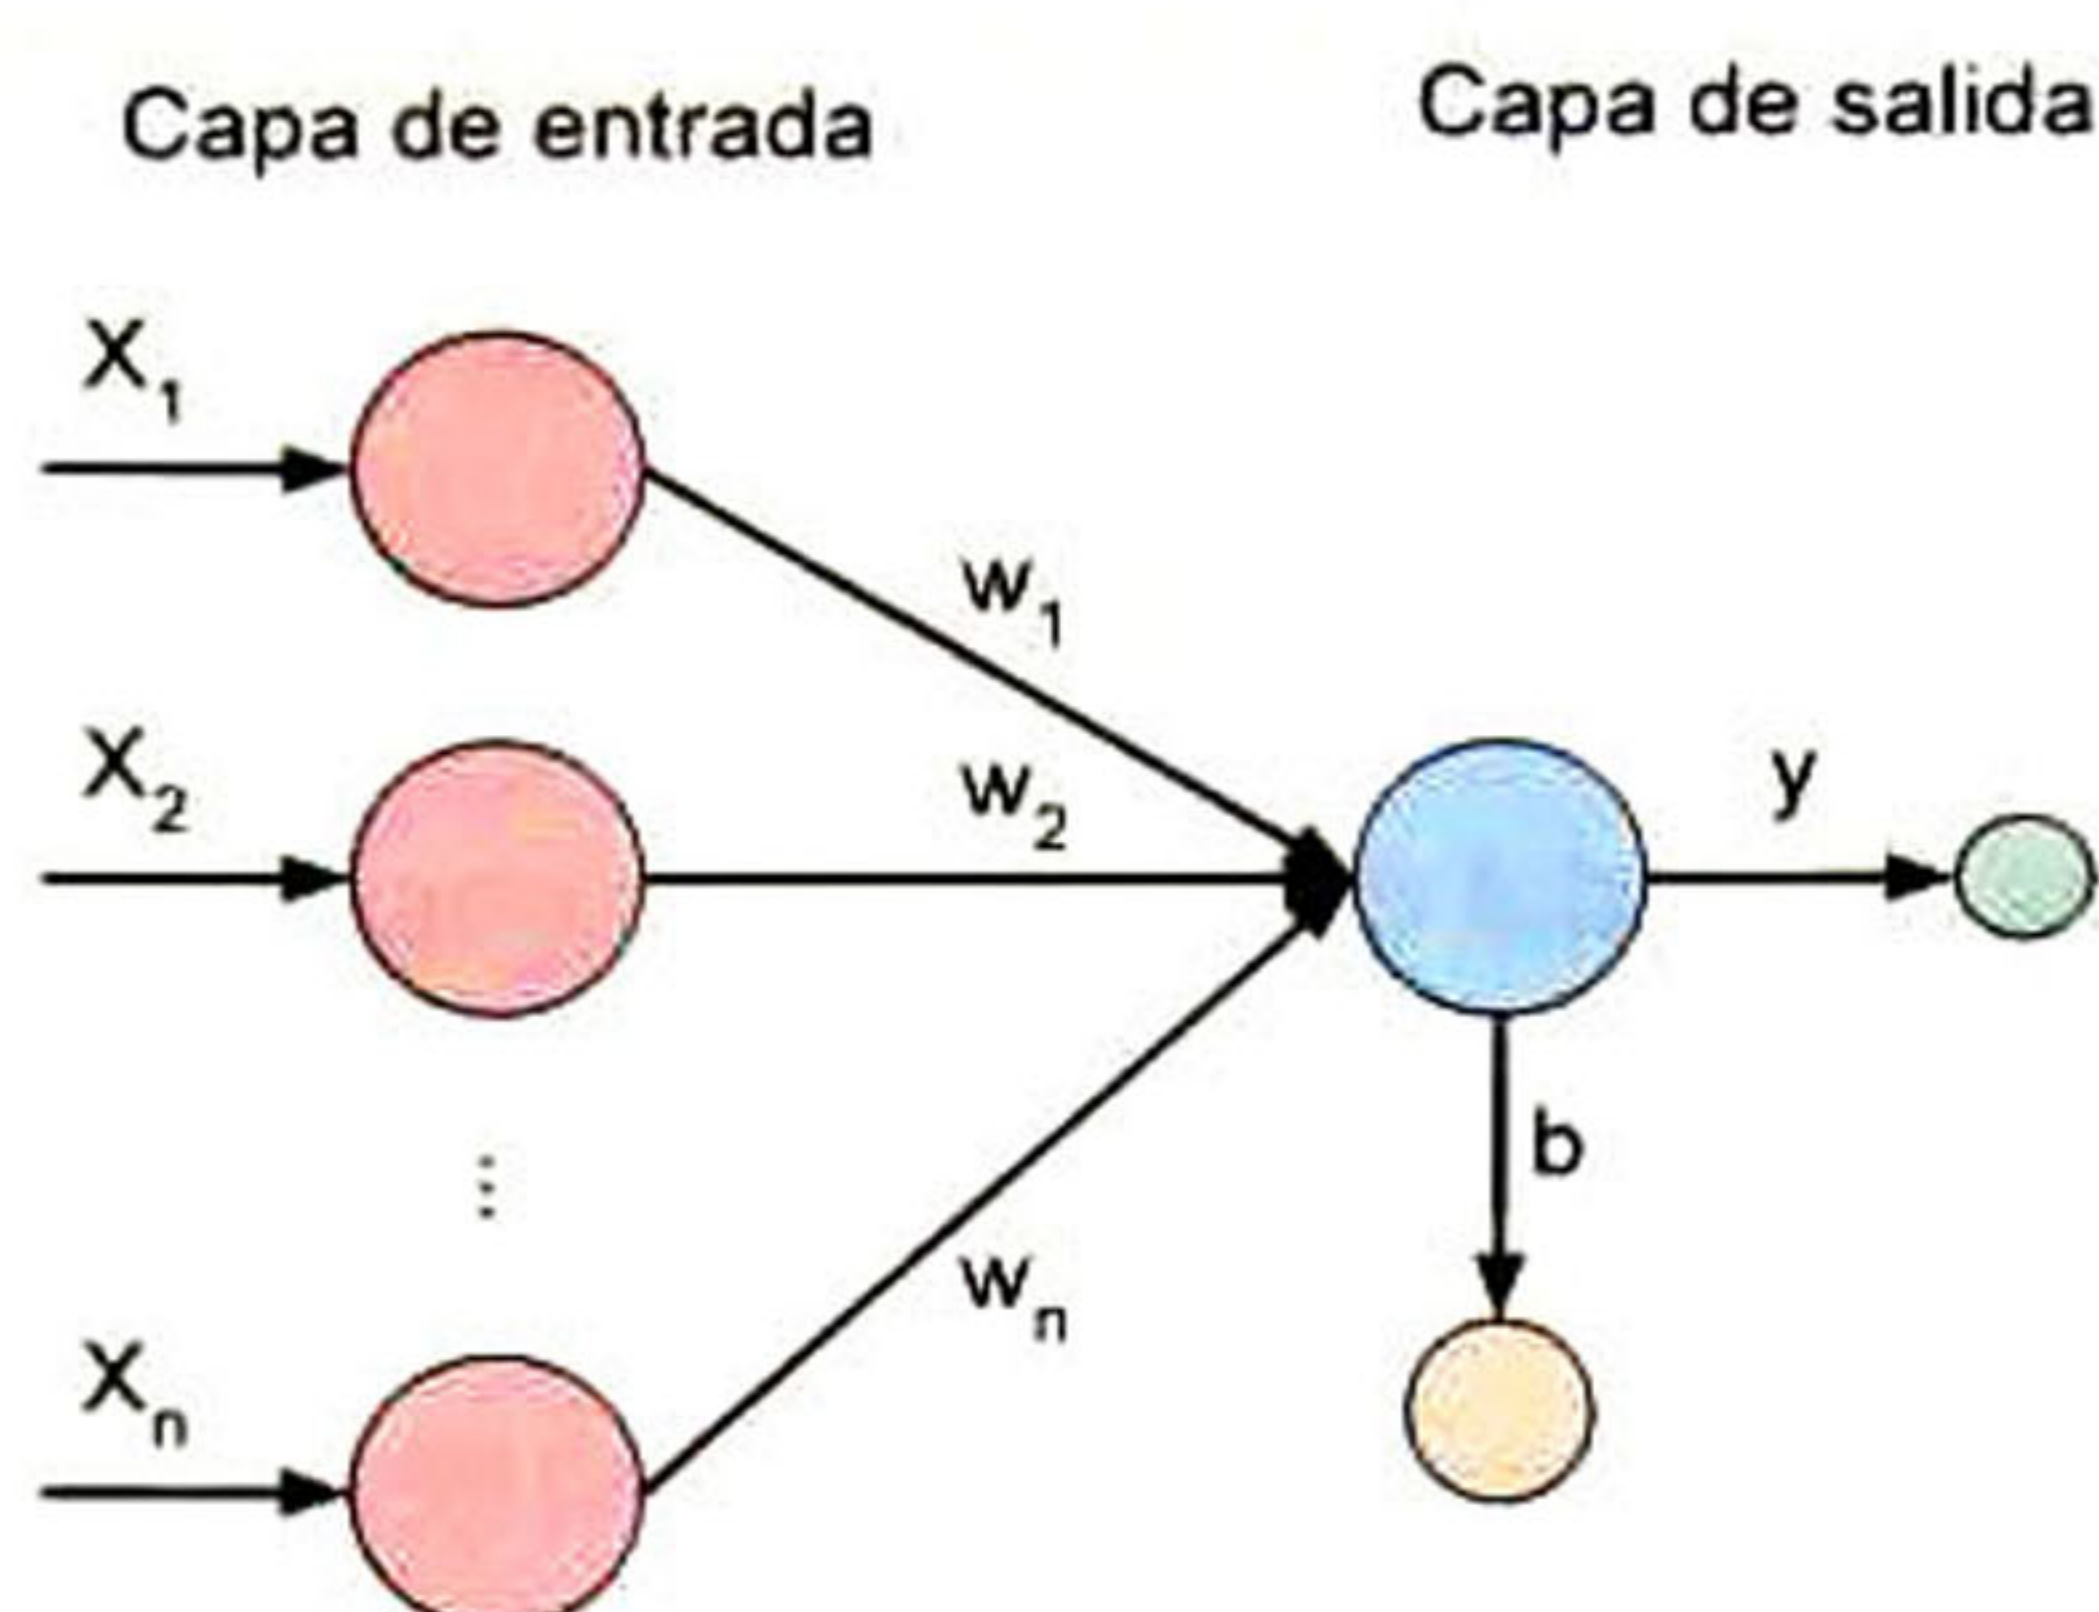


Figura 2.1: Arquitectura delno perceptrón simple

La función de transferencia *hardlim* utilizada en una red perceptrón se considera como función escalón, la cual acerca la salida  $y$  de la red a cero si el argumento de la función es menor que cero y la lleva a uno si es mayor o igual que cero. Esta función puede expresarse como se establece en la Ecuación (2.10).

$$y = \begin{cases} 1 & \text{si } y \geq 0 \\ 0 & \text{si } y < 0 \end{cases} \quad (2.10)$$

### 2.1.5.2. Red feedforward

En general las diferentes clases de redes neuronales artificiales se distinguen entre sí por los siguientes elementos:

- ▶ Las neuronas que constituye el elementos básico de procesamiento.
- ▶ La arquitectura de la red descrita por las conexiones ponderadas entre las neuronas.
- ▶ El algoritmo de entrenamiento usado para encontrar los parámetros de la red.



La red neuronal artificial más estudiada y utilizada en diversas aplicaciones es la red *feedforward*, a diferencia de una red perceptrón ésta se compone de una capa de entrada, una o más capas ocultas (intermedias) y una capa de salida. Una vez definida la arquitectura que se desea utilizar en un problema particular, la red neuronal debe ajustarse a una muestra dada a través del proceso de aprendizaje.

Dado de un conjunto de entradas, la tarea del aprendizaje neuronal es construir un estimador  $g_\lambda(\mathbf{x}, \mathbf{w})$  de la función desconocida  $f(x)$  del cual solo se conoce un conjunto de datos, esto se indica en la Ecuación (2.11).

$$g_\lambda(\mathbf{x}, \mathbf{w}) = \gamma_2 \left( \sum_{j=1}^{\lambda} w_j \gamma_1 \left( \sum_{i=1}^n w_{ij} x_i + w_{n+1,j} \right) + w_{\lambda+1} \right) \quad (2.11)$$

Donde  $\mathbf{w} = w_1, w_2, \dots, w_n$  es el vector paramétrico a ser estimado y equivale a las ponderaciones de las conexiones entre las neuronas de la red,  $\mathbf{x} = x_1, x_2, \dots, x_n$  las entradas de la red,  $\lambda_1$  es una función no lineal acotada y diferenciable con forma de función sigmoideal,  $\lambda_2$  es una función que puede ser lineal o no y  $\lambda$  es el parámetro de control que indica el número de neuronas ocultas.

El algoritmo de aprendizaje consiste en un problema de inferencia de los parámetros libres de la red dado por las conexiones entre las neuronas. El proceso de aprendizaje de una red neuronal *feedforward* se caracteriza por ser supervisado pues los parámetros de la red, conocidos como pesos, son estimados a partir de un conjunto de patrones de entrenamiento compuesto por patrones de entrada y salida [44, 46, 47].

Una red *feedforward* se basa en el algoritmo de entrenamiento *backpropagation* el cual emplea un ciclo de propagación y adaptación. Una vez aplicado un patrón a la entrada de la red como estímulo, éste se propaga desde la primera capa a través de las siguientes capas de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas. Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida.



Sin embargo, las neuronas de la capa oculta solo reciben una fracción de la señal total del error, basándose aproximadamente en la contribución relativa que haya aportado cada neurona a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total. Con base a la señal de error percibida se actualizan los pesos de conexión de cada neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento [45, 48].

La importancia de este proceso consiste en que, a medida que se entrena la red, las neuronas de las capas intermedias se organizan así mismas de tal modo que las distintas neuronas aprenden a reconocer distintas características del espacio total de entrada. Después del entrenamiento, cuando se les presenta un patrón arbitrario de entrada, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas hayan aprendido a reconocer durante su entrenamiento. La estructura básica de una red neuronal *feedforward* se compone de una capa de entrada, una o más capas ocultas y una capa de salida, tal como se ilustra en la Figura 2.2.

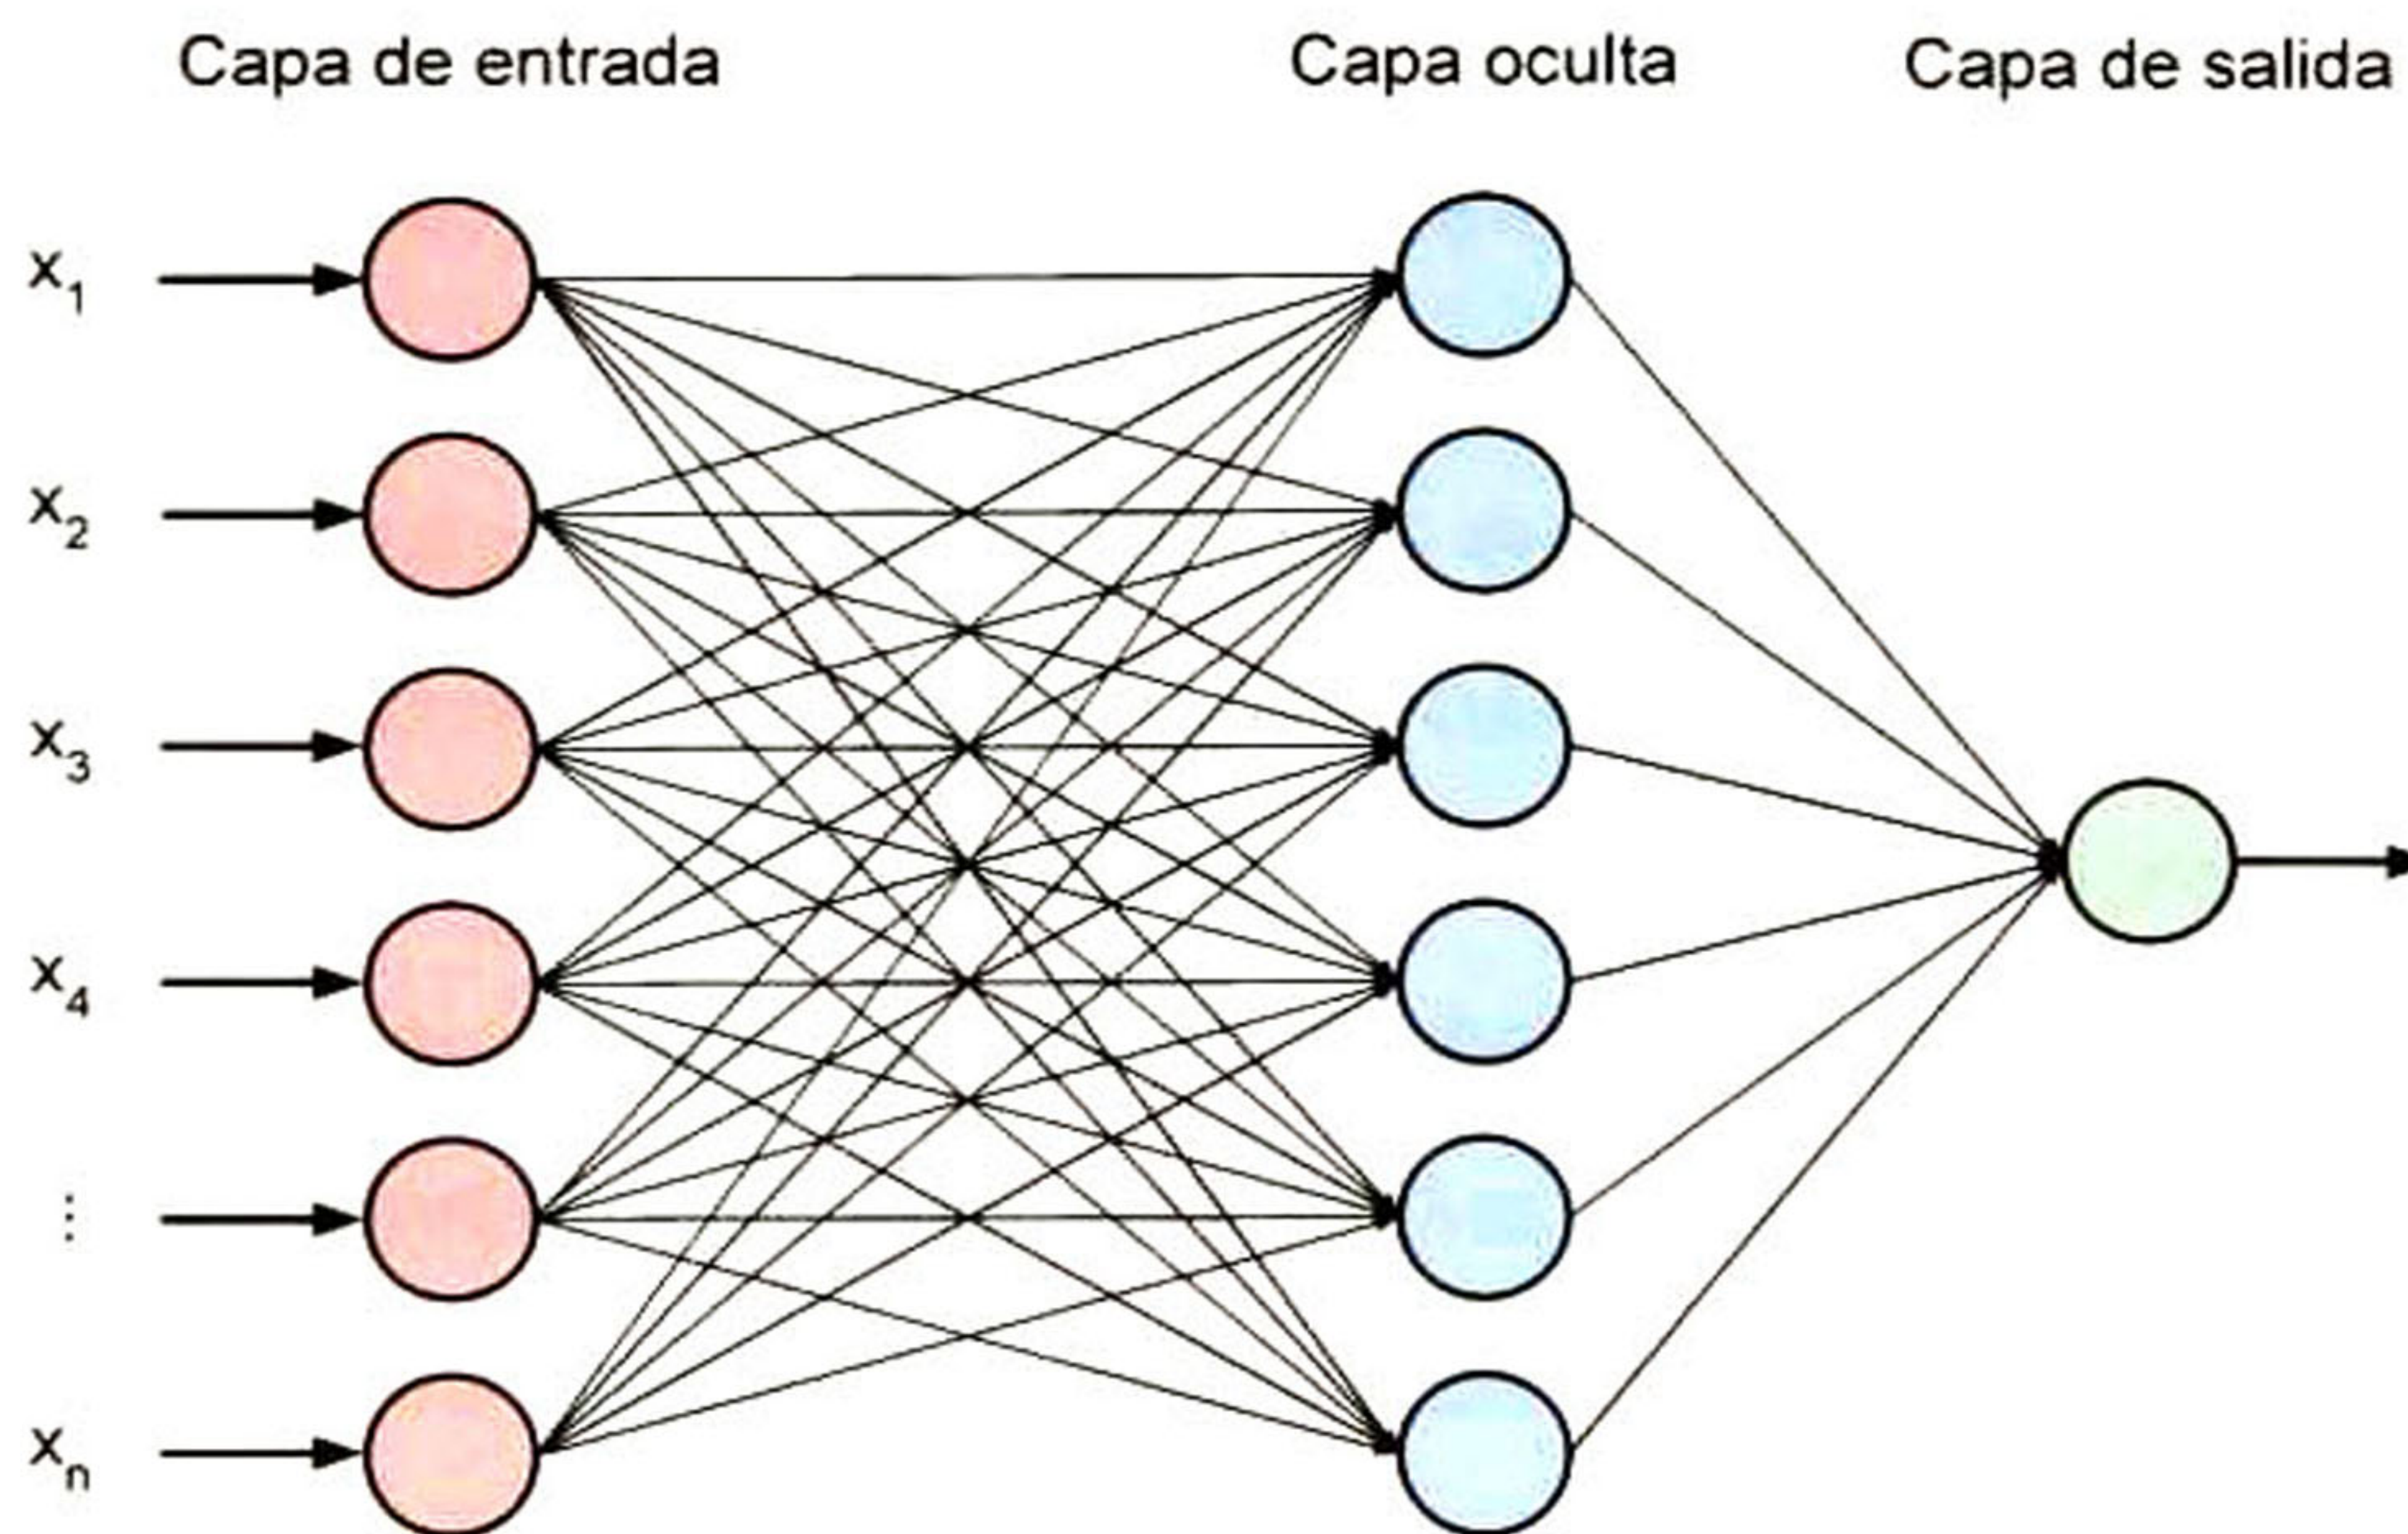


Figura 2.2: Arquitectura de una red *feedforward*.



En el caso de las redes *feedforward* las funciones de transferencias usualmente utilizadas son las siguientes:

- *Logarítmica sigmoidal (logsig)*: esta función toma los valores de entrada, los cuales pueden oscilar entre más y menos infinito, y restringe la salida a valores entre 0 y 1, se establece como se muestra en la Ecuación(2.12).

$$a = \frac{1}{1 + e^{-n}} \quad (2.12)$$

- *Tangente sigmoidal (tansig)*: al igual que la función anterior toma valores de entrada que oscilan entre más y menos infinito y restringe la salida a valores entre  $-1$  y  $1$ , de acuerdo a la Ecuación(2.13).

$$a = \frac{2}{(1 + e^{-2n}) - 1} \quad (2.13)$$

## 2.2 Estado del arte

En la literatura se han reportado diversos trabajos de investigación relacionados al reconocimiento de actividades físicas, debido a que tiene una gran aplicación en múltiples áreas. Por ejemplo: en la salud, la terapia física, detección de caídas, tratamiento de enfermedades de parkison, etc [49, 50, 51, 52, 53]. En la mayoría de los trabajos reportados en la literatura se ha utilizado más de un acelerómetro asociado a diferentes ubicaciones en el cuerpo del usuario. También se ha reportado el uso de un solo acelerómetro con la condición de estar ajustados a una posición específica. Bajo estos escenarios de ambiente controlado, se han obtenido buenos resultados en el reconocimiento de actividades físicas los cuales están en el rango del 85 % al 97 %. Otro de los puntos importantes que se destaca en los trabajos relacionados es el estudio realizado acerca de las características (dominio del tiempo y la frecuencia) y los métodos de clasificación que mejor se ajustan para el reconocimiento



de actividades físicas. Algunos trabajos relacionados al desarrollo de esta investigación se describe en los siguientes párrafos.

Siirtola y Röning [54] realizaron un sistema de reconocimiento de cinco actividades: caminar, correr, andar en bicicleta, andar en vehículo y sentado/acostado. Los datos fueron recolectados por ocho usuarios mediante el acelerómetro del smartphone a una frecuencia de 40 Hz, colocando el dispositivo en los bolsillos frontales de un pantalón. La extracción de características se realizó sobre ventanas de 300 muestras (aproximadamente 7.5 segundos) considerando 21 características del dominio del tiempo, tales como: desviación estándar, media, mínimo, máximo y los percentiles ( $P_{10}$ ,  $P_{25}$ ,  $P_{50}$ ,  $P_{75}$ ,  $P_{90}$ ). Se utilizaron dos clasificadores para reconocer las actividades: el análisis discriminante cuadrático (QDA) y el  $K$ -NN, éstos se aplicaron fuera de línea y como resultado se obtuvo un porcentaje de reconocimiento promedio del 95.8 % y 93.9 % respectivamente. Sin embargo cuando se evaluaron en línea (smartphone) el reconocimiento disminuyó hasta un 76.3 % y 65.6 % para el caso de dos usuarios. Las actividades donde se obtuvo un bajo porcentaje de clasificación corresponden a caminar y andar en bicicleta, se argumenta que esto se debe a que cada usuario tiene diferentes estilos de caminar. En este trabajo no se reporta algún tipo de preprocesamiento de datos.

Sun *et al.* [1] propusieron reconocer las actividades físicas mencionadas en [54] y además, subir y bajar escaleras. Se consideraron seis posiciones donde el usuario coloca el smartphone: bolsillos frontales y posteriores de un pantalón y los bolsillos de un saco, esto se ilustra en la Figura 2.3. Los datos fueron recolectados a una frecuencia de 10 Hz por el acelerómetro del smartphone y fueron segmentados en ventanas de cinco segundos y con traslapes de un segundo. Se extrajeron características del dominio del tiempo y la frecuencia tales como: la media, la varianza, la correlación, la energía, la entropía, los coeficientes espectrales y la transformada rápida de fourier (FFT). Como clasificador se diseñó una SVM fuera de línea considerando ubicaciones (bolsillos) específicas y otra considerando todas las posiciones. De los resultados obtenidos la SVM para posiciones específicas proporcionaron una mejor precisión en comparación con la diseñada para todas las posiciones. Esto se muestra en la Tabla 2.4. Al igual que [54] no se reporta alguna técnica de preprocesamiento.





Figura 2.3: Posiciones del smartphone consideradas en el trabajo [1].

SVM	Precisión	Recall	Score
Todas las posiciones	91.6 %	91.4 %	91.5 %
Posición específica	94.8 %	94.8 %	94.8 %

Tabla 2.4: Resultados obtenidos a partir de la evaluación de las SVMs diseñadas en el trabajo [1].

Khan *et al.* [55] realizaron un sistema de reconocimiento de 15 actividades de las ya mencionadas en los trabajos anteriores y las otras corresponden a las transiciones generadas entre las actividades estáticas (acostado, sentado y de pie). Los datos fueron recolectados a una frecuencia de 20 Hz, colocando un acelerómetro (Witilt v2.5) en el pecho del usuario. Un filtro promedio móvil de orden tres fue aplicado para reducir el ruido de los datos correspondientes a la aceleración. Se emplearon características tales como los coeficientes autorregresivos (10 por cada componente de la aceleración), el área abarcada por la magnitud de la señal (SMA) y el ángulo de inclinación. También aplicaron el análisis discriminante lineal (LDA), para lograr una mayor separabilidad entre las clases y obtener un mejor porcentaje de discriminación al utilizarse en combinación con una red neuronal (*feedforward*) como clasificador. Las redes que se diseñaron fueron utilizadas en un esquema jerárquico sobre el cual se evaluaron las 15 actividades para su clasificación y como resultado de éste se obtuvo un porcentaje de reconocimiento del 97.9 %.

Liang *et al.* [56] propusieron un método para reconocer las actividades físicas descritas en [1, 54], buscando que el sistema sea energéticamente eficiente. Los datos fueron recolectados a diferentes frecuencias de muestreo (0.5 Hz, 2 Hz, 10 Hz, y 20 Hz) colocando al smartphone en los bolsillos delanteros. Para seleccionar las características más representativas tanto del dominio del tiempo como la frecuencia el ACP fue aplicado sobre las características mencionadas en [54], el



coeficiente lineal regresivo y el coeficiente Wavelet. Se encontró que las características frecuenciales contribuyen a un mejor porcentaje de reconocimiento, sin embargo su extracción requiere de un alto costo computacional. A fin de tener un menor consumo de energía en el dispositivo al emplear las características frecuenciales, un esquema jerárquico fue diseñado en el cual estas características se utilizaron cuando las del dominio del tiempo no eran discriminatorias. Los resultados obtenidos muestran que se logró un porcentaje en el reconocimiento de las actividades superior al 85% y respecto al consumo de energía por el dispositivo (HTC G11, Samsung i909) se reporta una duración de la batería de 3.2 horas.

Yang [57] realizó un sistema para el reconocimiento de actividades físicas, las cuales se mencionaron en [1, 54, 55]. Los datos se capturaron a una frecuencia de 36 Hz a través del acelerómetro del smartphone y al conjunto de datos se les aplicó un filtro promedio móvil de orden cinco, con la finalidad de reducir el *jittering*. Al igual que en los trabajos anteriores se emplearon las mismas características, éstas fueron extraídas sobre las componentes verticales, horizontales y sobre la magnitud de la aceleración. Se experimentaron diferentes clasificadores (NB, DT,  $K$ -NN y SVM) utilizando diferentes características y se evaluaron a través de la técnica de validación cruzada con  $k = 10$ . De los resultados obtenidos se observó que los árboles de decisión son los de mayor precisión en el reconocimiento de las actividades, tal como se muestra en la Tabla 2.5. En este trabajo no se especifica la posición donde el usuario colocó el smartphone.

Conjunto de característica	DT	NB	K-NN	SVM
Verticales y horizontales	90.6 %	68.7 %	77.9 %	84.3 %
Verticales	88.7 %	68.3 %	85.0 %	85.1 %
Horizontales	71.0 %	66.3 %	68.0 %	69.3 %
Dominio del tiempo	89.8 %	68.6 %	78.1 %	84.8 %
Magnitud	88.1 %	75.3 %	86.8 %	86.0 %

Tabla 2.5: Evaluación de características y precisión de los clasificadores [57].



Abbate *et al.* [2] propusieron un sistema automático para la detección de caídas, para ello se incluyeron otras actividades como saltar, caminar y correr con el fin de obtener un alto porcentaje en el reconocimiento de caídas. Los datos fueron capturados por el acelerómetro del smartphone a una frecuencia de 50 Hz, ubicándolo en la cintura del usuario. Un filtro basado en la mediana de orden tres fue aplicado a los datos para mejorar la detección de caídas. Las características empleadas en este trabajo son diferentes a las mencionadas en los trabajos anteriores, por lo tanto no se hará mención de ellas. Sin embargo es importante resaltar que se empleó una red neuronal multicapa *feedforward* para la clasificación de caídas, de la cual se obtuvo una sensibilidad, especificidad y precisión del 100 % en el reconocimiento de las caídas reales. El diseño de la red empleada se ilustra en Figura 2.4.

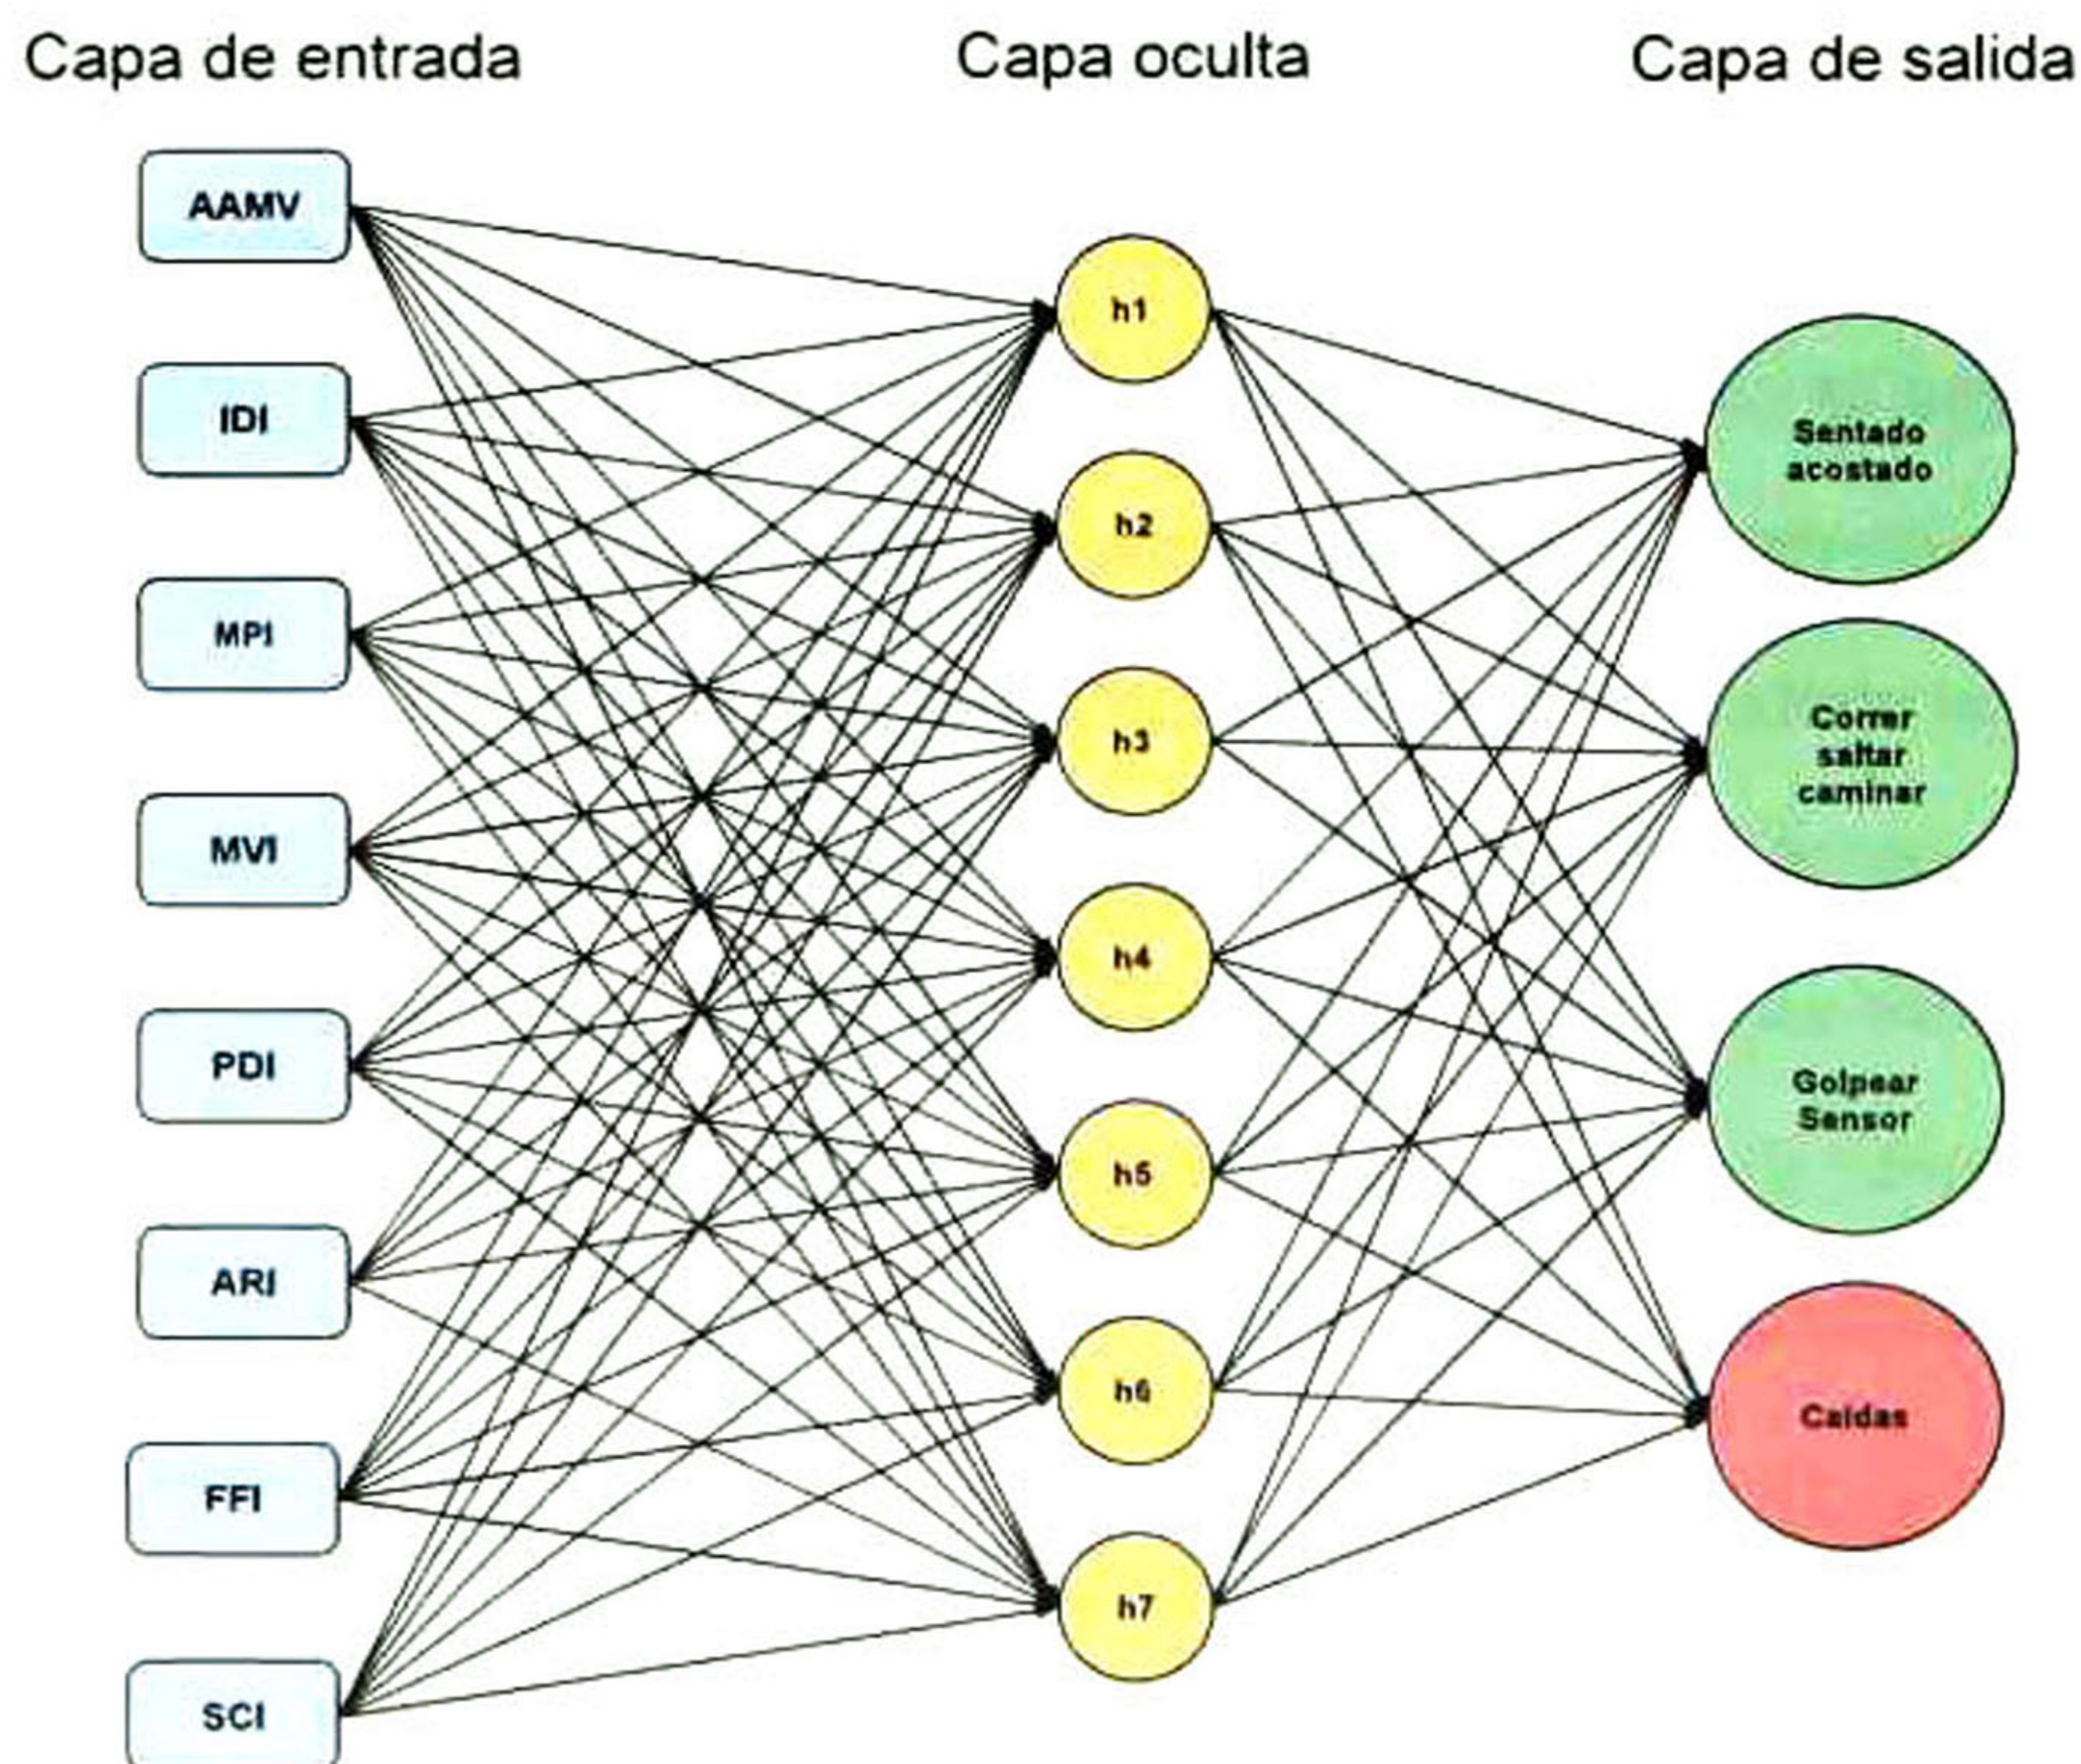


Figura 2.4: Diseño de la red neuronal propuesta en el trabajo [2].



Lu *et al.* [3] propusieron un sistema capaz de reconocer y registrar las actividades dinámicas descritas en [54] a través de un smartphone. Los datos se recopilaban a una frecuencia de 32 Hz y al igual que en [57] se utilizó una técnica para el preprocesamiento de datos. Las características empleadas se evaluaron a través del método de selección de características basado en la correlación (CFS), con el fin de elegir aquellas que requieran de un costo computacional menor. Éstas son: raíz cuadrada media (RMS), entropía espectral, correlación entre ejes, picos espectrales, energía de sub-banda espectral, relación de energía y las mencionadas en [1, 54]. Como resultado de la evaluación se obtuvo que las características del dominio del tiempo son menos costosas computacionalmente, así como la energía espectral, los picos espectrales y la relación de la energía espectral. Para el proceso de clasificación cuatro clasificadores fueron evaluados (DT, NB,  $K$ -NN, SVM y el clasificador Gaussiano Multivariante (MG) empleando 10 veces la validación cruzada y utilizando diferentes características. Los resultados obtenidos se muestran en la Tabla 2.6 y se observa que para caminar y correr la precisión es alta, sin embargo para andar en bicicleta y en vehículo la precisión es baja debido a que existen ciertas similitudes entre los patrones de clase.

Conjunto de característica	DT	NB	K-NN	SVM	MG
Todas las características (24)	92.8 %	87.7 %	90.4 %	90.1 %	89.7 %
Dominio del tiempo (6)	90.3 %	81.8 %	89.7 %	84.1 %	85.1 %
Dominio de la frecuencia (18)	92.6 %	87.9 %	88.1 %	86.0 %	88.5 %
Verticales (12)	91.3 %	83.0 %	87.6 %	84.6 %	85.6 %
Horizontales (12)	87.3 %	73.4 %	86.6 %	80.3 %	82.3 %

Tabla 2.6: Desempeño obtenido de las características evaluadas con los diferentes clasificadores descritos en [3].

Huang *et al.* [4] propusieron un algoritmo para la detección adaptativa de pasos (ASD) mediante el uso de dos smartphones. Los datos se recolectaron a una frecuencia de 10 Hz a través del acelerómetro de los smartphones, colocándolos en diferentes posiciones tal como se muestra en la Tabla 2.7. Puesto que la forma de caminar entre usuarios es diferente, se establecieron umbrales a través del algoritmo (ASD) propuesto. Los resultados obtenidos varían de acuerdo a la portabilidad del smartphone: para pantalones cortos (short) en el bolsillo derecho se obtuvo un porcentaje de reconocimiento del 100 %,



en los bolsillos del pecho derecho 95 % y colocado en las piernas un 91.7 %. En este trabajo no se menciona el uso de características.

Experimento	Teléfono móvil 1	Teléfono móvil 2
1	Bolsillo izquierdo del <i>shorts</i>	Bolsillo derecho del <i>shorts</i>
2	Tobillo derecho	Bolsillo derecho del pecho
3	Bolso por encima del hombro derecho	Pierna derecha
4	Cintura	En la mochila
5	Tobillo derecho	Bolsillo derecho del pecho

Tabla 2.7: Modos de portabilidad considerados en [4].

La Tabla 2.8 muestra de manera resumida la revisión de los trabajos relacionados, en ella se muestran las técnicas de preprocesamiento de datos utilizadas, las características empleadas y los clasificadores seleccionados o propuestos para discriminar entre las actividades.

Ref.	IP	Actividades D/E	Preprocesamiento	Características	Clasificador
[54]	Si	D/E	No reporta	Dominio del tiempo	QDA
[1]	Si	D	No reporta	Dominio del tiempo y la frecuencia	Máquinas de soporte vectorial
[56]	No	D/E	No reporta	Dominio del tiempo y la frecuencia	Esquema jerárquico
[2]	Si	D/E	Filtro basado en la mediana	Dominio del tiempo	Redes neuronales
[3]	Si	D/E	Filtro promedio móvil	Dominio del tiempo y la frecuencia	Árboles de decisión
[55]	No	D/E	Filtro promedio móvil	Dominio del tiempo	RNA y esquema jerárquico
[57]	No	D/E	Filtro promedio móvil	Dominio del tiempo y la frecuencia	Árboles de decisión
[4]	Si	D	No reporta	Dominio del tiempo	Algoritmo basado en umbrales

Tabla 2.8: Resumen de los trabajos revisados en el estado del arte. Acrónimos: IP: Independencia de la posición, D/E: Dinámicas y estáticas

## 2.3 Resumen

En la revisión del estado del arte se encontró que existen diversos trabajos relacionados al reconocimiento de actividades físicas, sin embargo, estos trabajos presentan ciertas limitaciones, tales como: considerar posiciones específicas de como colocar el smartphone [56, 57, 58], obtienen



un bajo porcentaje de reconocimiento de las actividades (específicamente para caminar, subir/bajar escaleras y andar en bicicleta) [3, 54, 58] y la mayoría de los sistemas de reconocimiento no son implementados en el dispositivo móvil, es decir, solo utilizan el smartphone para recolectar datos y no realizan el reconocimiento de actividades en línea [1, 3, 57].

En este trabajo de tesis se pretende mejorar algunas de las debilidades que hay en los trabajos revisados, retomando los métodos o técnicas más apropiadas. Para el caso del preprocesamiento aplicado a los datos se empleó un filtro promedio móvil como se indica en [3, 32, 55, 56, 57], para seleccionar las características se consideraron aquellas evaluadas en [3, 56, 57] por requerir de un menor costo computacional, así como los coeficientes autorregresivos [55] debido a que el uso de estos incrementó el porcentaje de precisión. Aunado a esto se consideraron enfoques de clasificación como el esquema jerárquico y las redes neuronales [2, 55, 56].



# 3

## Sistema de reconocimiento de actividades físicas

*A lo largo de este capítulo se detalla la solución propuesta para desarrollar el sistema de reconocimiento de actividades físicas y se describe también cada una de las etapas planteadas en la metodología, así como las técnicas o métodos empleados en cada una de ellas.*

### 3.1 Panorama general

La solución propuesta para el desarrollo del sistema de reconocimiento de actividades físicas está íntimamente relacionada al paradigma de reconocimiento de patrones, por lo que de manera general la propuesta incluye las siguientes etapas:

- ▶ Emplear un filtro pasa altas de primer orden y un filtro promedio sobre la señal de la magnitud de la aceleración para remover la gravedad y atenuar el *jittering*. Una vez preprocesada la señal correspondiente a la magnitud de la aceleración, se aplicó un método de interpolación lineal para inferir las muestras que no son capturadas en intervalos de tiempo constante.



- ▶ Segmentar los datos obtenidos por el acelerómetro en ventanas de 200 muestras (aproximadamente cinco segundos).
- ▶ Extraer un conjunto de características temporales: estadísticas y coeficientes autorregresivos.
- ▶ Emplear un método de clasificación basado en un esquema jerárquico combinado con redes neuronales (perceptrón y *feedforward*).

De manera resumida, en la Figura 3.1 se ilustra cada uno de los pasos a seguir y en la siguiente subsecciones se describe brevemente cada uno de ellos.

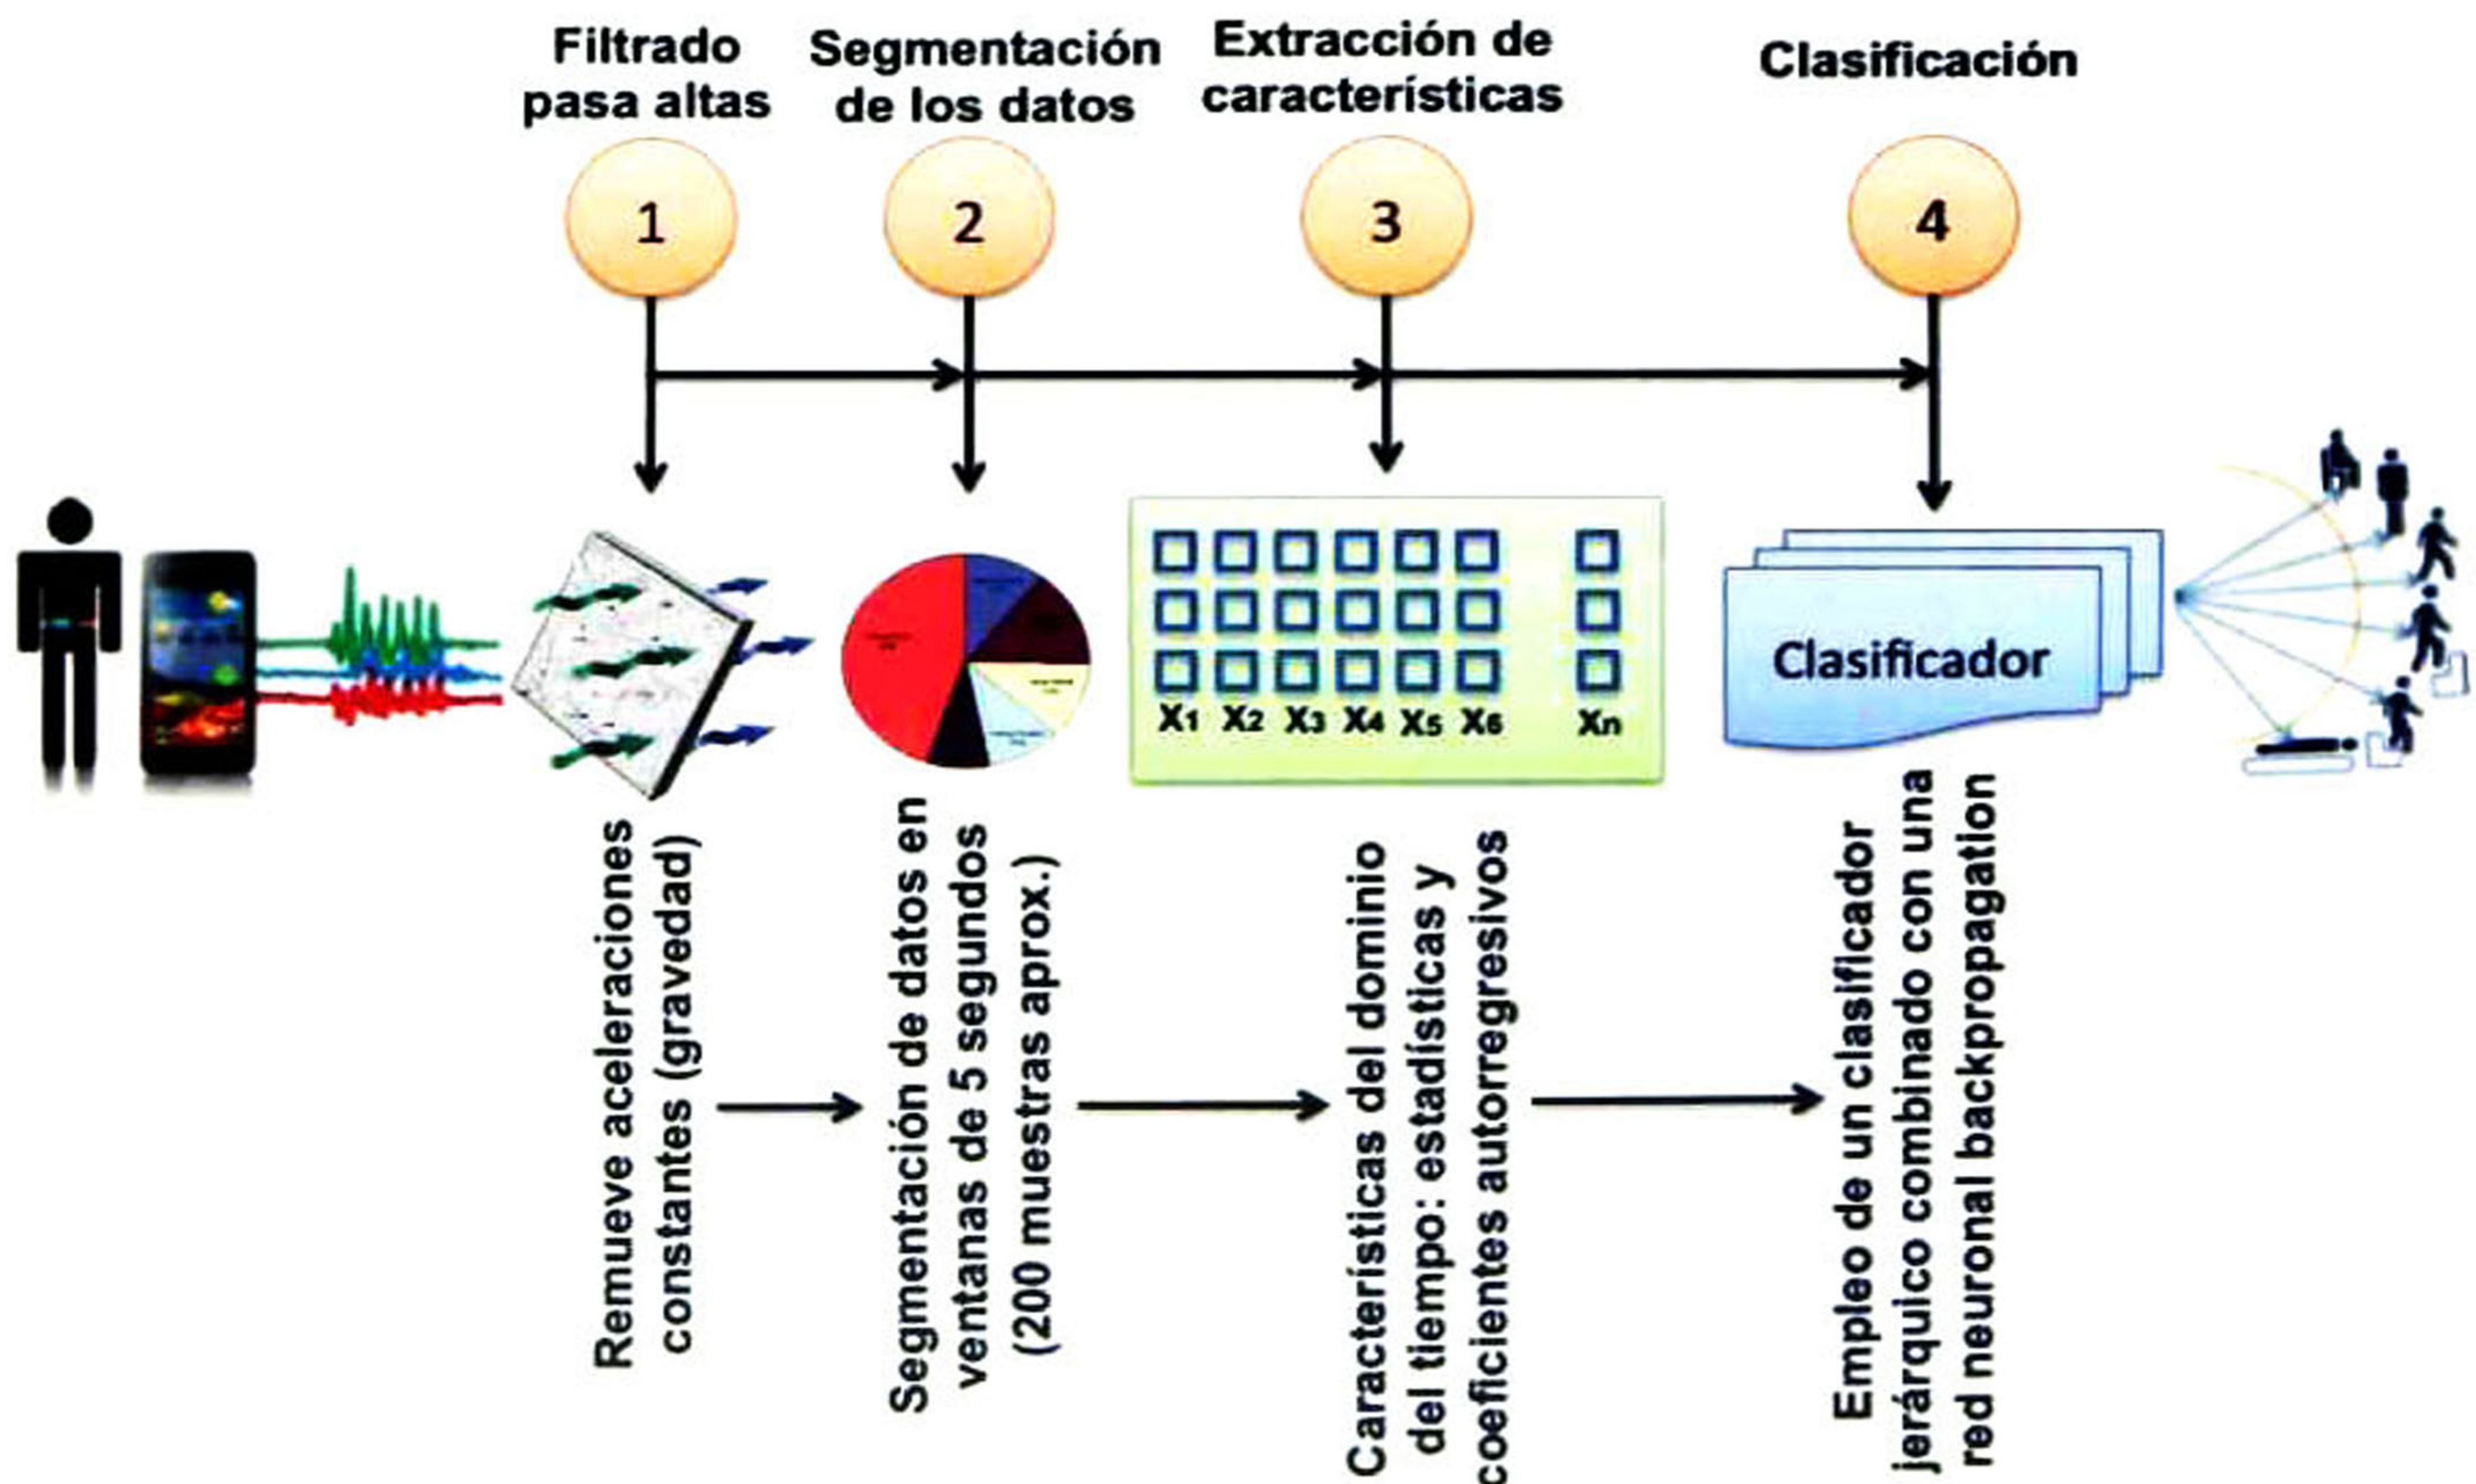


Figura 3.1: Etapas de la solución propuesta para el reconocimiento de actividades físicas



## 3.2 Preprocesamiento de datos

Generalmente las señales capturadas por un sensor presentan datos con algún tipo de ruido, datos inconsistentes e incompletos. Es por ello que aplicar un preprocesamiento al conjunto de datos facilitaría la interpretación de los mismos. En el contexto de esta investigación, los datos de la aceleración capturados por el acelerómetro que no son generados por el movimiento del usuario corresponden a la gravedad (estimada como  $g = 9.8 \text{ m/s}^2$ ) y el *jittering* [11, 21]. Por otro lado, el hecho de que los sistemas operativos móviles como Android no están diseñados para la captura constante de muestras implica que no se tenga una frecuencia de muestreo regular, es decir, que las muestras no sean capturadas en intervalos de tiempo constante. Para solventar estos inconvenientes se emplearon técnicas o métodos reportados en la literatura, los cuales se describen a continuación.

### 3.2.1 Eliminación de ruido

Para remover la aceleración de la gravedad se ha empleado un filtro pasa altas de primer orden (ecuación (2.1)) sobre cada una de las componentes de la aceleración ( $a_x, a_y, a_z$ ) y para el caso del *jittering* el filtro promedio móvil se aplicó sobre la magnitud de la aceleración obtenida como  $\sqrt{a_x^2 + a_y^2 + a_z^2}$ . Básicamente un filtro pasa altas permite el paso de señales con altas frecuencias y remueve aquellas que sean de baja frecuencia. A manera de ilustración en la gráfica de la Figura 3.2 a), se observa que una señal generada por una actividad estática mide aceleraciones superiores a los  $9.8 \text{ m/s}^2$  cuando se esperaría una medida alrededor de 0. Sin embargo, después de aplicar el filtro pasa altas a la señal de la aceleración la gravedad es removida, esto se ilustra en la Figura 3.2 b).

Para remover la gravedad se empleó el algoritmo de filtrado sugerido en la documentación oficial de Android (ver Algoritmo 1) [24], debido a que uno de los propósitos fue la implementación en un dispositivo móvil. Este algoritmo recibe dos parámetros de entrada: la señal de la aceleración con sus valores correspondiente a cada una de sus componentes **aceleración** ( $a_x, a_y, a_z$ ) y  $\alpha$  un valor definido entre 0 y 1 (en la documentación oficial de Android es considerado como 0.8).



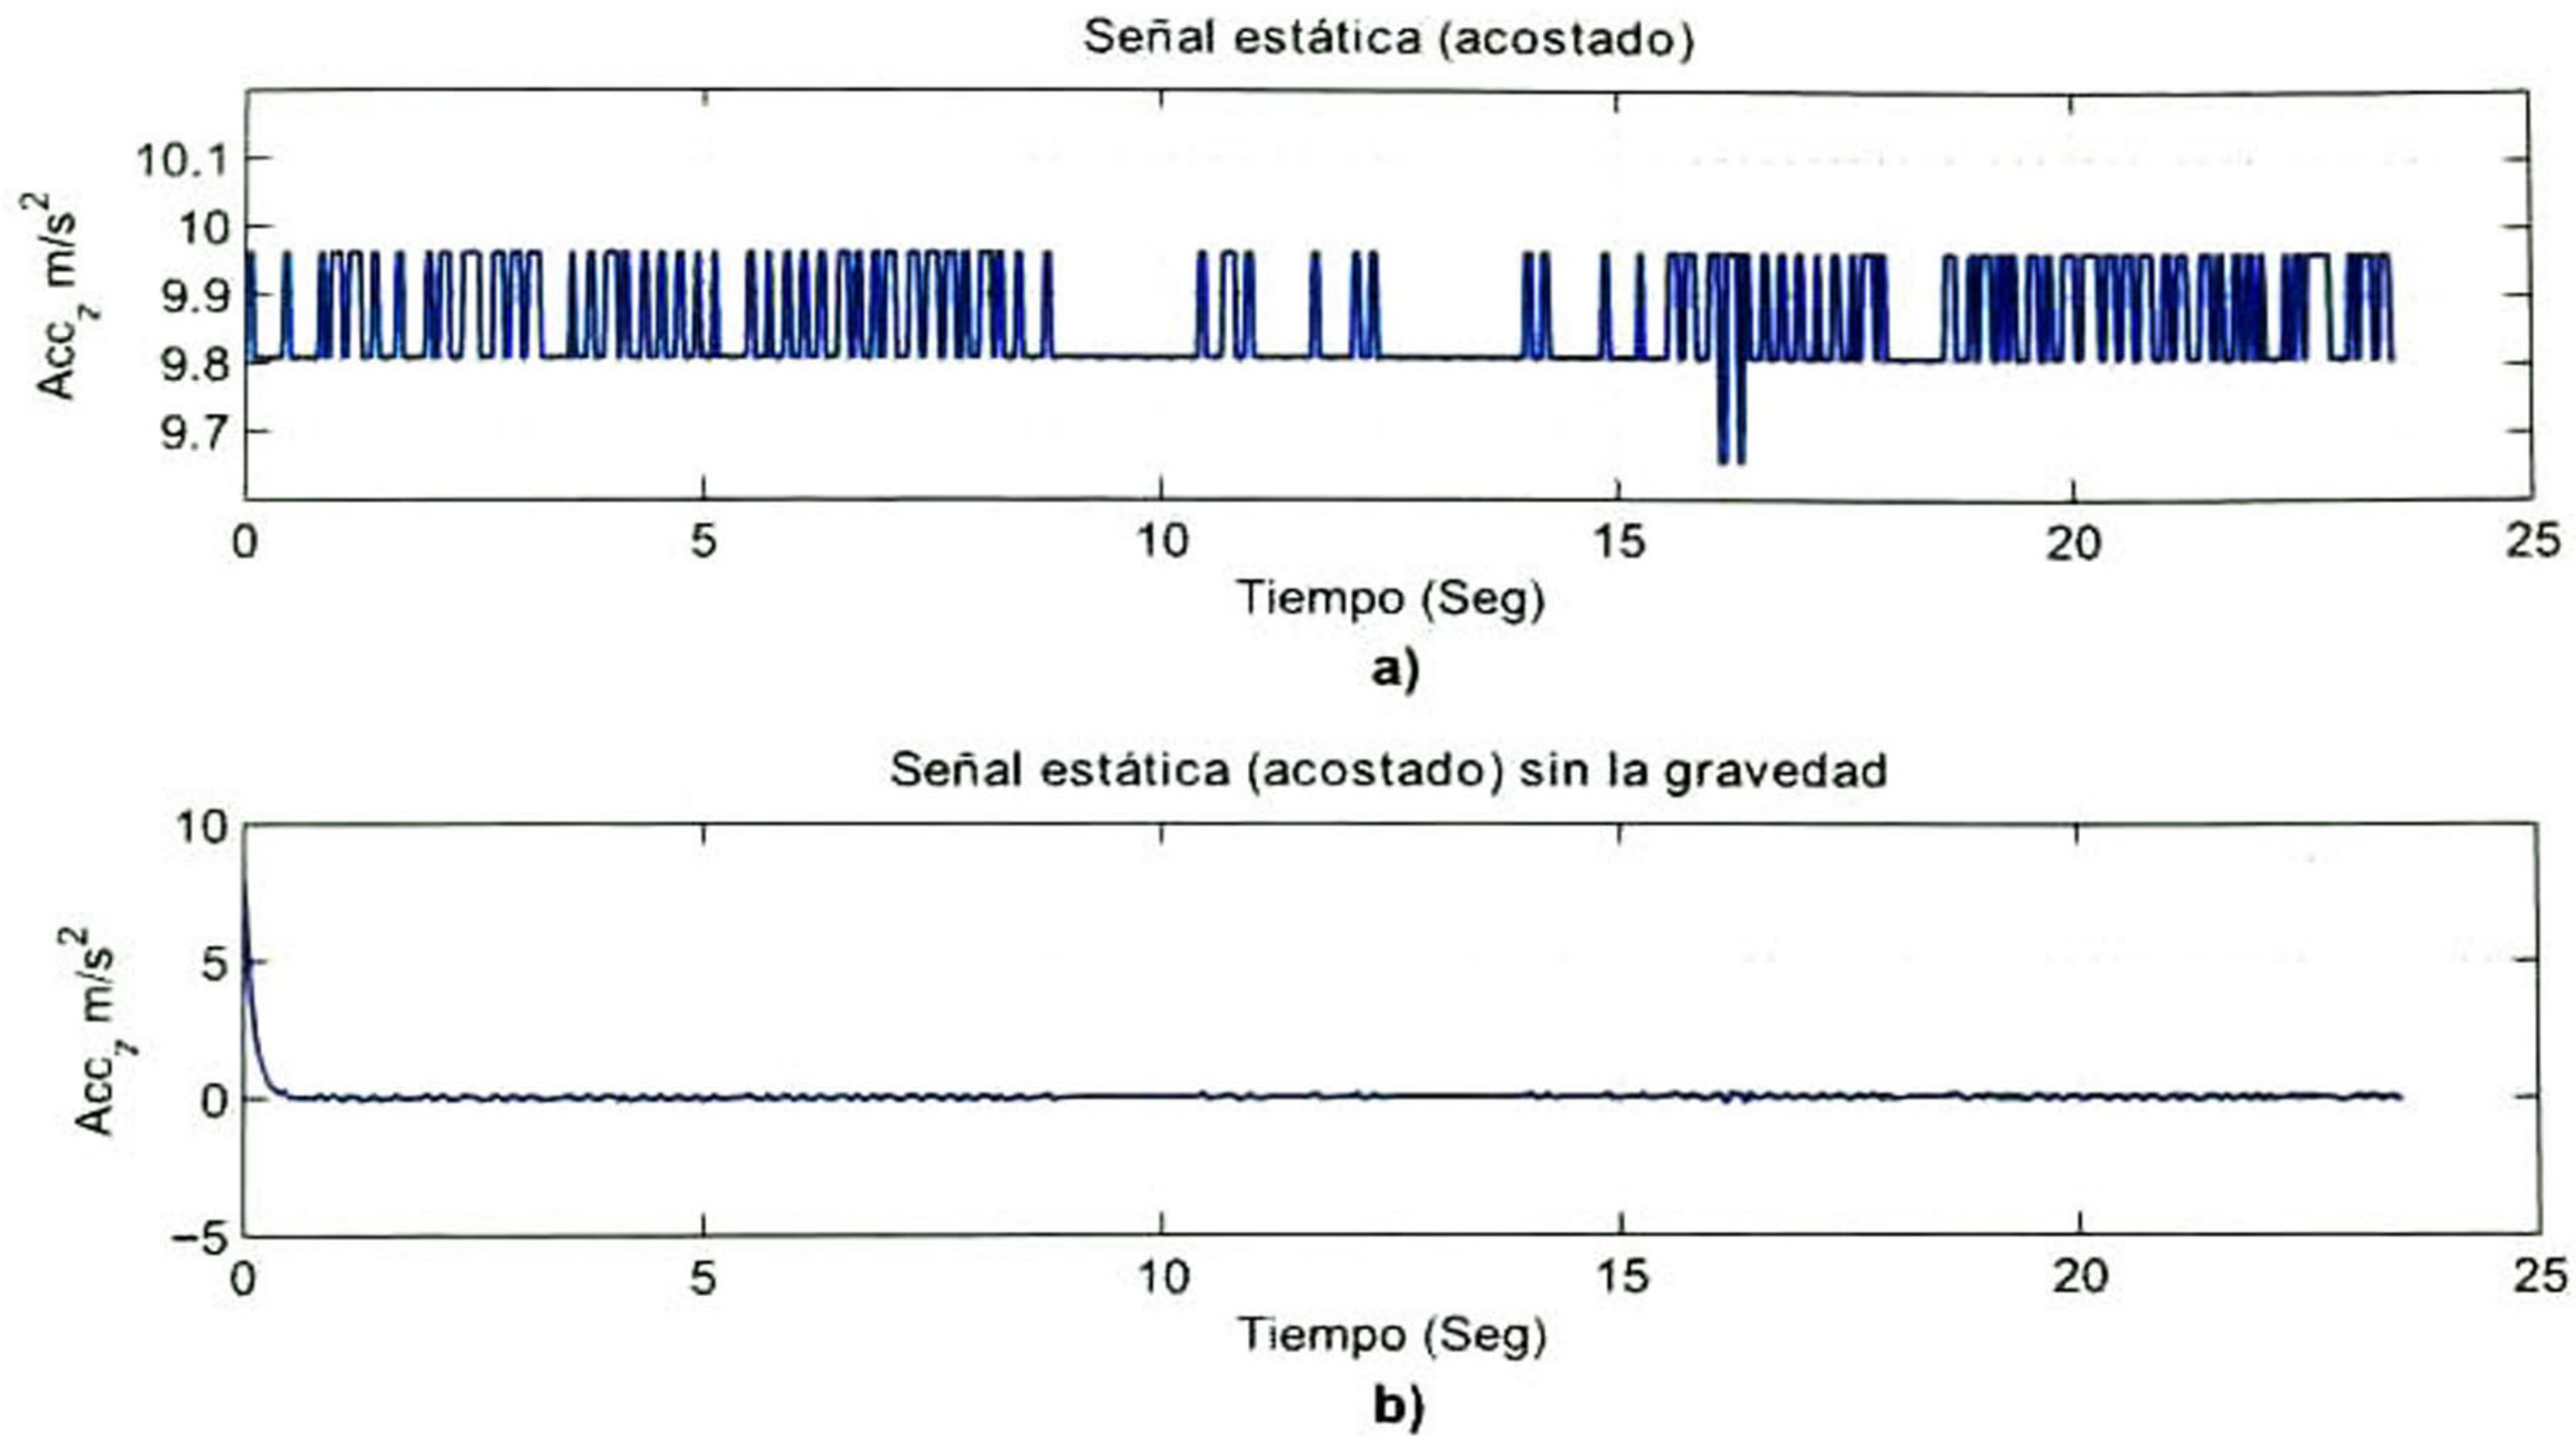


Figura 3.2: Remoción de la gravedad a través de un filtro pasa altas.

---

**Algoritmo 1** Algoritmo de filtrado para la remoción de la gravedad

---

**Entrada:** Aceleración original `aceleracion[0..2]` y  $\alpha$  un valor comprendido entre 0 y 1 (0.8)

**Salida:** `aceleracion_lineal[0..2]`

- 1:  $g[0] \leftarrow 0, g[1] \leftarrow 0, g[2] \leftarrow 0$
  - 2:  $g[0] \leftarrow \alpha * g[0] + (1 - \alpha) * aceleracion[0]$
  - 3:  $g[1] \leftarrow \alpha * g[1] + (1 - \alpha) * aceleracion[1]$
  - 4:  $g[2] \leftarrow \alpha * g[2] + (1 - \alpha) * aceleracion[2]$
  - 5:  $aceleracion\_lineal[0] \leftarrow aceleracion[0] - g[0]$
  - 6:  $aceleracion\_lineal[1] \leftarrow aceleracion[1] - g[1]$
  - 7:  $aceleracion\_lineal[2] \leftarrow aceleracion[2] - g[2]$
  - 8: **return** `aceleracion_lineal`
- 

Para disminuir el *jittering* se ha aplicado un filtro promedio móvil de orden 3 tal como se reporta en [55] utilizando la Ecuación (2.2). Para ilustrar el efecto de reducción del *jittering* en las gráficas de la Figura 3.3 se observa cómo la señal original cambia a una señal más suavizada.



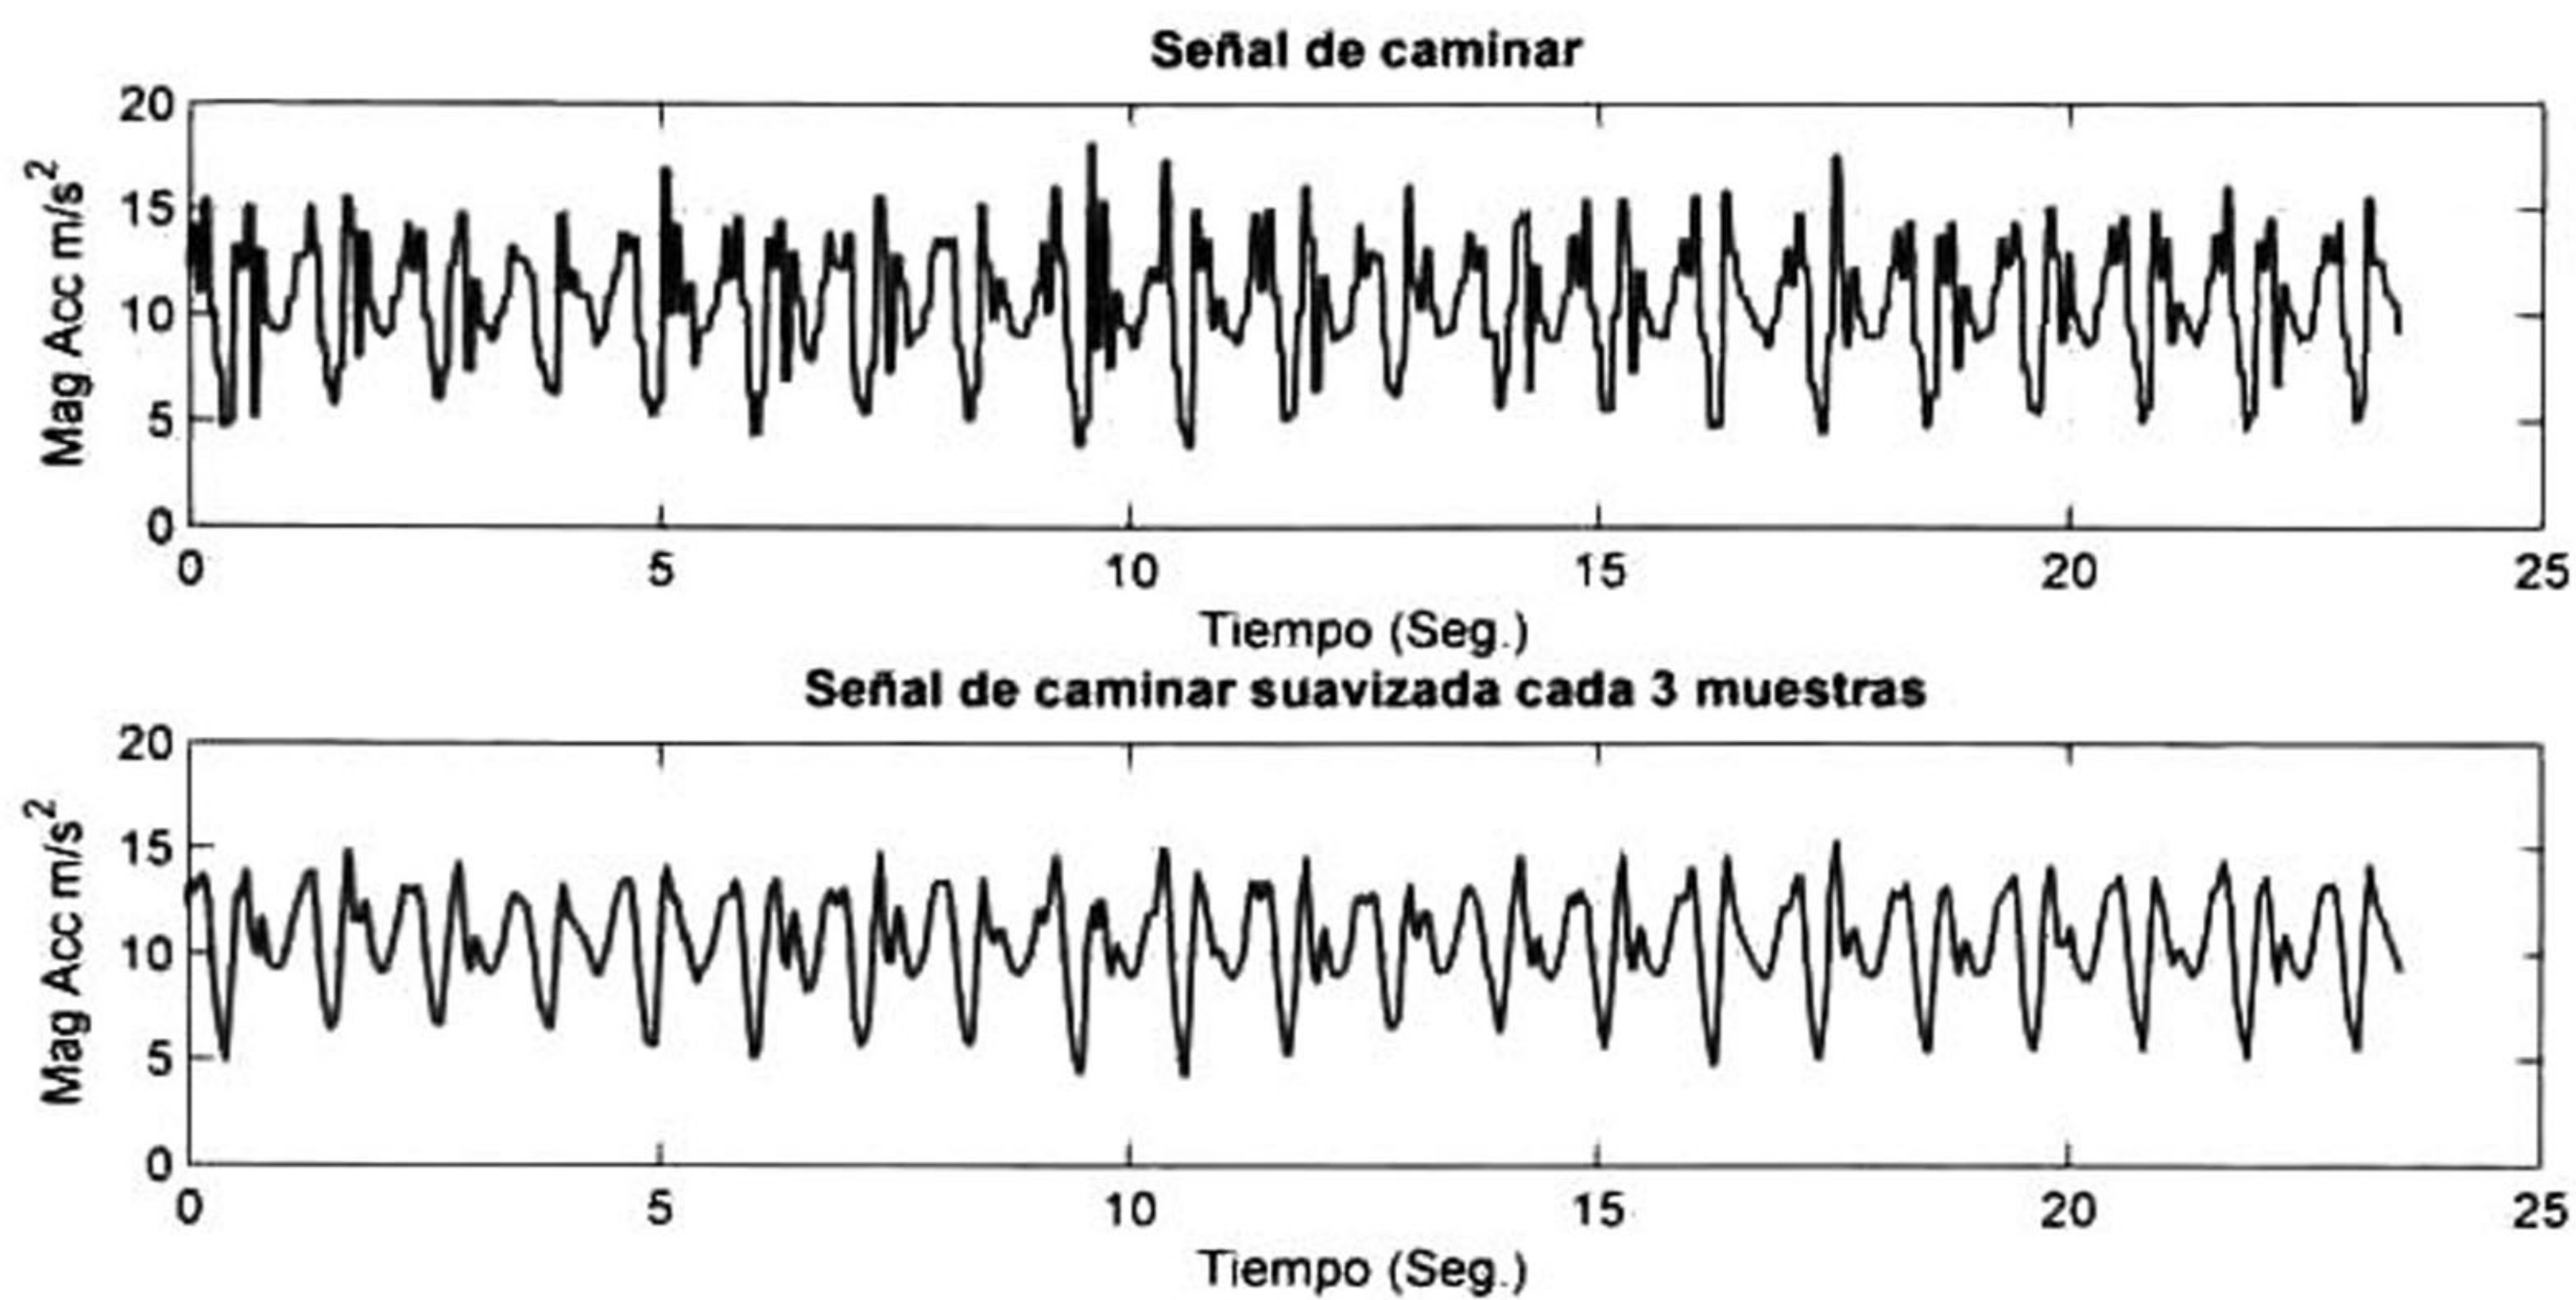


Figura 3.3: Señal suavizada a partir un filtro promedio de orden tres.

### 3.2.2 Interpolación de datos

Para solventar el problema de la frecuencia de muestreo no regular, una de las técnicas o métodos empleados es la interpolación. Este método consiste en la obtención de nuevos puntos partiendo de un conjunto previamente establecido. En este trabajo se ha seleccionado la interpolación lineal, debido a que el costo computacional requerido es bajo, lo cual hace factible su implementación en plataformas móviles. Éste método se realiza mediante la Ecuación (2.4), donde la variable independiente es el tiempo y la variable dependiente es la aceleración.

En general, el intervalo de tiempo aproximado entre la captura de cada muestra depende de la frecuencia de muestreo del acelerómetro. Por ejemplo durante la experimentación realizada en una plataforma Android, se observó que el tiempo promedio en el que se captura cada muestra es de 23 milisegundos para una frecuencia de muestreo de 40 Hz. Sin embargo, hay muestras que son capturadas por encima de los 23 milisegundos, ésto se debe a diversos factores tales como las interrupciones realizadas en el SO para atender otros procesos.



Una forma de ilustrar el problema de la frecuencia de muestreo no regular específicamente para el SO Android, se muestra en Figura 3.4 donde se observa la diferencia de tiempo de captura entre muestras consecutivas las cuales son superiores al promedio que hay entre cada muestra, éstos son resaltados con puntos rojos. En este trabajo las muestras capturadas en intervalos de tiempo superiores a los 23 milisegundos fueron determinadas a través del método de interpolación lineal.

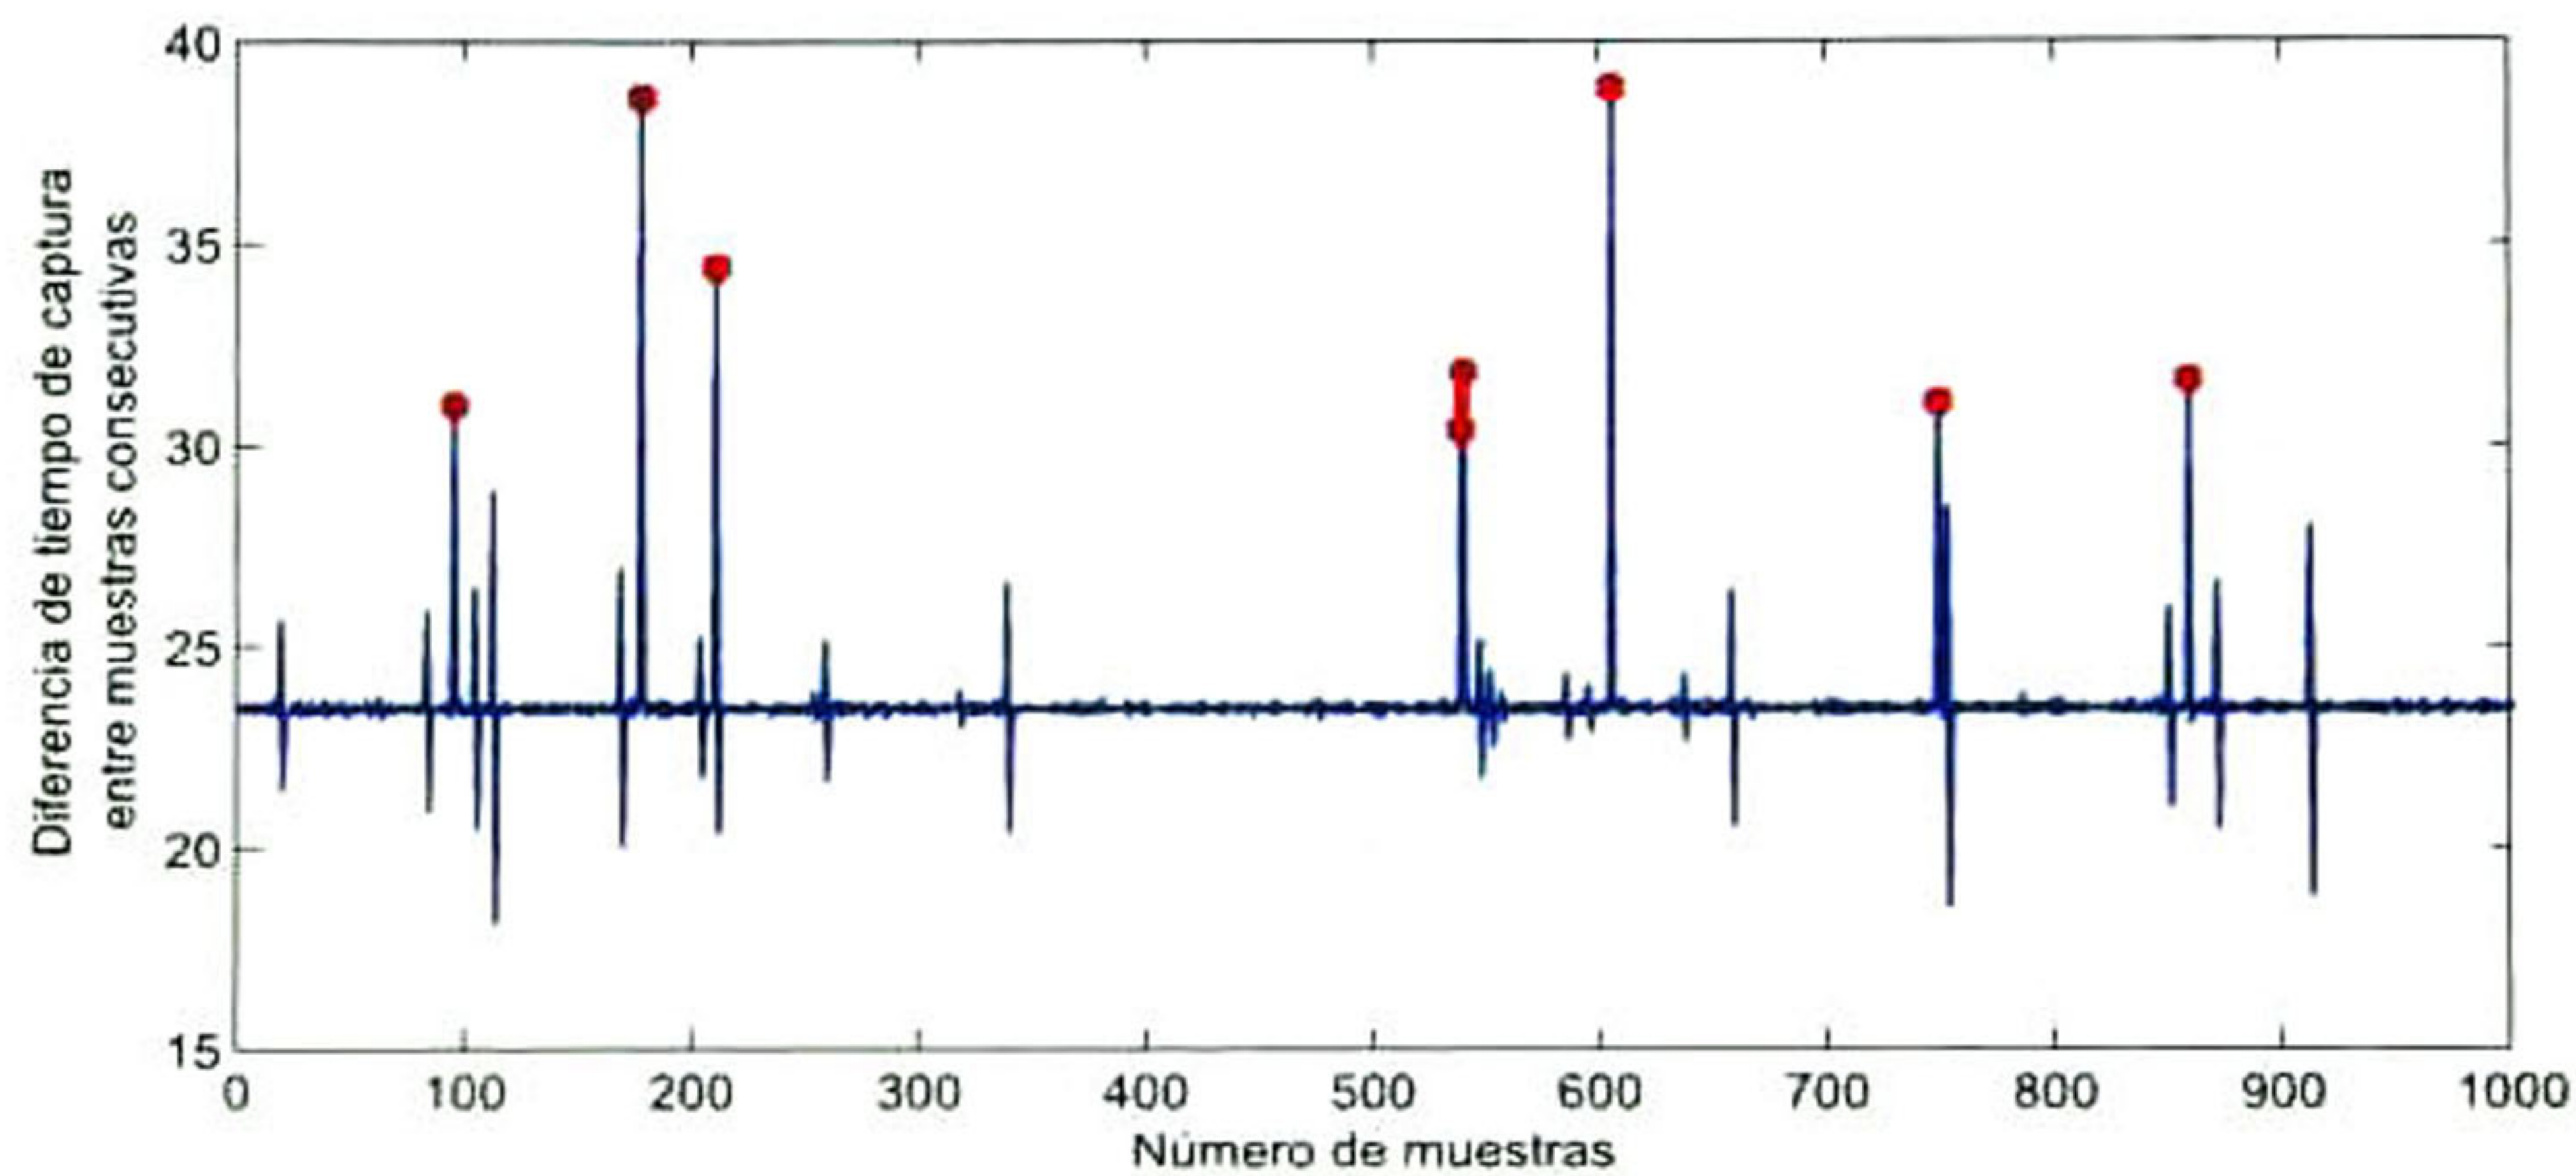


Figura 3.4: Ejemplificación de la frecuencia de muestreo no regular en un smartphone con SO Android. Los puntos rojos indican los tiempos superiores al promedio en los que una muestra fue capturada.

### 3.3 Segmentación de datos

La técnica de segmentación consiste en dividir una secuencia de datos en subconjuntos de tamaño  $k$ , tal como se ilustra en la Figura 3.5. Para definir el tamaño de ventana apropiado es necesario considerar la frecuencia de muestreo del acelerómetro y el tiempo de observación en el que se determina la actividad realizada por el usuario. Algunos tamaños de ventana que se han reportado en la literatura se muestran en la Tabla 3.1, en la que puede observarse cómo el tamaño de la ventana está asociada a la frecuencia de muestreo. Además se muestra el uso de traslapes los cuales han sido utilizados para inferir la actividad realizada cuando ocurre una transición o cambio de actividad física [54].





Figura 3.5: División de un conjunto de datos en ventanas o segmentos de tamaño  $k$ .

Referencias	Tamaños de ventana (segundos)	Traslape	Frecuencia de muestreo (Hz)
[11]	1	No	36
[59]	5	No	16
[15]	10	No	20
[23]	2	No	50
[55]	3.2	No	20
[60]	5	No	20
[61]	4	Si	32
[62]	1.02	No	50
[28]	2.56	Si	100
[54]	7.5	Si	40

Tabla 3.1: Tamaños de ventanas considerados en la literatura.

Particularmente en este trabajo se ha empleado un tamaño de ventana de 5 segundos y una frecuencia de muestreo de 40 Hz en promedio. Estos parámetros fueron considerados suficientes para determinar la actividad que realiza una persona con base en [1] y las experimentaciones descritas en el Capítulo 4 de la presente tesis. Básicamente el proceso de segmentación se realizó dividiendo la señal de la magnitud de la aceleración preprocesada cada 200 muestras. Un ejemplo de esto se ilustra en la Figura 3.6, donde una señal de entrada (magnitud de la aceleración) de 1600 muestras se divide en un total de 8 segmentos de 200 muestras cada uno. Éstos segmentos son empleados para extraer las características que se hayan seleccionado.



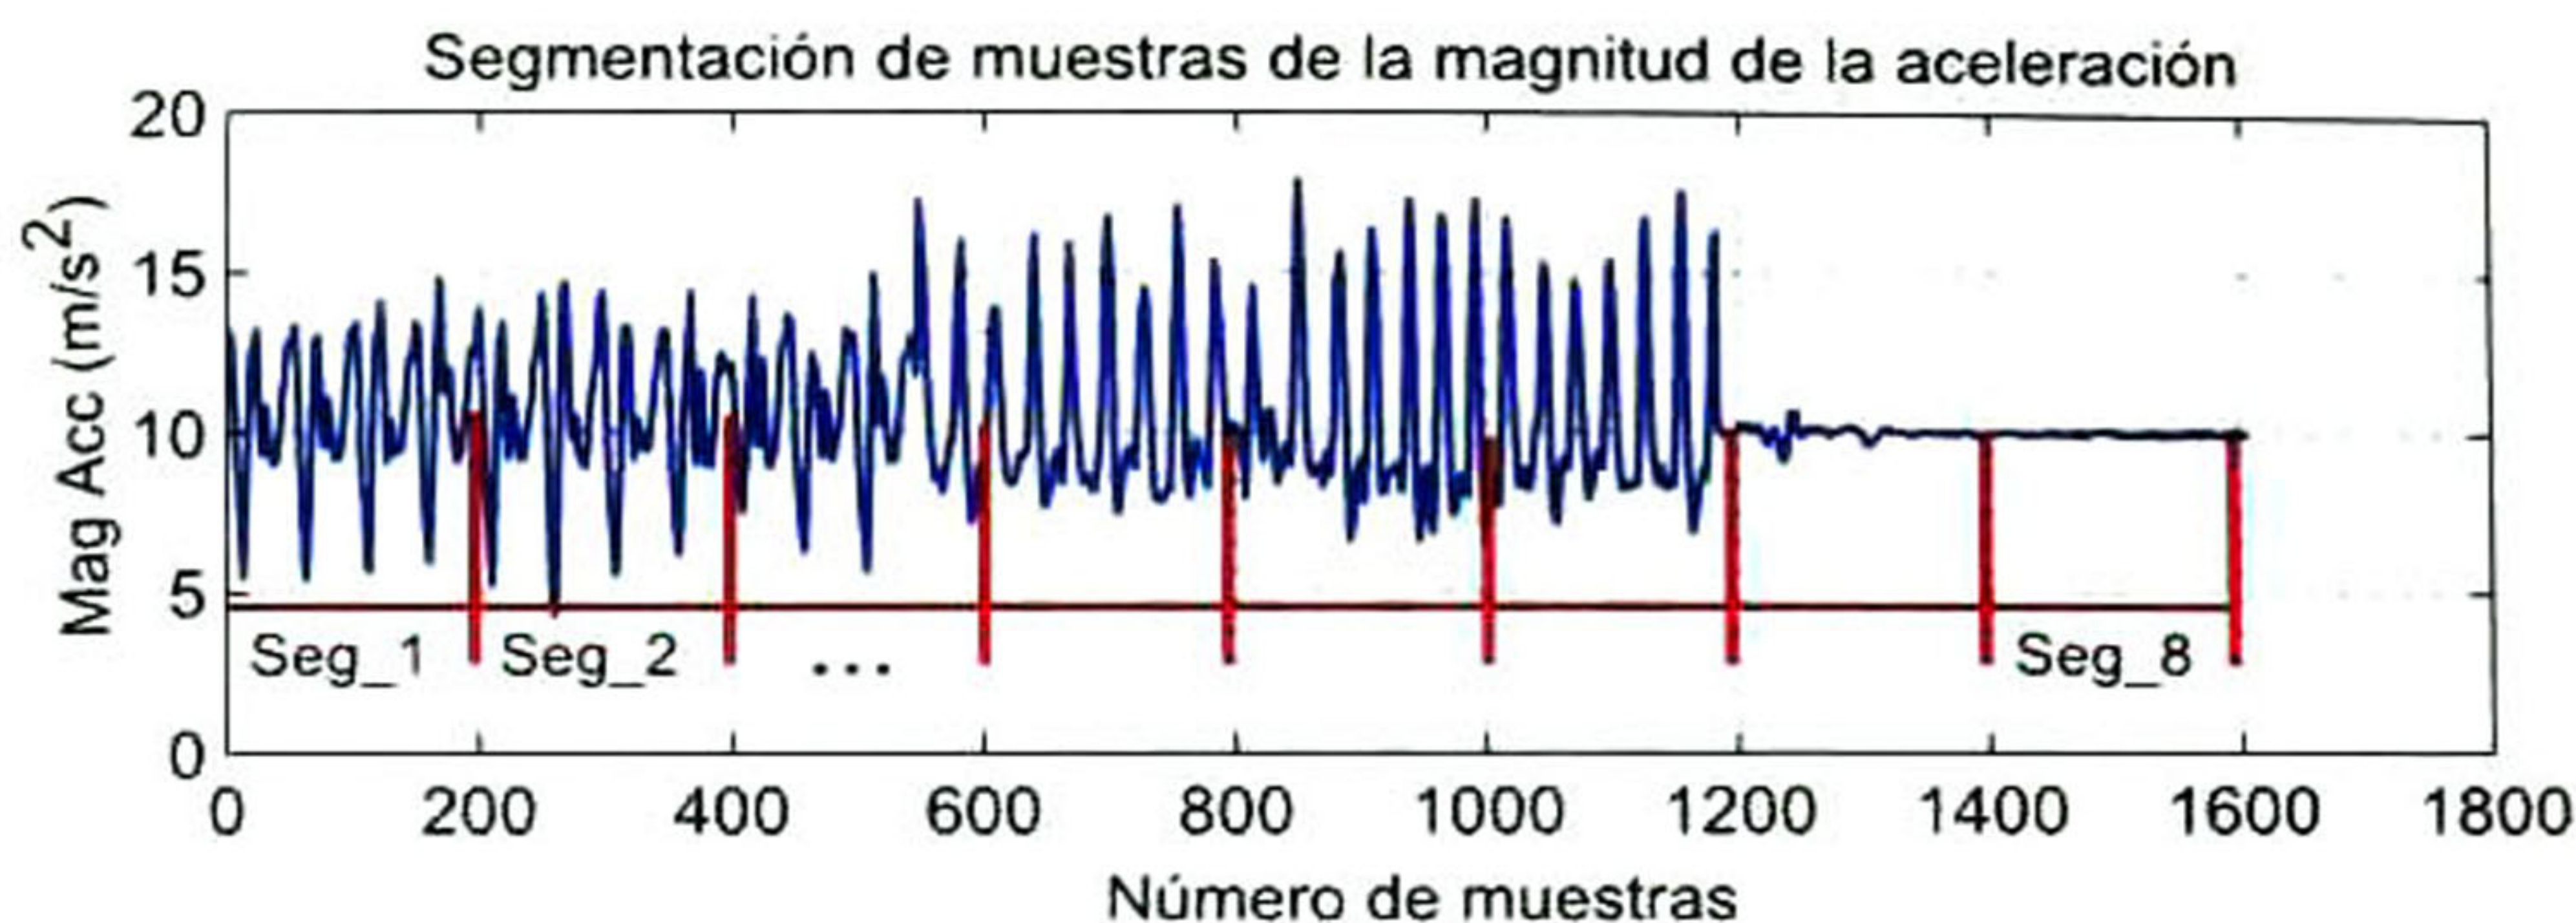


Figura 3.6: Ejemplificación de una señal segmentada cada 200 muestras.

### 3.4 Extracción y selección de características

El proceso de extracción de características consiste en analizar los atributos de cada objeto de interés para generar información que permita diferenciar una clase de otra. Es por ello que la selección apropiada de un conjunto de características, es uno de los factores más importantes para poder realizar el reconocimiento de actividades con alta precisión. Además, la extracción de características simplifica al conjunto de datos ya que permite eliminar la información redundante y como consecuencia reducen en gran medida el costo computacional requerido durante la fase de clasificación.

Para el reconocimiento de actividades físicas, en la literatura se ha reportado el uso de características del dominio del tiempo y la frecuencia [28, 63]. Las características del dominio de la frecuencia han sido utilizadas ampliamente debido a que aportan una mayor información en el proceso de clasificación, aunque el cálculo requerido para su obtención es elevado. Debido a este inconveniente en esta investigación se han seleccionado características del dominio del tiempo, puesto que no exigen de un alto costo computacional para ser calculadas en un dispositivo móvil. Estas características se muestran de manera resumida en la Tabla 3.2.

De las características seleccionadas, cabe señalar que la media y la desviación estándar son características consideradas independientes de la posición, orientación y del tamaño de ventana. Dichas características son empleadas para discriminar entre actividades que generen señales con



Referencia	Característica	Fórmula
[25, 28, 29, 64]	Media aritmética	$\bar{x} = \frac{1}{n} \sum_{i=1}^n a_i$
[25, 28]	Desviación estándar	$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - \bar{x})^2}$
[17, 30, 36]	Percentil $_k$	$P_k = k(n + 1)/100$
[32, 35, 65]	Coefficientes autorregresivos	$Y_t = \sum_{i=1}^P \phi_i Y_{t-i} + \varepsilon_t$

Tabla 3.2: Características seleccionadas para el reconocimiento de actividades físicas

variaciones muy grandes y pequeñas, por ejemplo, para el caso de las actividades dinámicas y estáticas. Sin embargo, la media y la desviación estándar no son características representativas para actividades como caminar, subir y bajar escaleras debido a que sus medidas son similares entre sí, lo cual aumenta la probabilidad de una clasificación errónea. Para solventar este inconveniente se requieren de características que aporten mayor información de las señales, como el uso de coeficientes autorregresivos y los percentiles. En las siguientes subsecciones se describen de manera general cada una de estas características.

### 3.4.1 Modelo autorregresivo

Básicamente un modelo autorregresivo permite modelar señales de tiempo, la idea fundamental consiste en que a partir de un conjunto de coeficientes que ponderan a un subconjunto de muestras de la señal real reconstruyan o estimen las señales futuras. Esto es, las muestras sucesivas  $Y_t$  de un proceso autorregresivo dependen de sus predecesoras más un término de error (típicamente, ruido blanco) y se obtienen mediante la Ecuación (3.1).

$$Y_t = \sum_{i=1}^P \phi_i Y_{t-i} + \varepsilon_t \quad (3.1)$$



Donde  $\phi_i$  representa los coeficientes autorregresivos,  $Y_t$  las muestras generadas,  $\varepsilon$  es un termino de error (el termino de error es considerado debido a que la señal obtenida es aproximada) y  $P$  es el número de los coeficientes.

En el Algoritmo 2 se describe el método para obtener los coeficientes autorregresivos. El algoritmo recibe como parámetros de entrada un subconjunto de muestras  $M$  y el número de coeficientes  $P$ , y produce como salida los coeficientes autorregresivos. La obtención de los coeficientes se basan en el método de Burg descrito en [66, 67, 68, 69].

---

**Algoritmo 2** Algoritmo de Burg para la obtención de los coeficientes de un modelo autorregresivo

---

**Entrada:** Un subconjunto de muestras  $M[1..200]$  y  $P$  el número de coeficientes.

**Salida:** Los coeficientes autorregresivos **Coeff**.

```

1:  $efp[1..P-1] \leftarrow \{0\}$ 
2:  $ebp[1..P-1] \leftarrow \{0\}$ 
3:  $Coeff \leftarrow \{0\}$ 
4:  $K \leftarrow \{0\}$ 
5:  $a \leftarrow \{1\}$ 
6:  $num \leftarrow 0$ 
7:  $den \leftarrow 0$ 
8:  $ef \leftarrow M$ 
9:  $eb \leftarrow M$ 
10: for  $i \leftarrow 1$  to  $P$  do
11:    $efp \leftarrow ef[2..P]$ 
12:    $ebp \leftarrow eb[1..P-1]$ 
13:    $num \leftarrow -2 * ebp^T * efp$ 
14:    $den \leftarrow efb^T * efp + ebp^T * ebp$ 
15:    $K(i) \leftarrow num/den$ 
16:    $ef \leftarrow efp + K[i] * ebp$ 
17:    $eb \leftarrow ebp + K[i] * efp$ 
18:    $a \leftarrow Concatenar(a^T, 0) + K[i] * Concatenar(0, Invertir(a)^T)$ 
19: end for
20:  $Coeff \leftarrow a$ 
21: return  $Coeff$ 

```

---

Uno de los aspectos abiertos acerca de los modelos autorregresivos es seleccionar el número apropiado de ellos. Para determinarlos se empleo el error cuadrático medio [55, 70], el cual se establece mediante la Ecuación (3.2).



$$\rho = \frac{1}{n - P} \sum_{k=P+1}^n (a_p(k) - a_d(k))^2 \quad (3.2)$$

Donde  $a_p(k)$  corresponde a las muestras de la señal estimada por los coeficientes autorregresivos,  $a_d(k)$  son las muestras de la señal real,  $n$  es el número total de muestras,  $P$  el orden de los coeficientes y  $\rho$  el error estimado. Cabe mencionar que entre menor sea el valor de  $\rho$  la señal estimada será más aproximada a la real.

Una vez determinado el número de los coeficientes, un conjunto de experimentaciones fue realizado para evaluar el porcentaje de reconocimiento de las actividades empleando los coeficientes seleccionados. En la sección 4.2.1 se describe con más detalle que el número de coeficientes seleccionados es de 50.

### 3.4.2 Cálculo de los percentiles

Otra de las características empleadas en el reconocimiento de actividades son los percentiles, los cuales son considerados como una medida estadística de posición no central, que determinan aquellos valores que superan un porcentaje de los miembros de una población. Para el percentil  $k$ -ésimo, donde  $k$  toma valores enteros entre 1 y 99, el  $k\%$  de las muestras son valores menores que él y el  $(100 - k)\%$  restante son mayores.

Un método empleado para obtener el *percentil*  $_k$  sería el siguiente:

1. Se ordenan las muestras de mayor a menor y se almacenan en  $a$
2. Se calcula  $i = \frac{n * k}{100}$
3. Si  $i$  no es un entero,  $Percentil_k = a([i] + 1)$
4. Si  $i$  es un entero  $Percentil_k = \frac{a(i) + a(i + 1)}{2}$

Donde  $n$  es el número de muestras,  $k$  el percentil deseado y  $a(i)$  es el valor obtenido en la posición  $i$  de las muestras ordenadas.



El percentil se ha empleado como característica para distinguir las variaciones de las señales que superan a un cierto umbral y como las señales generadas por las actividades correspondientes a caminar, subir y bajar escaleras tienen esta particularidad, éstos fueron empleados en cada una de estas señales. A manera de ilustración en la Figura 3.7 se muestra las diferencias entre las variaciones generadas en cada señal.




Figura 3.7: Señales generadas al realizar las actividades de caminar, subir y bajar escaleras (el valor del percentil 95 de cada señal es 17.06, 13.78 y 15.17 respectivamente).

### 3.4.3 Construcción del vector de características

Las características fueron extraídas de la magnitud de la aceleración en ventanas de 200 muestras y posteriormente se estableció el vector de características, tal como se ilustra en la Figura 3.8.

El tamaño del vector de características construido es de 53, debido a que se seleccionaron la






Figura 3.8: Proceso de extracción de características.

media, desviación estándar, percentil<sub>95</sub> y 50 coeficientes autorregresivos. Estas características se muestran de manera resumida en la Tabla 3.2.

### 3.5 Obtención de los componentes principales

Como se describió en el marco teórico, el ACP es una técnica estadística utilizada para reducir la dimensionalidad o el número de características obtenidas de un conjunto de datos. Para ilustrar esto, en la Figura 3.9 se muestra la proyección del espacio de características ( $X_1, X_2$  y  $X_3$ ) sobre los CPs que mejor representan al conjunto de datos.

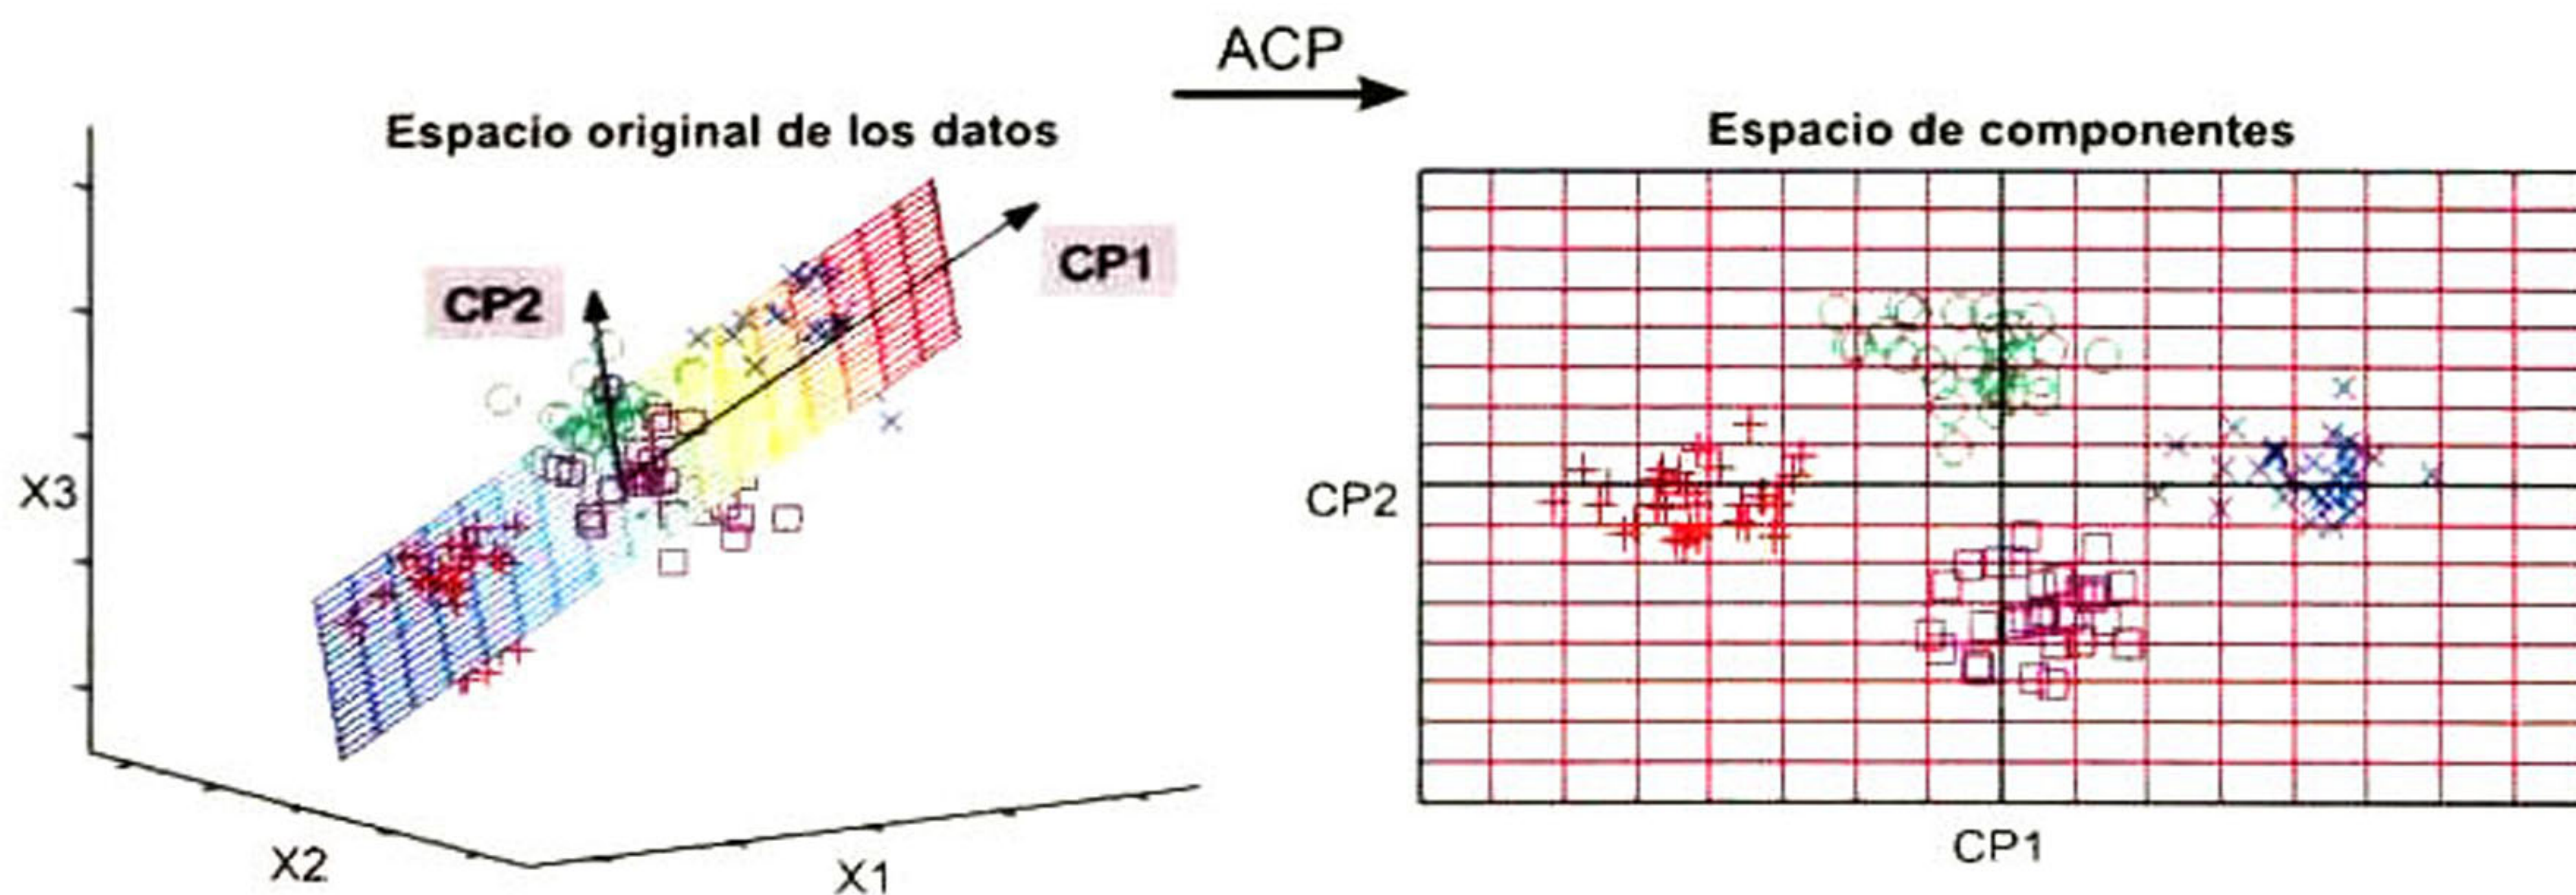


Figura 3.9: Proyección del espacio de características sobre los CPs obtenidos del ACP.



En la Figura 3.10 se muestra de manera resumida la obtención de los CPs. Básicamente se requiere de un vector de características, posteriormente el ACP es aplicado sobre estas características y finalmente se genera el conjunto de CPs. Puesto que el tamaño del vector de características seleccionado es de 53 entonces el conjunto de CPs obtenidos será del mismo tamaño, sin embargo se han seleccionado un total de 25 CPs con base a la varianza mayor representada por éstos. En la sección 4.2.2 se describe con más detalle la experimentación realizada para seleccionar número apropiado de CPs.

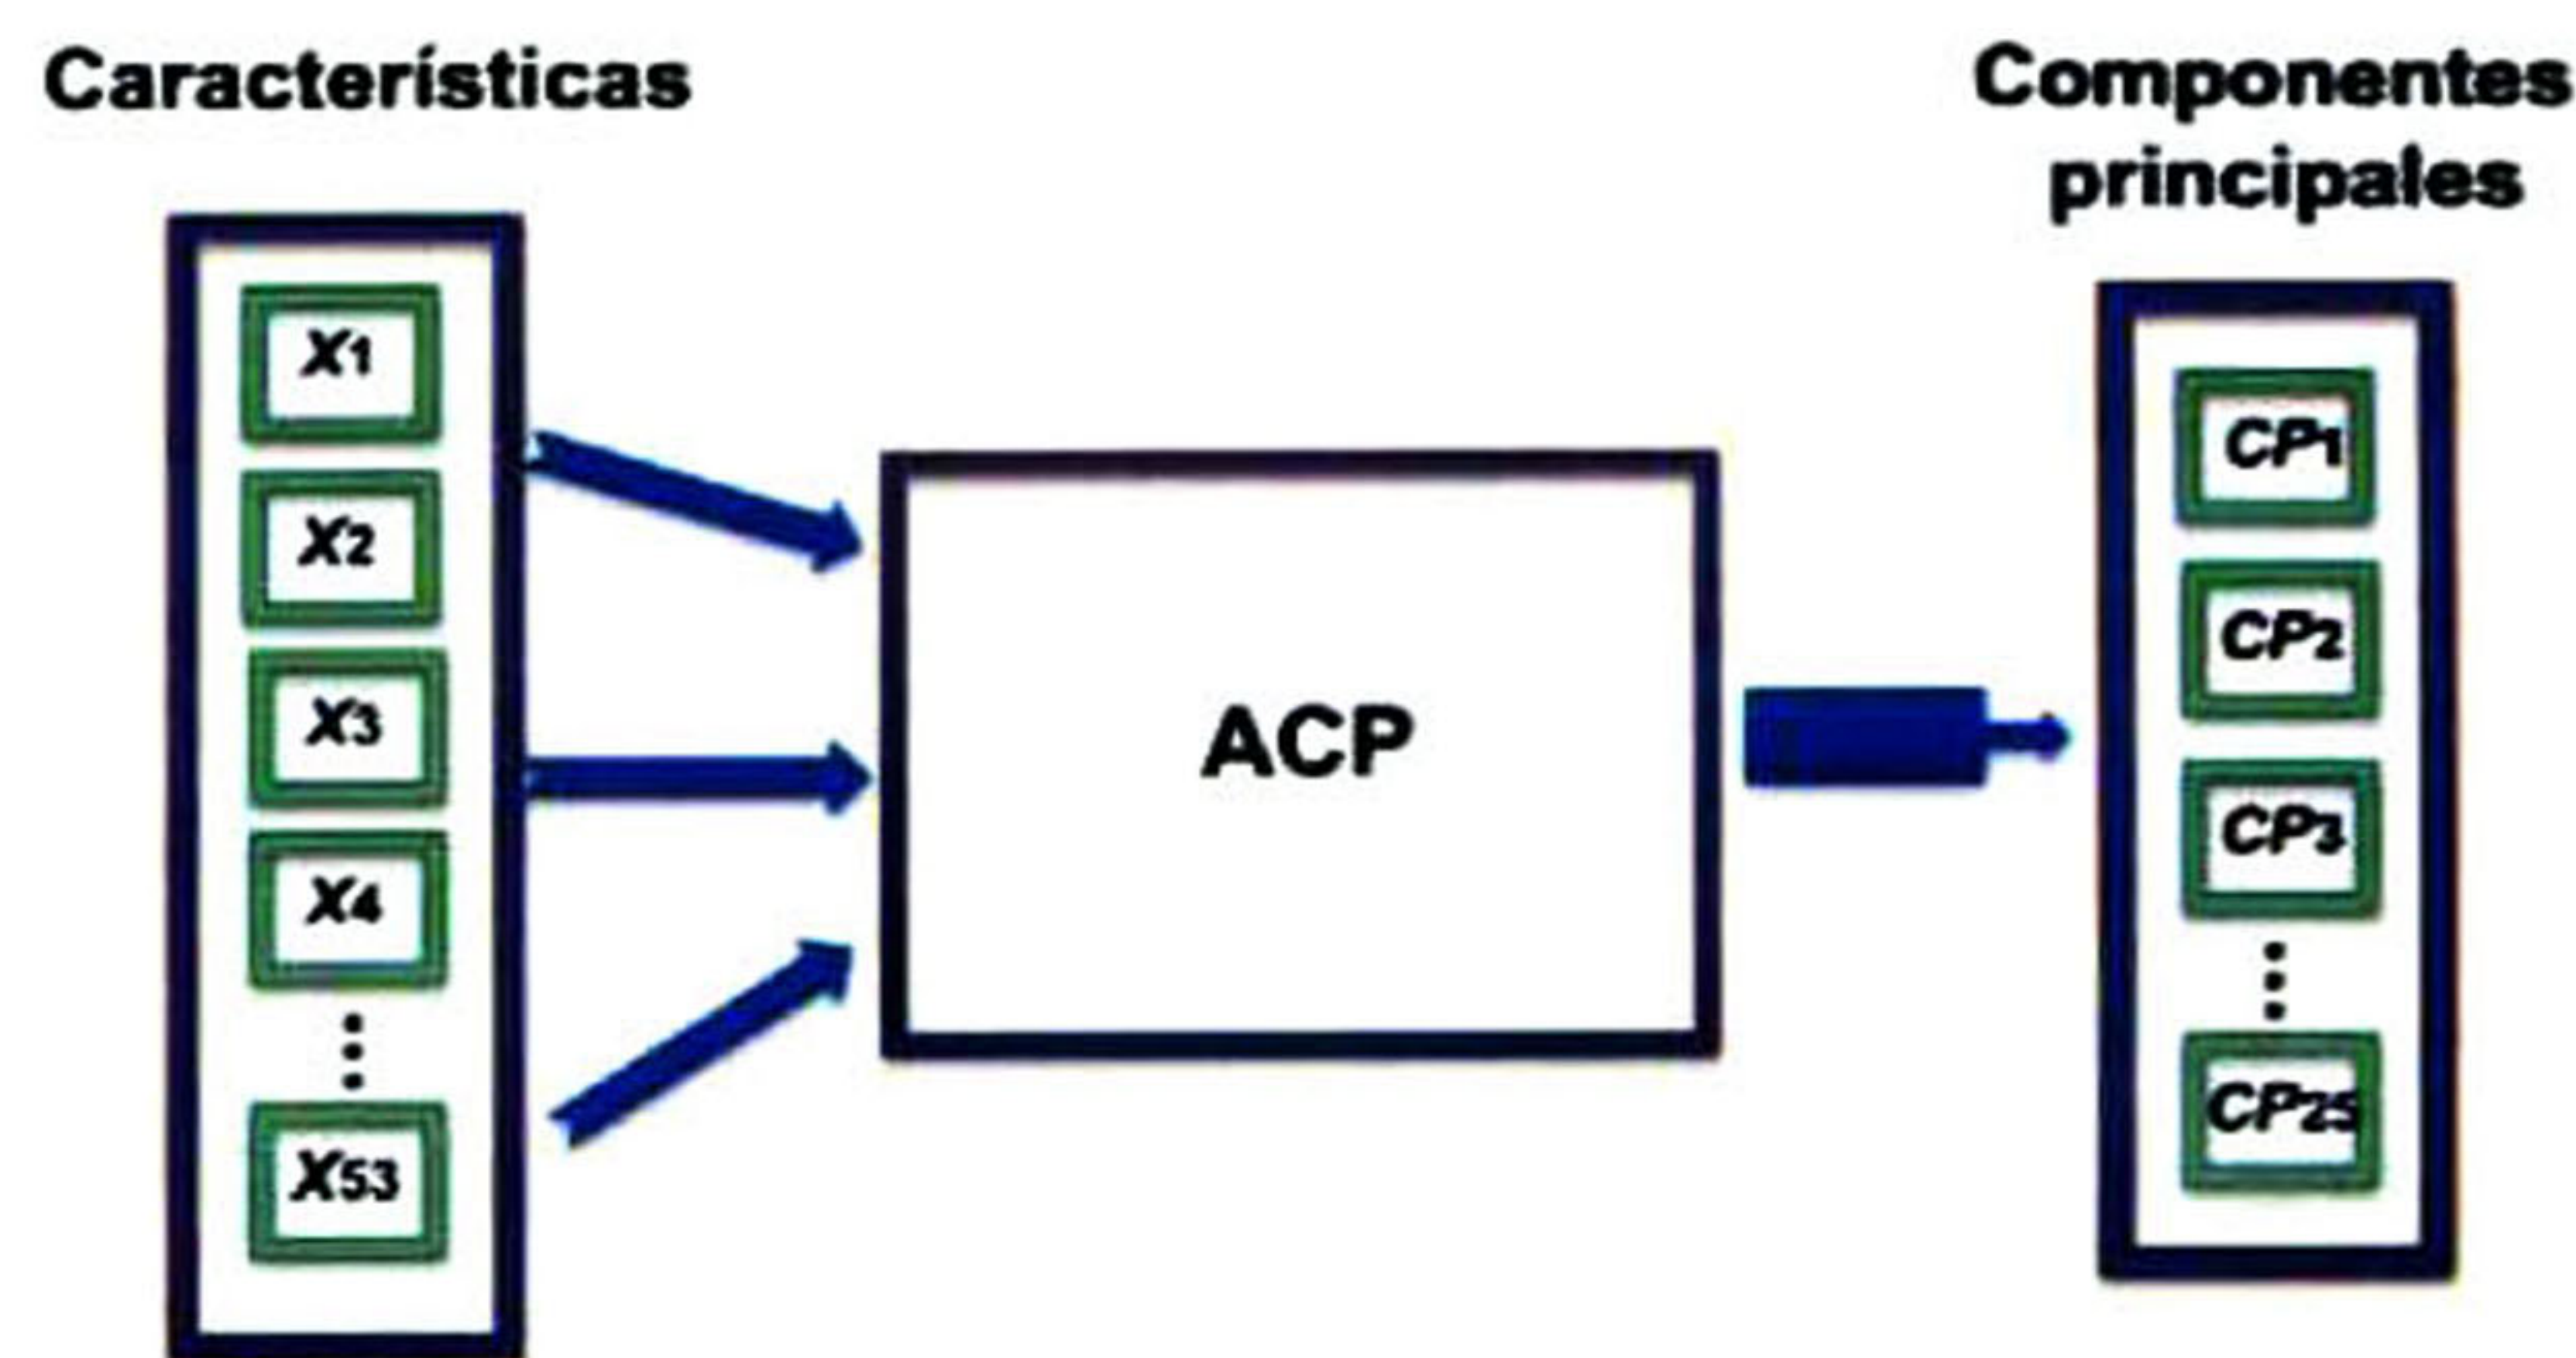


Figura 3.10: Diagrama general para la obtención de los CPs.

## 3.6 Clasificación de las actividades

Como se ha mencionado para discriminar las actividades físicas se consideró utilizar un método de clasificación supervisado, para el cual se ha definido como etiquetas de clase el nombre de cada actividad: correr, caminar, subir escaleras, bajar escaleras (consideradas como actividades dinámicas) y estáticas (sentado, acostado y de pie). El objetivo principal del aprendizaje supervisado es crear una función capaz de predecir el valor correspondiente a cualquier patrón de entrada válido después de haber sido entrenada con una serie de ejemplos (datos de entrenamiento). En la literatura se ha reportado que clasificadores como los árboles de decisión y las redes neuronales artificiales



aportan un alto porcentaje de precisión, para el contexto del reconocimiento de actividades físicas [2, 3, 32, 35, 43, 55]. Particularmente en este trabajo se ha seleccionado una combinación de estos dos clasificadores. Los detalles del enfoque de clasificación propuesto se describen en las siguientes subsecciones.

### 3.6.1 Distribución de las clases

Se realizó un análisis acerca de la distribución de los patrones de clase con el fin de tener una idea de como diseñar el clasificador propuesto. Para ello, se obtuvo la distribución de las clases (correr, caminar, subir escaleras, bajar escaleras y estático) empleando características estadísticas como la media y la desviación estándar, tal como se observa gráficamente en la Figura 3.11. Es notorio que existen patrones de clases muy separados entre si, tales como correr y estático, sin embargo, también se observa que hay patrones de clases traslapados totalmente como caminar, subir y bajar escaleras lo cual incrementa la posibilidad de clasificar erróneamente las actividades.

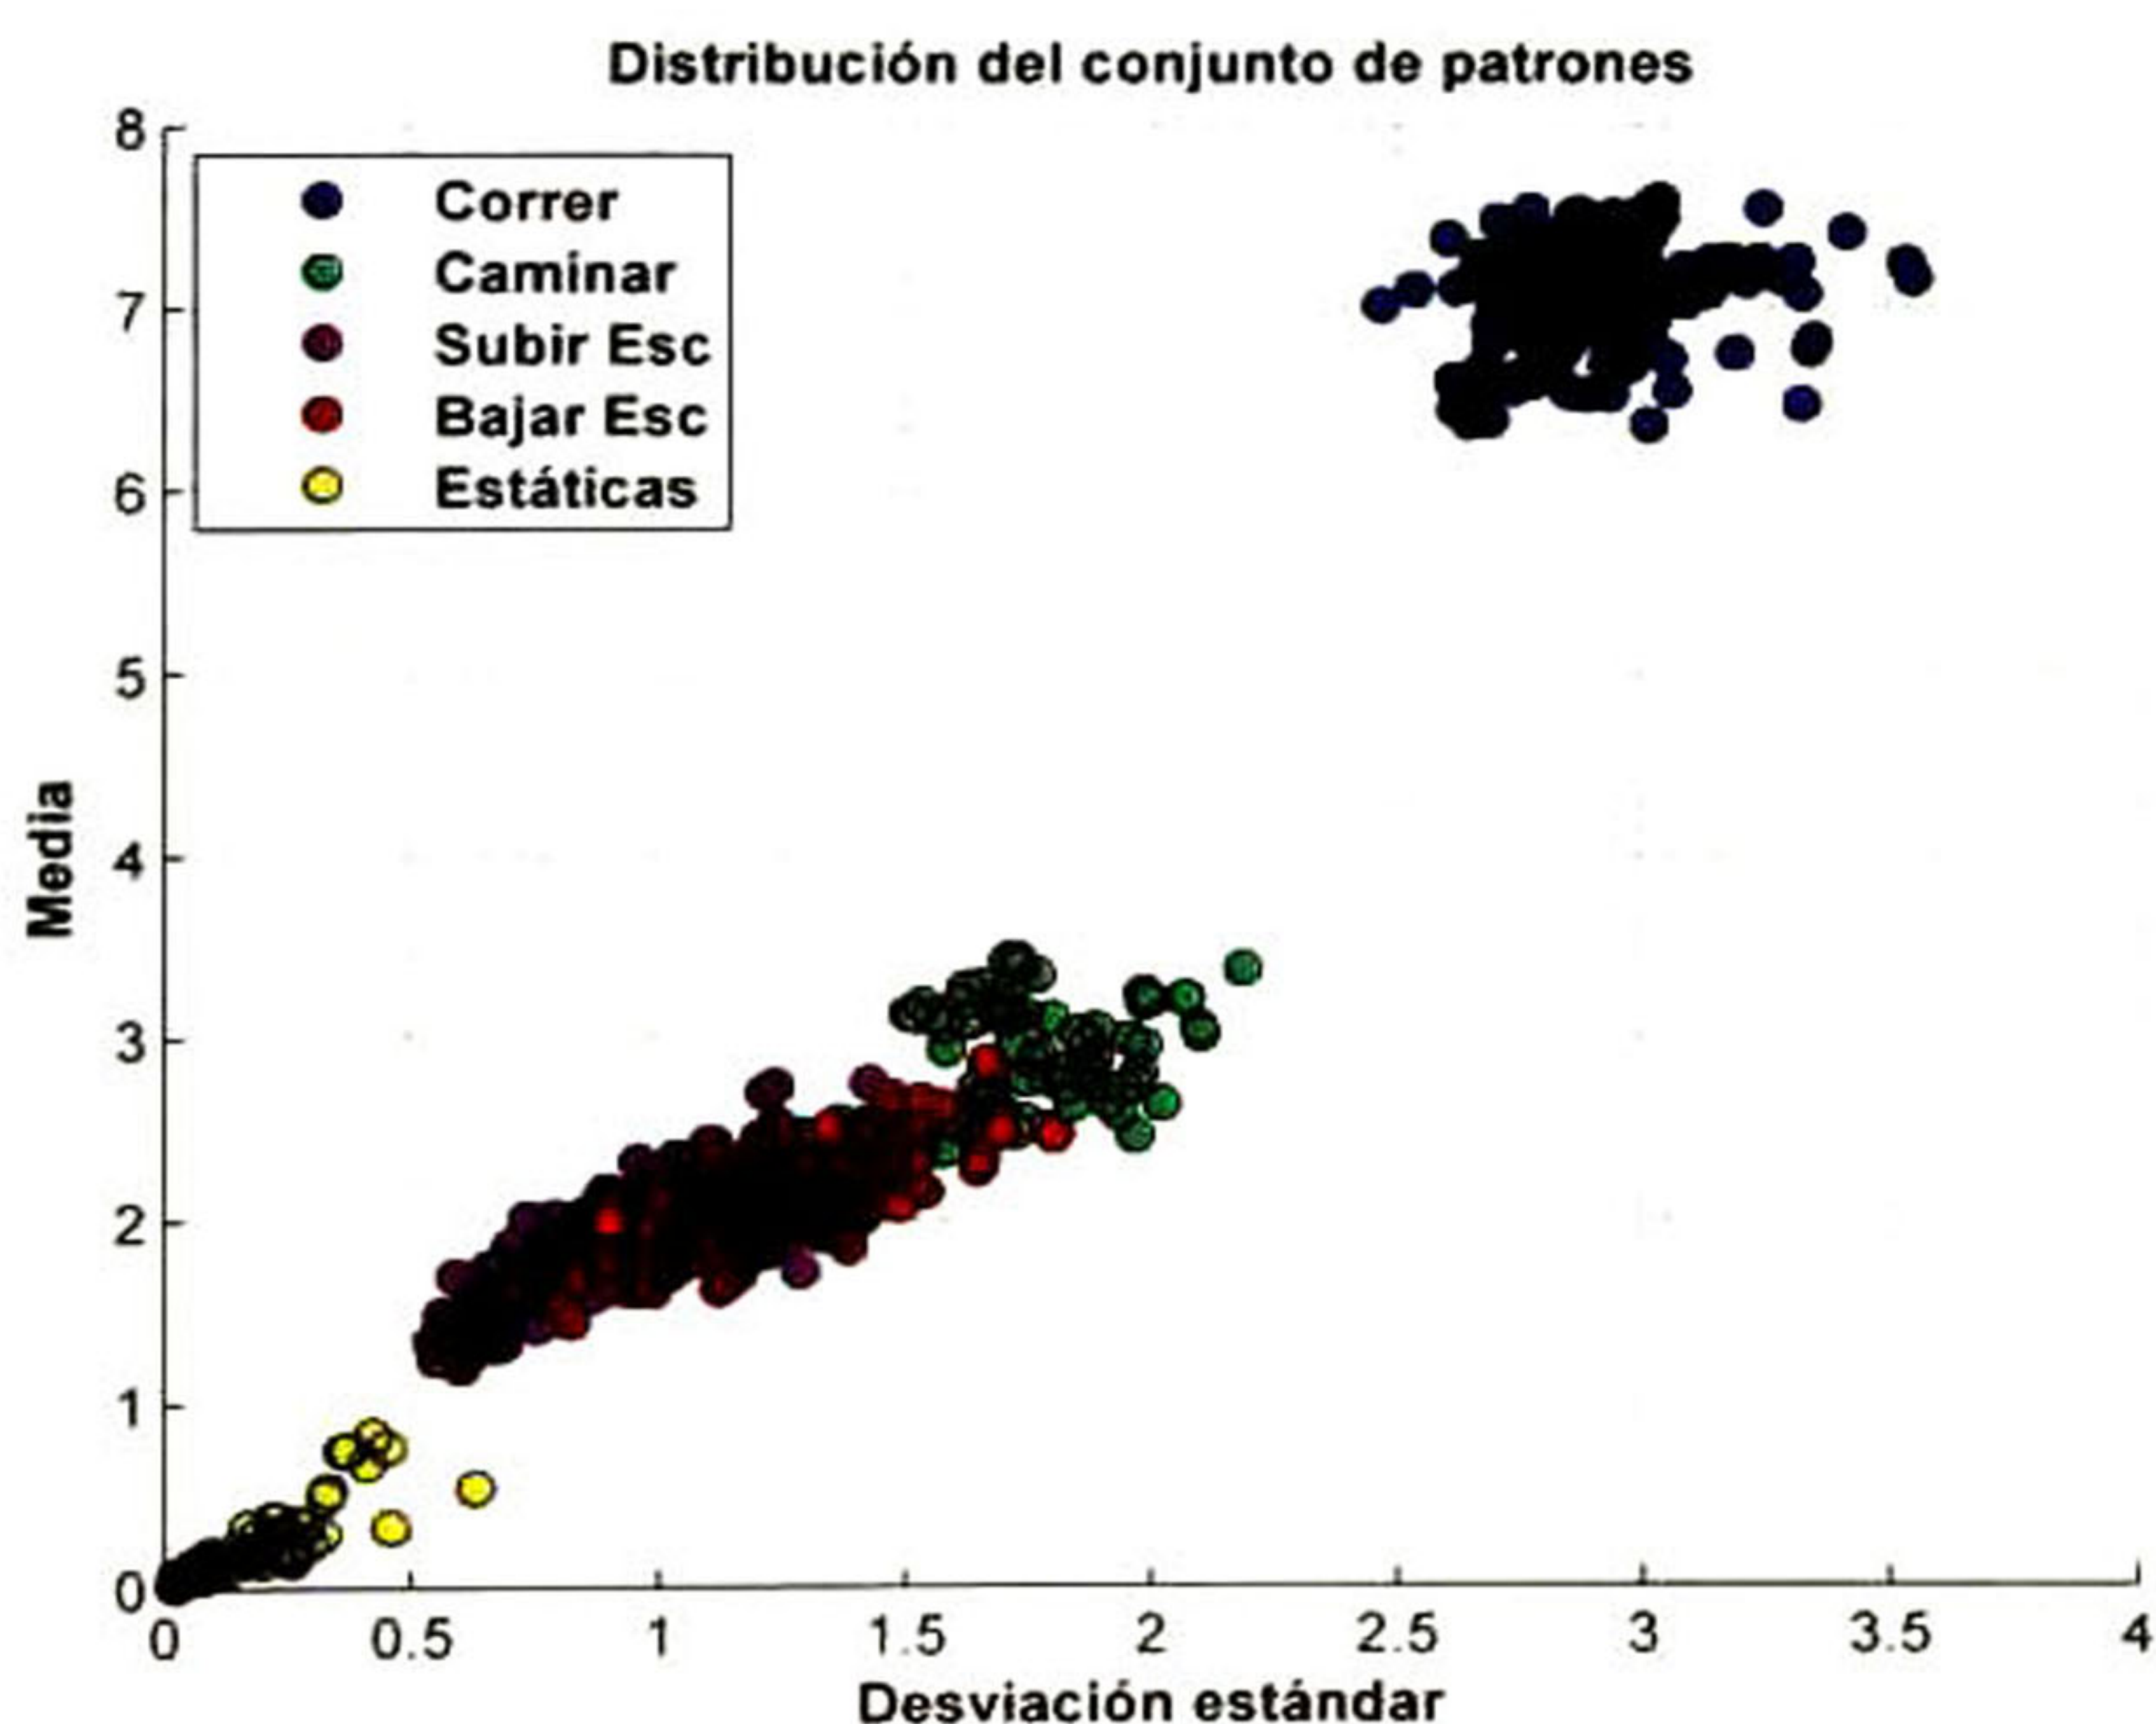
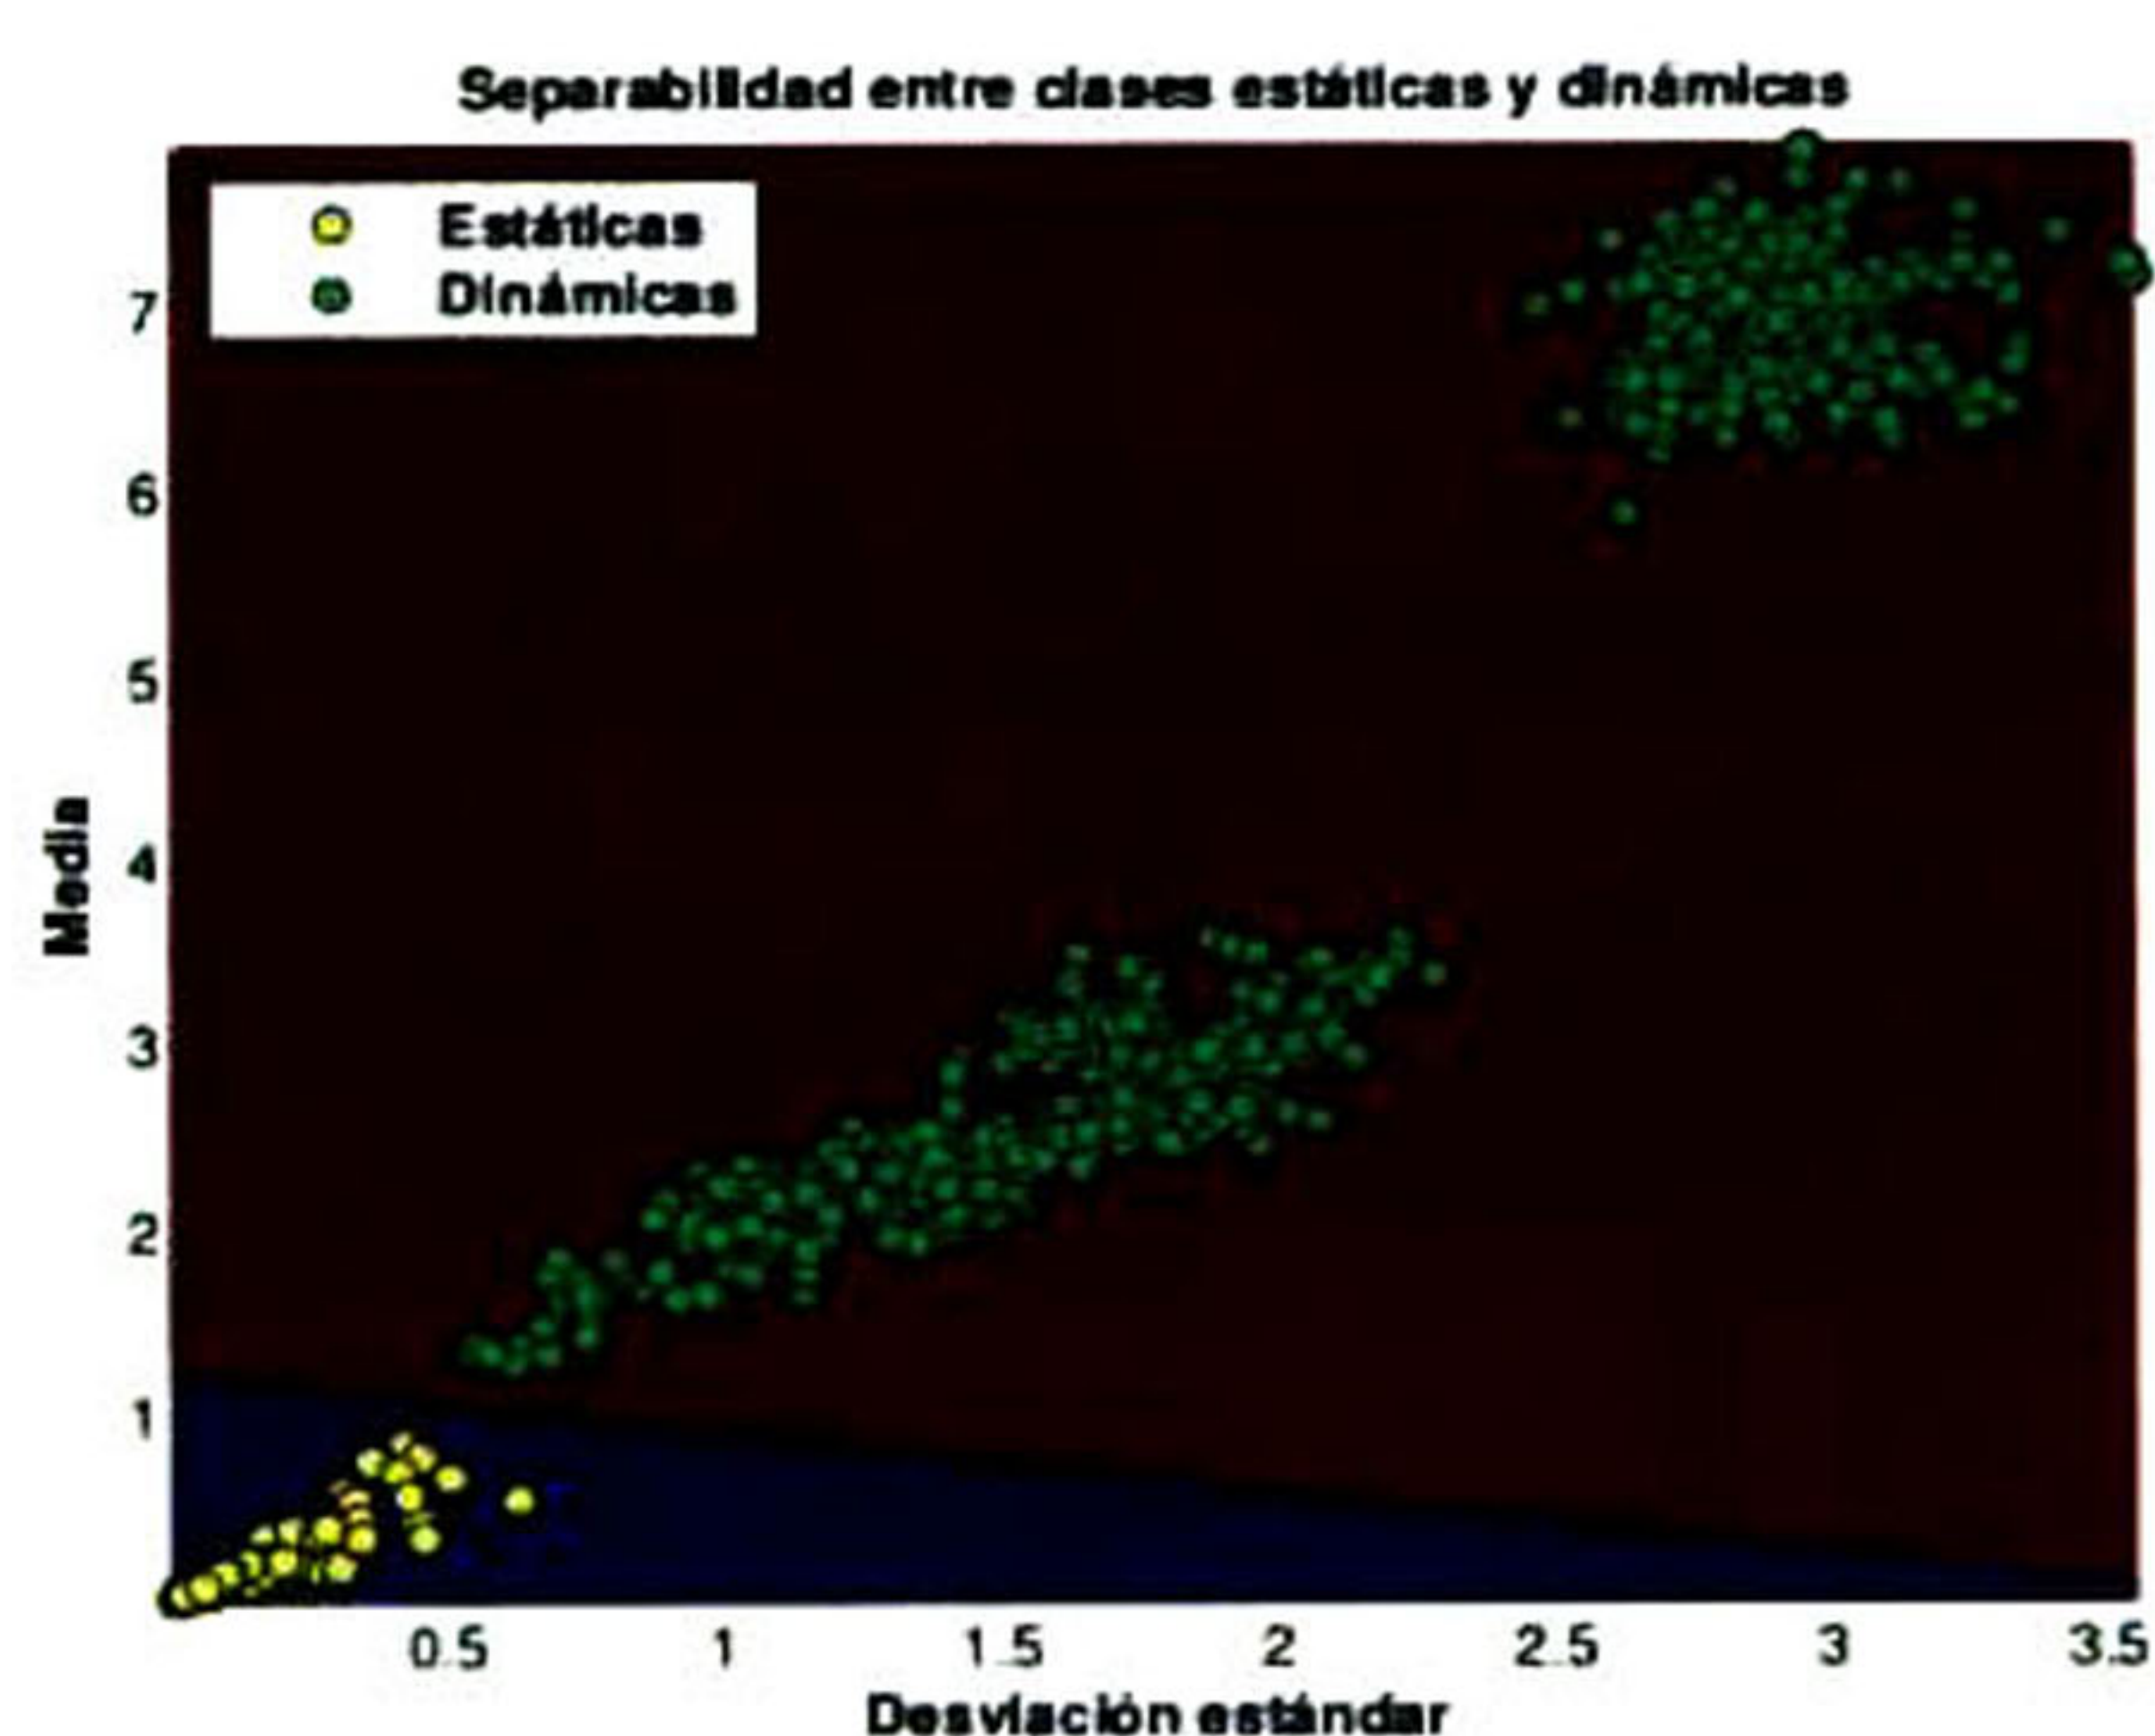


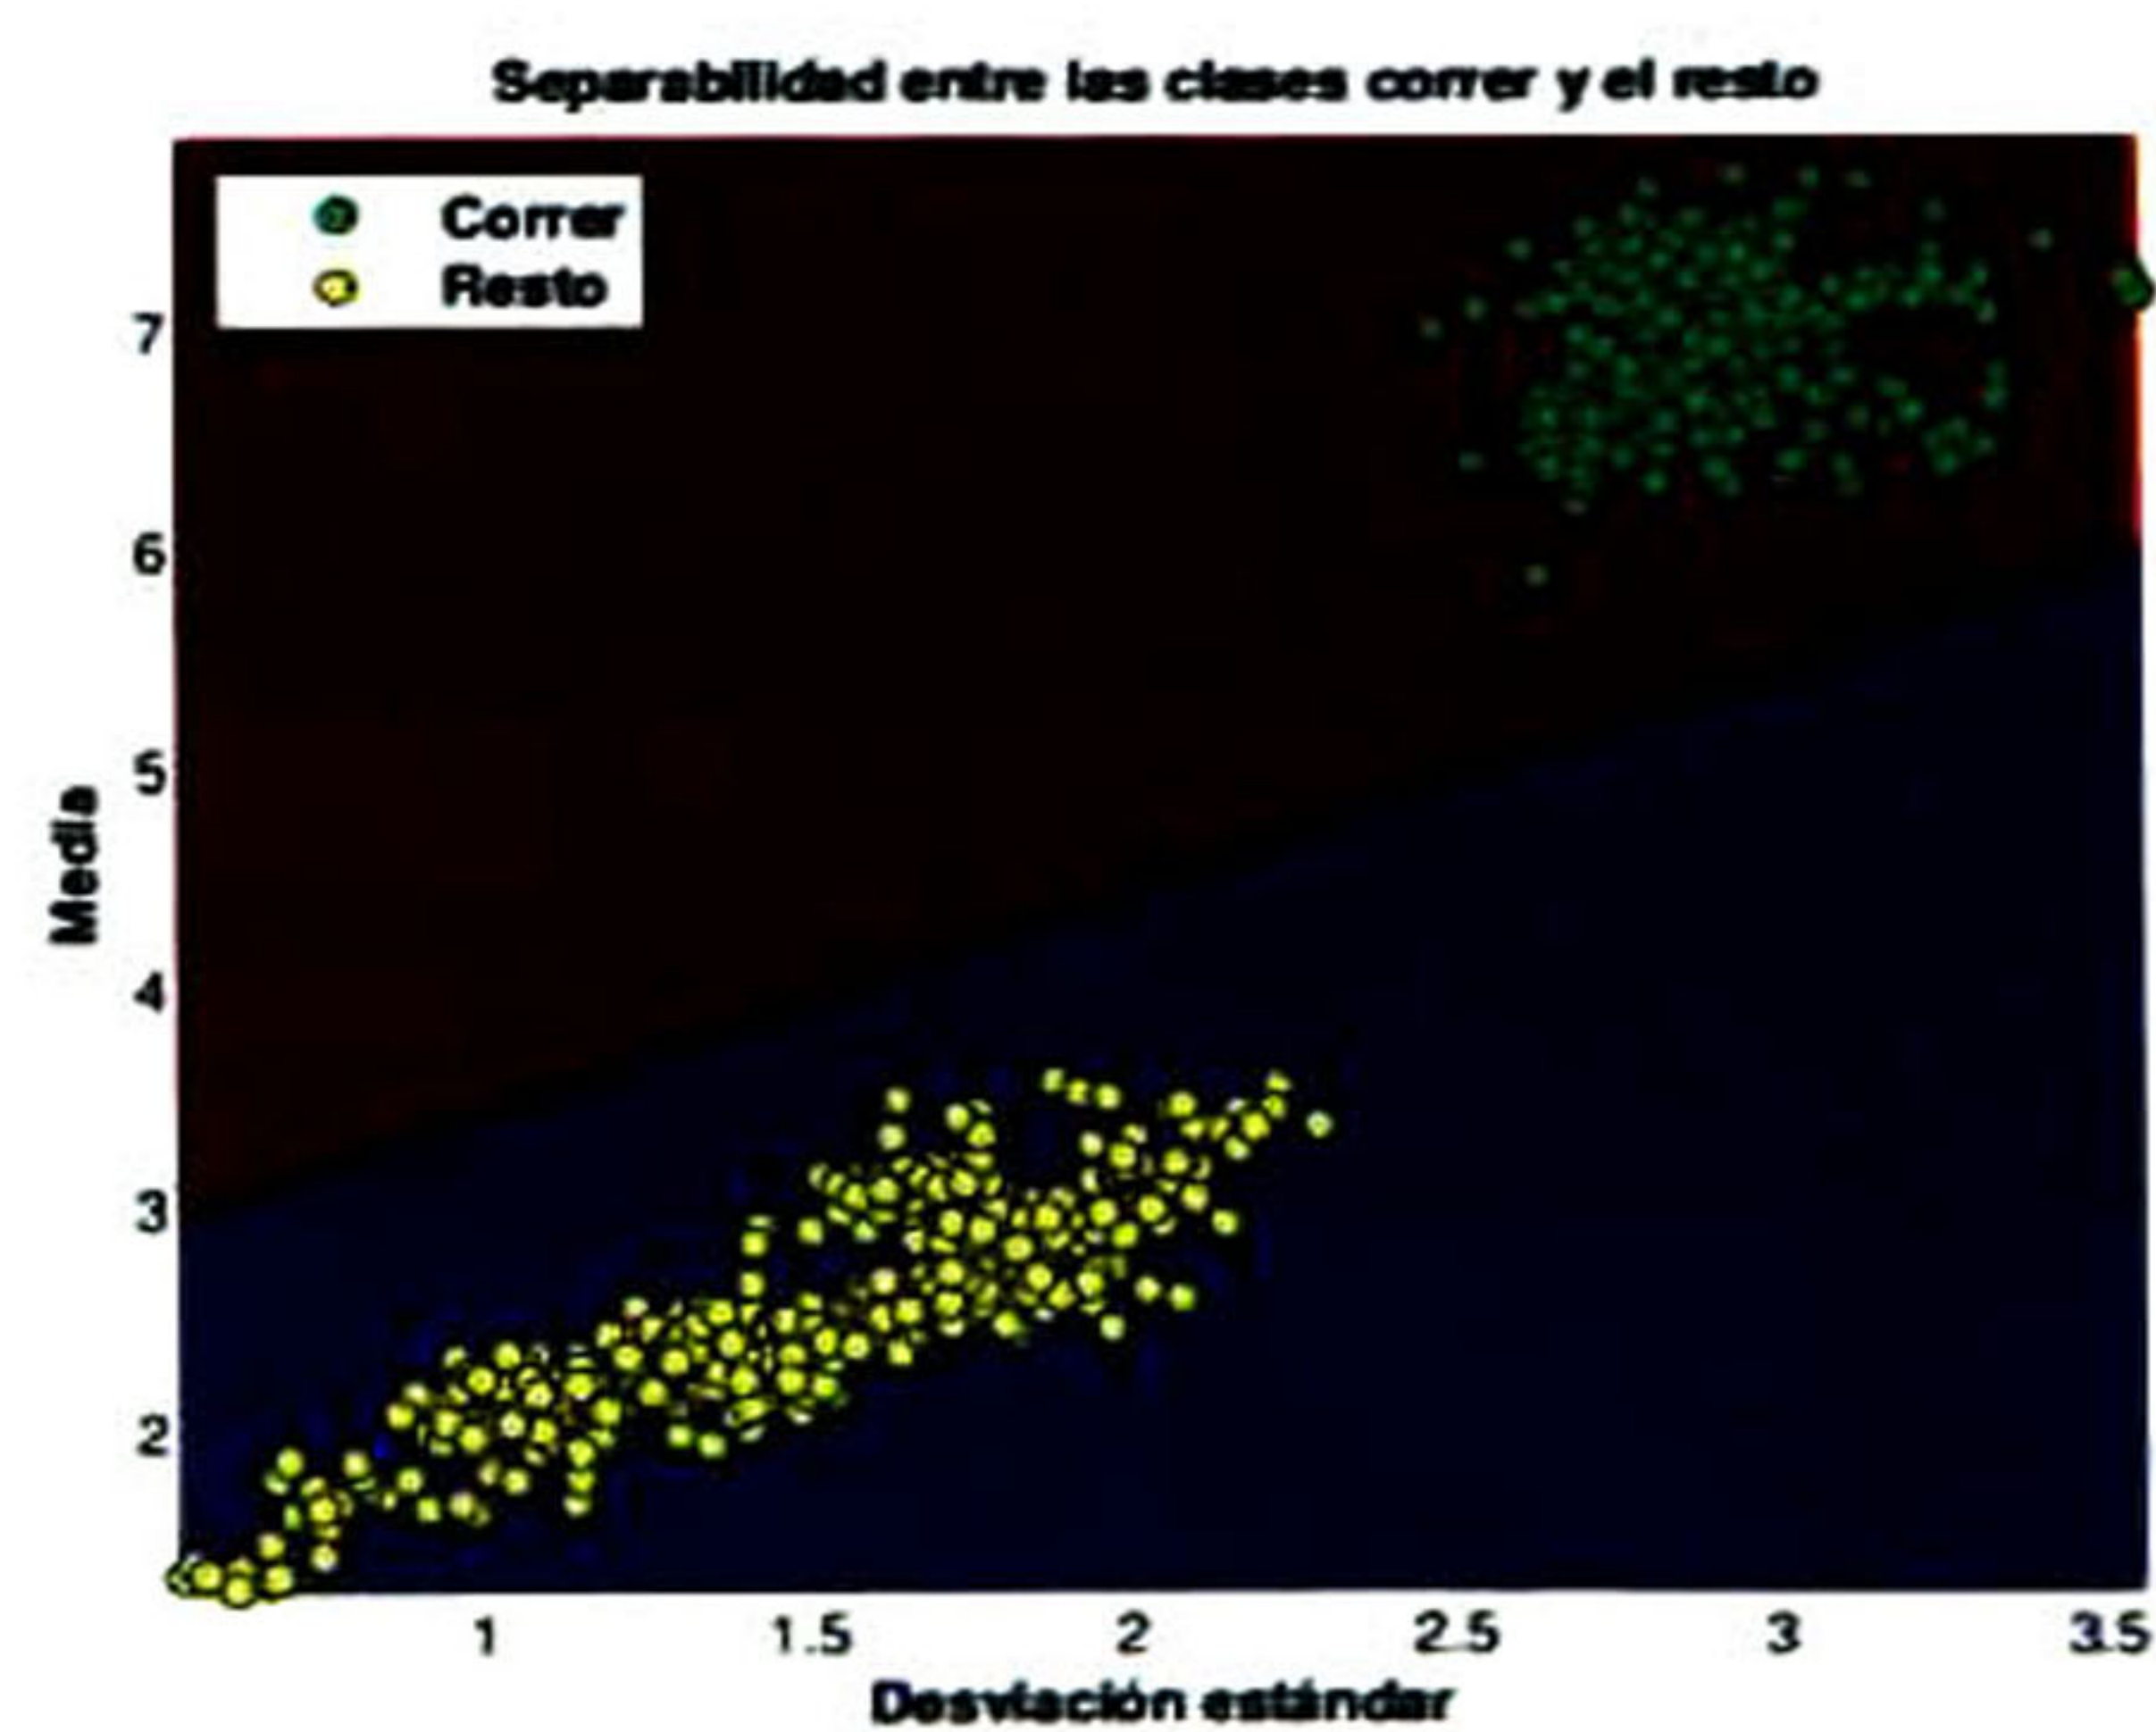
Figura 3.11: Distribución de las clases para el reconocimiento de actividades considerando la media y la desviación estándar.



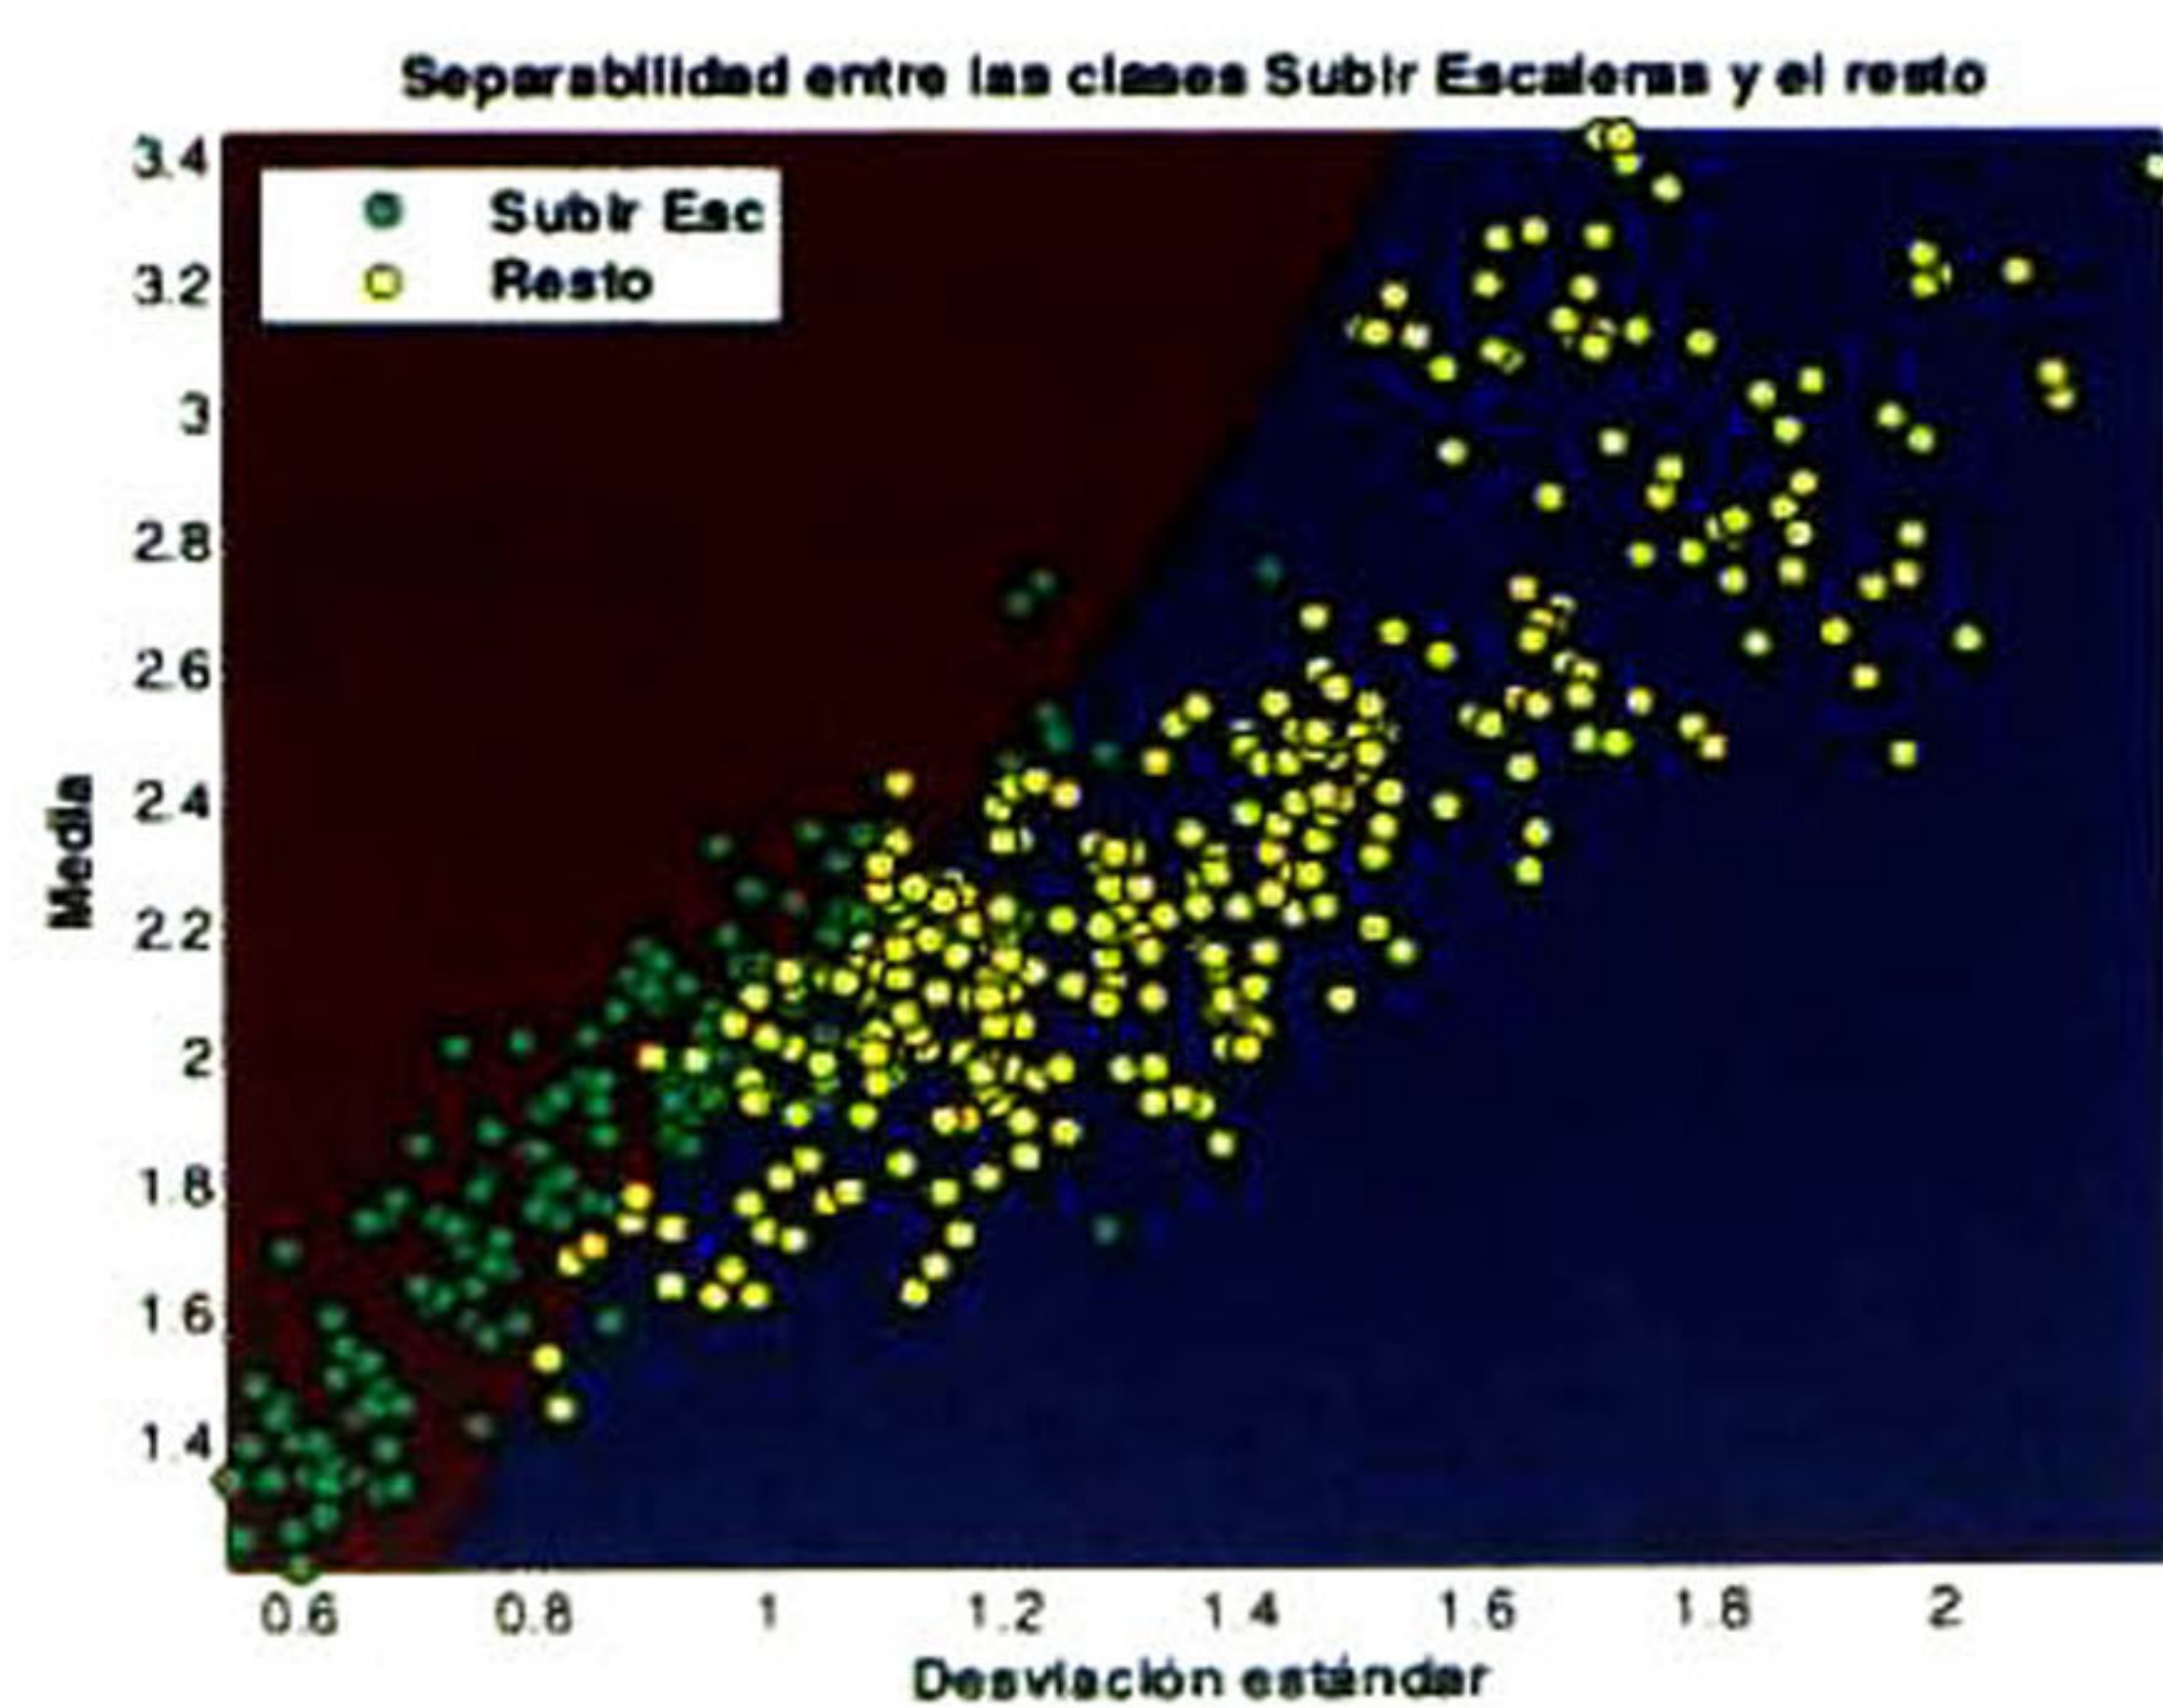
Experimentalmente se observó que a través de dichas características algunas actividades son linealmente separables como lo son las dinámicas y las estáticas. Ésto se observa en la Figura 3.12 a). De manera similar se observó el mismo efecto en el resto de las actividades dinámicas, específicamente al analizar correr y el resto de las actividades como se ilustra en Figura 3.12 b). Posteriormente se comparó la actividad física de subir escaleras con el resto y finalmente caminar con bajar escaleras. Para estas tres últimas actividades, se encontró que no existe una separabilidad lineal al igual que las otras clases, puesto que hay una fuerte correlación entre los patrones de las clases. Esto se ilustra en la Figura 3.12 c) y Figura 3.12 d).



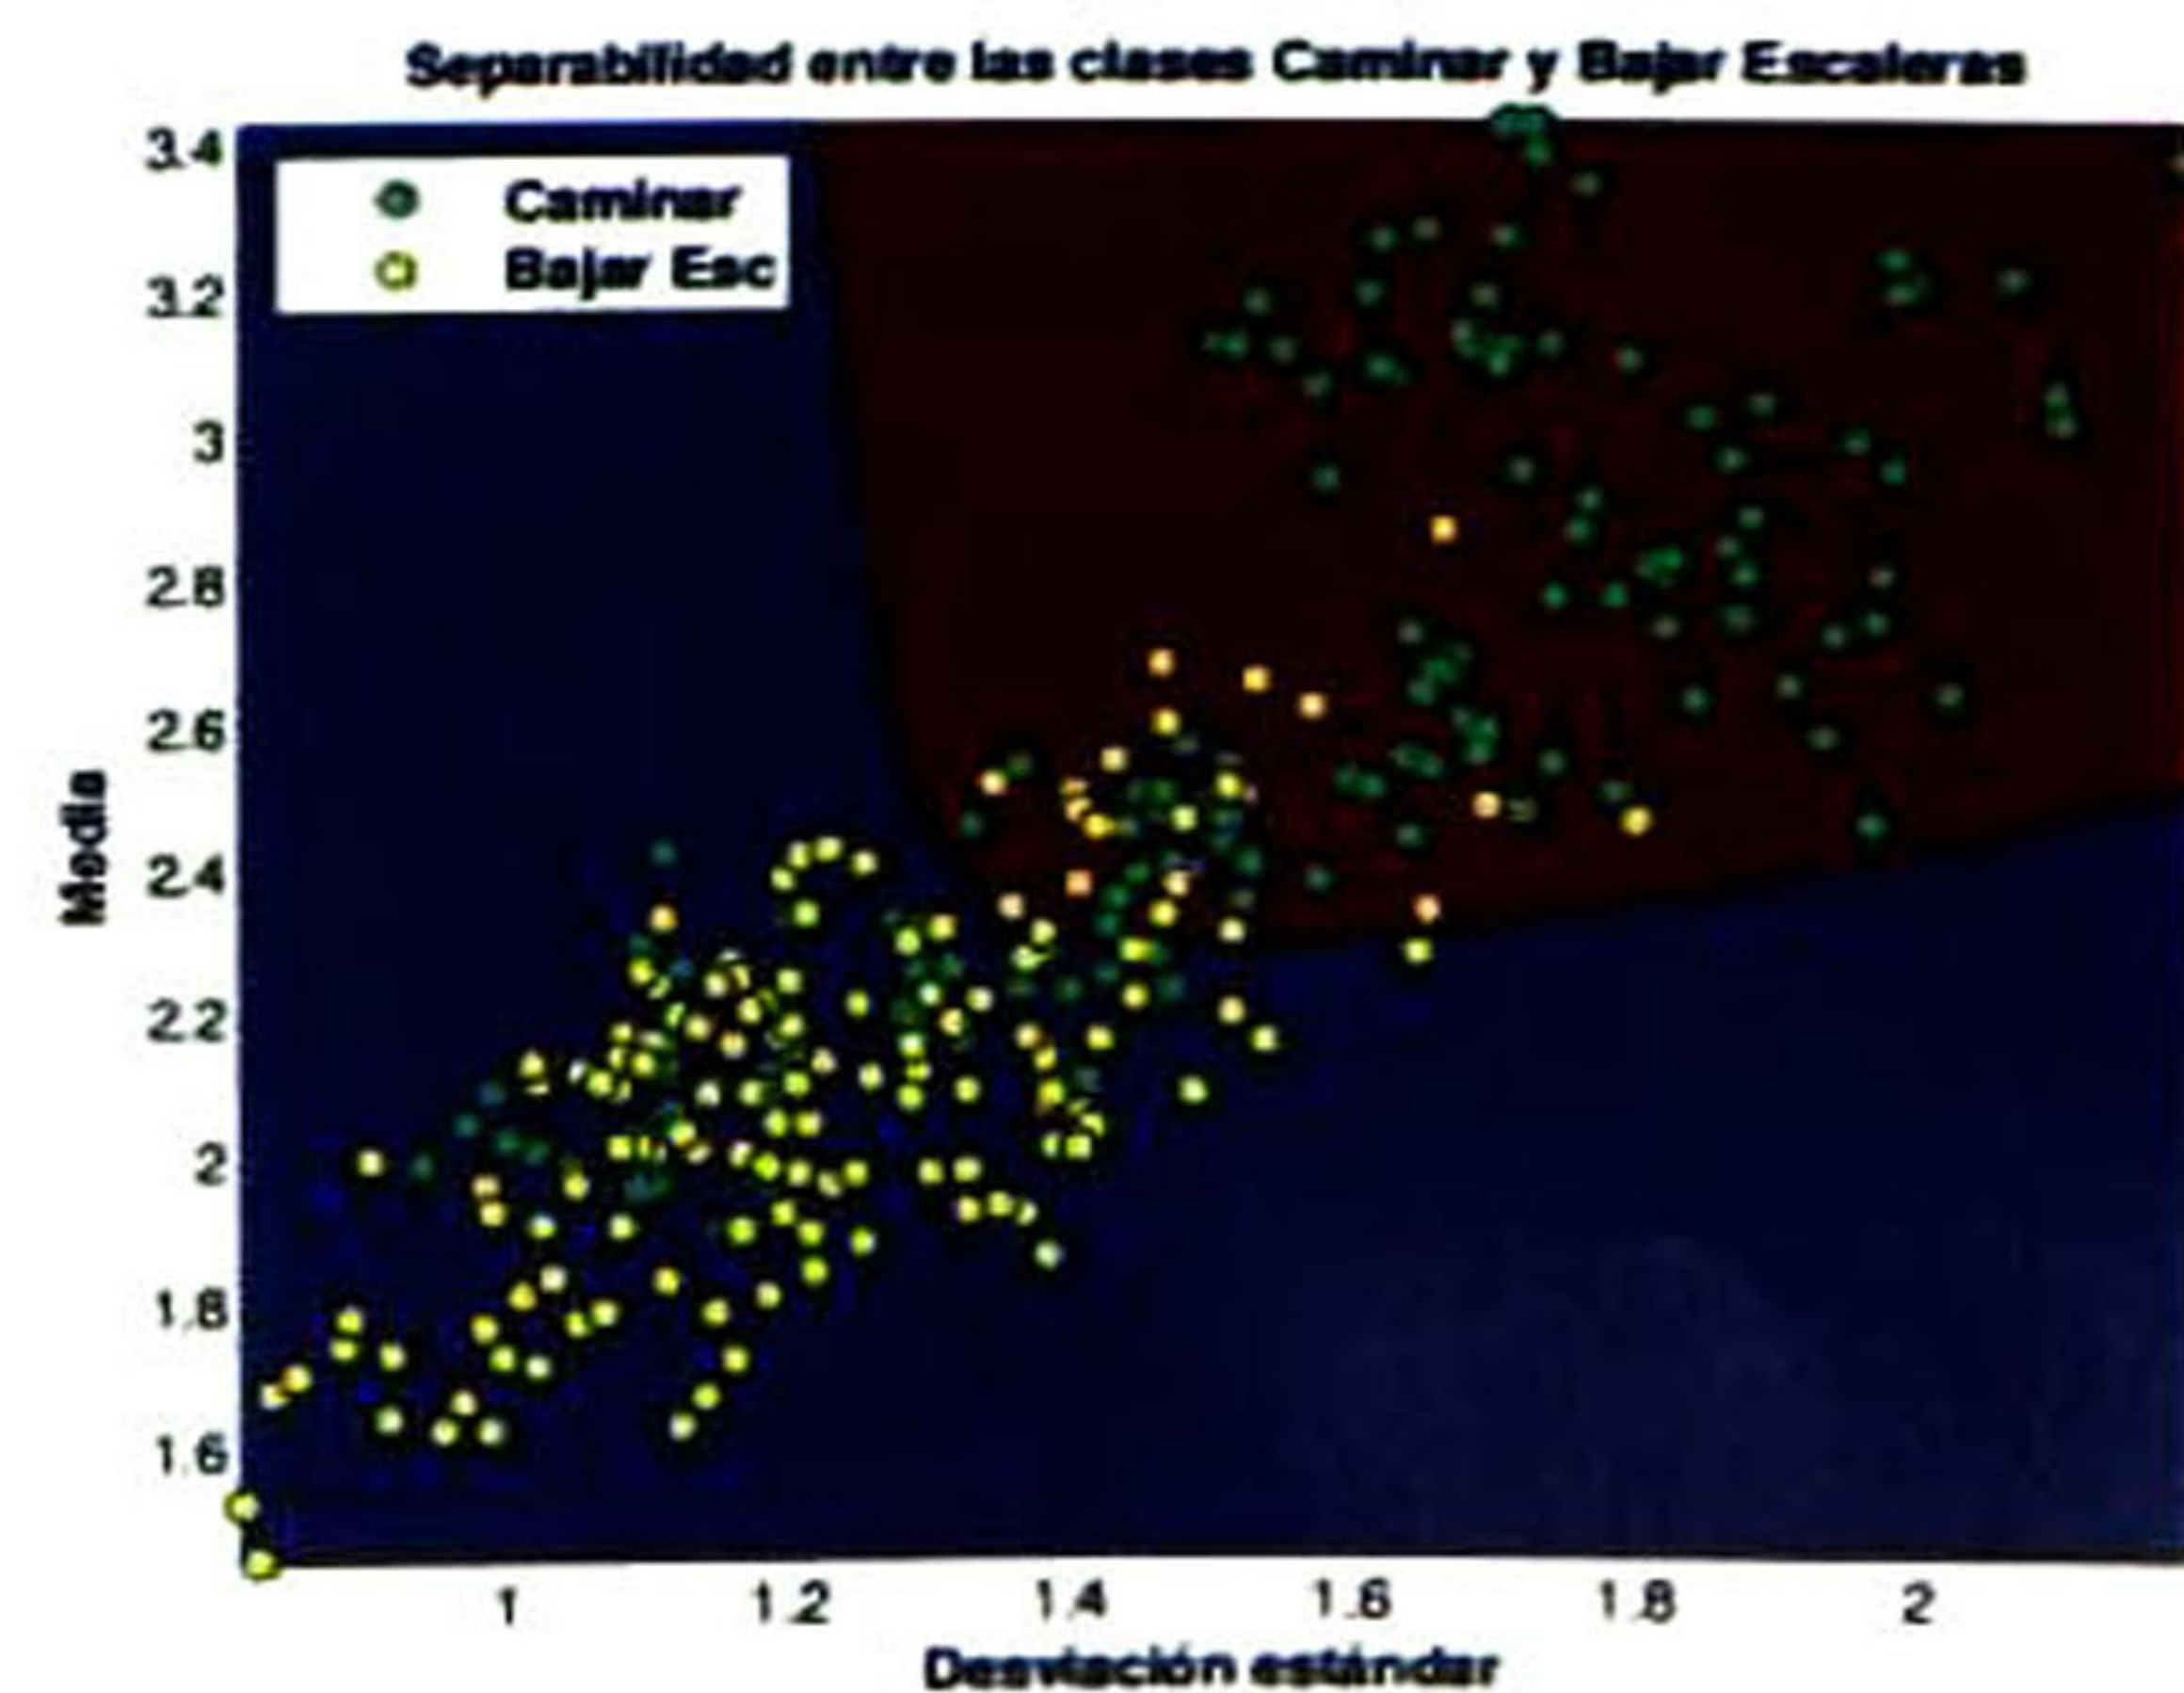
a) Clases dinámicas y estáticas



b) Clases correr y el resto



c) Clases subir y Resto



d) Clases caminar y bajar escaleras

Figura 3.12: Ilustración de clases linealmente separables (a, b)) y las no separables (c, d)).



A partir de las observaciones y del análisis realizado acerca de la distribución de los patrones de clases, fue posible deducir un esquema jerárquico que permitiera discriminar entre clases fácilmente separables. En la siguiente subsección se describe la estructura del esquema de clasificación jerárquico que se propuso.

### 3.6.2 Esquema de clasificación jerárquico

Uno de los objetivos que se han planteado en este trabajo de tesis, consiste en emplear un esquema de clasificación que no requiera de un alto costo computacional, debido a que entre mayor sea éste mayor será el consumo de energía en el dispositivo móvil.

La solución que se ha propuesto para el proceso de clasificación de actividades, consistió en emplear un esquema jerárquico donde las clases fácilmente separables son discriminadas en el primer nivel de la jerarquía. Posteriormente, las clases que no estuvieran fuertemente correlacionadas con el resto y así hasta concluir con todas las clases. Una vez definida la jerarquía se seleccionó un clasificador basado en redes neuronales, debido a que éstos tienen la característica de ser no lineales, lo cual permite discriminar entre clases linealmente no separables y además han sido empleadas en la literatura ya que permiten obtener un nivel alto precisión.

Para el caso de las actividades linealmente separables ubicadas en el nivel  $L_1$  y  $L_2$  de la jerarquía se utilizó una red perceptrón, empleando como entrada características estadísticas (media y desviación estándar) y función de transferencia *hardlim*. Para clasificar el resto de las actividades una red neuronal *feedforward* basada en el algoritmo de aprendizaje *backpropagation* fue empleada en los últimos niveles de la jerarquía ( $L_3$  y  $L_4$ ). En estos niveles la función de transferencia utilizada por red fue la *tansig* y las entradas corresponden a los CPs obtenidos del ACP y las características empleadas. El esquema de clasificación propuesto se ilustra en la Figura 3.13.

En cada una de las redes neuronales se ha considerado el uso de la función de transferencia *hardlim* y *tansig* debido a que en la experimentación se observó que la normalización de los datos con estas funciones se ajustaron mejor para discriminar entre una clase y otra.



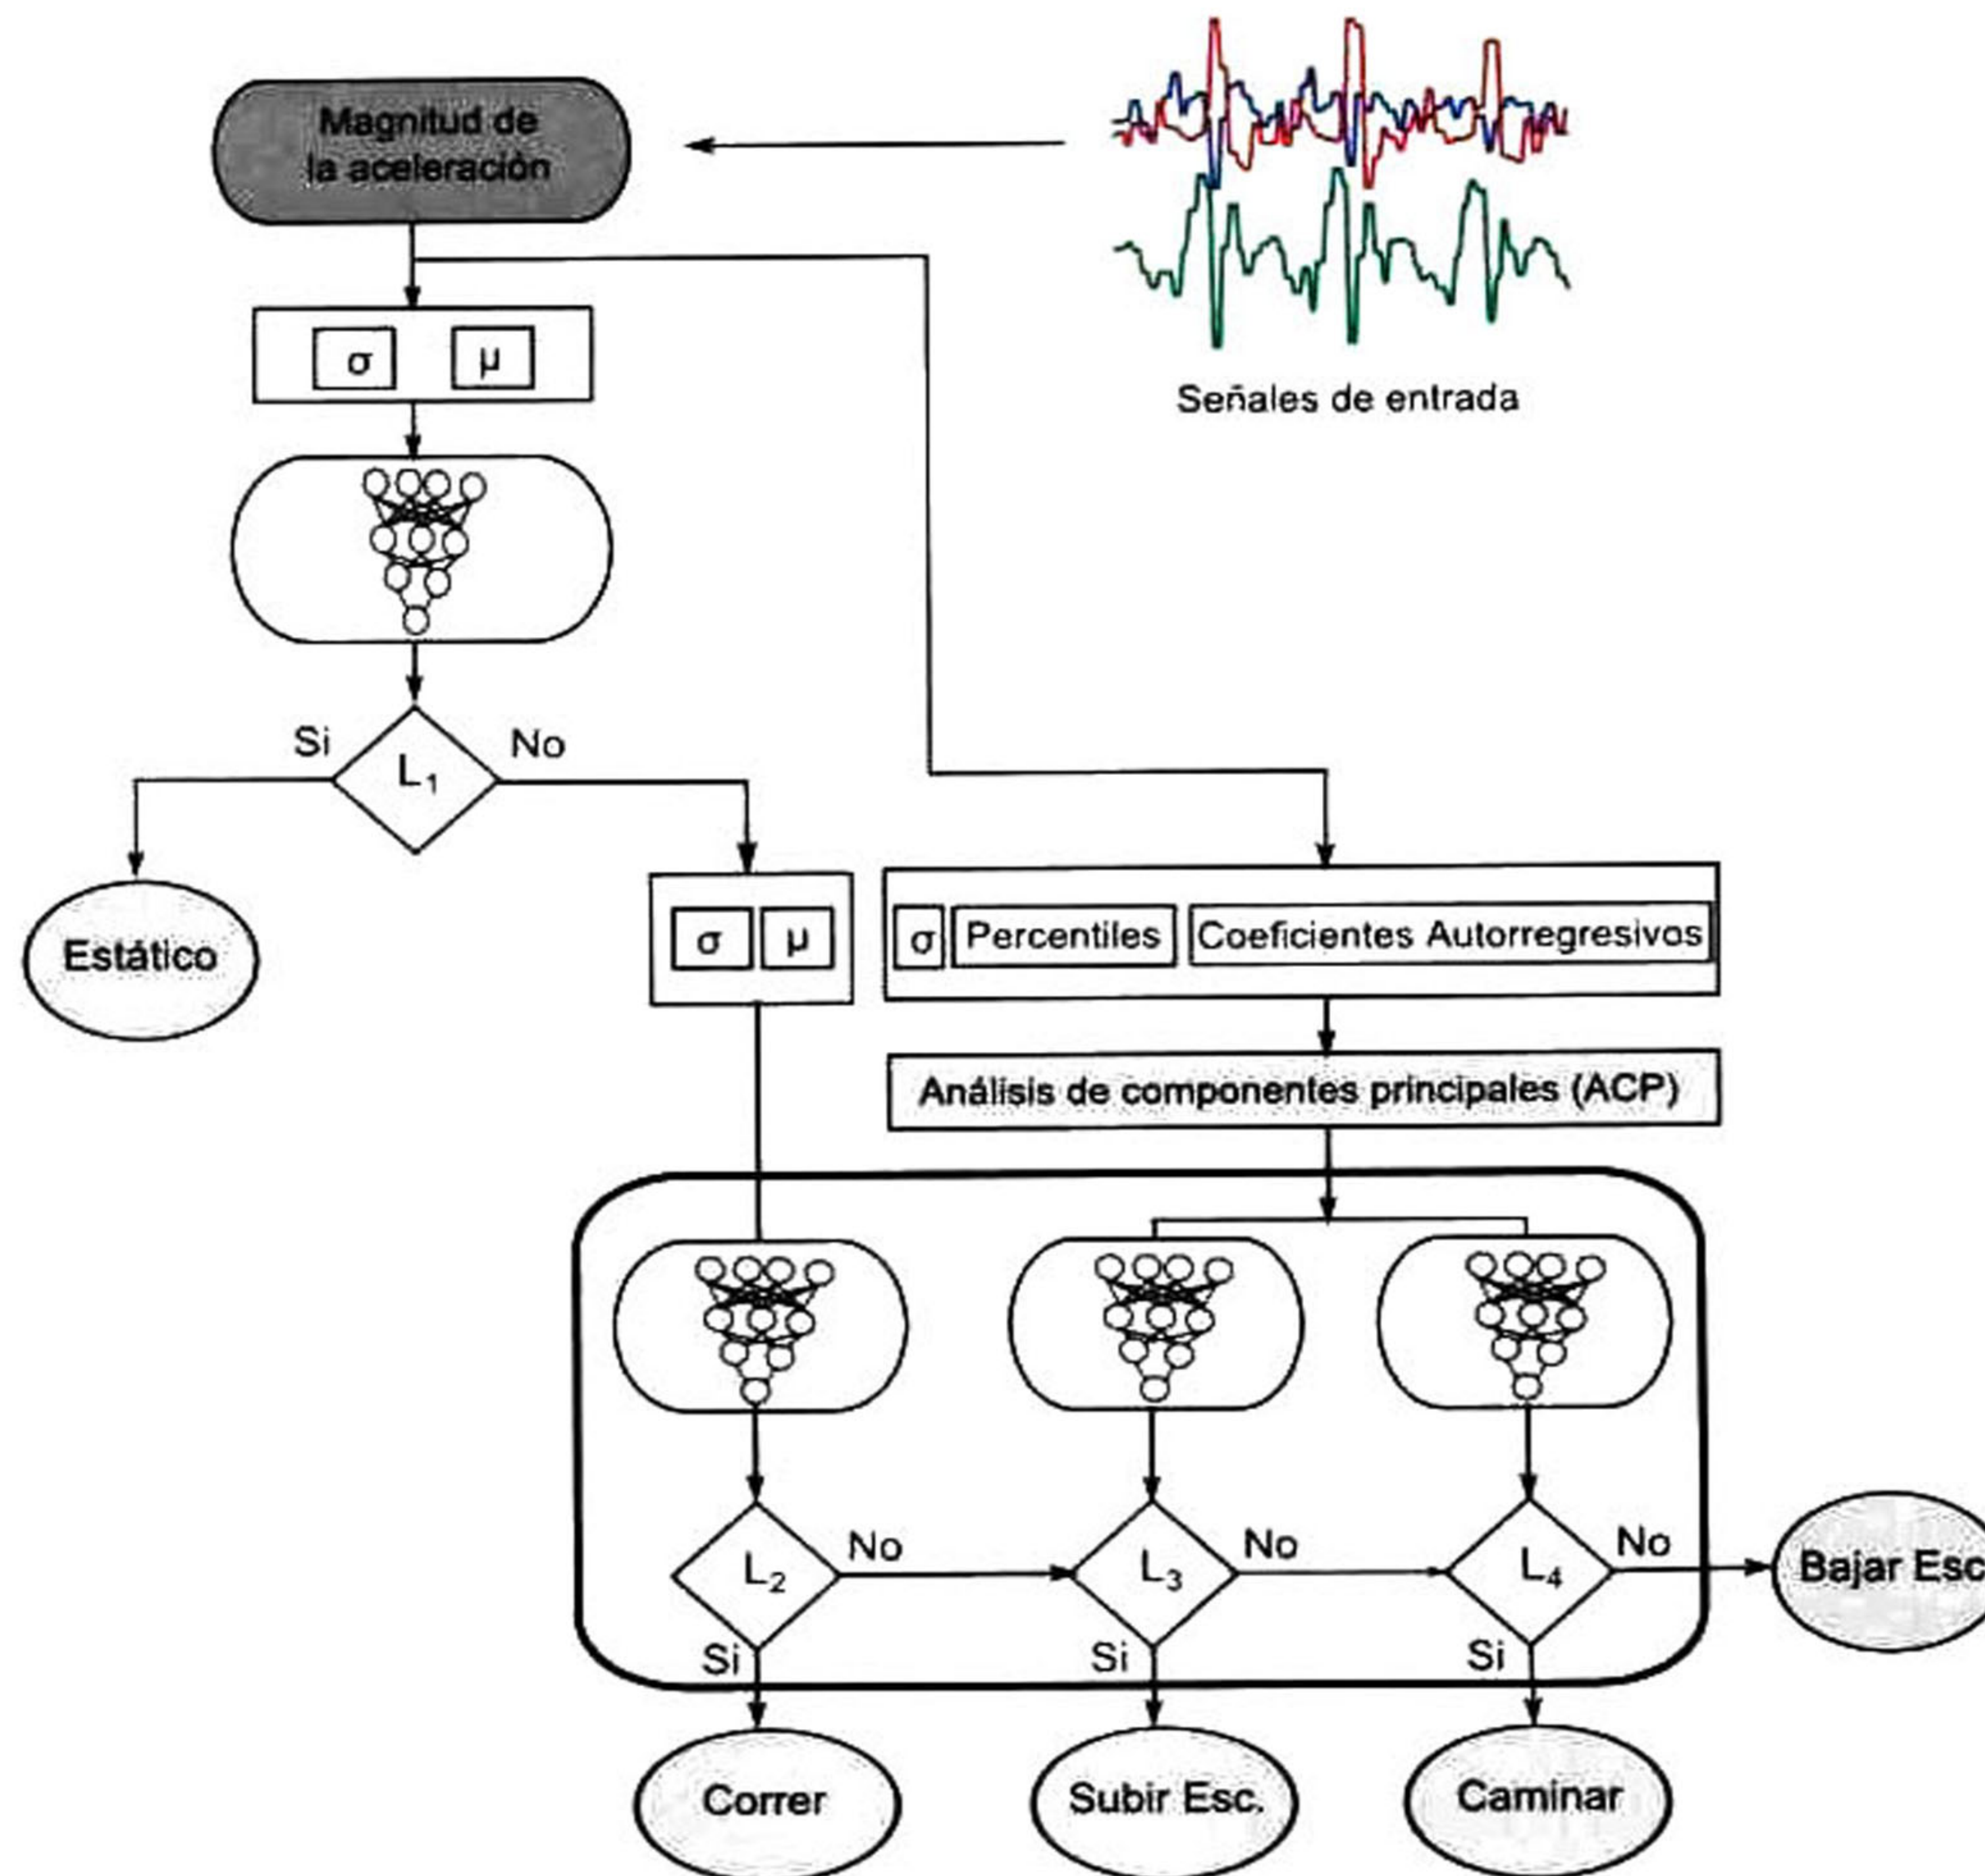


Figura 3.13: Esquema jerárquico propuesto para el reconocimiento de actividades físicas

La salida de cada una de las redes empleadas en los niveles de la jerarquía, se asociaron a cada una de las etiquetas de clases y posteriormente se decidía si el resultado era el esperado.

La topología general de las redes seleccionadas y los parámetros de configuración se detallan en la Sección 4.2.3.

## 3.7 Resumen

A lo largo de este capítulo se ha descrito la metodología planteada para dar solución al problema de reconocimiento de actividades físicas. Básicamente se propuso el uso de técnicas para mejorar la calidad de los datos tales como el filtro pasa altas, el filtro promedio móvil y la interpolación



lineal. En particular, en la presente tesis se ha optado por el uso de características del dominio del tiempo debido a que éstas no requieren de un alto costo computacional (media, desviación estándar, percentiles y coeficientes autorregresivos). Adicionalmente se utilizó el método del ACP para reducir la redundancia de información entre las variables de entrada, de tal forma que se obtuvieron y seleccionaron las CPs más representativos como las nuevas entradas del clasificador. Para discriminar entre las actividades físicas un esquema jerárquico basado en redes neuronales (perceptrón y feedforward) ha sido propuesto en esta investigación. En el siguiente capítulo se describirán las experimentaciones y los resultados obtenidos a partir del uso de las técnicas empleadas.



# 4

## Experimentación y resultados

*En el presente capítulo se describe la experimentación realizada para evaluar la funcionalidad y el desempeño del sistema de reconocimiento de actividades físicas, también se muestran los resultados obtenidos en cada una de las experimentaciones.*

### 4.1 Recopilación de datos por el acelerómetro

Para entrenar y validar el modelo de clasificación jerárquico, es necesario contar con un conjunto de datos etiquetados, los cuales sean capturados por uno o más usuarios durante un periodo de tiempo. Para llevar a cabo esta tarea, es necesario considerar las actividades que el usuario realice, es decir, correr, caminar, subir escaleras, bajar escaleras y estáticas. También es importante registrar las posiciones y orientaciones donde el usuario ubique el smartphone, esto es, bolsillos frontales y bolsillos posteriores (izquierdo y derecho para ambos casos). Particularmente, la forma de los bolsillos del pantalón que se han considerado se ilustran en la Figura 4.1 a) y las etiquetas asignadas a éstos son: bolsillo frontal derecho (BFD), bolsillo frontal izquierdo (BFI), bolsillo posterior derecho (BPD),



bolsillo posterior izquierdo (BPI). Para el caso de las orientaciones del smartphone éstas fueron etiquetadas con base a la siguiente notación: vertical norte (VN), vertical sur (VS), horizontal este (HE), horizontal oeste (HO), tal como se observa Figura 4.1 b).




Figura 4.1: Bolsillos y orientaciones considerados donde el usuario coloca el smartphone. VN: vertical norte, VS: vertical sur, HE: horizontal este, HO: horizontal oeste.

Para realizar la recolección de datos se diseñó una aplicación en un smartphone con SO Android, la cual permite almacenar de forma automática los datos capturados por el acelerómetro, a partir de los movimientos generados por el usuario al realizar alguna actividad física (los detalles de diseño de la aplicación se describen en el apéndice A.1). La aplicación móvil se desarrolló considerando diferentes parámetros con los que son etiquetados los datos, éstos se describen a continuación:

- ▶ **Actividad física:** Permite definir el tipo de actividad física que el usuario realizará.
- ▶ **Portabilidad del smartphone:** El usuario indica la posición donde colocará el dispositivo (Figura 4.1 a)) y la orientación del smartphone (Figura 4.1 b)).



- ▶ **Tiempo de captura:** Permite al usuario, establecer el tiempo en el que realizará alguna actividad física.

Puesto que la aplicación fue desarrollada en Android, es importante resaltar que solo existen cuatro modalidades para seleccionar la frecuencia de muestreo: *SENSOR\_DELAY\_NORMAL*, *SENSOR\_DELAY\_UI*, *SENSOR\_DELAY\_GAME* y *SENSOR\_DELAY\_FASTEST* [71]. Las frecuencias de cada una de estas modalidades dependen de las características del dispositivo móvil, por ejemplo, para el Samsung Galaxy Ace las frecuencias correspondientes a cada modalidad son en promedio 6 Hz, 16 Hz, 40 Hz y 60 Hz respectivamente. En este trabajo se ha utilizado la modalidad *SENSOR\_DELAY\_GAME*, debido a que en la experimentación se observó que los datos capturados por el acelerómetro a esta frecuencia son suficientes para determinar la actividad que realiza un usuario, además en [72] se argumenta que una frecuencia de 32 Hz es considerada suficiente para el reconocimiento de los movimientos del cuerpo.

Algunas de las características del smartphone Samsung Galaxy Ace que se ha empleado para la tarea de recolección de datos, son las siguientes:

- ▶ Sistema operativo Android, versión 2.3.6 *Gingerbread*
- ▶ Procesador ARM Qualcomm MSM7227 832 MHz
- ▶ Memoria interna 278 MB RAM y MicroSD 2 GB
- ▶ Acelerómetro *Bosch Sensortec* modelo BMA222

El conjunto de datos recolectados se organizó conceptualmente como se ilustra en la Figura 4.2, a cada usuario ( $U$ ) se le solicitó realizar cinco diferentes actividades ( $A$ ) considerando cuatro posiciones ( $P$ ) y cuatro orientaciones ( $O$ ) ( $n = 5, m = k = 4$ ). Las actividades se realizaron por el usuario en un periodo de tiempo de un minuto (aproximadamente 2400 muestras) y las muestras se almacenaban en un archivo de texto.

Una vez obtenido los datos de un usuario éstos fueron segmentados en ventanas de 200 muestras y se obtuvo un total de 2406 ejemplos. Cabe resaltar que para balancear el número de ejemplos con el que se evaluó el clasificador se capturaron datos repetidos considerando la misma actividad y las mismas posiciones



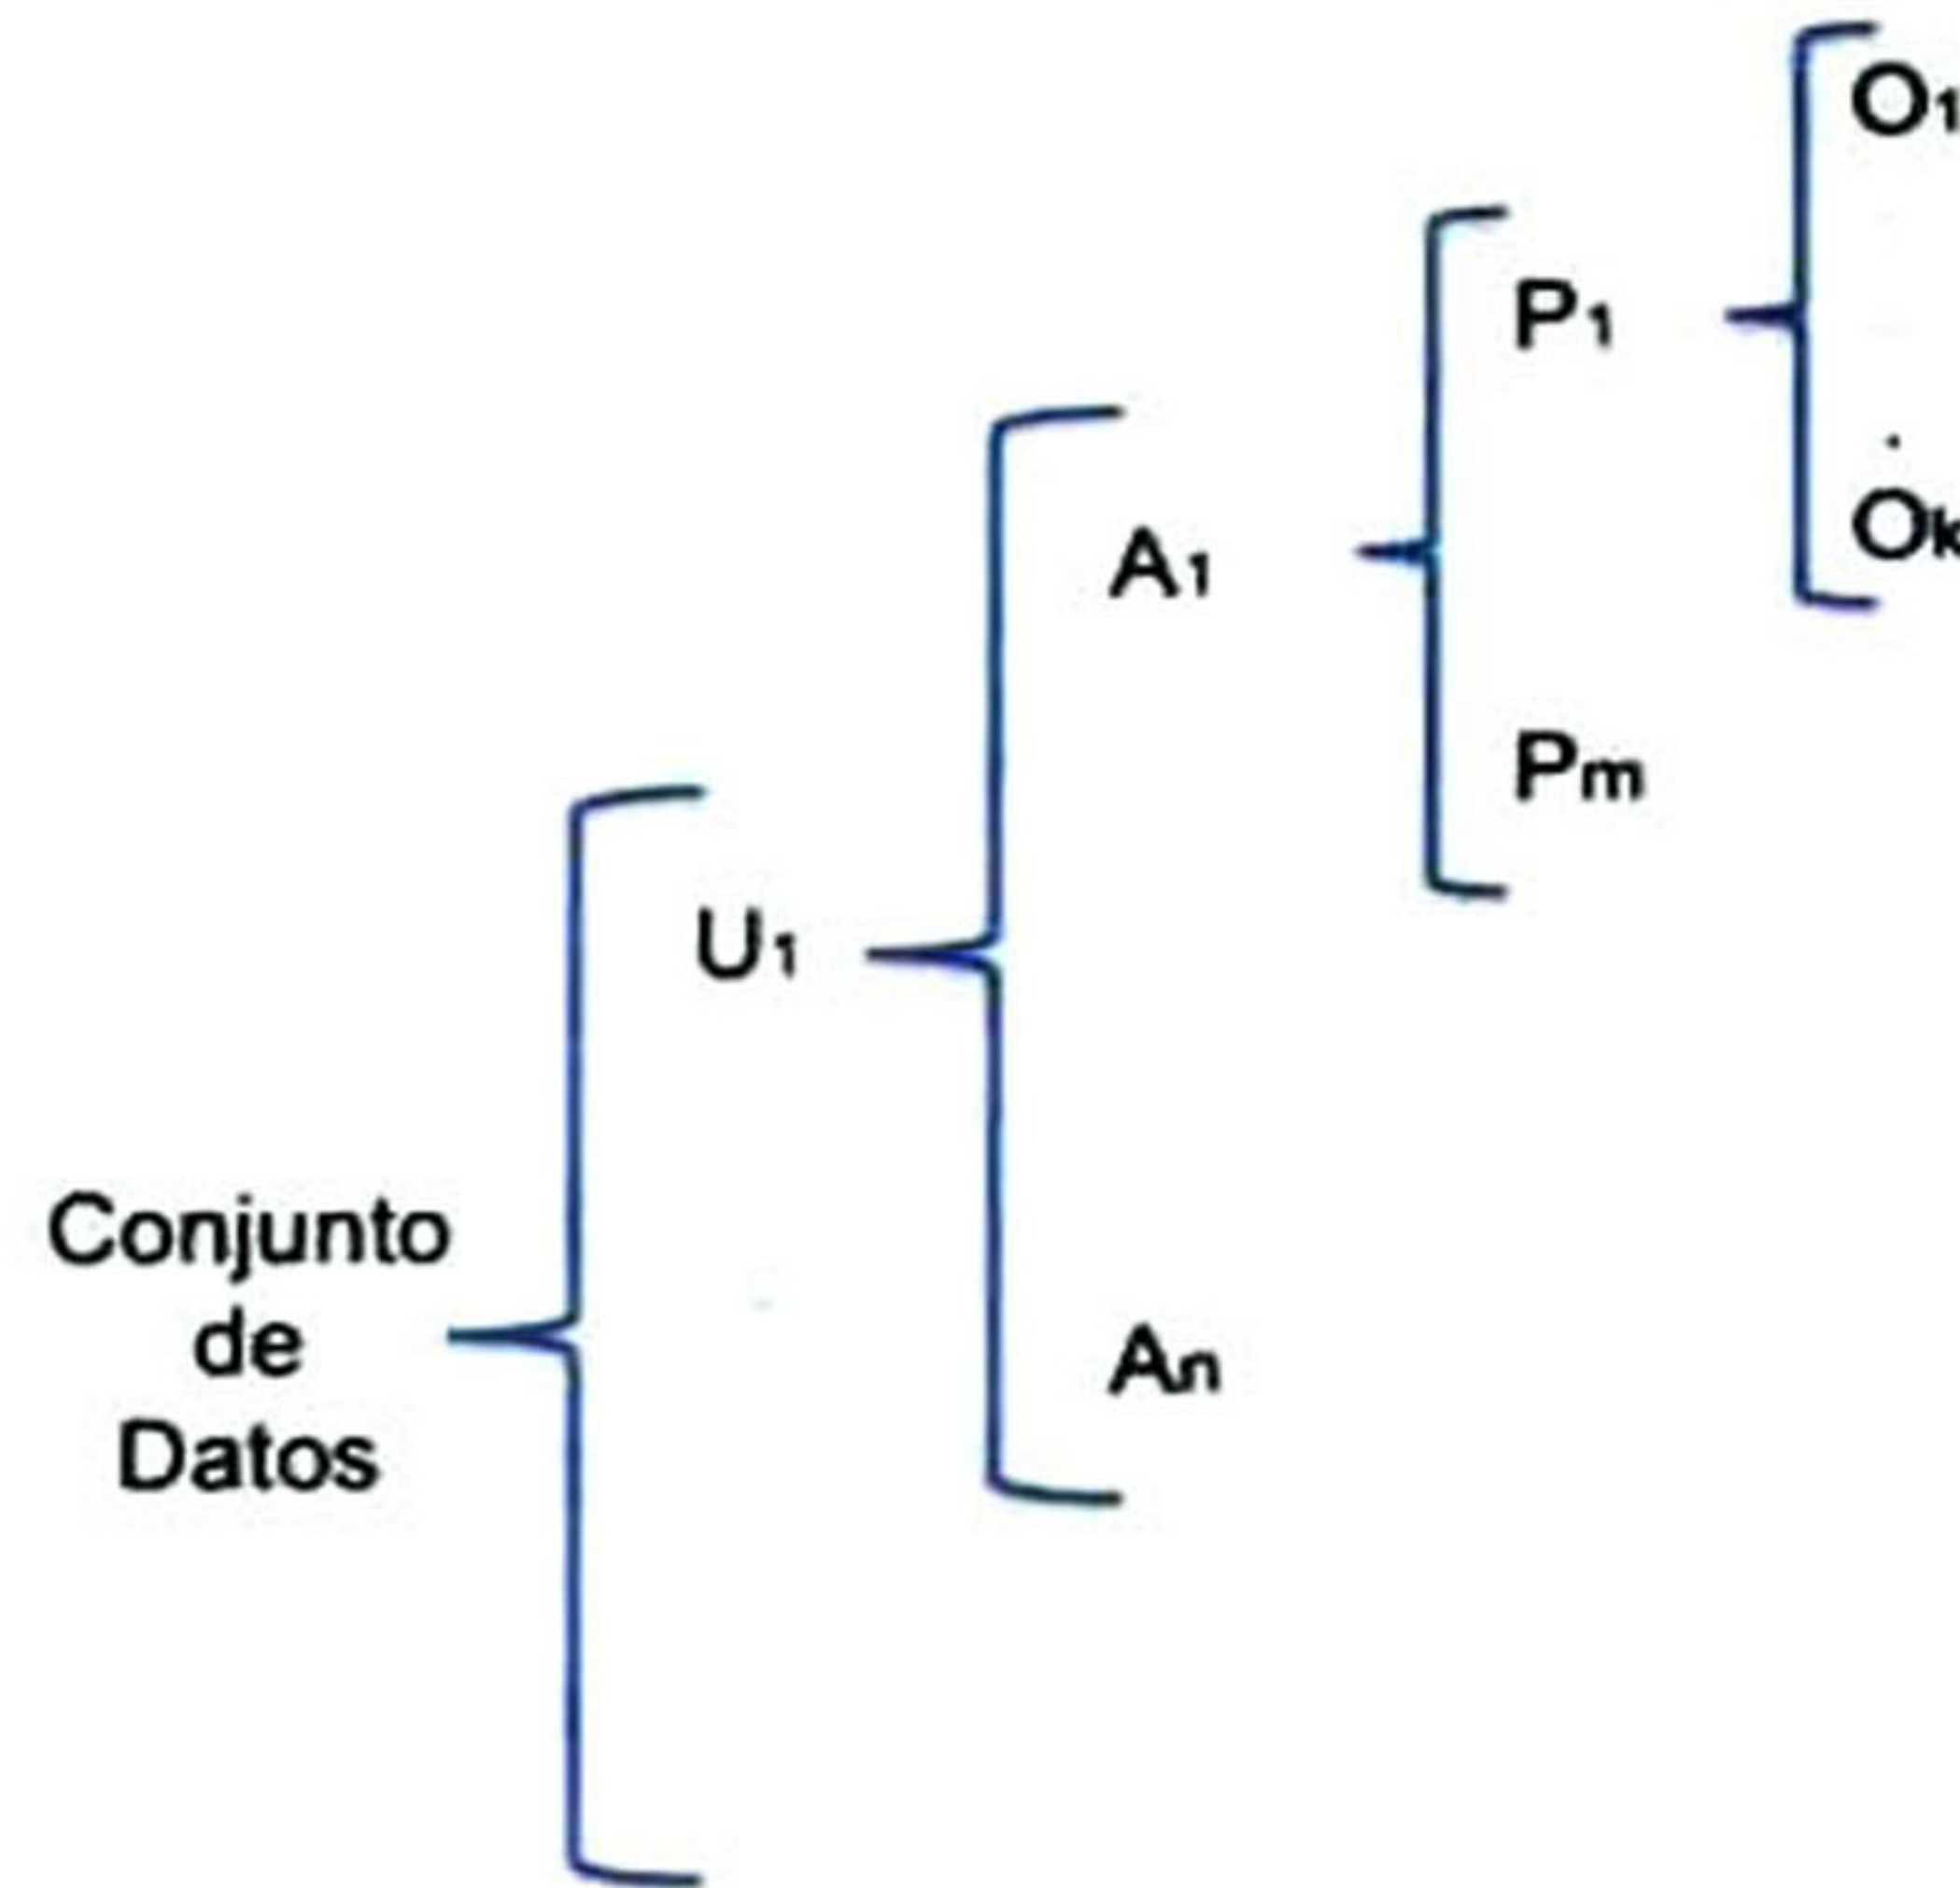


Figura 4.2: Organización de los datos recolectados.

y orientaciones, por ejemplo, en el caso de las actividades estáticas como sentado y acostado solo se tomaron en cuenta los bolsillos posteriores. En la Tabla 4.1 se muestran estos ejemplos organizados con base a las actividades y las posiciones donde el usuario colocó el smartphone. De manera similar se registraron más datos de otros usuarios, los cuales han sido utilizados para otras experimentaciones que se describirán más adelante.

Actividades \ Posiciones	BFD	BFI	BPD	BPI	Total
Estáticas	138	135	141	133	547
Correr	108	114	116	108	446
Caminar	131	105	136	124	496
Subir Esc	116	112	114	120	462
Bajar Esc	110	115	119	111	455
<b>Total</b>	<b>603</b>	<b>581</b>	<b>626</b>	<b>596</b>	<b>2406</b>

Tabla 4.1: Datos recolectados por un usuario.

A partir del conjunto de datos mostrado en la Tabla 4.1, se entrenó y validó el modelo de clasificación propuesto, tal como se describe en la sección 4.2.5.



## 4.2 Parametrización del esquema jerárquico

Existen diferentes parámetros de configuración en las etapas del modelo de clasificación jerárquico que se ha diseñado. Por ejemplo, el número de los coeficientes autorregresivos, el número de componentes principales para el caso del ACP y la topología de las redes utilizadas en cada nivel de la jerarquía. En las siguientes subsecciones se discutirán las experimentaciones realizadas para definir cada uno de estos parámetros.

### 4.2.1 Estimación del número de coeficientes autorregresivos

Uno de los aspectos abiertos del modelado autorregresivo es obtener el número de coeficientes apropiado debido a que a partir de éstos y de un subconjunto de muestras de la señal original es posible reconstruir las señales futuras. Para seleccionar el número de coeficientes en este trabajo se realizó un conjunto de experimentaciones, las cuales consistieron en obtener un número determinado de coeficientes de las señales correspondientes a las actividades (caminar, subir y bajar escaleras). Posteriormente se hizo un análisis empleando el error cuadrático medio para deducir las similitudes que hay entre las señales a partir del porcentaje de error obtenido. El número de coeficientes considerados durante las experimentaciones fue de 5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55 y 60.

A través de la obtención del error cuadrático medio aplicado a diferentes señales generadas por las actividades de caminar, subir y bajar escaleras, se observó que a partir de 50 coeficientes el error no disminuye significativamente, tal como se ilustra en las gráficas de la Figura 4.3.

Para observar si a partir de un determinado número de coeficientes autorregresivos la señal era reconstruida, en las gráficas de la Figura 4.4 se ilustra la aproximación de una señal (caminar) empleando un número de 30, 50 y 60 coeficientes.

Con base al análisis realizado sobre el comportamiento del error y la reconstrucción de la señal observada, en este trabajo se seleccionó un número total de 50 coeficientes autorregresivos, donde cada uno de ellos es empleado como una característica.



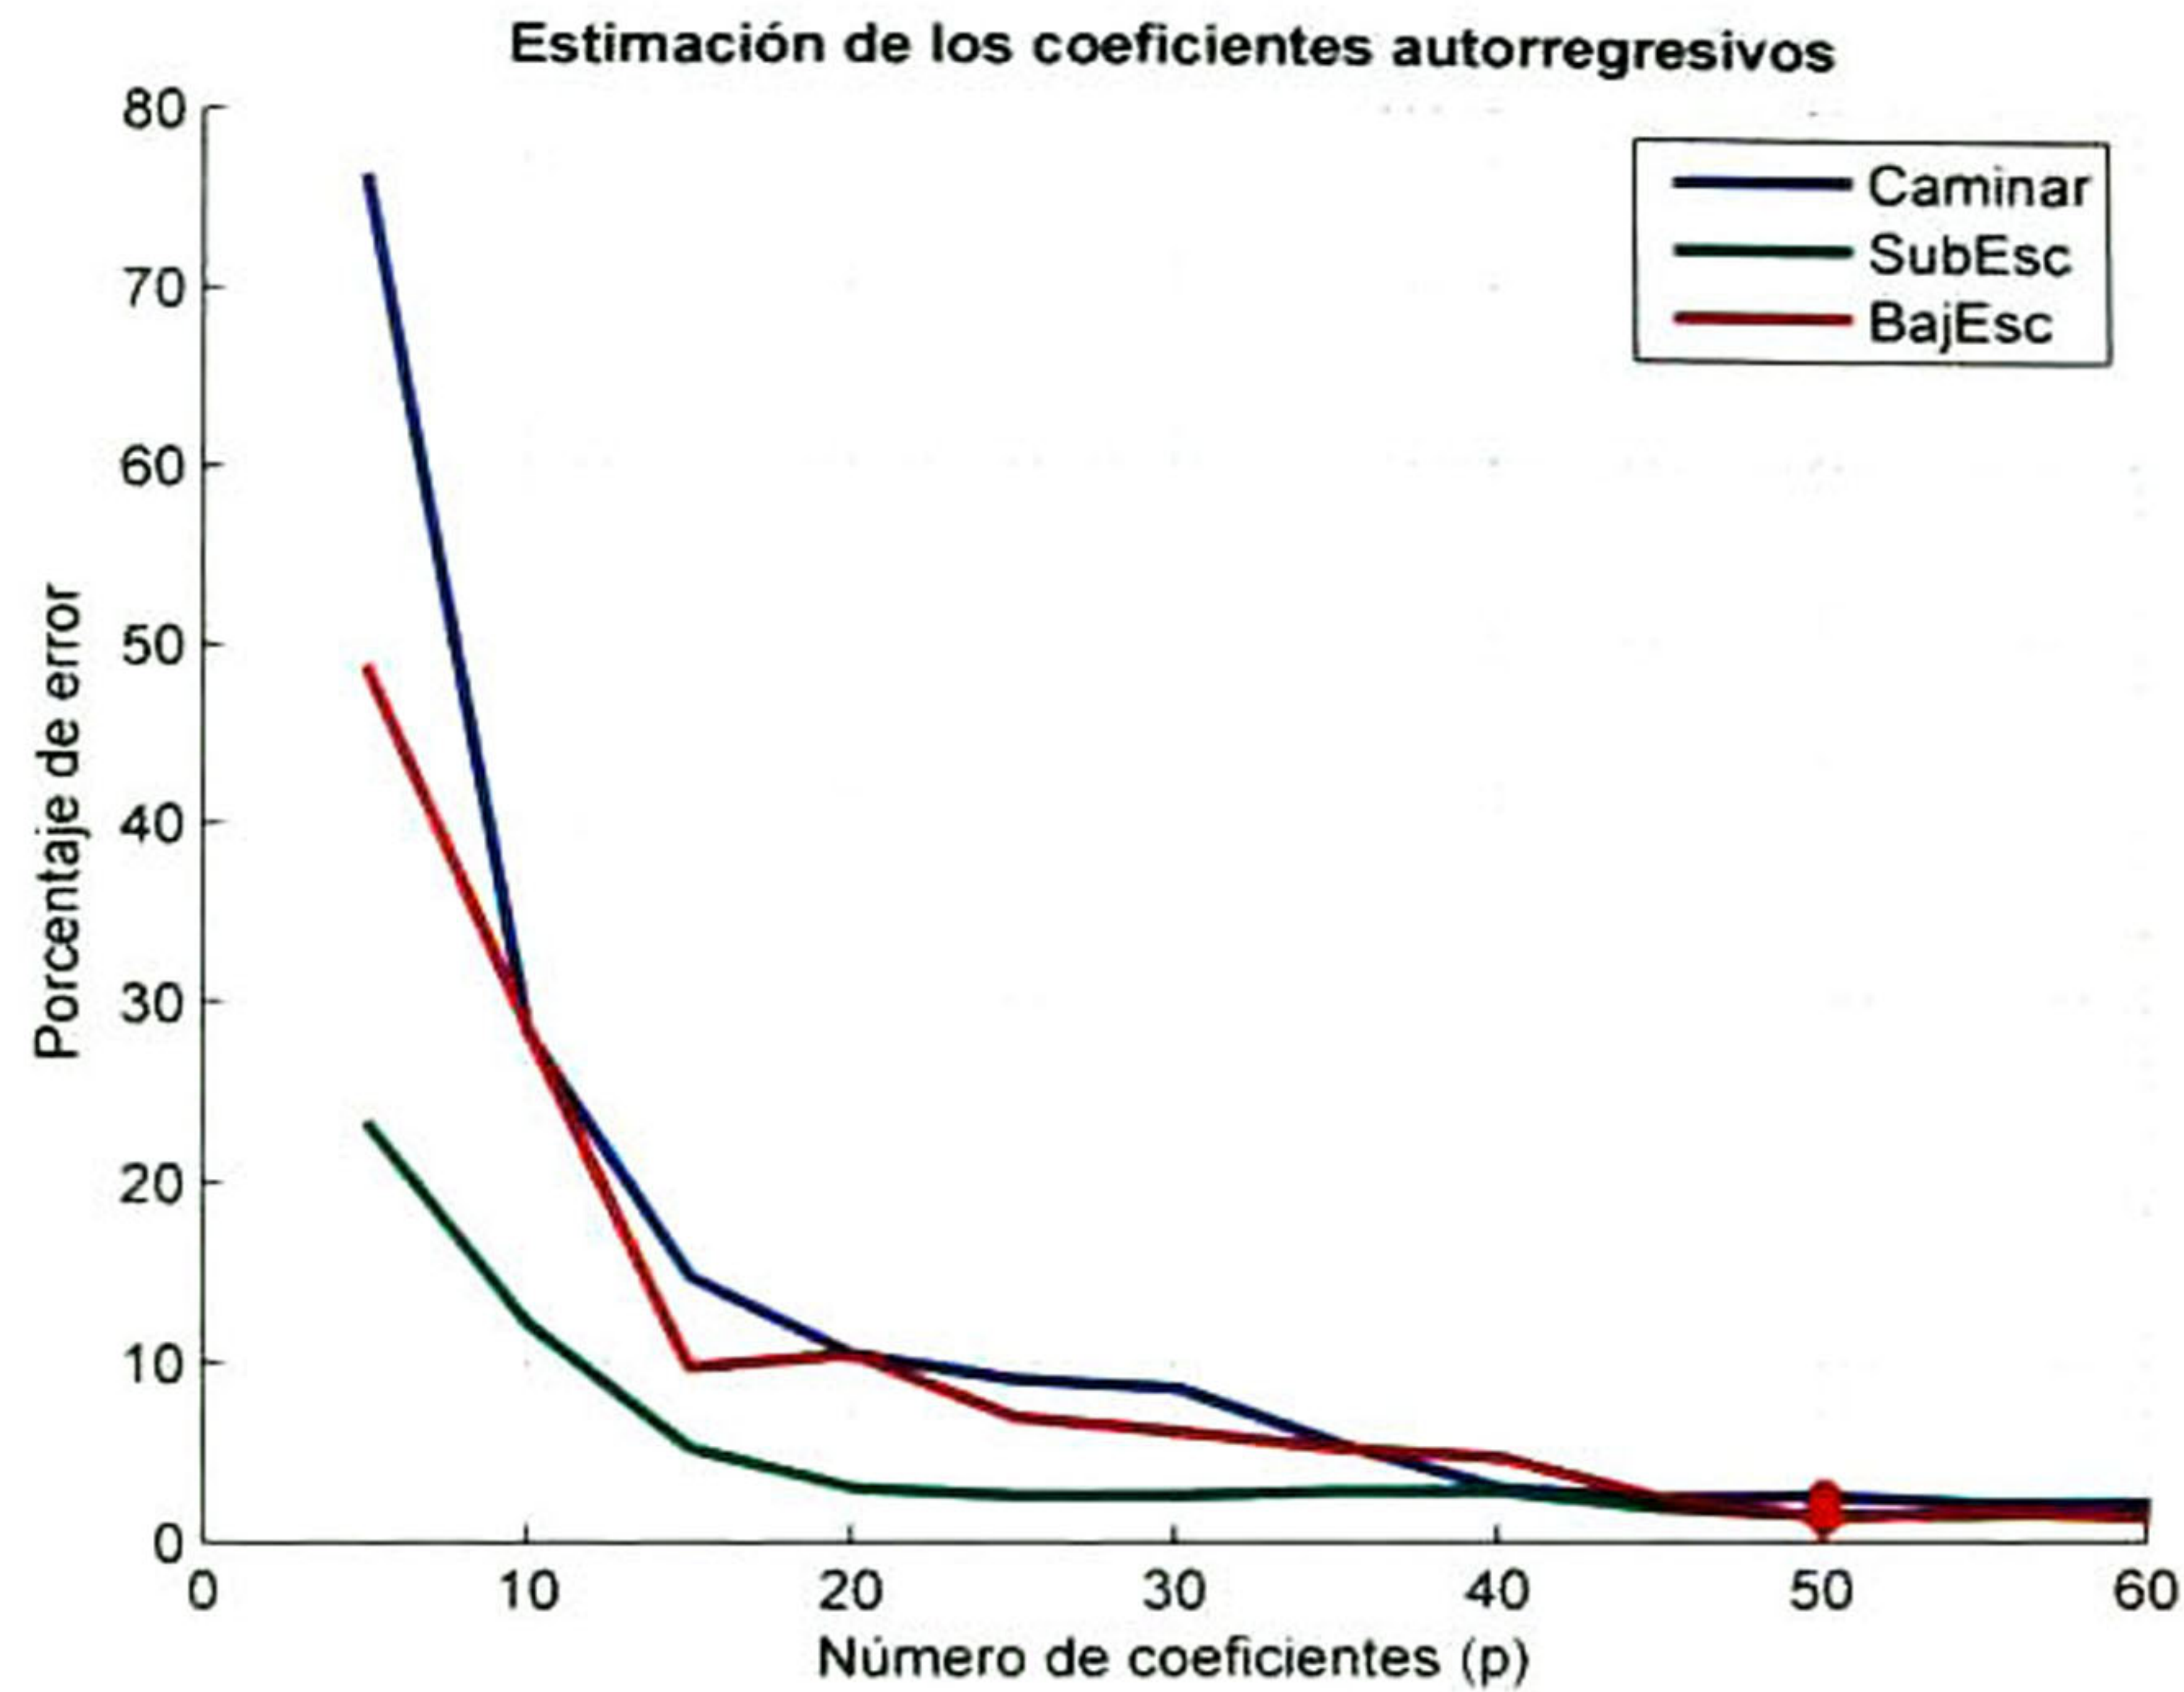


Figura 4.3: Comportamiento del error cuadrático medio con respecto al número de coeficientes autorregresivos de tres actividades diferentes. El punto rojo indica donde el error se puede considerar mínimo para las tres señales y por lo tanto el orden del modelo.

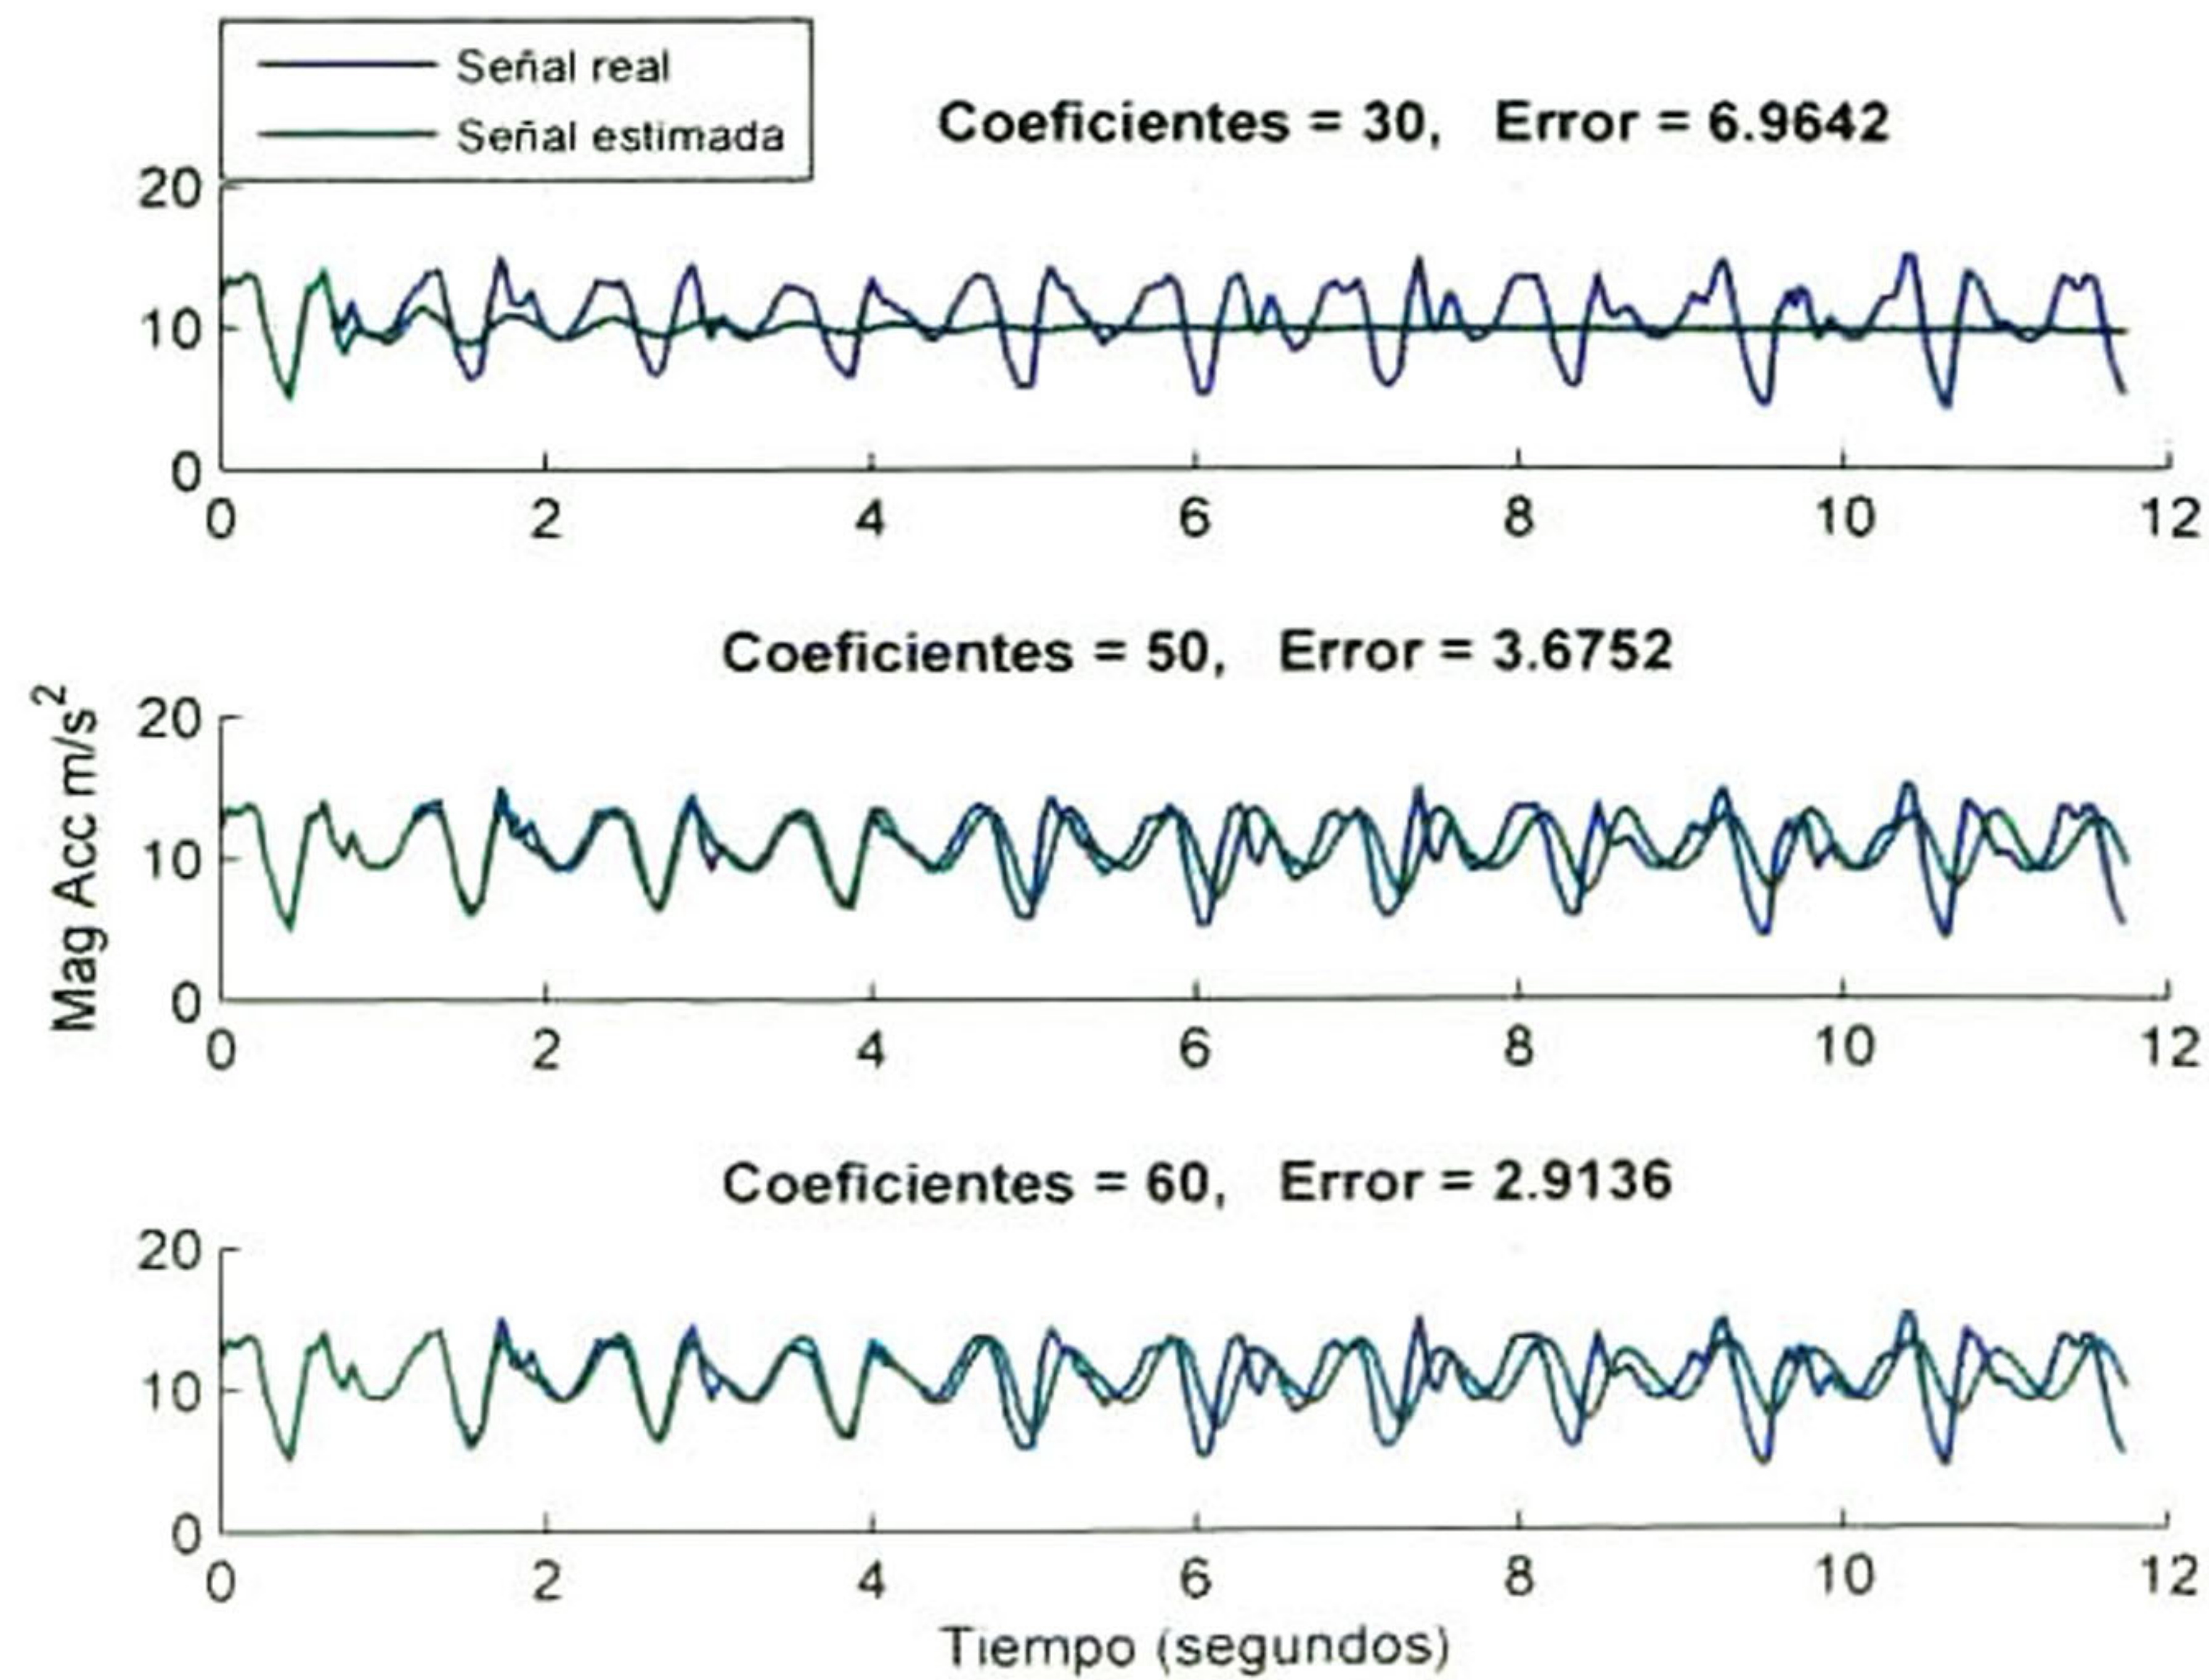


Figura 4.4: Estimación de una señal a partir de 30, 50 y 60 coeficientes autorregresivos.



### 4.2.2 Selección del número de componentes principales

Los CPs son combinaciones lineales de las variables originales que se van construyendo según el orden de importancia en cuanto a la variabilidad total que representan los datos. Por ejemplo, el primer CP representa la varianza máxima, el siguiente CP la segunda varianza mayor y ortogonal al primer CP y así sucesivamente.

Para determinar el menor número de CPs que mejor representen la información obtenida de las características, el ACP fue aplicado sobre el conjunto de características del cual se obtuvo un total de 53 CPs. De los CPs obtenidos 25 fueron seleccionados, debido a que representaron una varianza de 0.97 % y por lo tanto la pérdida de información fue de 0.03 % la cual podría considerarse no significativa. En la Tabla 4.2 se muestran los CPs seleccionados, el valor correspondiente a su desviación estándar y la varianza acumulada.

Componentes principales	Desviación estándar	Varianza Acumulada
CP1	1.125	0.601
CP2	1.195	0.604
CP3	0.352	0.657
CP4	0.293	0.693
CP5	0.279	0.726
CP6	0.270	0.757
CP7	0.257	0.785
CP8	0.240	0.809
CP9	0.233	0.832
CP10	0.221	0.853
CP11	0.220	0.873
CP12	0.200	0.890
CP13	0.178	0.904
CP14	0.168	0.915
CP15	0.155	0.926
CP16	0.138	0.934
CP17	0.132	0.941
CP18	0.115	0.947
CP19	0.109	0.952
CP20	0.100	0.956
CP21	0.090	0.959
CP22	0.087	0.962
CP23	0.083	0.965
CP24	0.079	0.968
CP25	0.078	0.971

Tabla 4.2: Selección de los CPs a partir de su varianza



Para evaluar si con 25 CPs el porcentaje de reconocimiento por el clasificador era alto, un conjunto de experimentos fueron realizados en los cuales se observó que a partir de 25 CPs la exactitud del clasificador es del 93.3 % y para un número menor a 25 es aproximadamente del 92 %.

Los CPs seleccionados fueron empleados como las entradas de las redes diseñadas en el nivel  $L_3$  y  $L_4$  del esquema jerárquico. Los resultados obtenidos de la evaluación del clasificador se muestran en la sección 4.3.

### 4.2.3 Topología de las redes

Diseñar una RNA involucra definir su topología la cual requiere de un número de capas, un número de neuronas y la función de transferencia. Puesto que no existe un método que nos indique la configuración de una red para un determinado problema de clasificación, en este trabajo diversas experimentaciones fueron realizadas para seleccionar la topología apropiada restringiendo solo a redes *feedforward*.

Durante las experimentaciones cada uno de los diferentes parámetros requeridos por la red fueron modificados para evaluar su desempeño de clasificación y las redes que discriminaban con un alto porcentaje en el reconocimiento de las actividades fueron seleccionadas para el proceso de clasificación.

Como se mencionó en el capítulo 3, cuatro redes neuronales fueron empleadas en cada uno de los niveles del esquema jerárquico. Para estas redes la topología seleccionada se muestran en la Tabla 4.3, en ella se observa que en el caso de las redes *feedforward* se requiere de 25 entradas (corresponden a los 25 CPs), 2 neuronas en la primera capa, 1 neurona en la segunda capa y una en la salida, la cual determina a que clase corresponde.

Niveles	Red	Entradas	Función de transferencia	Salida
1	Perceptrón	$\sigma, \mu$	<i>Hardlim</i>	Estático
2	Perceptrón	$\sigma, \mu$	<i>Hardlim</i>	Correr
3	<i>feedforward</i> [25-2-1-1]	$CPs_{25}(Coeff-AR, \sigma, P_{95})$	<i>Tansig</i>	Subir
4	<i>feedforward</i> [25-2-1-1]	$CPs_{25}(Coeff-AR, P_{95})$	<i>Tansig</i>	Cam/Bajar

Tabla 4.3: Configuración de las redes empleadas en el esquema jerárquico



## 4.3 Evaluación del enfoque propuesto

En esta sección se describe la evaluación del enfoque propuesto, la cual se realiza mediante técnicas y medidas estadísticas reportadas en la literatura para el contexto del reconocimiento de actividades físicas. Particularmente se consideró como método de evaluación la validación cruzada y como medidas estadísticas la exactitud, la precisión y la sensibilidad.

### 4.3.1 Técnicas y métricas de evaluación

La función de un clasificador es decidir cuales de las instancias de un conjunto están relacionadas o no a su tipo o clase. Usualmente se emplean técnicas para la validación del clasificador y medidas estadísticas para obtener su precisión y un estimado del error esperado. Las técnicas o métricas utilizadas dependen de la tarea de clasificación, es por ello que se han seleccionado aquellas reportadas en la literatura para la clasificación de actividades físicas [2, 3, 32, 35, 43, 55].

Para evaluar un modelo de clasificación, es necesario contar con datos de prueba etiquetados con la clase a la que pertenecen y así estimar o calcular el porcentaje de error de predicción. Para ello se emplean diversos métodos tales como la validación cruzada (cross-validation), el bootstrap, entre otros. Para este trabajo se utilizó la técnica de validación cruzada con  $k = 10$  iteraciones, puesto que ha sido reportada en la literatura para la evaluación de clasificadores empleados en el reconocimiento de actividades físicas. Básicamente la validación cruzada consiste en dividir los datos etiquetados en  $K$  subconjuntos, uno de ellos es utilizado como datos de prueba y el resto ( $k - 1$ ) como datos de entrenamiento. El proceso de validación es repetido durante  $k$  iteraciones, con cada uno de los posibles subconjuntos de datos de prueba y finalmente realiza la media aritmética de los resultados de cada iteración para obtener un único resultado.

Para observar la distribución de los errores cometidos por el clasificador a lo largo de las distintas clases o categorías, se empleo la matriz de confusión, donde cada una de las columnas representan el número de predicciones de cada clase y las filas representan a las instancias de la clase real. En la Tabla 4.4 se ejemplifica la estructura de una matriz de confusión empleada para dos clases.



Una vez establecida la matriz de confusión es posible obtener las medidas estadísticas que evalúen el desempeño del clasificador [73], algunas de ellas se describen de manera general (para  $l$  clases) en la Tabla 4.5.

Real \ Predicha	Predicha	
	$C_1$	$C_2$
$C_1$	Verdaderos Positivos (VP)	Falsos Negativos (FN)
$C_2$	Falsos Positivos (FP)	Verdaderos Negativos (VN)

Tabla 4.4: Matriz de confusión empleada para dos clases.

Medidas	Fórmula	Descripción
Precisión	$\frac{\sum_{i=1}^l VP_i}{\sum_{i=1}^l (VP_i + FP_i)}$	Son los casos positivos predichos como correctos.
Exactitud	$\frac{\sum_{i=1}^l (VP_i + VN_i)}{\sum_{i=1}^l (VP_i + FN_i + FP_i + VN_i)}$	Es el número total de predicciones que son correctas.
Sensitividad	$\frac{\sum_{i=1}^l VP_i}{\sum_{i=1}^l (VP_i + FN_i)}$	Representa a los casos positivos que fueron identificados correctamente.
Especificidad	$\frac{\sum_{i=1}^l VN_i}{\sum_{i=1}^l (FP_i + VN_i)}$	Son los casos negativos predichos como negativos.

Tabla 4.5: Medidas utilizadas para la evaluación del clasificador.

Una vez definido los parámetros requeridos por las redes neuronales y las métricas utilizadas para evaluar a los clasificadores, en las siguientes subsecciones se muestra la evaluación del modelo de clasificación propuesto para discriminar entre las diferentes clases de actividades.



### 4.3.2 Precisión y exactitud del clasificador

Para evaluar el modelo de clasificación jerárquico basado en redes neuronales, se utilizó un conjunto de datos recolectados por un usuario los cuales fueron capturados y etiquetados considerando las diferentes posiciones y orientaciones en las que se colocó el smartphone. Una vez segmentado el conjunto de datos, un total de 2406 ejemplos fueron utilizados para realizar la evaluación del clasificador, éstos se dividieron en entrenamiento (aproximadamente 70 %) y validación (aproximadamente 30 %). En la Tabla 4.6 se muestra la distribución general de los ejemplos por el tipo o clase de actividad. Cabe mencionar que las posiciones definidas de como el usuario coloque el smartphone no son relevantes por el clasificador, puesto que éste debe ser capaz de reconocer las actividades independientemente de las posiciones y orientaciones del dispositivo.

Clases	Ejemplos de entrenamiento	Ejemplos de validación	Total
Estáticas	388	150	538
Correr	298	152	450
Caminar	331	158	489
Subir Esc	308	163	471
Bajar Esc	304	154	458
<b>Total</b>	<b>1629</b>	<b>777</b>	<b>2406</b>

Tabla 4.6: División de los ejemplos utilizados para validar y evaluar el clasificador.

De los resultados obtenidos por el clasificador en la Tabla 4.7 se observa que la precisión obtenida para las actividades linealmente separables como correr y estáticas el porcentaje de clasificación es elevado, sin embargo, para caminar, subir y bajar escaleras el porcentaje de clasificación es menor. Este comportamiento se debe a que dichas actividades tienen una fuerte correlación entre si, la cual impide que se tenga una mejor discriminación por el clasificador. En general la exactitud obtenida por el esquema de clasificación propuesto resultó del 93.3 % del reconocimiento de las cinco actividades. Este porcentaje se obtuvo sumando las diagonales de la matriz y dividiendo entre el número total de ejemplos tal como se muestra en la Tabla 4.5.

La exactitud obtenida por el clasificador es considerada competitiva con las reportadas en el estado del arte, debido a que éstas se encuentran en el rango entre 85 % y 97 % considerando posiciones específicas o más de un acelerómetro.



Clases	Estático	Correr	Caminar	SubEsc	BajEsc	Total	Precisión
Estático	150	0	0	0	0	150	100 %
Correr	0	152	0	0	0	152	100 %
Caminar	0	0	148	3	7	158	93.6 %
SubEsc	0	0	6	139	18	163	85.2 %
BajEsc	0	0	7	11	136	154	88.3 %
Total	150	152	161	153	161	777	
Sensitividad	100 %	100 %	91.9 %	90.8 %	84.4 %		

Tabla 4.7: Resultados de la evaluación del esquema de clasificación jerárquico.

Puesto que la evaluación del clasificador se realizó considerando un solo usuario, otra de las experimentaciones realizadas consistió en estimar el porcentaje de clasificación respecto a otros usuarios. La descripción general de este experimento se describe en la siguiente subsección.

### 4.3.3 Robustez del sistema respecto a cambios de usuario

Otra de las experimentaciones realizadas consistió en evaluar la robustez del sistema de reconocimiento con respecto a otros usuarios, debido a que los datos con los que fue entrenado y validado fueron tomados de un solo usuario. Para facilitar la evaluación correspondiente, el sistema de reconocimiento fue implementado en el dispositivo móvil, de tal manera que todo el proceso de reconocimiento se llevara a cabo en línea. Se les solicitó a cuatro usuarios que realizaran las cinco actividades en un periodo de tiempo de dos minutos y cada uno de ellos era libre de colocar el smartphone en cualquiera de las cuatro posiciones y orientaciones consideradas para este trabajo. Los resultados generados por el clasificador fueron almacenados en la memoria externa del dispositivo móvil y posteriormente fueron evaluados.

Los resultados obtenidos de esta experimentación se muestran en la Tabla 4.8, en ella se observa que el porcentaje de reconocimiento para la actividad de caminar en determinados usuarios resultó bajo en comparación con el esperado (superior al 90 %). Se determinó que uno de los posibles factores que influyen al bajo porcentaje de reconocimiento se debe a que la velocidad con la que camina cada usuario varía, es decir, hay usuarios que caminan más rápido que otros. Por otro lado se encontró que cuando el dispositivo no se mantenía fijo en una determinada posición al realizar alguna actividad, el clasificador discriminaba incorrectamente, lo cual influyó en la precisión del reconocimiento de las actividades.



Usuario	Estático	Correr	Caminar	Subir Esc	Bajar Esc
1	100 %	100 %	93.75 %	87.50 %	91.67 %
2	100 %	100 %	91.67 %	87.50 %	87.50 %
3	100 %	100 %	87.50 %	83.33 %	79.17 %
4	100 %	100 %	70.83 %	91.67 %	87.50 %

Tabla 4.8: Precisiones obtenidos al evaluar el sistema de reconocimiento con otros usuarios

Partiendo de los resultados observados del experimento, otro más fue realizado para determinar la velocidad promedio con la cual el sistema discrimina la actividad de caminar con un porcentaje de reconocimiento superior al 90 %. Para ello, cinco usuarios participaron caminando una distancia de 15 metros, en un tiempo estimado de entre 10 y 17 segundos (medido con un cronómetro).

De la experimentación realizada se encontró que el sistema reconocía mejor la actividad de caminar para velocidades superiores a los 1.3  $m/s$  en promedio y para velocidades menores a ésta, el sistema de reconocimiento clasifica erróneamente con las actividades de subir y bajar escaleras. Los resultados obtenidos de esta experimentación se muestran en la Tabla 4.9.

Usuarios	Velocidad ( $m/s$ )	Precisión
1	0.88	53.1 %
2	0.93	61.3 %
3	1.2	90.5 %
4	1.5	96.1 %
5	1.3	93.6 %

Tabla 4.9: Estimación de la velocidad y el porcentaje de reconocimiento por diferentes usuarios para la actividad de caminar

En el caso del resto de las actividades no se realizó alguna experimentación puesto que los resultados obtenidos son similares a los mostrados en la evaluación del clasificador (arriba del 85 %). Debido a que los resultados del clasificador propuesto son alentadores, en la siguiente subsección se describe una comparación realizada con otros enfoques de clasificación, los cuales han sido reportados en la literatura para el reconocimiento de actividades físicas.



#### 4.3.4 Comparación con otros clasificadores

Para comparar el desempeño del esquema de clasificación jerárquico, con respecto a otros clasificadores de los reportados en la literatura para el caso de reconocimiento de actividades [2, 3, 32, 35, 43, 55], se ha realizado una experimentación la cual consiste evaluar el mismo conjunto de patrones de ejemplos con los diferentes clasificadores. Esta comparativa se realizó utilizando un software de minería de datos denominado *RapidMiner* [74], dicho software implementa una gran variedad de métodos de clasificación los cuales solo requieren del conjunto de características y las etiquetas de clase.

Los métodos de clasificación comparados fueron  $K$ -NN, SVM y Naïve Bayes. Estos clasificadores se evaluaron a través del método de validación cruzada con  $k = 10$  tal como se realizó en [1, 11, 57]. De los clasificadores empleados el Naïve Bayes no requiere de una configuración previa de los parámetros, en comparación con los otros clasificadores que si lo requieren (la descripción de estos parámetros se detallan en la documentación de RapidMiner [75]). El valor correspondiente a los parámetros establecidos para el  $K$ -NN y el SVM se muestran en la Tabla 4.10.

Clasificador	Parámetros
$K$ -NN	$K = 1,2,3,4,5$ Medidas Numéricas: Euclidiana, Manhattan, alineamiento dinámico del tiempo (DTW), Chebyshevs y la similitud del coseno.
SVM	Tipo de SVM: <i>C-SVC</i> , <i>nu-SVC</i> . Tipo de Kernel: <i>rbf</i> , <i>poly</i> , <i>sigmoid</i> y <i>precomputed</i> . Gamma: [0.5, 3.0], con incrementos de 0.1. C: [0.1, 2.0], con incrementos de 0.1.

Tabla 4.10: Parametrización de los clasificadores.

De los experimentos realizados se tomaron aquellos parámetros que proporcionaron un porcentaje de clasificación alto. Para el  $K$ -NN se eligió un  $K = 5$  y distancia *Manhatan*, para el SVM se tomó un SVM de tipo *C – SVC*, kernel *rbf*,  $\gamma = 0.5$  y  $C = 1.5$ . Para el caso del esquema de clasificación propuesto los parámetros considerados se muestran en la Tabla 4.3.



Los resultados obtenidos por los clasificadores evaluados se muestran en la Tabla 4.11, en ella pueda observarse que el enfoque propuesto en promedio alcanza una precisión del 93.45 % en el reconocimiento de todas las actividades. Este resultado se obtuvo debido a que se busco un esquema de clasificación que permitiera discriminar entre clases linealmente separables y posteriormente clasificar las más correlacionadas empleando redes que permitan lidiar con clases linealmente no separables. También se muestra en la tabla que el porcentaje de reconocimiento por los todos los clasificadores para las actividades correspondientes a subir y bajar escaleras es bajo debido a la alta correlación entre estas clases.

Clases	NB		K-NN		SVM		Propuesto	
	P	S	P	S	P	S	P	S
Estáticas	100	99.36	100	99.36	100	100	100	100
Correr	100	100	100	100	100	100	100	100
Caminar	91.03	85.71	79.27	84.42	89.81	91.56	<b>93.67</b>	<b>91.92</b>
SubEsc	80.98	88.69	78.07	86.90	86.55	88.10	<b>85.27</b>	<b>90.85</b>
BajEsc	82.28	79.27	79.41	65.85	85.44	82.32	<b>88.31</b>	<b>84.47</b>
Promedio	90.85	90.60	87.35	87.30	92.36	92.39	<b>93.45</b>	<b>93.44</b>

Tabla 4.11: Resultados obtenidos de los clasificadores evaluados. Los renglones sombreados indican que la precisión (P) y la sensibilidad (S) para estas clases tienen un bajo porcentaje en todos los clasificadores.

En la siguiente sección se describen los escenarios empleados para evaluar el desempeño del sistema de reconocimiento implementado en el dispositivo móvil.

## 4.4 Implementación en un smartphone

Para evaluar el desempeño del sistema de reconocimiento en línea se realizaron dos experimentaciones, una para la estimación de los tiempos de cómputo requeridos por el sistema y la otra para medir el consumo de energía en el dispositivo. A continuación se describirá con más detalle estas experimentaciones.

### 4.4.1 Tiempos de ejecución

Para estimar el tiempo de cómputo requerido por el sistema de reconocimiento que se ha implementado en el dispositivo móvil, se diseñó una aplicación (los detalles de este módulo se describen en el apéndice



A.2) la cual obtuviera los tiempos iniciales y finales en cada una de las etapas empleadas por el esquema de clasificación jerárquico (preprocesamiento, extracción de características y clasificación).

A fin de evaluar los tiempos de ejecución la aplicación fue instalada en tres diferentes smartphones con las características que se describen en la Tabla 4.12.

Dispositivo Samsung Galaxy	Procesador (ARM)	Memoria (RAM)	Versión del SO Android
Ace	Qualcom 832 MHz	278 MB	2.3.6 Gingerbread
S	Cortex-A8 1 GHz	512 MB	2.2 Froyo
Note II	Cortex-A9 1.6 GHz	2 GB	4.1 Jelly Bean

Tabla 4.12: Características de los diferentes smartphones utilizados.

Los tiempos estimados en este experimento abarcan todo el procesamiento realizado en el esquema jerárquico, es decir, desde el primer nivel hasta el último, de manera que el tiempo podría disminuir aún más dependiendo si la actividad a reconocer se determina en los dos primeros niveles de la jerarquía donde no se requiere de un alto costo computacional. De los resultados obtenidos en la experimentación, la Tabla 4.13 muestra que a pesar de las diferencias que hay en las características de los smartphones el tiempo de cómputo más alto que se requiere es de 573 milisegundos, el cual no es elevado con respecto al tiempo de observación que se ha definido para reconocer una actividad (5 segundos). También se observa que los tiempos de ejecución más demandantes se dan al extraer las características seleccionadas, específicamente al obtener los coeficientes autorregresivos, sin embargo, en la etapa de preprocesamiento y clasificación (no considerando la extracción de características) los tiempos estimados son relativamente bajos.

Dispositivos Samsung Galaxy	Preprocesamiento	Extracción de características Total/Coef. Autorregresivos	Clasificador
Ace	185	553/550	573
S	62	186/184	195
Note II	35	146/145	156

Tabla 4.13: Estimación de los tiempos de ejecución en milisegundos, en cada una de las etapas del esquema propuesto.



Cabe mencionar que en este trabajo no se realizó una optimización de la implementación del sistema de reconocimiento en el dispositivo móvil, queda abierta la posibilidad de hacerlo empleando código nativo *Java Native Interface (JNI)* o explotando cada uno de los núcleos del dispositivo móvil, dependiendo de las capacidades o características de éste.

#### 4.4.2 Estimación del consumo de energía

Para estimar el consumo de energía por la aplicación móvil, se realizó un experimento, el cual consistió en dejar la aplicación en ejecución hasta que la batería del smartphone se agotara. Durante cada minuto se monitoreaba el estado de la batería del smartphone y el valor correspondiente al nivel de batería se almacenaba en la memoria externa del dispositivo móvil. La aplicación fue instalada y puesta en ejecución en tres diferentes smartphones, los cuales tenían la batería cargada al 100 % y los servicios de Wi-Fi, *Bluetooth* y GPS fueron desactivados para que su efecto no interfiriera en la estimación del consumo de la energía. Los detalles de la aplicación se describen en el apéndice A.3.

Los resultados obtenidos de esta experimentación se muestran en la Tabla 4.14, en ella puede observarse que la duración de la batería varía en proporción a las características de ésta. Por ejemplo para el Samsung Galaxy Ace que tiene capacidades restringidas la duración de la batería resultó aproximadamente de 10 horas y para el Samsung Galaxy Note con características más sofisticadas la duración aumentó a 16 horas.

Dispositivos Samsung Galaxy	Capacidad de Batería/Voltaje (mAh)/(Volts)	Duración (hrs)
Ace	1350/3.7	10
S	1650/3.7	13
Note II	3100/3.8	16

Tabla 4.14: Estimación del consumo de energía en tres diferentes dispositivos

Gráficamente en la Figura 4.5, se ilustra el perfil del consumo de energía de tres dispositivos diferentes, partiendo de que la batería de cada uno de ellos está cargada totalmente.



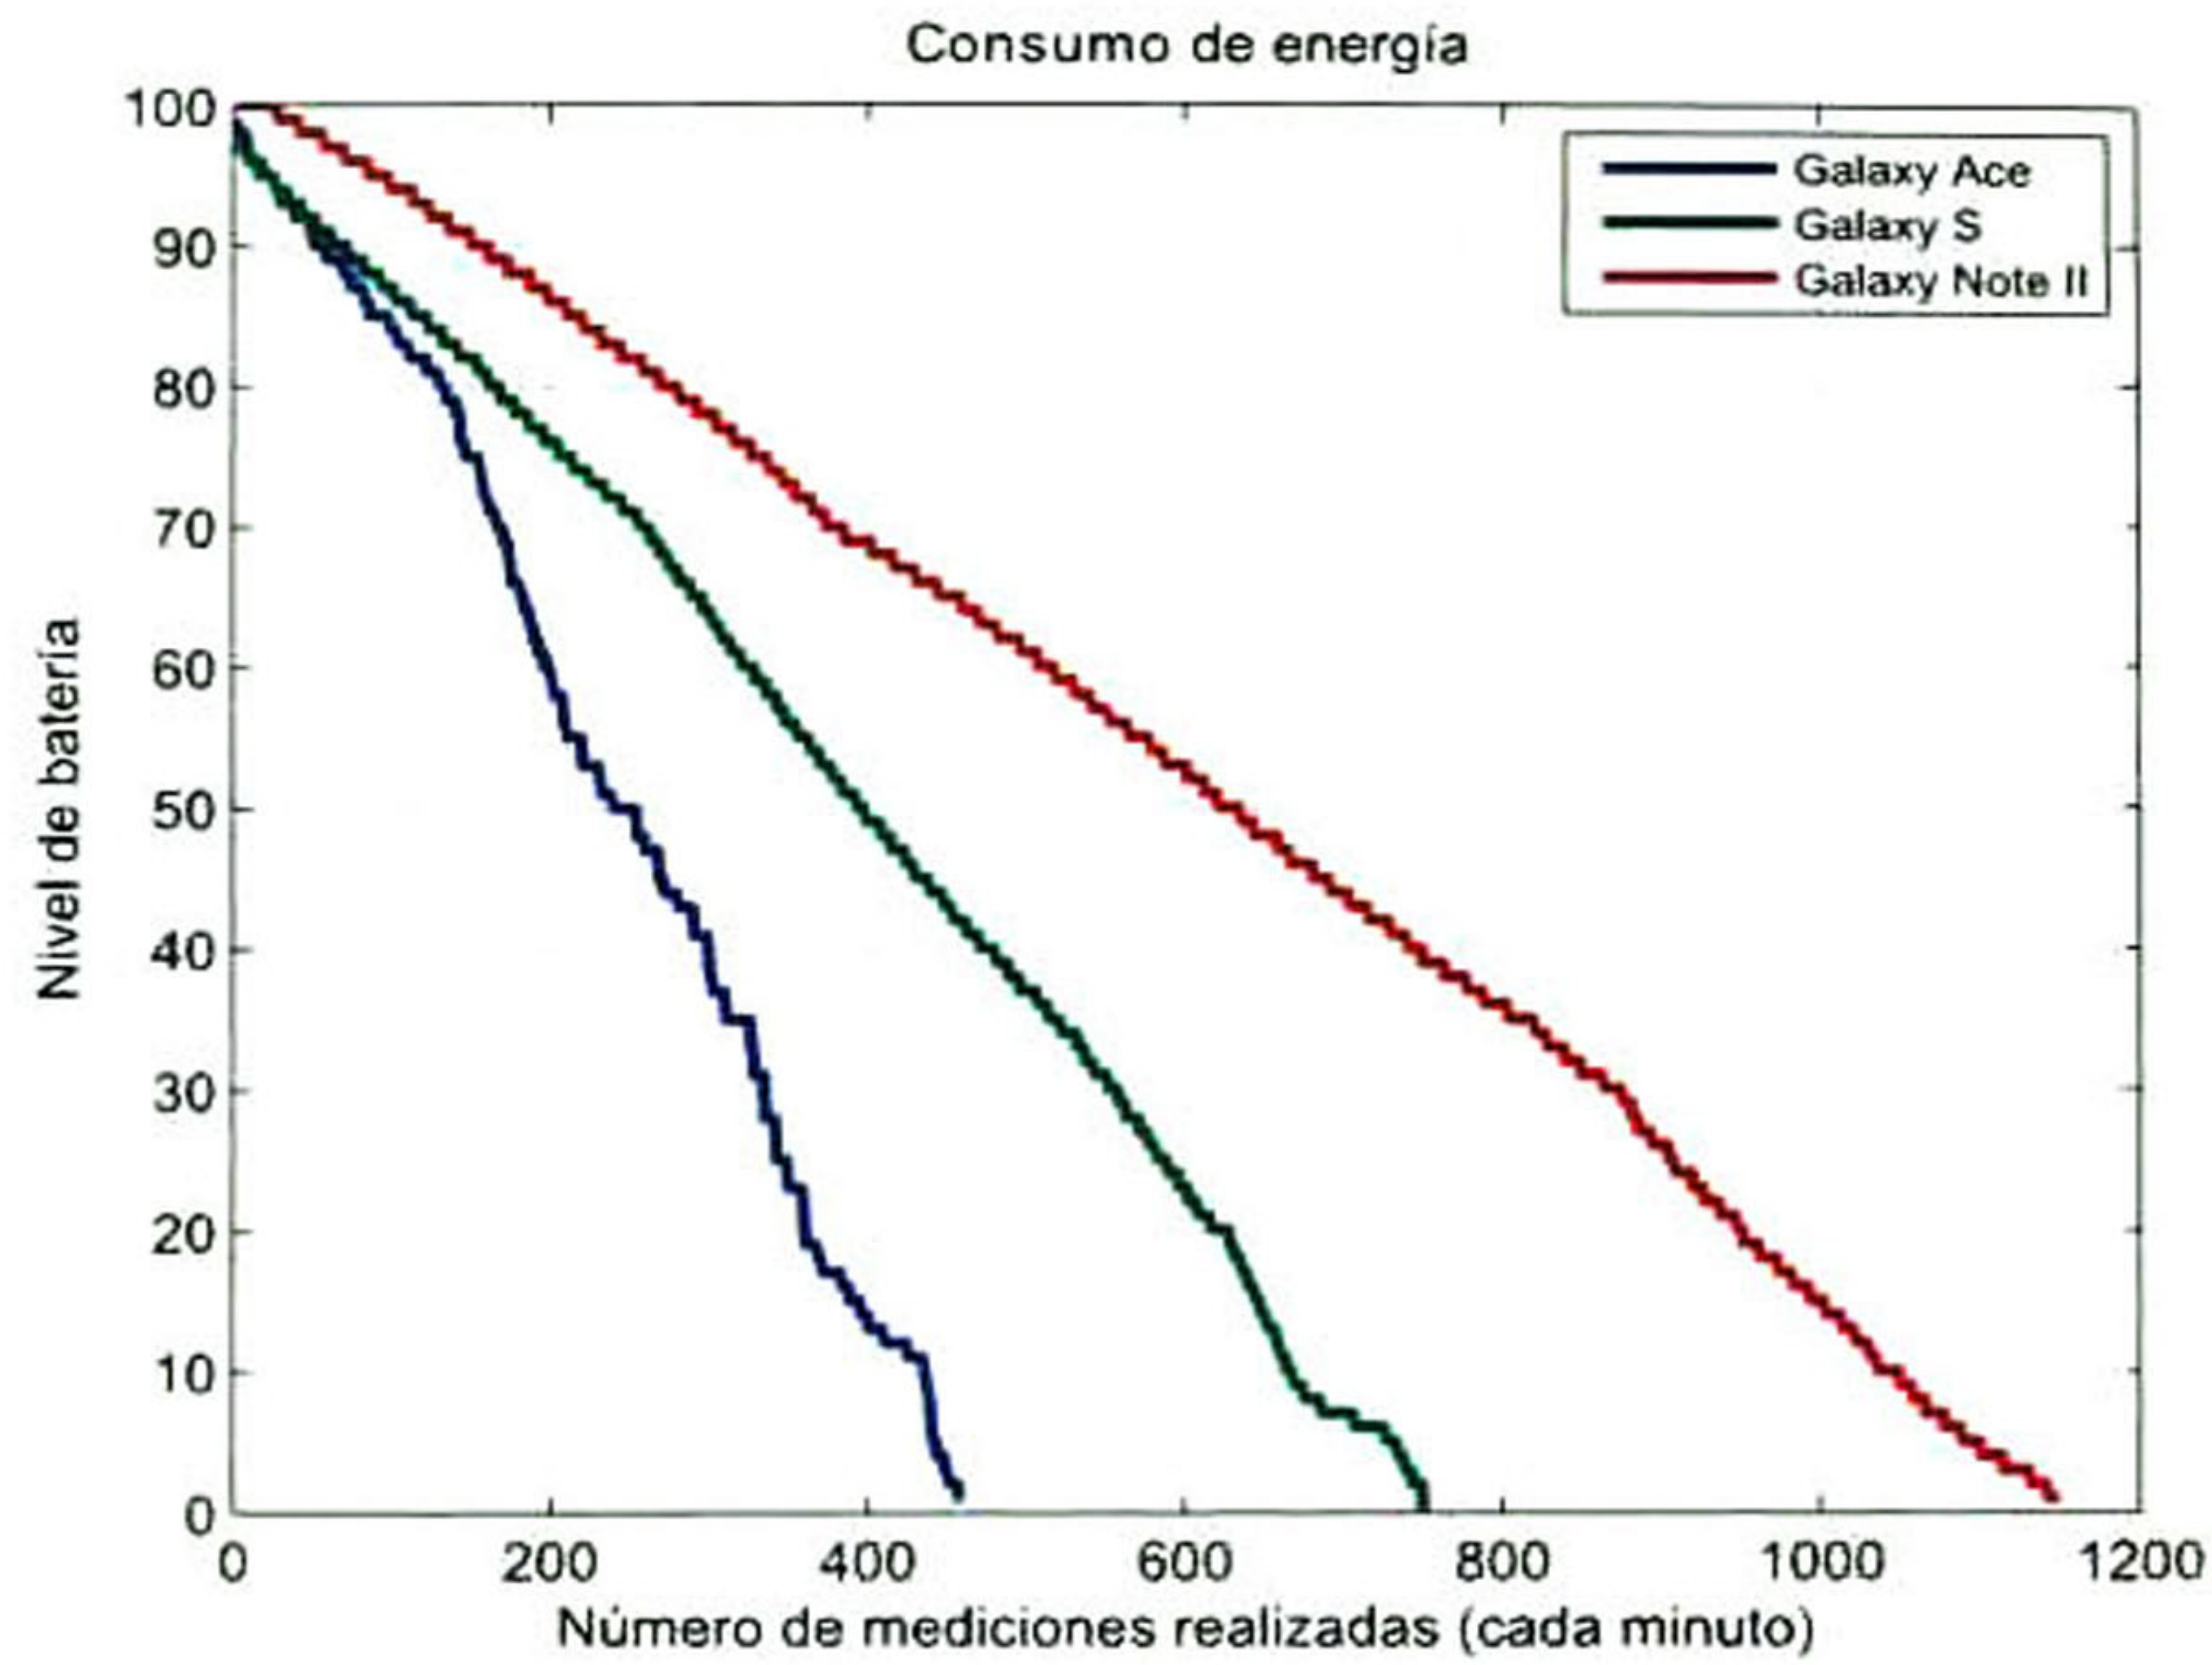


Figura 4.5: Perfiles de la energía consumida por el sistema de reconocimiento en tres dispositivos diferentes.

Para obtener la estimación del consumo de energía en el dispositivo móvil se utilizaron funciones propias del SO Android. Por ejemplo a través de la clase *BatteryManager* se puede obtener el estado de la batería y los detalles de la carga. En la documentación oficial de Android [76] se describe puntualmente como obtener el nivel de la batería del smartphone.

### 4.4.3 Aplicación de prueba de concepto

Uno de los objetivos que se han planteado en este trabajo de tesis es el desarrollo de una aplicación móvil de prueba de concepto. Esta aplicación consiste en que a partir de las actividades discriminadas por el sistema de reconocimiento implementado en el smartphone, envíe como información las etiquetas correspondientes a cada clase, los datos en crudo capturados por el acelerómetro y la fecha y hora de captura.

Una aplicación web fue diseñada con el fin de mostrar un resumen de las actividades realizadas por un usuario durante todo un día a partir de los datos enviados y almacenados previamente, estos datos se muestran a través de una gráfica en la cual se observa el porcentaje de cada una de las actividades realizadas (los detalles de esta aplicación se muestran en el Apéndice A.6). La idea fundamental que se planteó es que



el sistema web notifique automáticamente a la aplicación móvil alguna alerta relacionada con las actividades realizadas por el usuario continuamente, como por ejemplo, si un usuario permanece mucho tiempo estático (sentado, acostado o de pie) notificarle que necesita de realizar un poco más de actividad física.

Los pasos a seguir para realizar el proceso de notificación consisten en registrar e identificar a la aplicación móvil, a un servidor web y a los smartphones participantes en la plataforma *Google Cloud Messaging (GCM)*. En primera instancia, la aplicación móvil debe ser inscrita a través de una solicitud directa a GCM <sup>1</sup>, obteniendo un ID del emisor (sender ID). Después el smartphone debe ser registrado mediante un par de procesos específicos (métodos Java) en la aplicación móvil, recibiendo como respuesta un ID de registro (este ID debe ser compartido con el servidor ya que es utilizado para indicar el dispositivo destino al enviar una notificación). Finalmente, el servidor es registrado utilizando la consola de API's de Google <sup>2</sup>, obteniendo una API key que le autorizará para el envío de notificaciones. Un breve resumen de este proceso se muestra en la Figura 4.6.

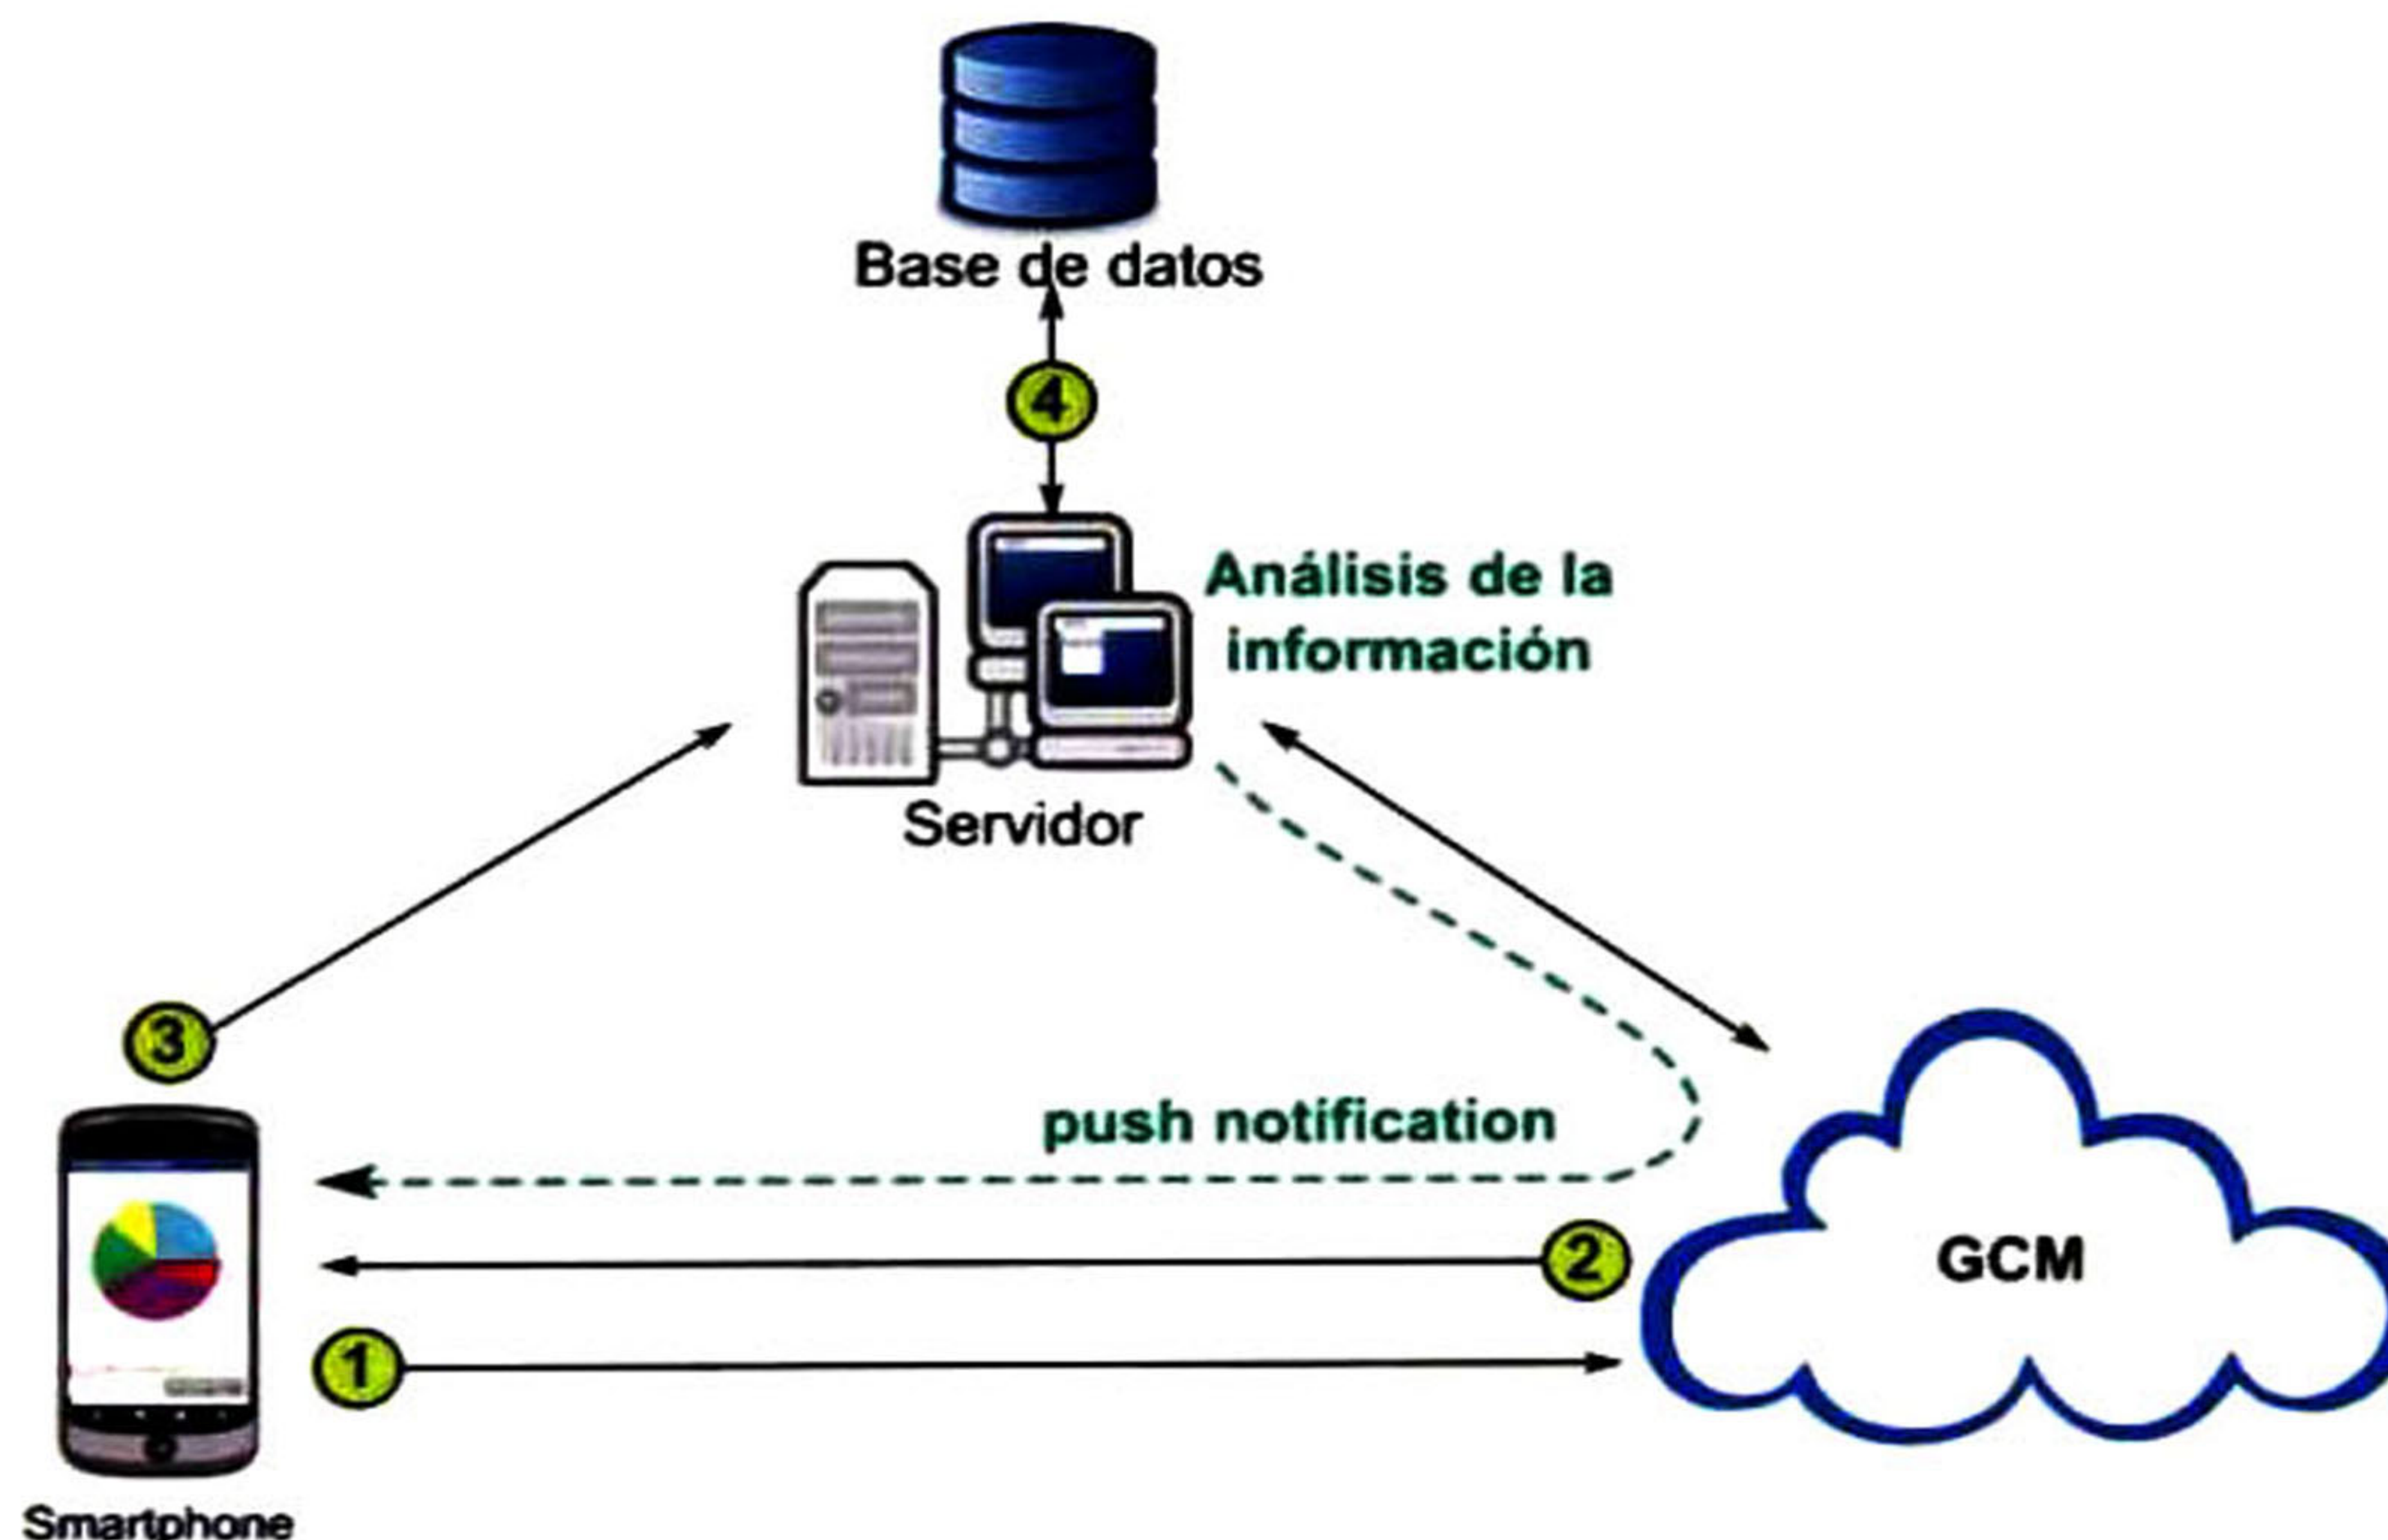


Figura 4.6: Esquema de notificación entre el GCM, la aplicación móvil y el sistema web.

En el Apéndice A.6 se dan más detalles acerca del diseño de la aplicación web y del servidor.

<sup>1</sup>Sitio web de GCM <http://developer.android.com/guide/google/gcm/index.html>

<sup>2</sup>API Access, <https://code.google.com/apis/console/>



## 4.5 Resumen

En este capítulo se han presentado las experimentaciones realizadas con las que se evaluó la funcionalidad del sistema de reconocimiento de actividades físicas. Las evaluaciones que se describieron en este capítulo incluyen: el desempeño del clasificador, la robustez del sistema con respecto a cambios de usuarios, la estimación de los tiempos de cómputo y del consumo de energía. Los resultados obtenidos por el clasificador muestran que son competitivos con los reportados en el estado del arte, debido a que se obtuvo una exactitud del 93.3% en el reconocimiento de las cinco actividades. Además se comprobó que el diseño del clasificador propuesto es mejor en precisión con respecto a otros ( $k$ -NN, NB, SVM), considerando determinados parámetros puesto que no se realizó un análisis exhaustivo acerca de la combinación de los parámetros empleados. En el siguiente capítulo se describen las conclusiones obtenidas de este trabajo de tesis.



# 5

## Conclusiones y trabajo futuro

*En este capítulo se presentan las conclusiones derivadas de este trabajo de tesis y se proponen algunas mejoras que podrían desarrollarse a partir de esta investigación.*

### 5.1 Conclusiones

Este trabajo de tesis se engloba dentro del área de cómputo móvil donde se emplean diversos dispositivos móviles para realizar tareas de comunicación y procesamiento de información. Un ejemplo de estos dispositivos son los smartphones los cuales son utilizados diariamente alrededor del mundo debido al incremento de sus funcionalidades y capacidades. Actualmente estos dispositivos incluyen una gran variedad de sensores y circuitería adicional, que incrementan sus funcionalidades para desarrollar nuevas aplicaciones como la presentada en este trabajo de tesis, la cual motiva al desarrollo de sistemas o aplicaciones más complejas.

Particularmente en este trabajo de tesis, se mostró la factibilidad del reconocimiento de las actividades físicas realizadas por un usuario en escenarios más realistas, es decir, considerando posiciones donde usualmente un usuario coloca el smartphone. Para lograr el reconocimiento de las actividades se propuso



un esquema jerárquico basado en redes neuronales, empleando características estadísticas, coeficientes autorregresivos y el ACP. Bajo este enfoque se logró una exactitud del 93.3 % en el reconocimiento de cinco actividades físicas (correr, caminar subir escaleras, bajar escaleras y estático) considerando cuatro posiciones (los dos bolsillos frontales y los dos bolsillos posteriores) y orientaciones. Aunado a esto se demostró que el sistema de reconocimiento es robusto respecto a cambios de usuarios.

También se implementó el sistema de reconocimiento en el dispositivo móvil y se estimó que el tiempo de respuesta por la aplicación es alrededor de 0.6 segundos para un dispositivo Samsung Galaxy Ace con características restringidas, sin embargo, este tiempo disminuye en dispositivos móviles con características más sofisticadas. Por otro lado, también se determinó que la duración de la batería es de aproximadamente 10 horas, cuando se realiza el monitoreo continuo del reconocimiento de las actividades en un dispositivo con capacidades de batería limitadas y una duración superior a las 10 horas para smartphones con baterías de mayor capacidad.

Adicionalmente se desarrolló una aplicación móvil de prueba de concepto, la cual se comunica con un sistema web para notificarle un resumen de las actividades físicas realizadas durante el día. Esto se realizó con la finalidad de ilustrar la factibilidad de desarrollar sistemas más complejos, debido a que los tiempos de ejecución y el monitoreo continuo obtenido por la aplicación son viables para ser implementados en un smartphone.

A pesar de los resultados obtenidos existen ciertos inconvenientes o desventajas en el sistema de reconocimiento implementado en el móvil. Por ejemplo, se encontró que cuando el dispositivo no se mantenía fijo en una determinada posición durante la realización de alguna actividad, ésta era discriminada incorrectamente. También se observó que para la actividad de caminar el porcentaje de reconocimiento es bajo cuando el usuario camina a velocidades menores a los  $1.3 \text{ m/s}$ , debido a que la correlación es alta con las actividades de subir y bajar escaleras. Las transiciones son otras de las desventajas presentes en el sistema de reconocimiento, debido a que no son consideradas lo cual hace que influyan en la precisión del clasificador.



## 5.2 Trabajo futuro

El sistema de reconocimiento de actividades físicas que se ha desarrollado, queda abierto a diferentes mejoras que enriquezcan o aumenten su funcionalidad, tales como:

- ▶ **Considerar otras ubicaciones donde el usuario coloque el dispositivo.** Puesto que hay usuarios que comúnmente colocan el dispositivo en los bolsillos de su camisa o ajustados en la cintura, existe la posibilidad de estas posiciones sean consideradas para integrarlas al sistema de reconocimiento desarrollado, debido a que no fueron tomados en cuenta.
- ▶ **Mejorar el porcentaje de reconocimiento.** Debido a que el porcentaje de reconocimiento para discriminar entre subir y bajar escaleras es bajo, sería importante considerar la extracción de características en cada una de las componentes de la aceleración, aumentar o disminuir el número de coeficientes autorregresivos, aplicar LDA o emplear otras características para aumentar el porcentaje de reconocimiento.
- ▶ **Identificar más actividades.** Aumentar el número de actividades enriquecería el trabajo de investigación, puesto que sería posible construir aplicaciones aún más complejas. Algunas de las actividades que podrían identificarse son andar en bicicleta, vehículo, saltar, etcétera.
- ▶ **Realizar un análisis más detallado acerca del tamaño de ventana o emplear traslapes.** Realizar experimentaciones con el fin de encontrar un tamaño de ventana apropiado que permita la detección de actividades con un menor tiempo de ejecución y consumo de energía. Adicionalmente se podría experimentar empleando ventanas de tiempo traslapadas para identificar transiciones o cambios de actividades para incrementar la precisión del clasificador.



# A

## Diseño de la aplicación móvil y el sistema web

En el presente Apéndice se describe la aplicación móvil diseñada para realizar el reconocimiento de las actividades físicas en línea. Esta aplicación fue desarrollada bajo una plataforma móvil con SO Android y se dividió en cuatro módulos: módulo de recolección de datos, módulo de procesamiento fuera de línea, módulo de clasificación totalmente en línea y el proceso de notificación. Los detalles de cada módulo se describen en las secciones siguientes.

### **A.1 Componentes de una aplicación móvil en Android**

Android es un SO móvil basado en Linux y es utilizado principalmente en teléfonos inteligentes o tabletas, fue creado por Google y es considerado como código abierto. En Android existe una serie de componentes esenciales para desarrollar aplicaciones en Android, los cuales se describen en [77]. A continuación se describirá de manera general algunos de los componentes que fueron empleados en el desarrollo de la aplicación móvil:



- ▶ **Vista (*View*)**. Las vistas son los elementos que componen la interfaz del usuario en una aplicación, algunos ejemplos son los botones, entrada de texto, etiquetas, etcétera. Todas las vistas son objetos descendientes de la clase *View*, habitualmente son definidas utilizando un archivo de lenguaje de marca extensible (XML por sus siglas en inglés, Extensible Markup Language) y son creadas por el sistema a partir de este archivo.
- ▶ **Layout**. Es un conjunto de vistas agrupadas que dispone de diferentes tipos de *Layouts* para organizar las vistas, ya sea de forma lineal, en cuadrícula o indicando la posición absoluta de cada vista. Los *Layouts* al igual que las vistas son definidas desde código Java, aunque la forma habitual es utilizando código *XML*.
- ▶ **Actividad (*Activity*)**. Una aplicación en Android esta formada por un conjunto de elementos básicos de visualización, donde cada uno de estos elementos o pantallas se les conoce como actividad y su función principal es la creación de la interfaz del usuario.
- ▶ **Servicio (*Service*)**. Es un proceso que se ejecuta en segundo plano, sin la necesidad de una interacción con el usuario y es utilizado para realizar operaciones de larga duración o para realizar una tarea con procesos remotos.
- ▶ **Intención (*Intent*)**. Permite realizar acciones y se encarga de notificar a las aplicaciones de varios eventos como cambios de estado en el *hardware*, notificaciones de datos entrantes y eventos en las aplicaciones.
- ▶ **Receptor de anuncios (*Broadcast receiver*)**. Es un componente que responde a los anuncios de difusión en todo el sistema, algunos ejemplos de los que son originadas por el sistema es la notificación de batería baja, llamada entrante, etcétera. Un *broadcast* no tienen interfaz de usuario, pero puede iniciar una actividad para atender a un anuncio.



Básicamente en el desarrollo de la aplicación se emplearon cuatro actividades las cuales son utilizadas para mostrar la interfaz del usuario y en cada actividad se mandan a ejecutar las tareas programadas en los eventos correspondientes a cada componente. También se utilizó un servicio en el que se realiza la captura constante de los datos por el acelerómetro, las Intenciones para notificar de cambios de estado e intercambiar información y un receptor de anuncios para levantar el servicio para capturar datos durante cada lapso de tiempo. En las siguientes secciones se muestra la interfaz diseñada en cada uno de los módulos de la aplicación.

## A.2 Módulo 1: Recolección de datos

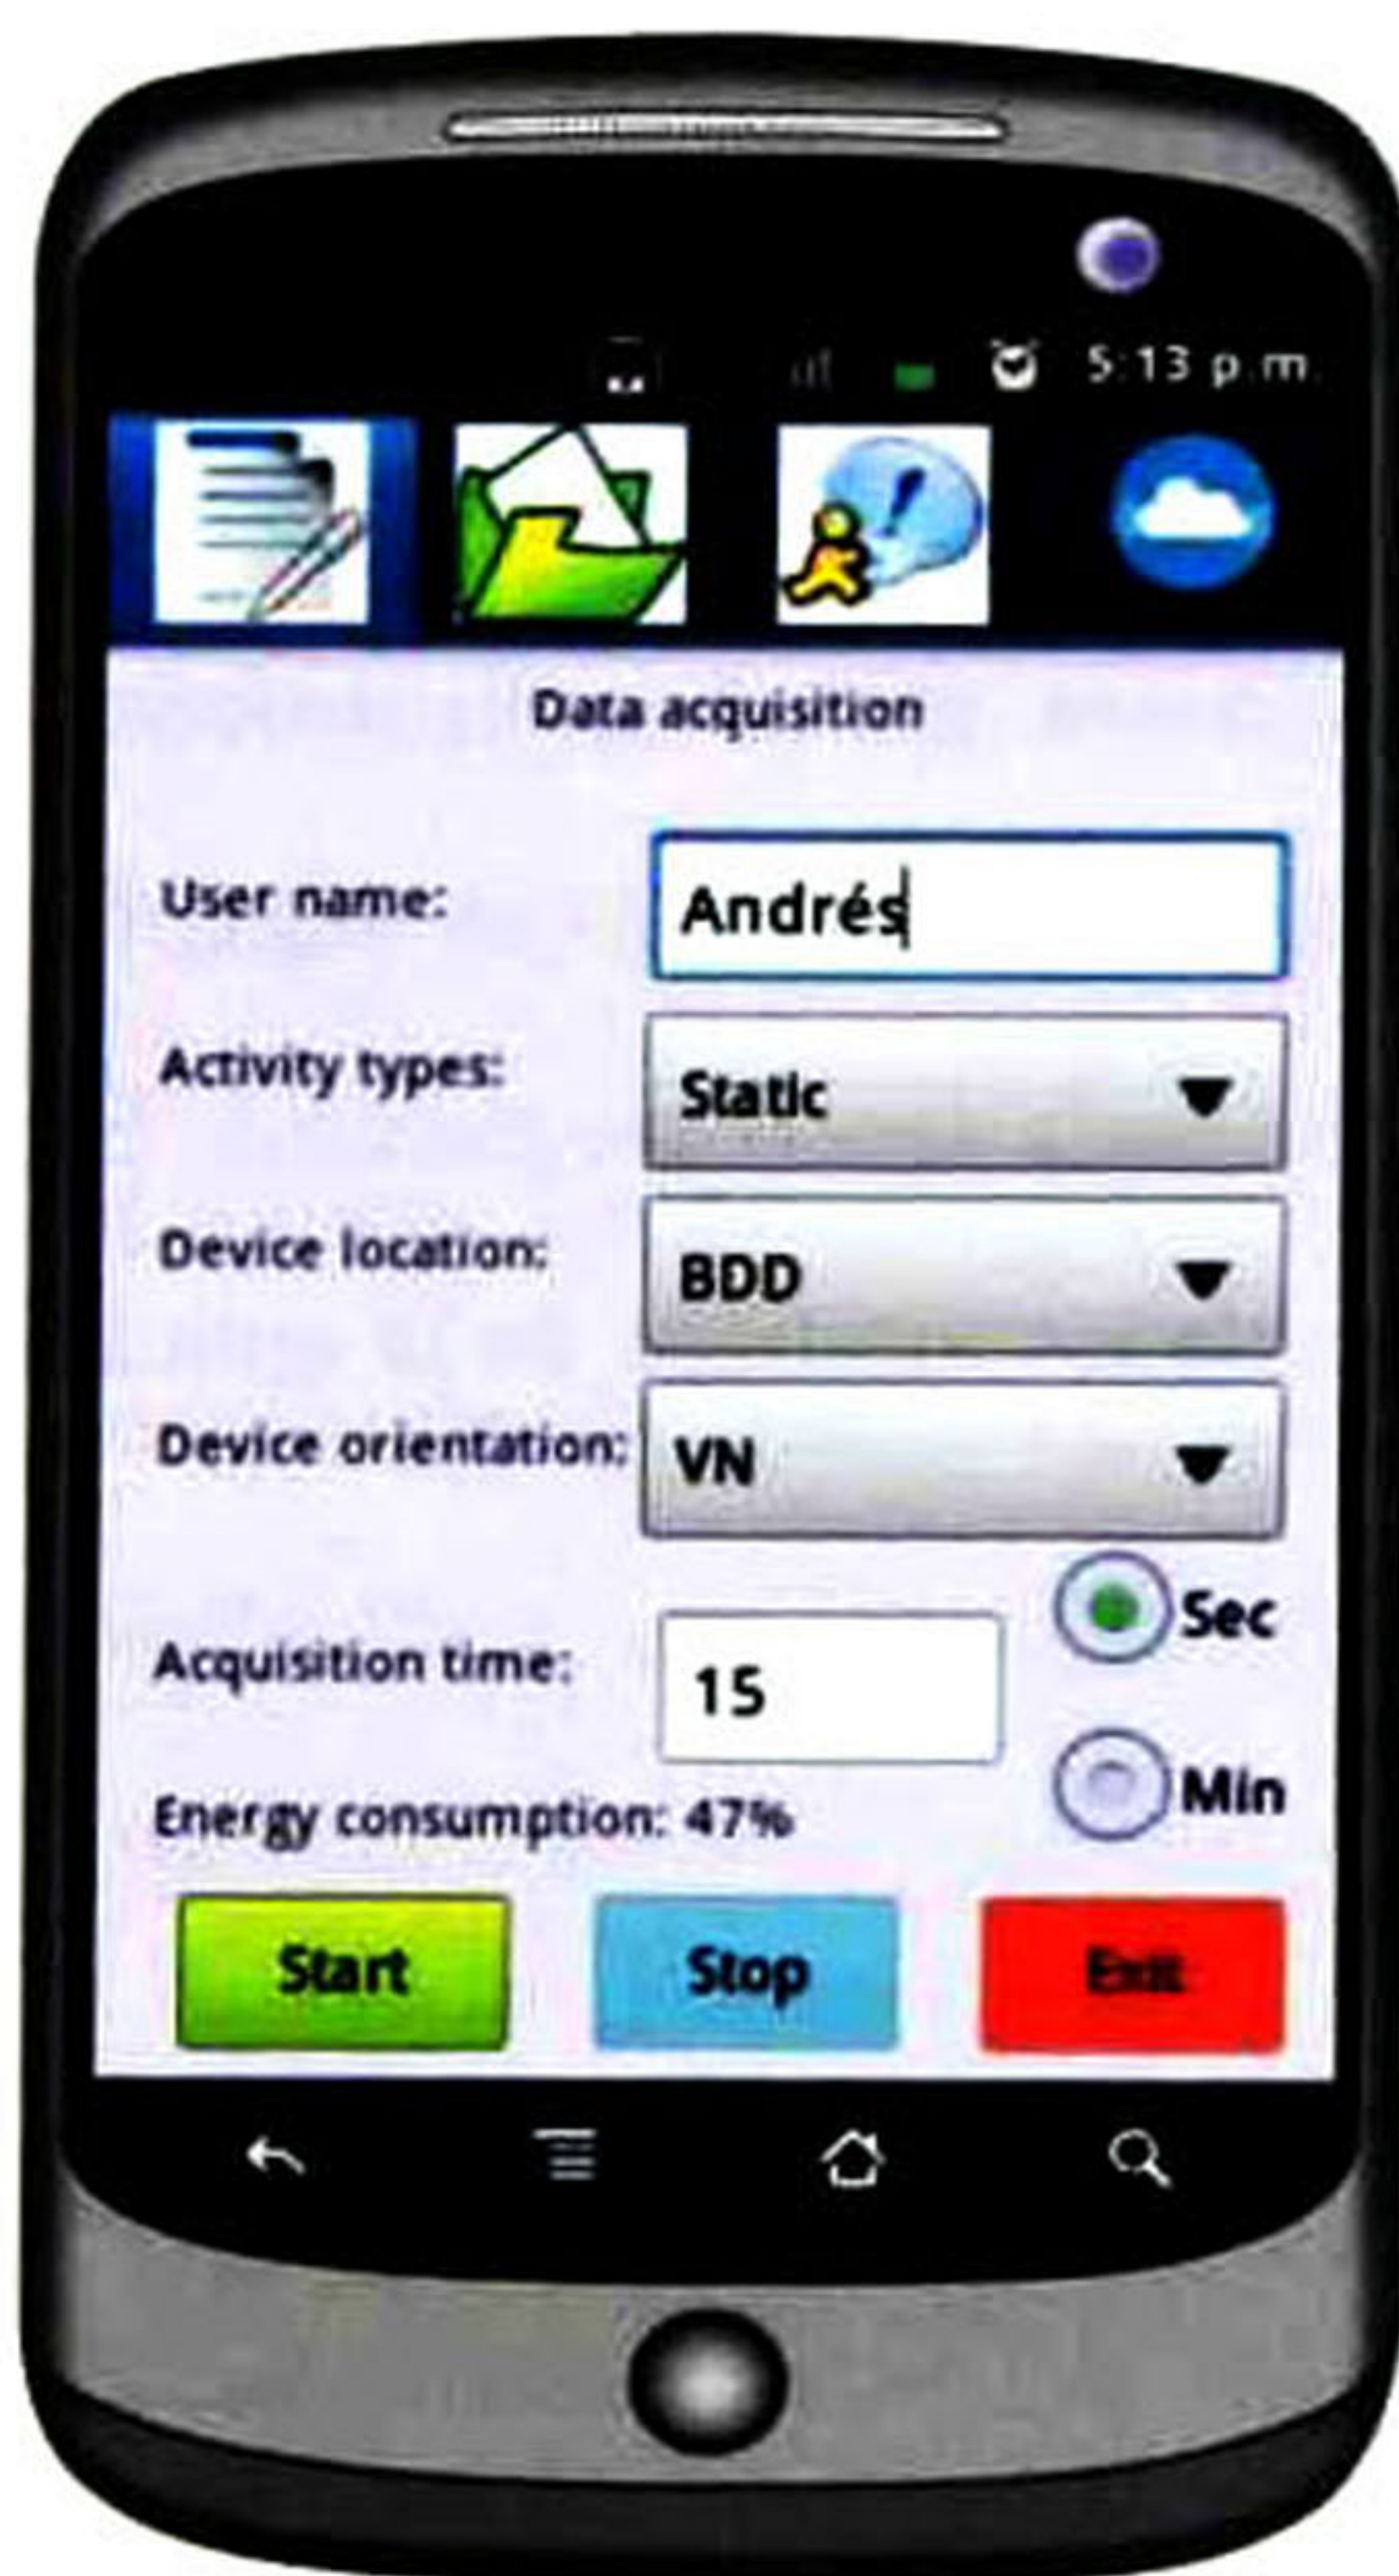
Básicamente lo que se realiza en este módulo es el etiquetado de los datos a recolectar, es decir, se establecen cada uno de los parámetros tales como el nombre del usuario, el tipo de actividad física que se va a realizar, la posición y orientación donde el usuario colocará el smartphone (bolsillo frontal derecho, bolsillo frontal izquierdo, bolsillo posterior derecho y bolsillo posterior izquierdo) y el tiempo en minutos o segundos. La interfaz de la aplicación que se ha diseñado para este primer módulo se ilustra en la Figura A.1 a).

El proceso realizado para la recolección de datos se muestra en el diagrama de la Figura A.1 b). En éste se muestra que a partir de la configuración de los parámetros de entrada, primero se requiere de iniciar un servicio<sup>1</sup> en segundo plano durante el tiempo establecido por el usuario, posteriormente se realizan las lecturas de las muestras por el acelerómetro y finalmente el archivo es guardado en la memoria externa del smartphone.

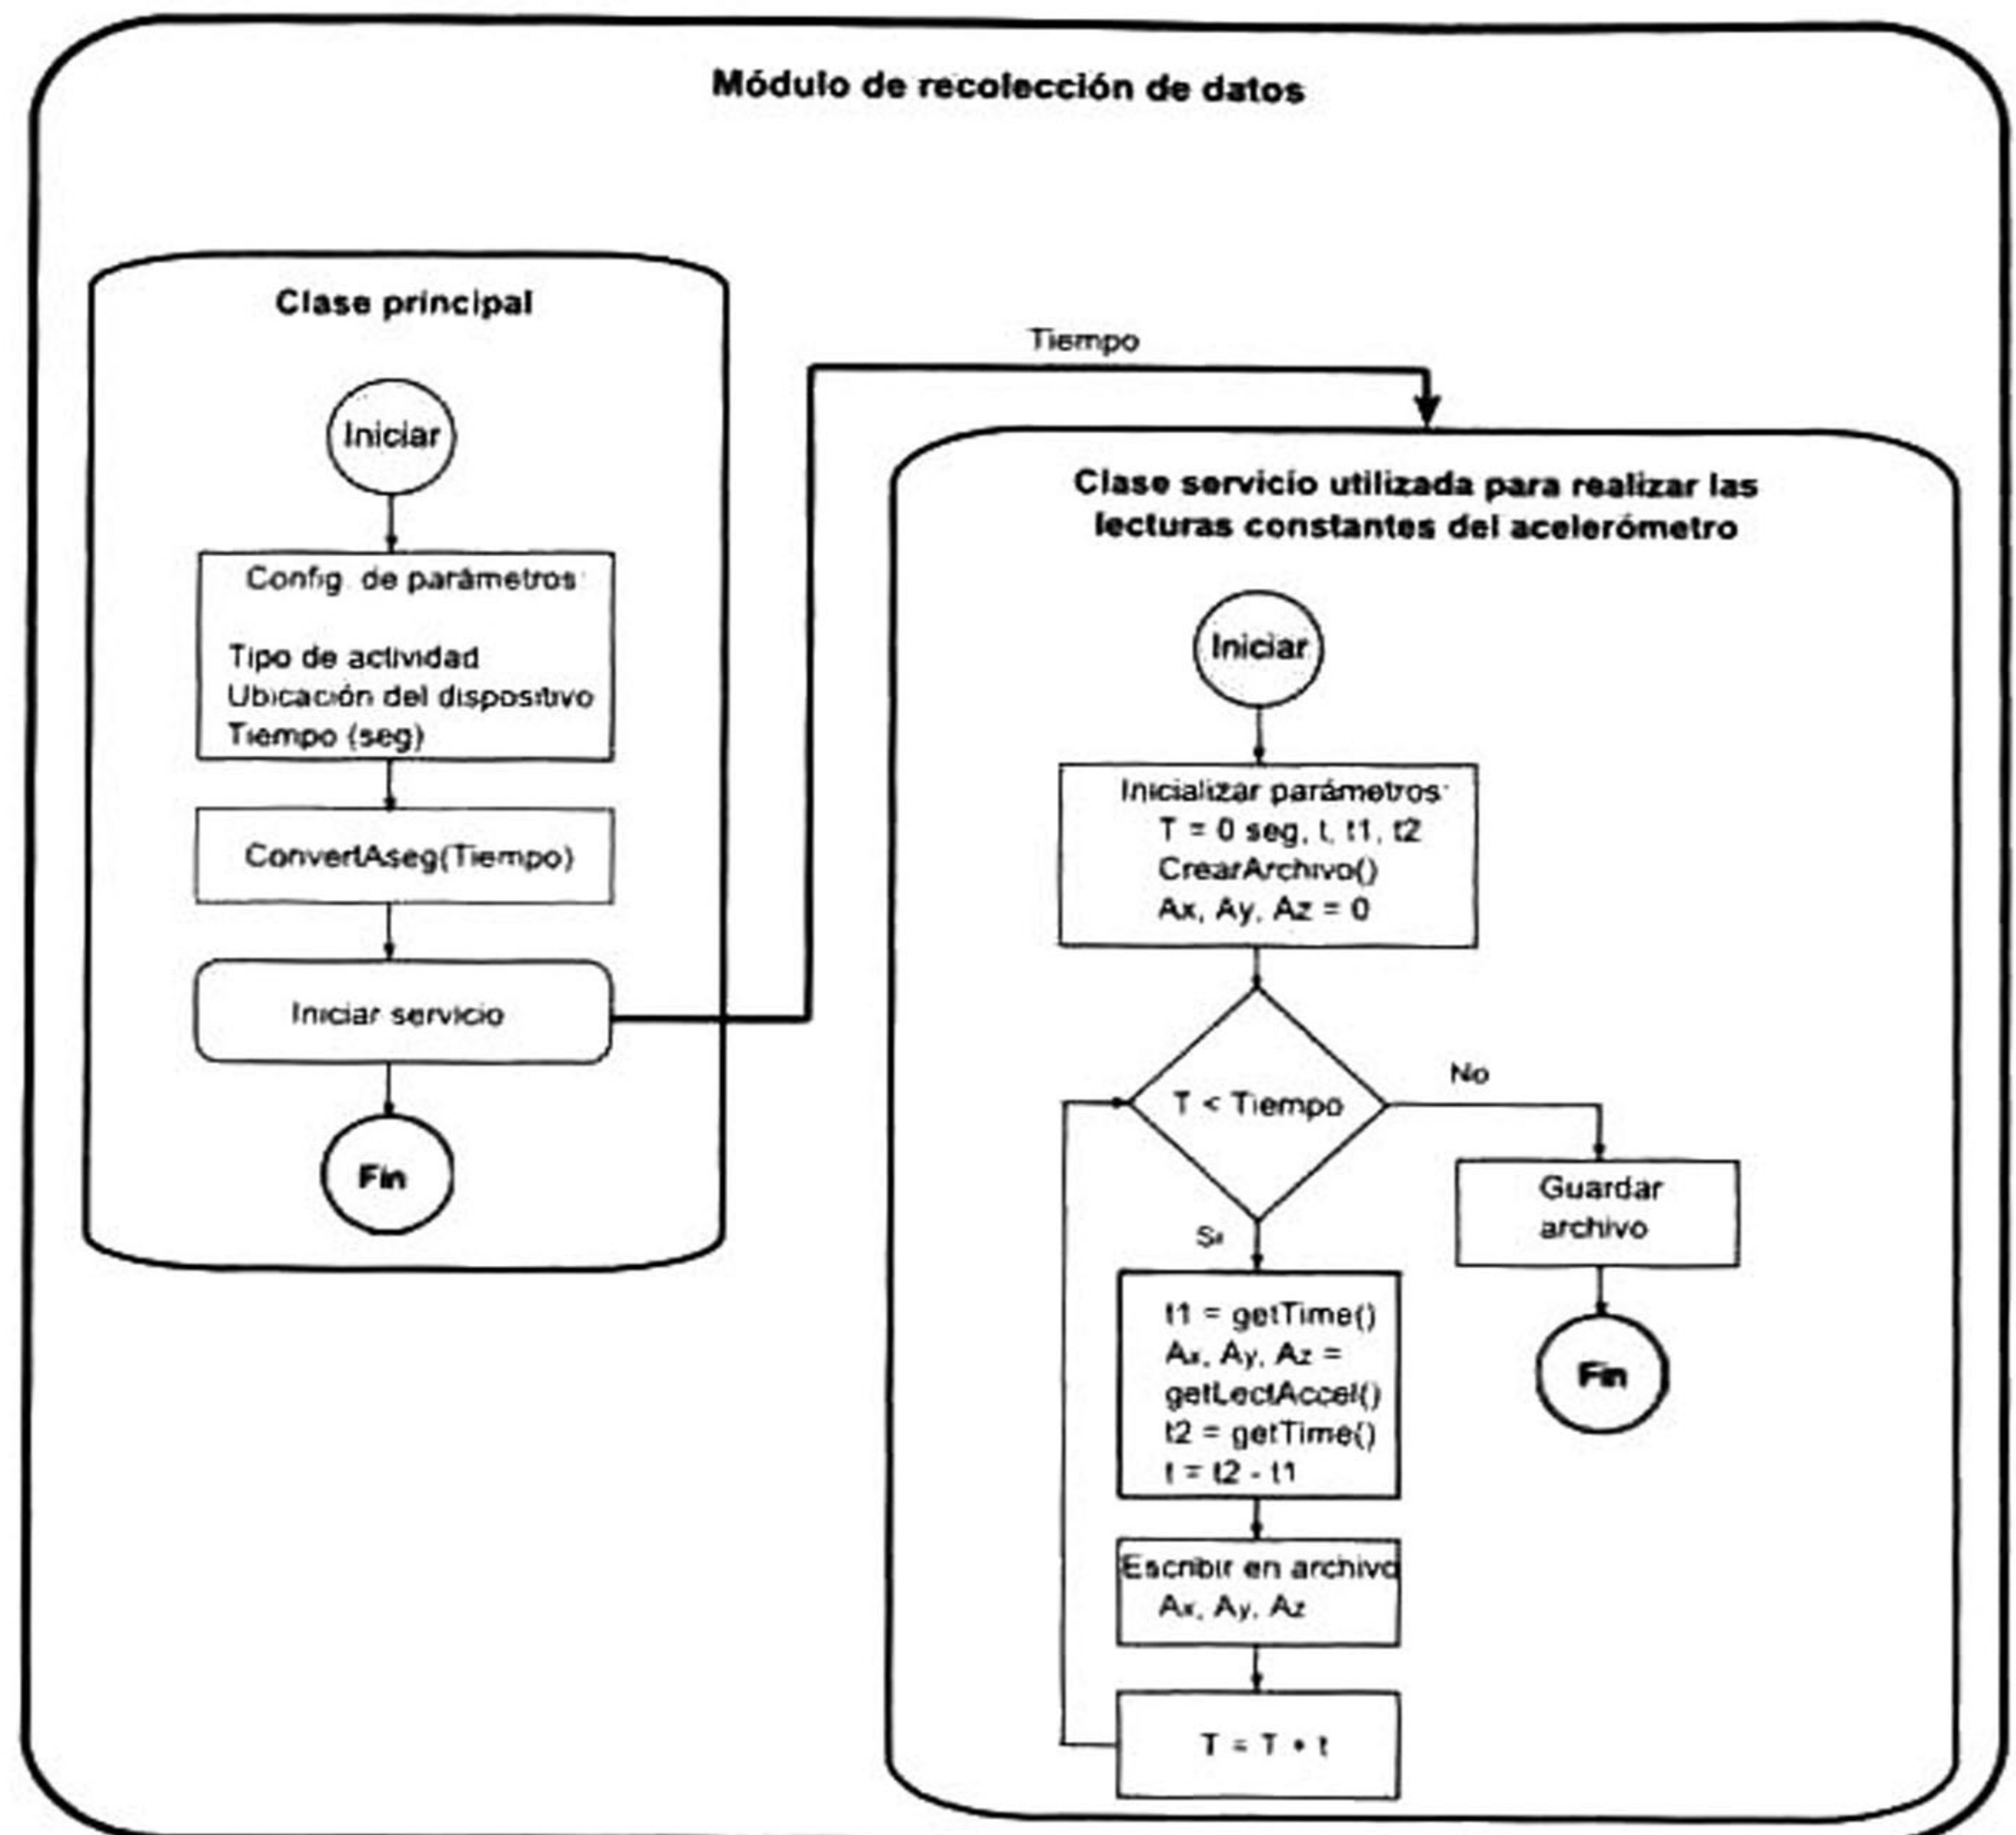
---

<sup>1</sup>Un servicio es un componente de una aplicación móvil utilizada para realizar una operación de mayor duración donde no se interactúa con el usuario [78].





a) Interfaz del usuario empleada para la recolección de datos



b) Diagrama de flujo para la recopilación de datos.

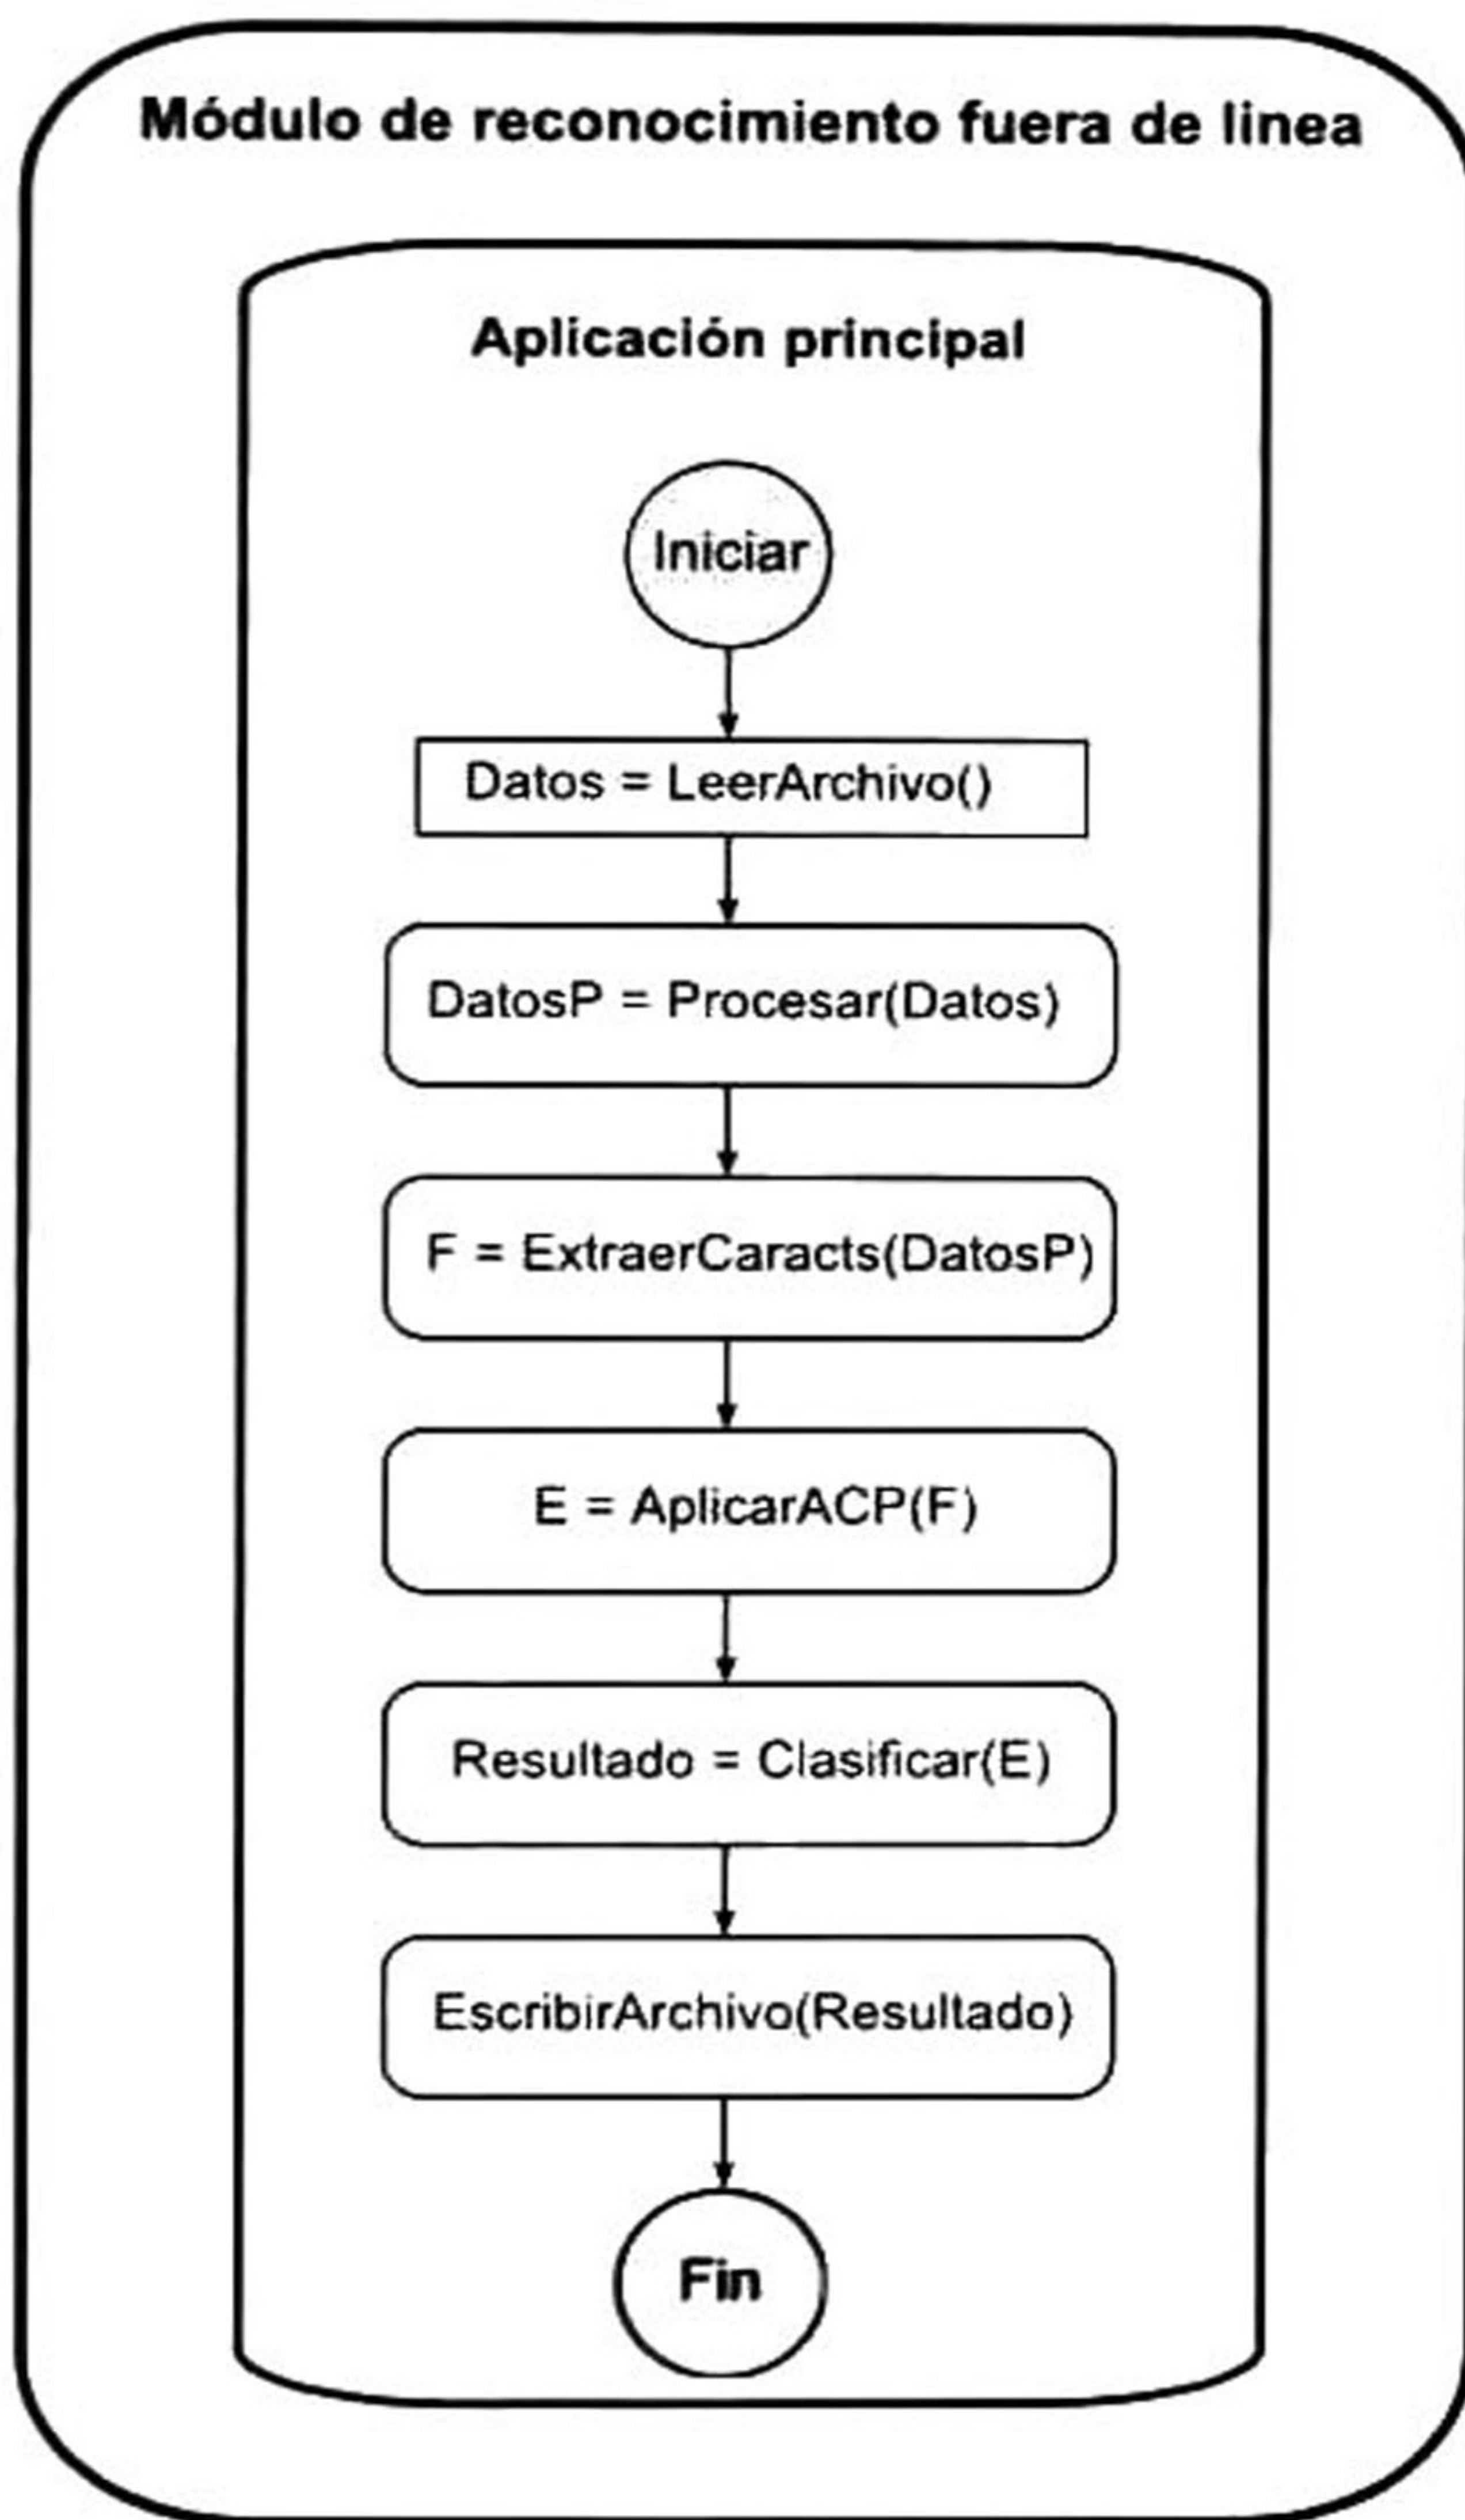
Figura A.1: Módulo 1 diseñado para la recolección de datos.

## A.3 Módulo 2: Reconocimiento fuera de línea

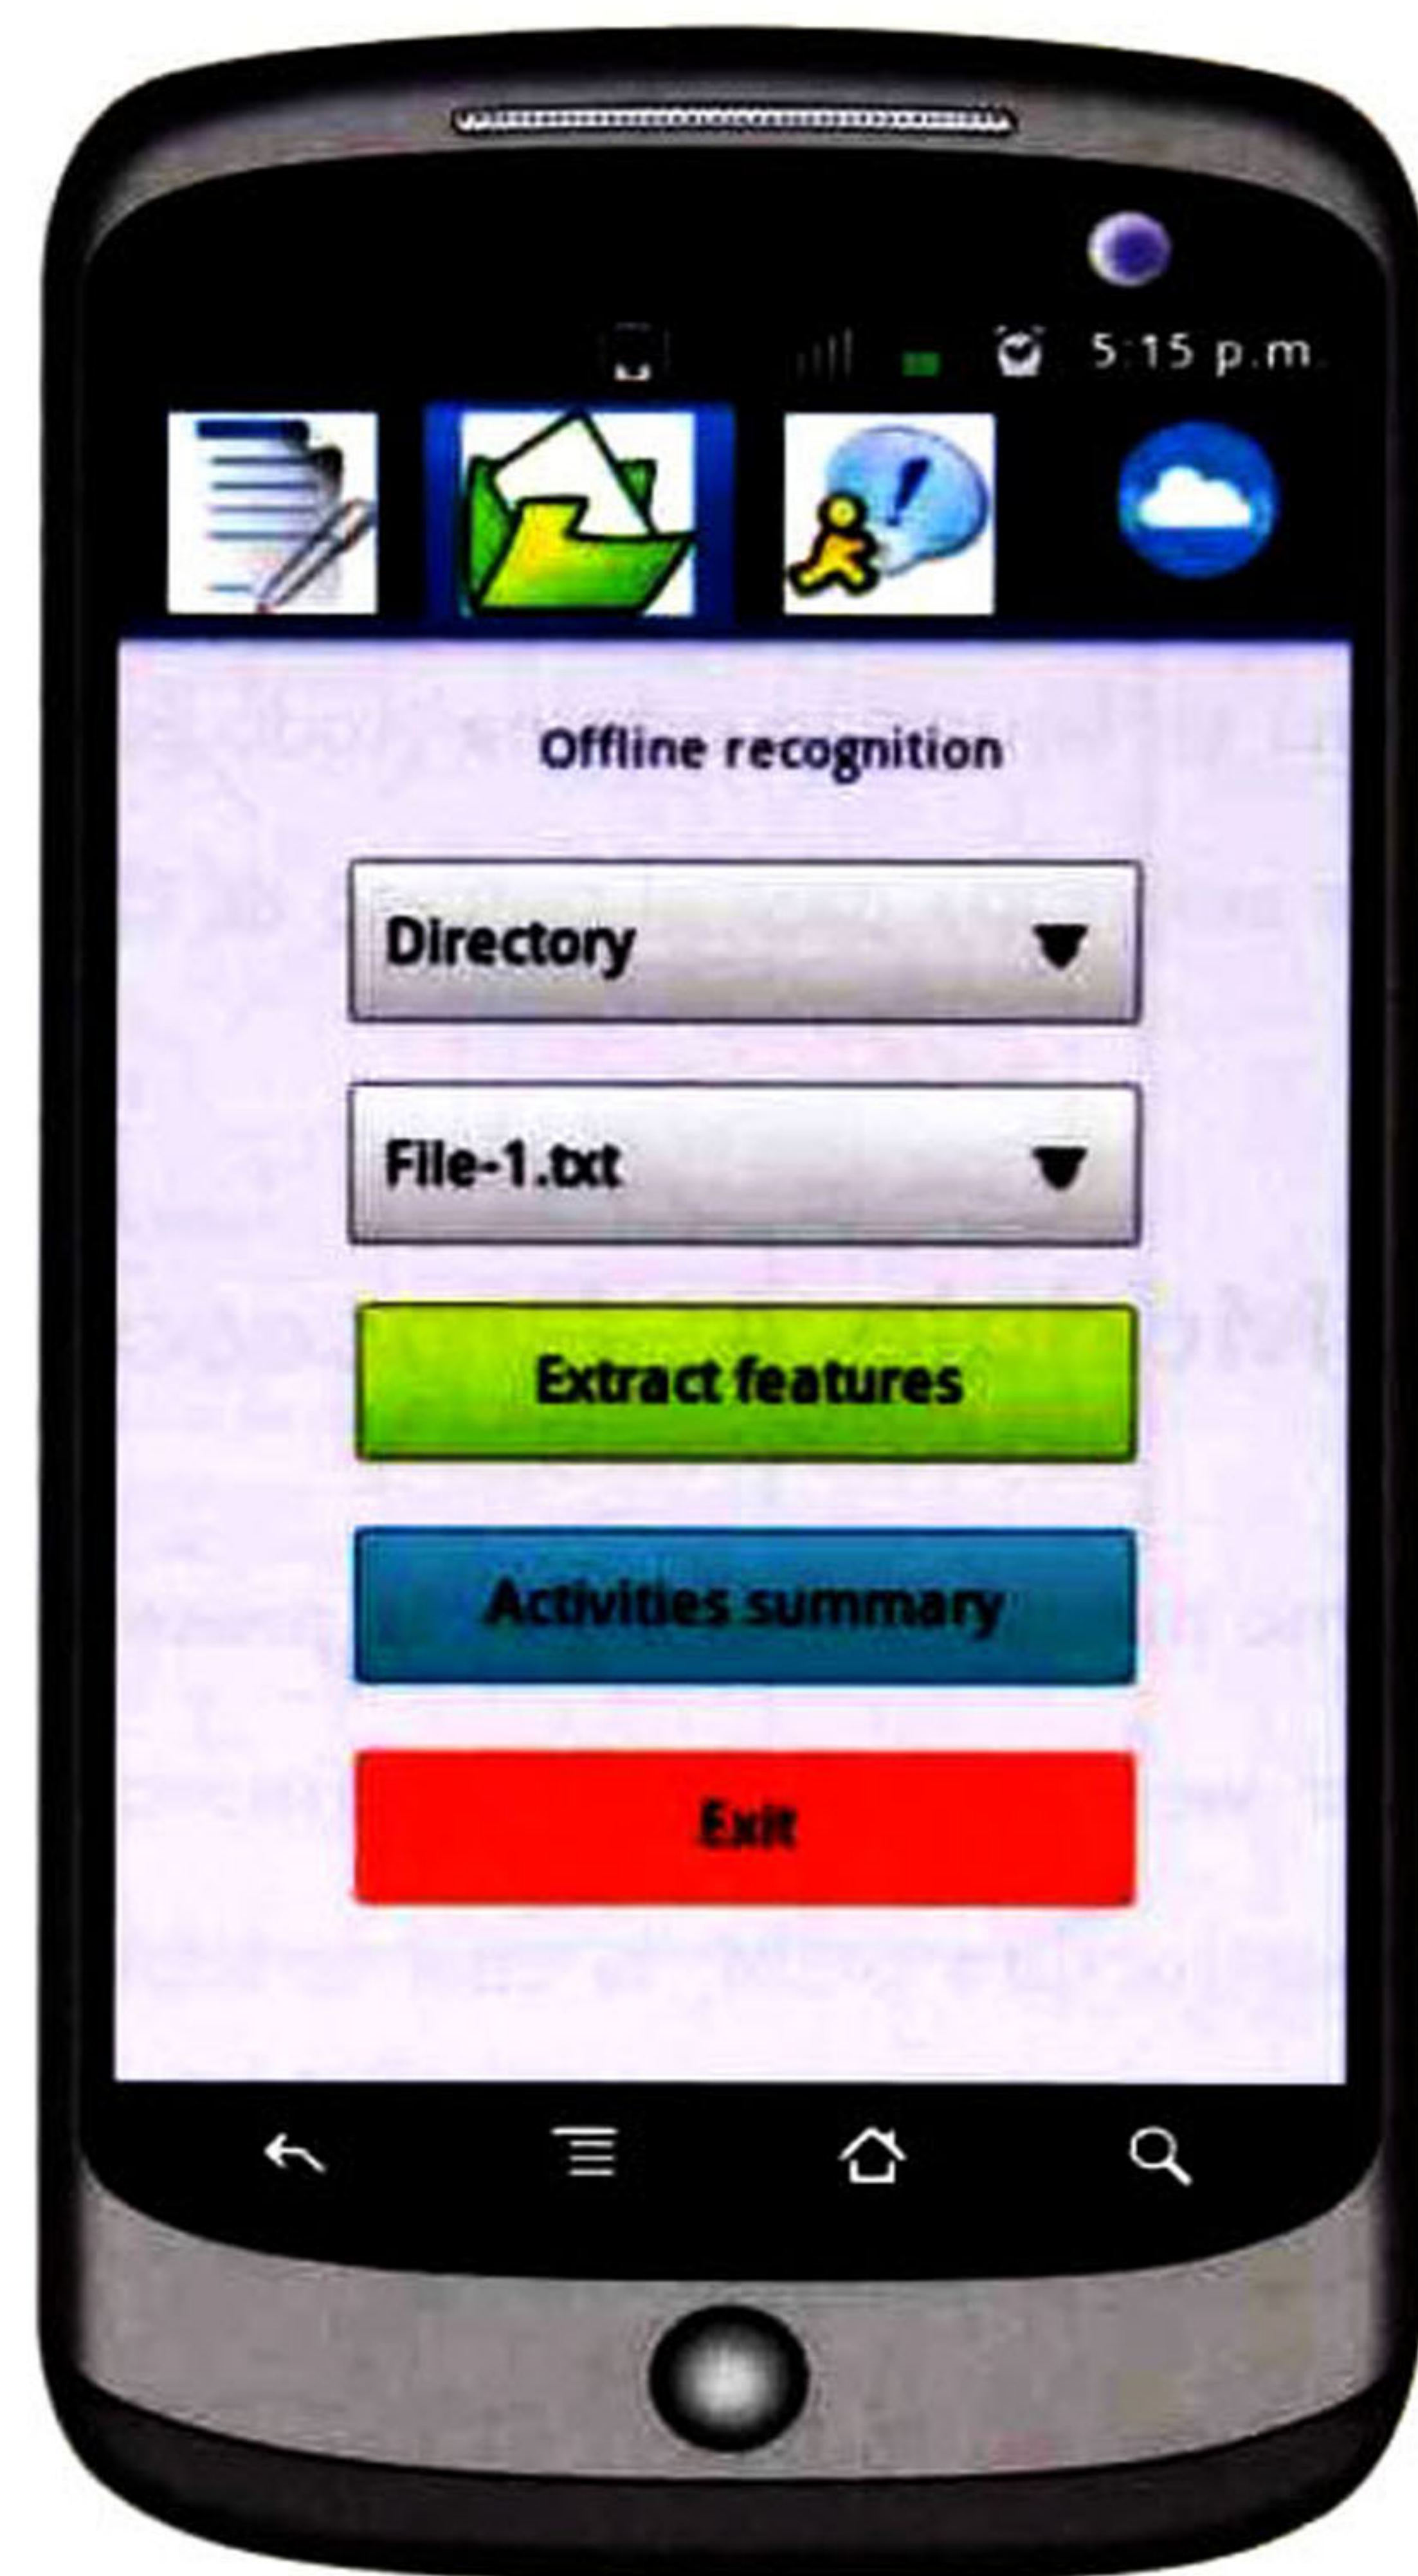
Este módulo tiene por objetivo validar que el sistema de reconocimiento de actividades esté obteniendo los mismos resultados, al igual que la versión que se desarrolló para una máquina de escritorio. Una vez organizado el conjunto de datos a validar, se realizan los pasos mostrados en el diagrama de la Figura A.2 a). En primer lugar se leen los datos archivo por archivo, posteriormente se les aplica un preprocesamiento a los datos, en seguida se extraen las características seleccionadas, luego se aplica el método de ACP y finalmente se emplea el método de clasificación propuesto. Los resultados son almacenados y evaluados con las métricas descritas en la sección 4.2.4.



Adicionalmente en este módulo también se realizó la estimación de los tiempos de cómputo que se describieron en la sección 4.3.2. Básicamente los tiempos fueron obtenidos al inicio y al final de cada etapa, empleando funciones propias del lenguaje java. Los resultados obtenidos eran mostrados a través de un cuadro de dialogo. Para este módulo, el diseño de la interfaz realizada se ilustra en la Figura A.2 b).



a) Diagrama de flujo



b) Interfaz de la aplicación

Figura A.2: Proceso empleado para el reconocimiento de actividades fuera de línea.



## A.4 Módulo 3: Reconocimiento en línea

El proceso de reconocimiento en línea consiste en discriminar el tipo de actividad física según la realice el usuario, esto es, a partir de las primeras 200 muestras capturas por el acelerómetro o la primera ventana de tiempo (5 segundos) un proceso o hilo es lanzado para ejecutar la tarea de clasificación. Ésto se repite constantemente hasta que el tiempo definido por el usuario termine. El diagrama de la Figura A.3 muestra los pasos de como se realiza esta tarea. El usuario define el tiempo durante el cual realizará la actividad física, a partir de ésto un ciclo es ejecutado hasta que el tiempo definido por el usuario se termine, dentro del primer ciclo a su vez se ejecuta otro, el cual consiste en recabar los datos por el acelerómetro hasta completar las 200 muestras, una vez completado las 200 muestras se realiza la discriminación de la actividad realizada y el resultado (etiqueta de la actividad) se almacena en la unidad externa (todo ésto se realiza a través de un proceso independiente (hilo)). La interfaz empleada para el proceso de clasificación en línea se ilustra en la Figura A.4.

## A.5 Módulo 4: Proceso de notificación

El último módulo corresponde al proceso empleado para enviar un mensaje de notificación, desde un servidor web a uno o muchos dispositivos móviles. Básicamente el proceso se realiza a través de la infraestructura GCM, la cual es soportada por diversas plataformas móviles como *Apple iOS*, *Windows Mobile*, *Android*. Los componentes requeridos para su implementación son:

- ▶ Los servidores (infraestructura) de *Google Cloud Messaging*.
- ▶ Una aplicación móvil ejecutándose en un dispositivo (para este caso Android versión 2.3 o superior)
- ▶ Un Servidor, para este trabajo se utilizó el *Google App Engine (GAE)*



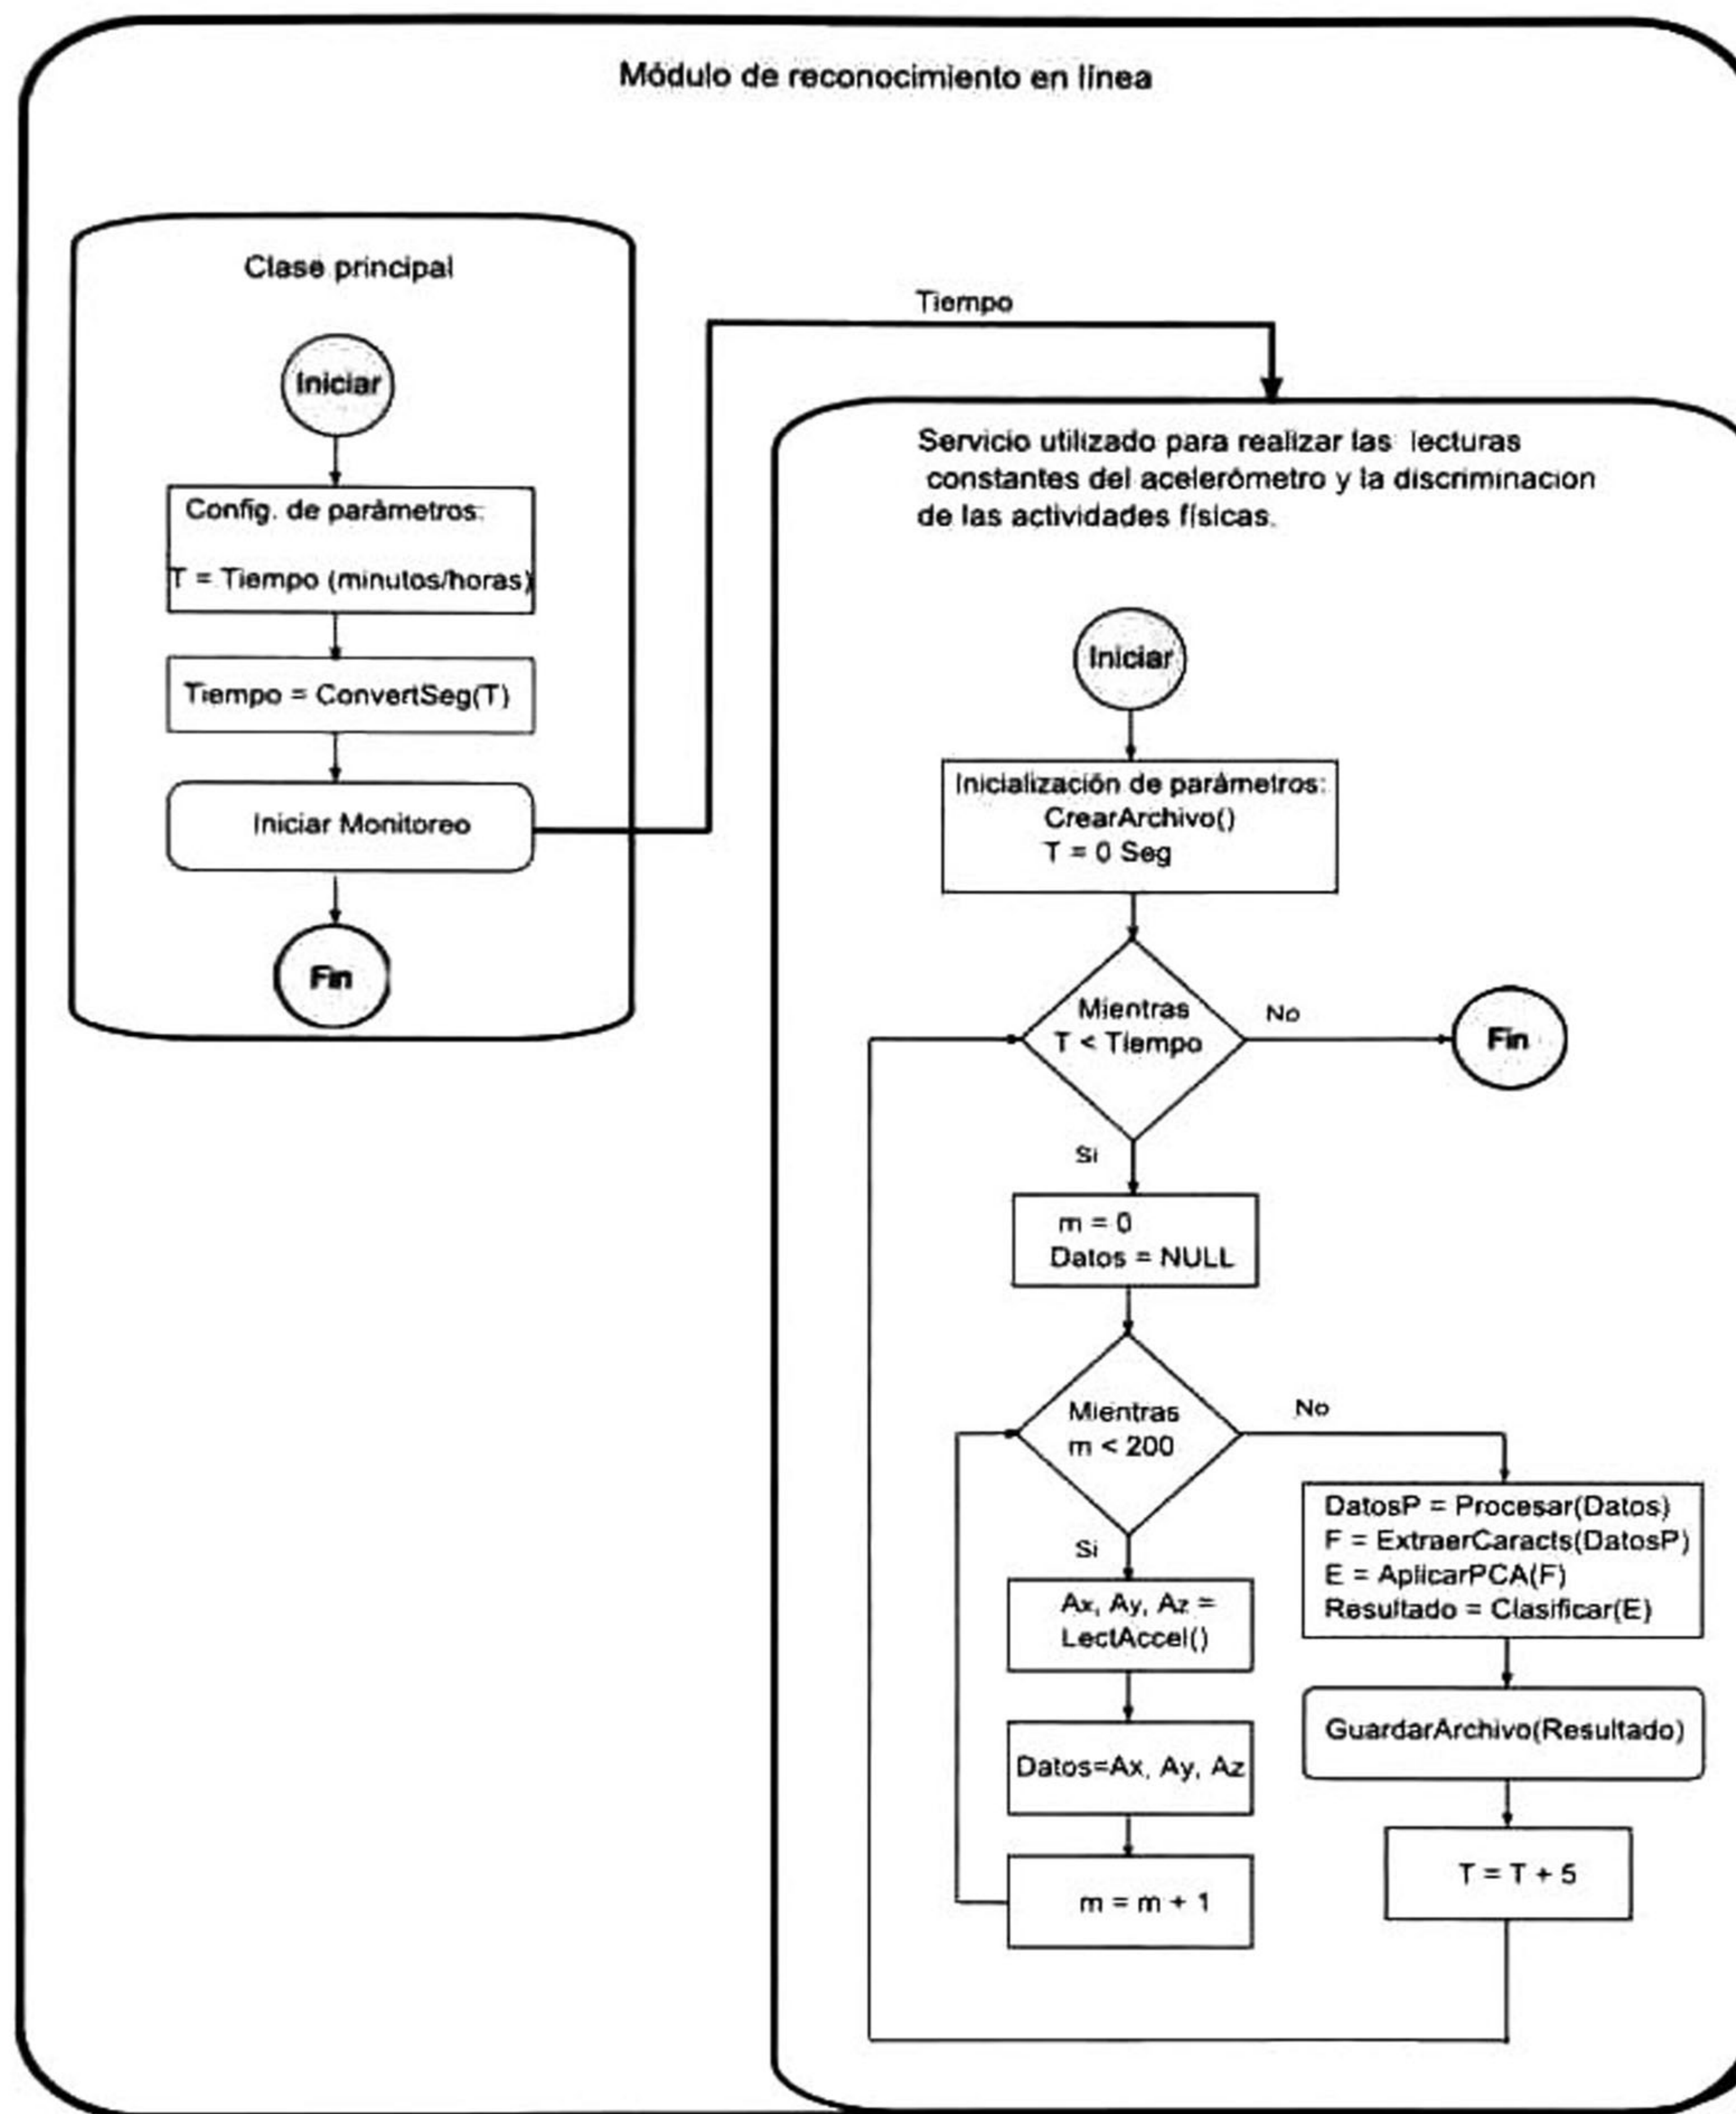


Figura A.3: Módulo de Clasificación en línea.

Los pasos para su implementación consisten en registrar e identificar a la aplicación móvil, al servidor GAE y a los smartphones participantes en la plataforma GCM. En primera instancia, la aplicación móvil debe ser inscrita a través de una solicitud directa a GCM <sup>2</sup>, obteniendo un ID de emisor (sender ID).

<sup>2</sup>4Sitio web de GCM <http://developer.android.com/guide/google/gcm/index.html>





Figura A.4: Interfaz empleada para el proceso de clasificación en línea.

Después el smartphone debe ser registrado a través de algunos métodos empleados en la aplicación móvil, recibiendo como respuesta un ID de registro (este ID debe ser compartido con el servidor GAE ya que es utilizado para indicar el dispositivo destino al enviar una notificación). Finalmente, el servidor GAE es registrado utilizando la consola de API's de Google <sup>3</sup>, obteniendo una API key que le autorizará para el envío de notificaciones. Gráficamente el resumen de este proceso se muestra en la Figura 4.6.

Una vez registrados los tres elementos, el proceso de envío de notificaciones es iniciado por el servidor GAE a través de una petición *POST* que debe incluir:

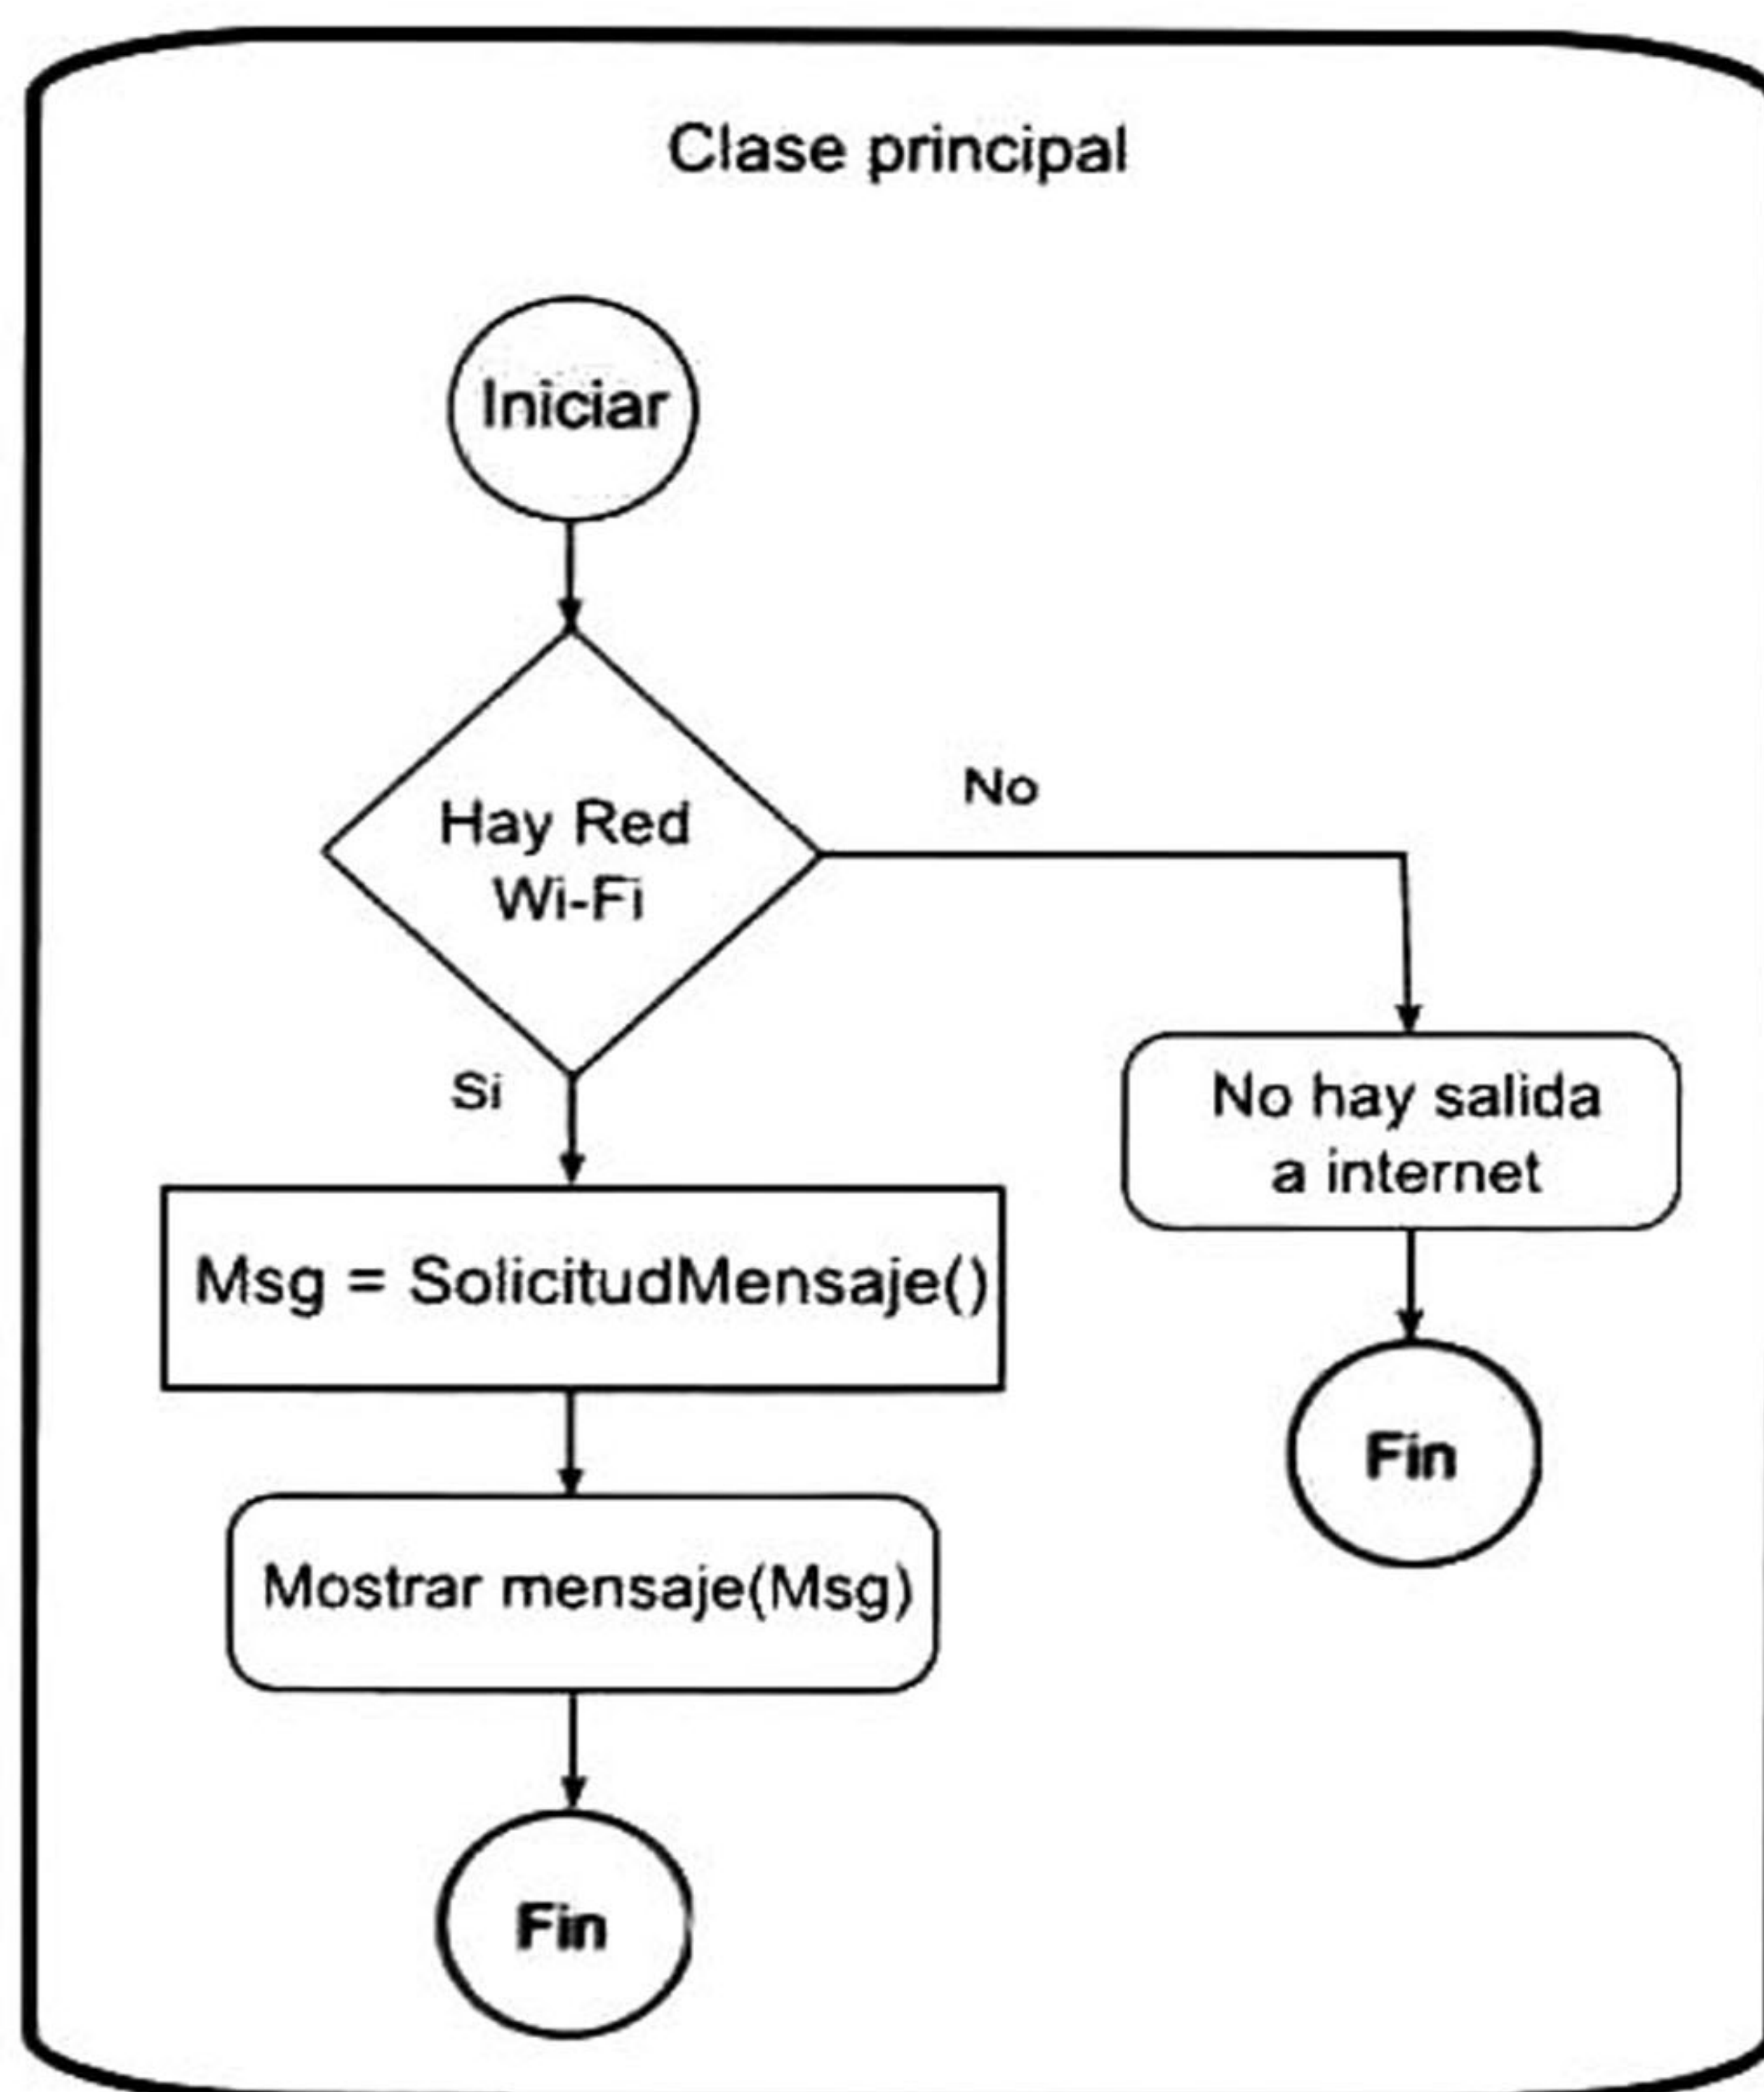
- ▶ La API key del servidor.
- ▶ El ID de registro del smartphone destino.
- ▶ El mensaje deseado.

<sup>3</sup>API Access, <https://code.google.com/apis/console/>

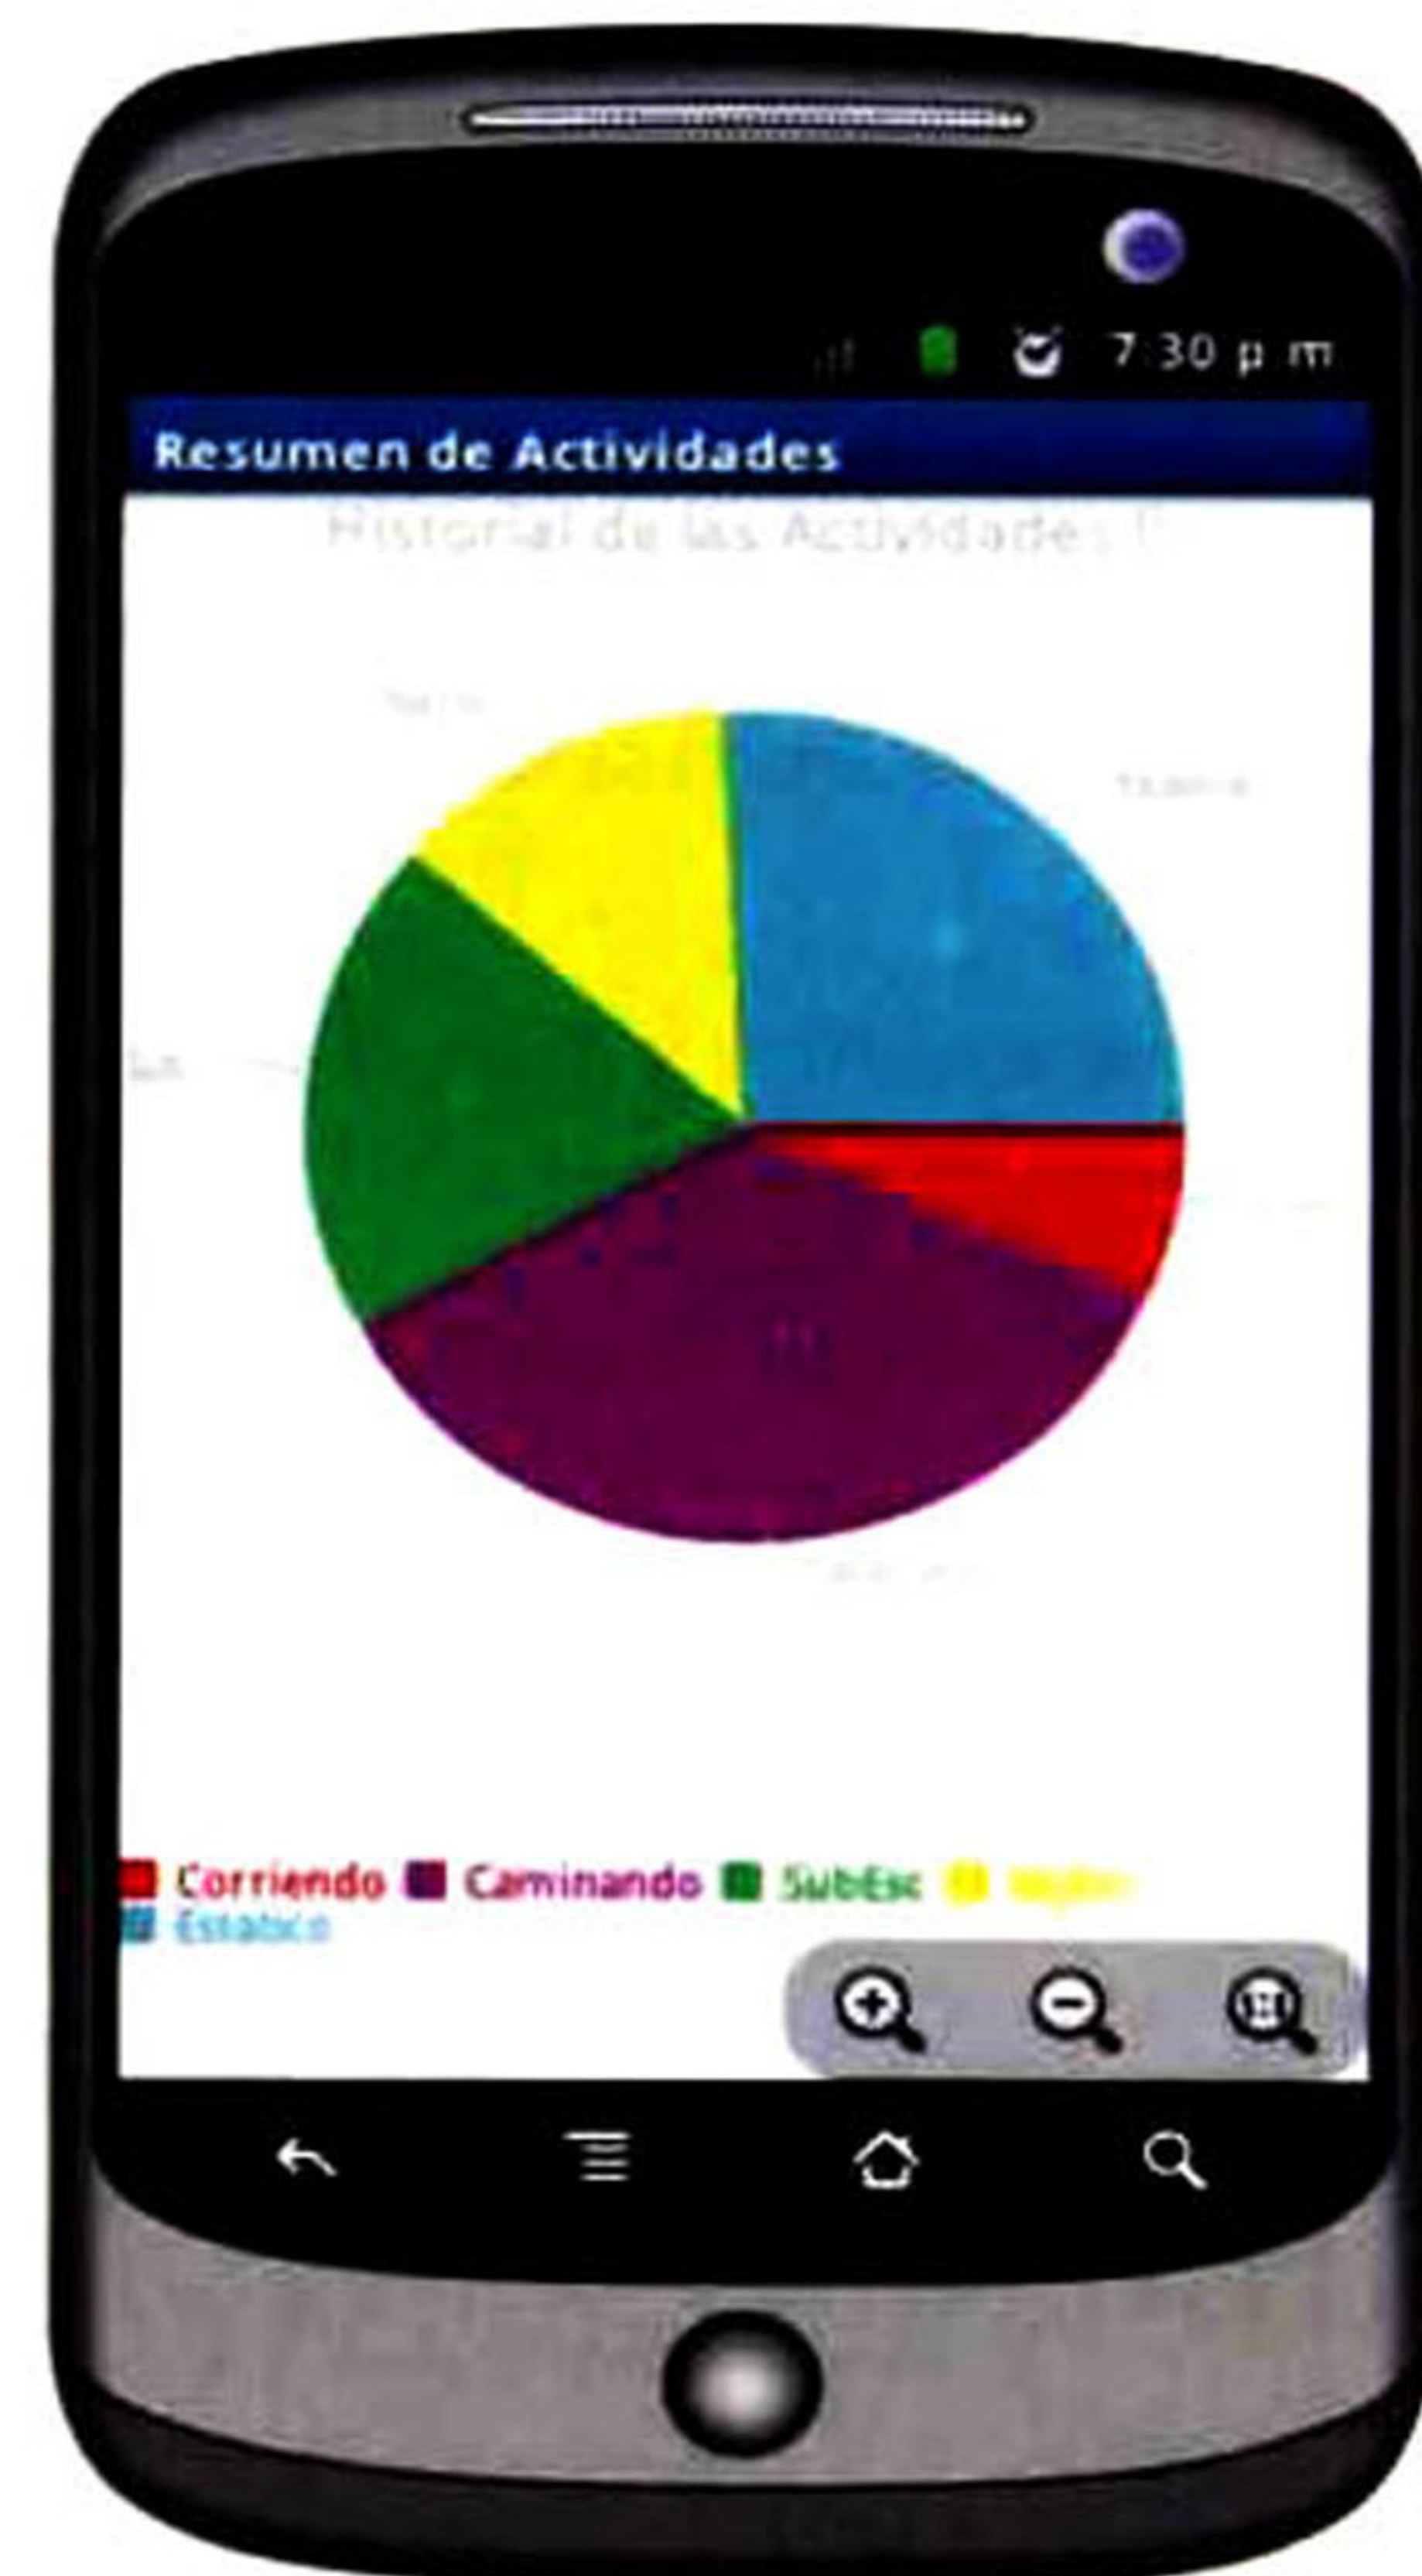


Un aspecto importante a considerar es el tamaño del mensaje a enviar como notificación (payload), debido a solo tiene como límite 4096 bytes. Particularmente se ha considerado un tamaño de mensaje por debajo de los 200 bytes lo suficiente para transmitir la información de interés.

El módulo utilizado en la aplicación móvil, prácticamente consiste en escuchar constantemente hasta recibir un mensaje de notificación enviado desde el servidor GAE. Para ello se realiza el proceso ilustrado en la Figura 4.6 y posteriormente el mensaje se muestra en la aplicación del dispositivo, éste procedimiento se muestra en la Figura A.5 a). También se ha diseñado una interfaz donde el usuario puede consultar explícitamente el historial de las actividades realizadas durante todo un día, un ejemplo de esto se observa en la Figura A.5 b).



a) Interfaz del módulo de notificación



b) Módulo de notificación

Figura A.5: Diseño e interfaz del módulo de notificación.



## A.6 Diseño de la aplicación web

Una parte complementaria de la aplicación móvil, consistió en desarrollar un sistema web, el cual atendiera las peticiones solicitadas por dicha aplicación. Básicamente las peticiones solicitadas al servidor consisten en que éste almacene el historial de las actividades discriminadas por el sistema de reconocimiento implementado en el móvil y también que notifique a la aplicación del móvil a partir de una determinada condición. Por ejemplo, si un usuario pasa estáticamente un tiempo determinado el servidor enviará un mensaje de alerta a la aplicación móvil.

El diseño del sistema web se realizó con la infraestructura del cómputo en la nube ofrecida por *Google App Engine (GAE)*. De manera general GAE permite desarrollar aplicaciones que se ejecuten de forma fiable, incluso con pesadas cargas de trabajo y grandes cantidades de datos [79]. Algunas de las funciones ofrecidas por esta infraestructura son:

- ▶ Servidor web dinámico, totalmente compatible con las tecnologías web más comunes.
- ▶ Almacenamiento permanente con funciones de consulta, clasificación y transacciones.
- ▶ Escalado automático y distribución de carga.
- ▶ API para autenticar usuarios y enviar correos electrónicos a través de Google Accounts.

La aplicación web desarrollada, accede a la mayoría de los servicios del GAE a través de la API estándar de Java y los datos se almacenan a través del JDO (Objetos de datos Java) del SDK Java. El esquema de comunicación entre la aplicación móvil y la aplicación Web se realiza mediante solicitudes HTTP (o HTTPS) en los puertos estándares.

El diseño de la interfaz web que se realizó consta de tres partes: el proceso de autenticación como usuario registrado (usuario y contraseña), un módulo de registro para un nuevo usuario, la página principal donde se muestra el historial de las actividades almacenadas y un módulo de despliegue para visualizar los usuarios registrados.



El diseño de las páginas de cada una de las partes de la aplicación web se ilustran en las Figuras A.6. Cabe resaltar que en el contenido de la página principal ilustra gráficamente el porcentaje de cada una de las actividades realizadas por un usuario durante un día y también se muestra una tabla que contiene las etiquetas de cada actividad, el número asociado a cada actividad y la fecha y hora en que fue realizada la actividad.

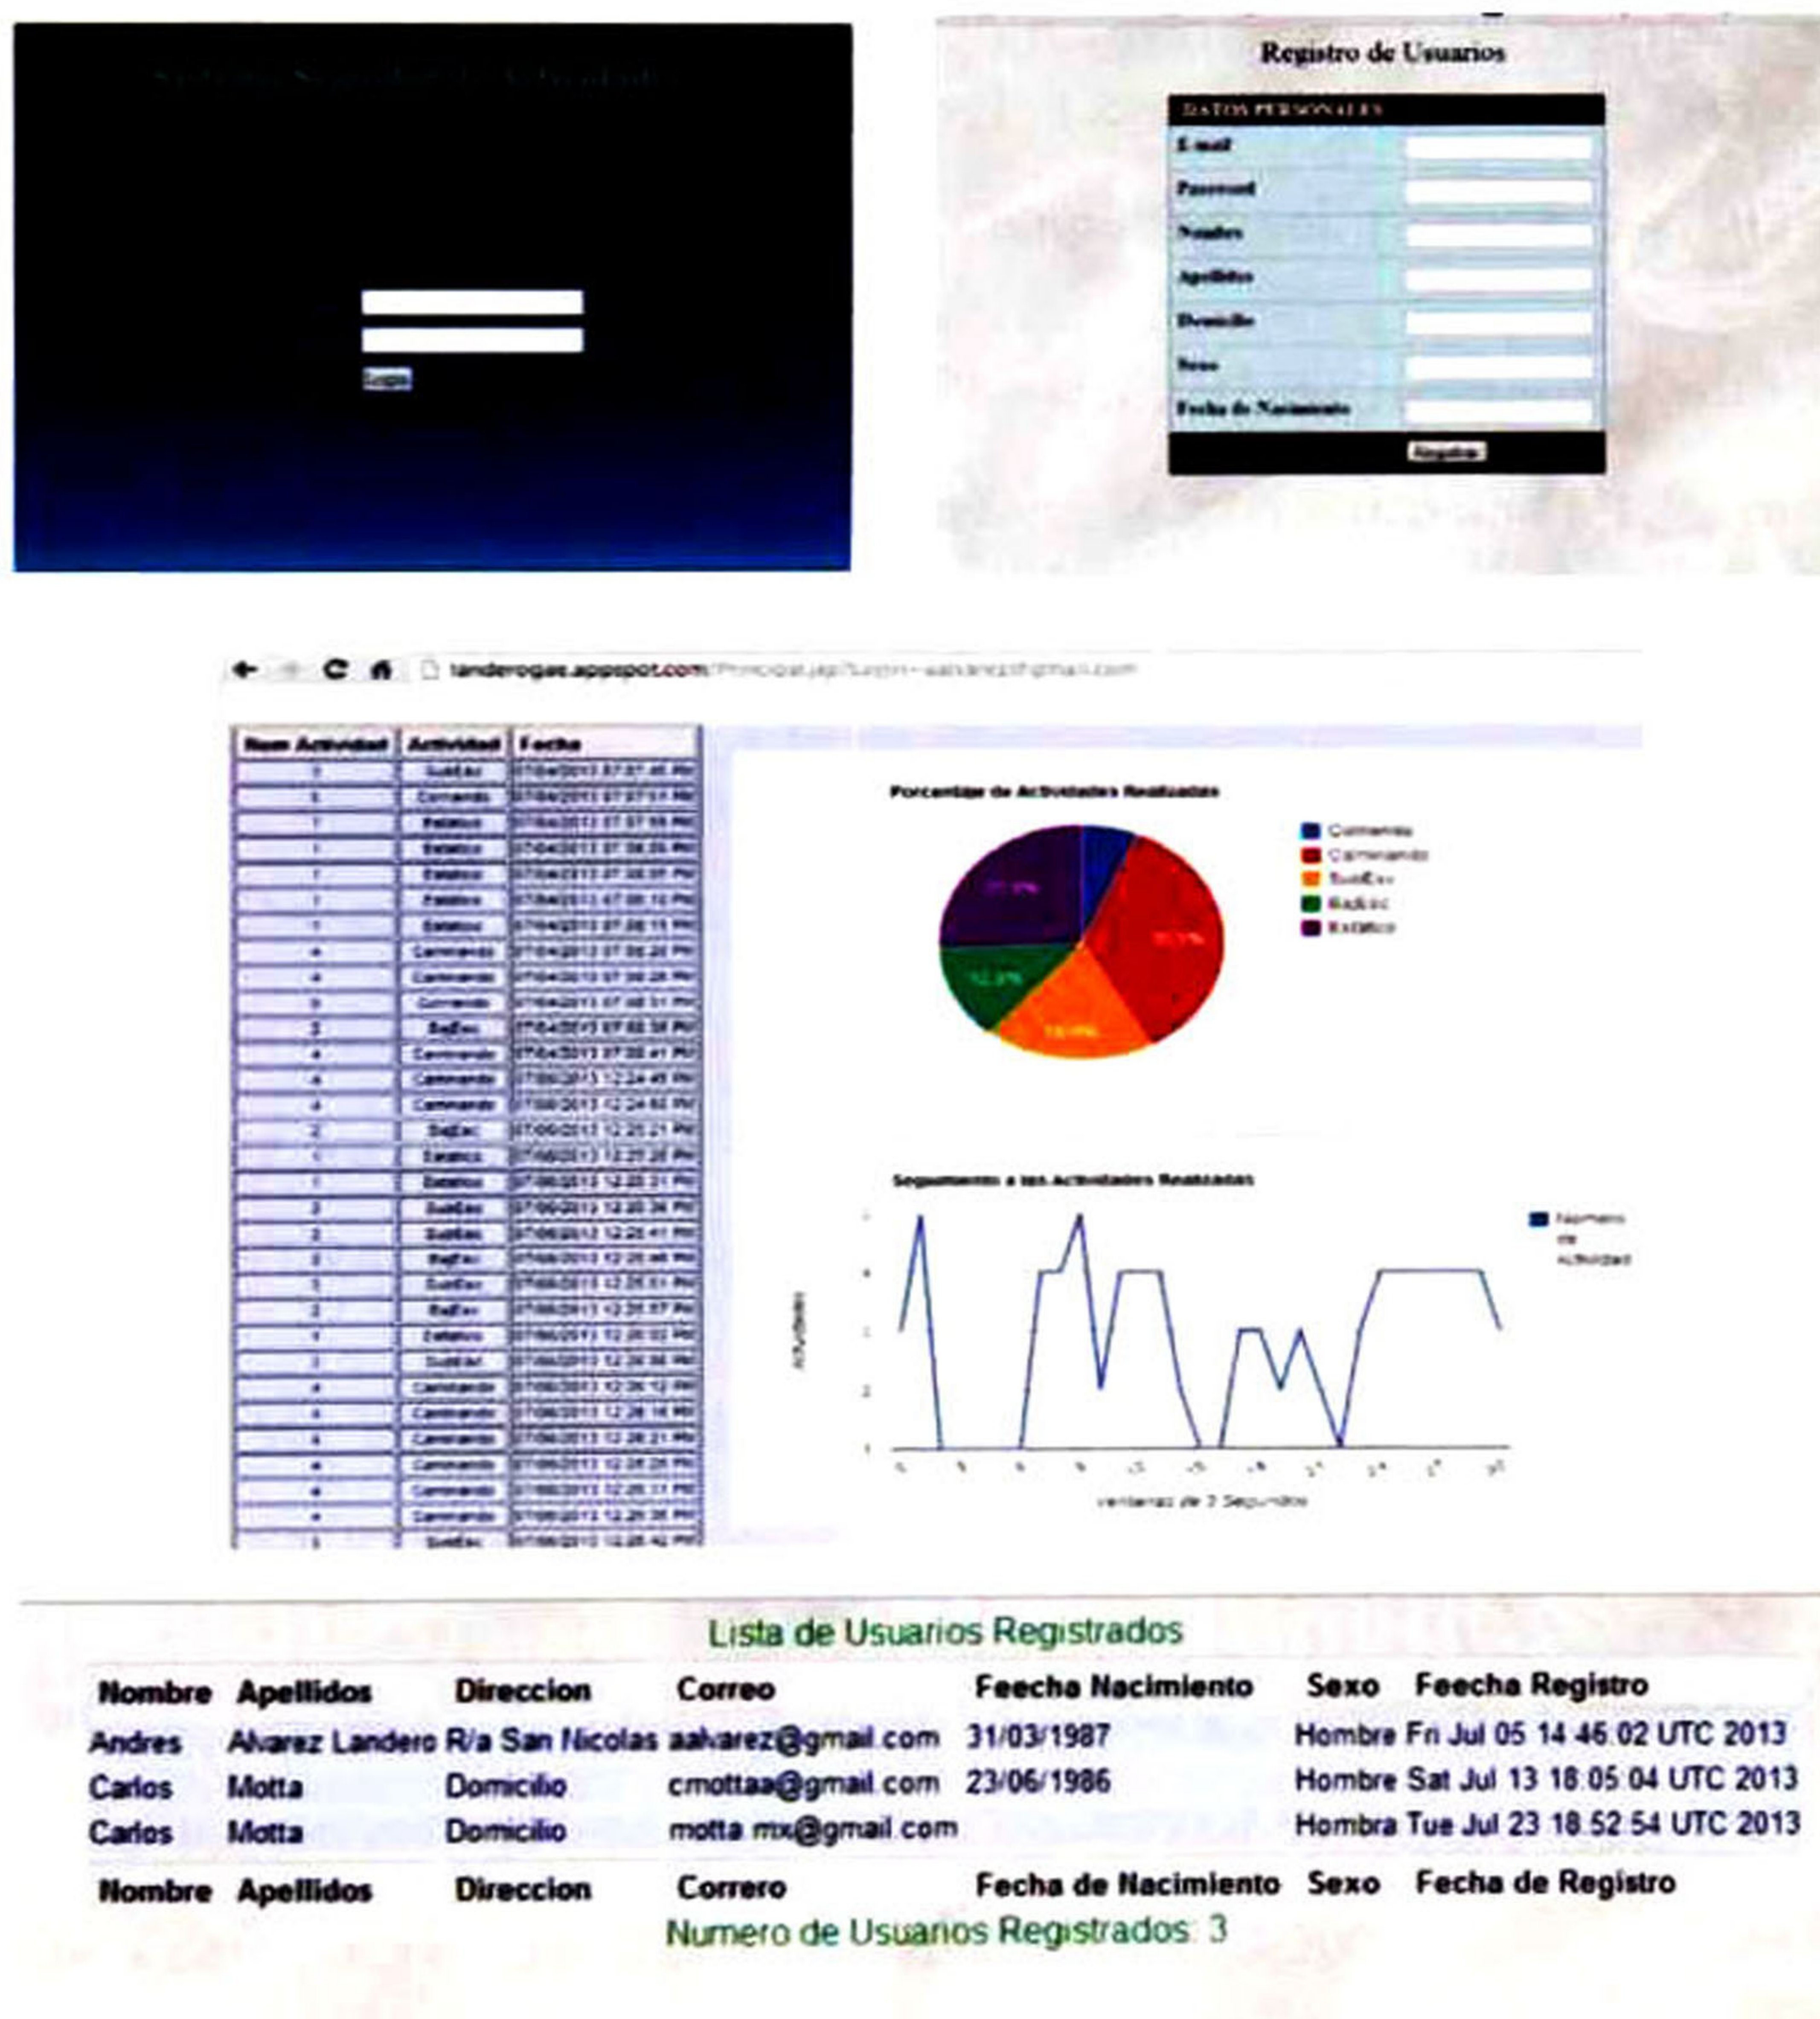


Figura A.6: Interfaz gráfica del sistema Web.



El diseño de las páginas de cada una de las partes de la aplicación web se ilustran en las Figuras A.6. Cabe resaltar que en el contenido de la página principal ilustra gráficamente el porcentaje de cada una de las actividades realizadas por un usuario durante un día y también se muestra una tabla que contiene las etiquetas de cada actividad, el número asociado a cada actividad y la fecha y hora en que fue realizada la actividad.

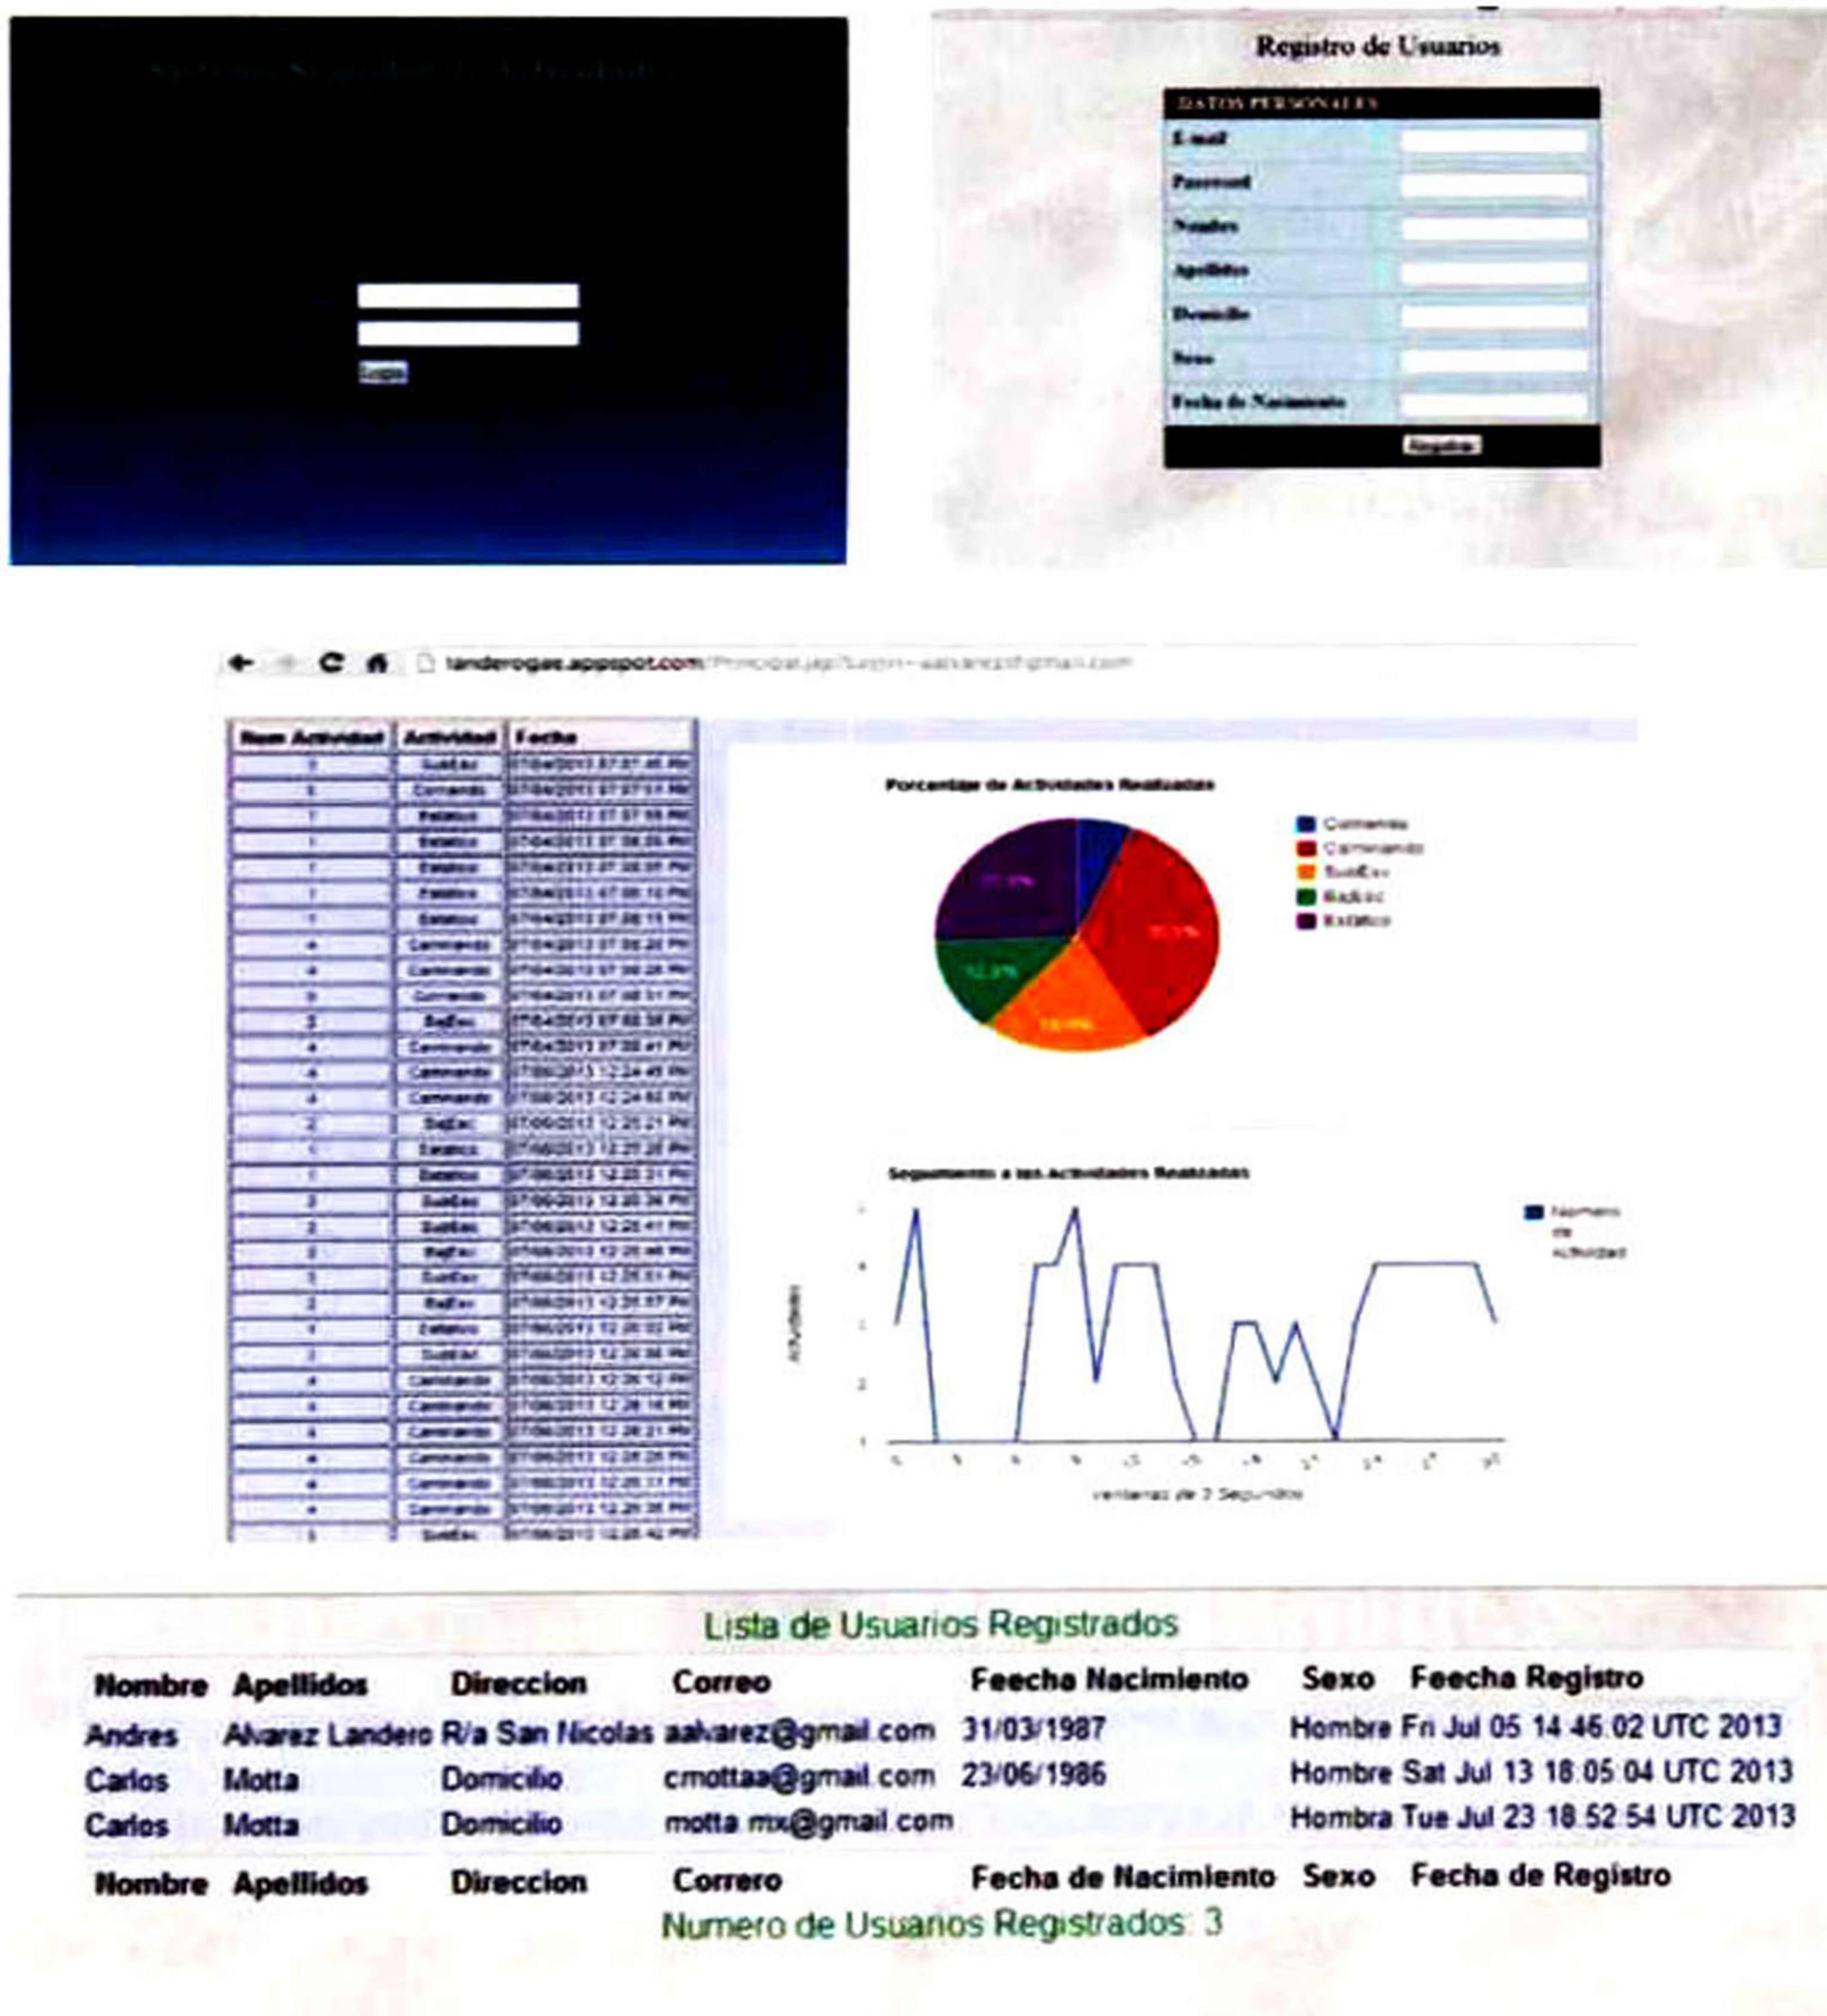


Figura A.6: Interfaz gráfica del sistema Web.



La finalidad de la aplicación móvil unificada con un sistema web, consiste en identificar las aplicaciones o sistemas que se pueden desarrollar a partir de un sistema de reconocimiento de actividades implementado totalmente en un dispositivo móvil. Algunas de estas aplicaciones o sistemas han sido mencionadas a lo largo de este trabajo, tales como el monitoreo y vigilancia a la salud, sistemas de recomendación y difusión publicitaria, etcétera. Es importante mencionar que a partir de que los datos son almacenados es posible inferir conocimiento aplicando minería de datos, la cual permite deducir los patrones y tendencias que existen en los datos y ser empleado para diversas aplicaciones.



- [1] L. Sun, D. Zhang, B. Li, B. Guo, and S. Li, "Activity recognition on an accelerometer embedded mobile phone with varying positions and orientations," in *Ubiquitous Intelligence and Computing* (Z. Yu, R. Liscano, G. Chen, D. Zhang, and X. Zhou, eds.), vol. 6406 of *Lecture Notes in Computer Science*, pp. 548–562, Springer Berlin Heidelberg, 2010.
- [2] S. Abbate, M. Avvenuti, F. Bonatesta, G. Cola, P. Corsini, and A. Vecchio, "A smartphone-based fall detection system," *Pervasive and Mobile Computing*, vol. 8, no. 6, pp. 883 – 899, 2012.
- [3] H. Lu, J. Yang, Z. Liu, and P. P. Boda, "Physical activity recognition with mobile phones: Challenges, methods, and applications," in *Multimedia Interaction and Intelligent User Interfaces* (L. Shao, C. Shan, J. Luo, and M. Etoh, eds.), *Advances in Pattern Recognition*, pp. 185–213, Springer London, 2010.
- [4] Y. Huang, H. Zheng, C. Nugent, P. McCullagh, S. M. McDonough, M. A. Tully, and S. O. Connor, "Activity monitoring using an intelligent mobile phone: a validation study," in *Proceedings of the 3rd International Conference on Pervasive Technologies Related to Assistive Environments, PETRA '10*, (New York, NY, USA), pp. 10:1–10:6, ACM, 2010.
- [5] R. K. Jennifer, M. W. Gary, and A. M. Samuel, "Activity recognition using cell phone accelerometers," *SIGKDD Explor. Newsl.*, vol. 12, pp. 74–82, Mar. 2011.
- [6] H. Zhenyu, J. Lianwen, Z. Lixin, and H. Jiancheng, "Gesture recognition based on 3d accelerometer for cell phones interaction," in *Circuits and Systems, 2008. APCCAS 2008. IEEE Asia Pacific Conference on*, pp. 217 –220, 30 2008-dec. 3 2008.
- [7] L. Jiayang, W. Zhen, Z. Lin, W. Jehan, and V. Venu, "uwave: Accelerometer-based personalized



- gesture recognition and its applications," *Pervasive and Mobile Computing*, vol. 5, no. 6, pp. 657 – 675, 2009. PerCom 2009.
- [8] M. L.-C. Blanca, D.-M. Carlos, and I. Jesus, "Ann for gesture recognition using accelerometer data," *Procedia Technology*, vol. 3, no. 0, pp. 109 – 120, 2012. The 2012 Iberoamerican Conference on Electronics Engineering and Computer Science.
- [9] L. Tobias, D. Claus, M. Alessandro, S. Gerhard, R. Gerhard, and S. Dieter, "Robust detection and tracking of annotations for outdoor augmented reality browsing," *Computers; Graphics*, vol. 35, no. 4, pp. 831–840, 2011. Semantic 3D Media and Content.
- [10] F. Davide, C. D. Pedro, F. Diogo, and M. P. C. JoaoM, "Preprocessing techniques for context recognition from accelerometer data," *Personal and Ubiquitous Computing*, vol. 14, pp. 645–662, 2010.
- [11] Y. Jun, "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*, IMCE 09, (New York, NY, USA), pp. 1–10, ACM, 2009.
- [12] M. Petar, H. Hrvoje, J. Marko, M. Roman, and L.-E. Aimé, "Fall detection of patients using 3-axis accelerometer system," in *Wearable and Autonomous Biomedical Devices and Systems for Smart Environment* (A. Lay-Ekuakille and S. Mukhopadhyay, eds.), vol. 75 of *Lecture Notes in Electrical Engineering*, pp. 259–275, Springer Berlin Heidelberg, 2010.
- [13] G. Bieber, P. Koldrack, C. Sablowski, C. Peter, and B. Urban, "Mobile physical activity recognition of stand-up and sit-down transitions for user behavior analysis," in *Proceedings of the 3rd International Conference on Pervasive Technologies Related to Assistive Environments*, PETRA 10, (New York, NY, USA), pp. 50:1–50:5, ACM, 2010.
- [14] H. Gaëtanne, L. Edward, and B. Natalie, "Mobility change-of-state detection using



- a smartphone-based approach," in *Medical Measurements and Applications Proceedings (MeMeA), 2010 IEEE International Workshop on*, pp. 43–46, 30 2010-may 1 2010.
- [15] K. Ville, M. Jani, S. Heidi, P. Juha, and E. Miikka, "Automatic feature selection for context recognition in mobile devices," *Pervasive and Mobile Computing*, vol. 6, no. 2, pp. 181–197, 2010. Context Modelling, Reasoning and Management.
- [16] W. L. Jeffrey, P. Tony, and M. Gary, "Applications of mobile activity recognition," in *Proceedings of the 2012 ACM Conference on Ubiquitous Computing, UbiComp 12*, (New York, NY, USA), pp. 1054–1058, ACM, 2012.
- [17] Y. Jun and L. Zhigang, "Adacem: automatic daily activity and calorie expenditure monitor on mobile phones," in *Proceedings of the 8th ACM Conference on Embedded Networked Sensor Systems, SenSys 10*, (New York, NY, USA), pp. 409–410, ACM, 2010.
- [18] H. Gaëtanne, D. L. Edward, and B. Natalie, "Wearable mobility monitoring using a multimedia. smartphone platform," *Instrumentation and Measurement, IEEE Transactions on*, vol. 60, pp. 3153–3161, sept. 2011.
- [19] I. P Release, "Worldwide mobile phone market forecast to grow 7.3 % in 2013 driven by 1 billion smartphone shipments, according to idc." <http://www.idc.com/getdoc.jsp?containerId=prUS24302813>, Consultado: 14 Septiembre 2013.
- [20] ITU, "The state of broadband 2012: Achieving digital inclusion for all." <http://www.broadbandcommission.org/documents/bb-annualreport2012.pdf>, Consultado: 25 Septiembre 2013.
- [21] Y. Jun, L. Hong, L. Zhigang, and B. PéterPál, "Physical activity recognition with mobile phones: Challenges, methods, and applications," in *Multimedia Interaction and Intelligent User Interfaces*



- (L. Shao, C. Shan, J. Luo, and M. Etoh, eds.), *Advances in Pattern Recognition*, pp. 185–213, Springer London, 2010.
- [22] L. Myong-Woo, M. K. Adil, and K. Tae-Seong, "A single tri-axial accelerometer-based real-time personal life log system capable of human activity recognition and exercise information generation," *Personal and Ubiquitous Computing*, vol. 15, pp. 887–898, 2011.
- [23] N. Györbíró, A. Fabián, and G. Hományi, "An activity recognition system for mobile phones," *Mob. Netw. Appl.*, vol. 14, pp. 82–91, Feb. 2009.
- [24] A. Developers, "Motion sensors, using the accelerometer." [http://developer.android.com/guide/topics/sensors/sensors\\_motion.html](http://developer.android.com/guide/topics/sensors/sensors_motion.html), Consultado: 28 Junio 2013.
- [25] J. Fontecha, F. Navarro, R. Hervás, and J. Bravo, "Elderly frailty detection by using accelerometer-enabled smartphones and clinical information records," *Personal and Ubiquitous Computing*, pp. 1–11, 2012.
- [26] J. D. Faires, *Numerical Methods*. Brooks Cole, 3 ed., 2002.
- [27] R. Burden and J. Faires, *Análisis Numérico*. Cengage Learning Latin America, 2001.
- [28] F. Davide, C. D. Pedro, F. Diogo, and M. P. C. JoaoM, "Preprocessing techniques for context recognition from accelerometer data," *Personal and Ubiquitous Computing*, vol. 14, pp. 645–662, 2010.
- [29] Y.-J. Hong, I.-J. Kim, S. C. Ahn, and H.-G. Kim, "Mobile health monitoring system based on activity recognition using accelerometer," *Simulation Modelling Practice and Theory*, vol. 18, no. 4, pp. 446 – 455, 2010. *Modeling and Simulation Techniques for Future Generation Communication Networks*.



- [30] P. S. and J. R., "Recognizing human activities user-independently on smartphones based on accelerometer data," *International Journal of Interactive Multimedia and Artificial Intelligence*, vol. 1, pp. 38–45, 06/2012 2012.
- [31] S. L. L. Lau, I. König, K. David, B. Parandian, C. Carius-Düffel, and M. Schultz, "Supporting patient monitoring using activity recognition with a smartphone," 2010.
- [32] A. Khan, Y.-K. Lee, S. Lee, and T.-S. Kim, "Human activity recognition via an accelerometer-enabled-smartphone using kernel discriminant analysis," in *Future Information Technology (FutureTech), 2010 5th International Conference on*, pp. 1–6, may 2010.
- [33] Z.-Y. He and L.-W. Jin, "Activity recognition from acceleration data using AR model representation and SVM," in *2008 International Conference on Machine Learning and Cybernetics*, pp. 2245–2250, IEEE, July 2008.
- [34] J. A. Derick and M. Trivedi, "Driving style recognition using a smartphone as a sensor platform," in *Intelligent Transportation Systems (ITSC), 2011 14th International IEEE Conference on*, pp. 1609–1615, oct. 2011.
- [35] A. M. Khan, Y. Lee, and S. Lee, "Accelerometer's position free human activity recognition using a hierarchical recognition model," in *e-Health Networking Applications and Services (Healthcom), 2010 12th IEEE International Conference on*, pp. 296–301, july 2010.
- [36] O. D. Lara and M. A. Labrador, "A survey on human activity recognition using wearable sensors."
- [37] T. Mashita, K. Shimatani, M. Iwata, H. Miyamoto, D. Komaki, T. Hara, K. Kiyokawa, H. Takemura, and S. Nishio, "Human activity recognition for a content search system considering situations of smartphone users," in *Virtual Reality Short Papers and Posters (VRW), 2012 IEEE*, pp. 1–2, march 2012.



- [38] N. Trivedi, D. V. Kumar, S. Singh, S. Ahuja, and R. Chadha, "Article: Speech recognition by wavelet analysis," *International Journal of Computer Applications*, vol. 15, pp. 27–32, February 2011. Published by Foundation of Computer Science.
- [39] R. K. Ganti, S. Srinivasan, and A. Gacic, "Multisensor fusion in smartphones for lifestyle monitoring," in *Body Sensor Networks (BSN), 2010 International Conference on*, pp. 36–43, June 2010.
- [40] B. Araujo, *Aprendizaje automático: conceptos básicos y avanzados : aspectos prácticos utilizando el software Weka*. Pearson Prentice Hall, 2006.
- [41] C. P., O. P., and R. P., "Human activity recognition from accelerometer data using a wearable device," in *Pattern Recognition and Image Analysis* (J. Vitriá, S. J. Miguel, and H. Mario, eds.), vol. 6669 of *Lecture Notes in Computer Science*, pp. 289–296, Springer Berlin Heidelberg, 2011.
- [42] Z. He, Z. Liu, L. Jin, L.-X. Zhen, and J.-C. Huang, "Weightlessness feature; a novel feature for single tri-axial accelerometer based activity recognition," in *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on*, pp. 1–4, Dec. 2008.
- [43] S. L. Lau, I. Kö andnig, K. David, B. Parandian, C. Carius-Du andssel, and M. Schultz, "Supporting patient monitoring using activity recognition with a smartphone," in *Wireless Communication Systems (ISWCS), 2010 7th International Symposium on*, pp. 810–814, Sept. 2010.
- [44] T. M. Jones, *Artificial Intelligence a Systems Approach*. Infinity Science Press LLC, 2008.
- [45] B. O. Xabier, *Redes Neuronales y sus Aplicaciones*. UPV-EHU, 2009.
- [46] B. Widrow and M. Lehr, "30 years of adaptive neural networks: perceptron, madaline, and backpropagation," *Proceedings of the IEEE*, vol. 78, no. 9, pp. 1415–1442, 1990.
- [47] V. N. Vapnik, *Statistics for Engineering and Information Science*. Springer, 2000.



- [48] E. P. Andries, *Computational Intelligence*. Wiley, 2007.
- [49] M. Zhang and A. A. Sawchuk, "Motion primitive-based human activity recognition using a bag-of-features approach," in *Proceedings of the 2nd ACM SIGHIT International Health Informatics Symposium, IHI '12*, (New York, NY, USA), pp. 631–640, ACM, 2012.
- [50] J. Wang, R. Chen, X. Sun, M. F. She, and Y. Wu, "Recognizing human daily activities from accelerometer signal," *Procedia Engineering*, vol. 15, no. 0, pp. 1780–1786, 2011. CEIS 2011.
- [51] G. Lyons, K. Culhane, D. Hilton, P. Grace, and D. Lyons, "A description of an accelerometer-based mobility monitoring technique," *Medical Engineering ; Physics*, vol. 27, no. 6, pp. 497 – 504, 2005.
- [52] C. Zhu and W. Sheng, "Realtime recognition of complex human daily activities using human motion and location data," *Biomedical Engineering, IEEE Transactions on*, vol. 59, pp. 2422 –2430, sept. 2012.
- [53] K. J. O'Donovan, D. T. O'Keefe, P. A. Grace, and G. M. Lyons, "Accelerometer based calf muscle pump activity monitoring," *Medical Engineering; Physics*, vol. 27, no. 8, pp. 717 – 722, 2005.
- [54] P. Siirtola and J. Röning, "User-independent human activity recognition using a mobile phone: Offline recognition vs. real-time on device recognition," in *Distributed Computing and Artificial Intelligence* (S. Omatu, J. F. De Paz S., S. R. González, J. M. Molina, A. M. Bernardos, and J. M. C. Rodríguez, eds.), vol. 151 of *Advances in Intelligent and Soft Computing*, pp. 617–627, Springer Berlin / Heidelberg, 2012.
- [55] A. M. Khan, Y.-K. Lee, S. Y. Lee, and T.-S. Kim, "A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer," *Trans. Info. Tech. Biomed.*, vol. 14, pp. 1166–1172, Sept. 2010.



- [56] Y. Liang, X. Zhou, Z. Yu, B. Guo, and Y. Yang, "Energy efficient activity recognition based on low resolution accelerometer in smart phones," in *Advances in Grid and Pervasive Computing* (R. Li, J. Cao, and J. Bourgeois, eds.), vol. 7296 of *Lecture Notes in Computer Science*, pp. 122–136, Springer Berlin Heidelberg, 2012.
- [57] J. Yang, "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, IMCE 09*, (New York, NY, USA), pp. 1–10, ACM, 2009.
- [58] Y.-S. Lee and S.-B. Cho, "Activity recognition using hierarchical hidden markov models on a smartphone with 3d accelerometer," in *Hybrid Artificial Intelligent Systems* (E. Corchado, M. Kurzynski, and M. Wozniak, eds.), vol. 6678 of *Lecture Notes in Computer Science*, pp. 460–467, Springer Berlin / Heidelberg, 2011.
- [59] H. Seonguk, K. Kyuchang, and B. Changseok, "Activity classification using a single tri-axial accelerometer of smartphone," in *Human Centric Technology and Service in Smart Space* (J. H. J. Park, Q. Jin, M. Sang-soo Yeo, and B. Hu, eds.), vol. 182 of *Lecture Notes in Electrical Engineering*, pp. 269–275, Springer Netherlands, 2012.
- [60] S. Inoue and Y. Hattori, "Toward highlevel activity recognition from accelerometers on mobile phones," in *Internet of Things (iThingsCPSCoM), 2011 International Conference on and 4th International Conference on Cyber, Physical and Social Computing*, pp. 225–231, oct. 2011.
- [61] Z. Zhao, Y. Chen, S. Wang, and Z. Chen, "Fallalarm: Smart phone based fall detecting and positioning system," *Procedia Computer Science*, vol. 10, no. 0, pp. 617 – 624, 2012. ANT 2012 and MobiWIS 2012.
- [62] G. Haché, E. D. Lemaire, and N. Baddour, "Wearable mobility monitoring using a multimedia. smartphone platform," *Instrumentation and Measurement, IEEE Transactions on*, vol. 60, pp. 3153–3161, sept. 2011.



- [63] M. Zhang and A. A. Sawchuk, "A feature selection-based framework for human activity recognition using wearable multimodal sensors," in *Proceedings of the 6th International Conference on Body Area Networks, BodyNets '11*, (ICST, Brussels, Belgium, Belgium), pp. 92-98, ICST (Institute for Computer Sciences, SocialInformatics and Telecommunications Engineering), 2011.
- [64] A. A., S. B., M. Mihai, M. Raluca, and P. H., "Activity recognition using inertial sensing for healthcare, wellbeing and sports applications: A survey," in *Proceedings of the 23th International Conference on Architecture of Computing Systems, ARCS 2010*, (Berlin), pp. 167-176, VDE Verlag, February 2010.
- [65] M.-W. Lee, A. M. Khan, and T.-S. Kim, "A single tri-axial accelerometer-based real-time personal life log system capable of human activity recognition and exercise information generation," *Personal Ubiquitous Comput.*, vol. 15, pp. 887–898, Dec. 2011.
- [66] K. Roth, I. Kauppinen, P. A. A. Esquef, and V. Valimaki, "Frequency warped burg's method for ar-modeling," in *Applications of Signal Processing to Audio and Acoustics, 2003 IEEE Workshop on.*, pp. 5–8, 2003.
- [67] T. J. Ulrych and T. N. Bishop, "Maximum entropy spectral analysis and autoregressive decomposition," *Reviews of Geophysics*, vol. 13, no. 1, pp. 183–200, 1975.
- [68] S. M. Kay, *Modern Spectral Estimation: Theory And Application/Book And Disk (Prentice-Hall Signal Processing Series)*. Prentice Hall, 1998.
- [69] Mathworks, "Autoregressive (ar) all-pole model parameters estimated using burg method." <http://www.mathworks.com/help/signal/ref/arburg.html>, Consultado: 25 Agosto 2013.
- [70] K. Wear, R. Wagner, and B. Garra, "High resolution ultrasonic backscatter coefficient estimation



- based on autoregressive spectral estimation using burg's algorithm," *Medical Imaging, IEEE Transactions on*, vol. 13, no. 3, pp. 500–507, 1994.
- [71] A. Developers, "Sensors overview." [http://developer.android.com/guide/topics/sensors/sensors\\_overview.html](http://developer.android.com/guide/topics/sensors/sensors_overview.html), Consultado: 04 Julio 2013.
- [72] G. Bieber, J. Voskamp, and B. Urban, "Activity recognition for everyday life on mobile phones," in *Universal Access in Human-Computer Interaction. Intelligent and Ubiquitous Interaction Environments* (C. Stephanidis, ed.), vol. 5615 of *Lecture Notes in Computer Science*, pp. 289–296, Springer Berlin Heidelberg, 2009.
- [73] G. Bieber, J. Voskamp, and B. Urban, "Activity recognition for everyday life on mobile phones," in *Universal Access in Human-Computer Interaction. Intelligent and Ubiquitous Interaction Environments* (C. Stephanidis, ed.), vol. 5615 of *Lecture Notes in Computer Science*, pp. 289–296, Springer Berlin Heidelberg, 2009.
- [74] RapidMiner, "Rapidminer, open source software for big data analytics." <http://rapid-i.com/>, Consultado: 28 Junio 2013.
- [75] RapidMiner, "Rapidminer 5, operator reference." [http://docs.rapid-i.com/files/rapidminer/RapidMiner\\_OperatorReference\\_en.pdf](http://docs.rapid-i.com/files/rapidminer/RapidMiner_OperatorReference_en.pdf), Consultado: 15 Julio 2013.
- [76] A. Developers, "Monitoring the battery level and charging state." <http://developer.android.com/training/monitoring-device-state/battery-monitoring.html>, Consultado: 25 Junio 2013.
- [77] A. Developers, "Application components." <http://developer.android.com/guide/components/fundamentals.html>, Consultado: 20 Agosto 2013.



- 
- [78] A. Developers, "Service." <http://developer.android.com/reference/android/app/Service.html>, Consultado: 15 Junio 2013.
- [79] G. A. Engine, "Qué es google app engine." <https://developers.google.com/appengine/docs/whatisgoogleappengine?hl=es>, Consultado 20 Junio 2013.





# CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL IPN

## UNIDAD TAMAULIPAS

Cd. Victoria, Tamaulipas, a 24 de octubre de 2013.

Los abajo firmantes, integrantes del jurado para el examen de grado que sustentará el C. Andrés Álvarez Landero, declaramos que hemos revisado la tesis titulada:

**“Reconocimiento de Actividades Físicas de un Usuario Móvil a través de un Acelerómetro Tri-axial Incorporado en un Smartphoce”**

Y consideramos que cumple con los requisitos para obtener el grado de Maestro en Ciencias en Computación.

Atentamente,

**Dr. José Juan García Hernández**

**Dr. Hiram Galeana Zapién**

**Dr. César Torres Huitzil**





CINVESTAV - IPN  
Biblioteca Central



SSIT0012195