

**DEFINICIÓN DE COMPONENTES MÍNIMAS PARA EL
RECONOCIMIENTO AUTOMÁTICO DE ACTIVIDADES FÍSICAS
HUMANAS UTILIZANDO UNA RED DE ACELERÓMETROS**

Víctor Alfonso Quintero Gutierrez

Proyecto de grado presentado como requisito parcial
para aspirar al título de Ingeniero Electrónico

Director

Ing. Andrés F. Calvo Salcedo, M.Sc

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA
FACULTAD DE INGENIERÍAS
PROGRAMA DE INGENIERÍA ELECTRÓNICA
PEREIRA
2015**

Nota de Aceptación

Firma del Presidente del jurado

Firma del jurado 1 - Evaluador

Firma del jurado 2 - Evaluador

Firma del jurado 3 - Director

Agradecimientos

Agradezco Dios por brindarme la fuerza y dedicación para finalizar esta proyecto, a mis padres y familiares por su apoyo incondicional, al Grupo de Investigación en Ingeniería Electrónica y al profesor Andrés Felipe Calvo por su orientación durante la preparación de este proyecto de grado. También no olvido agradecer a todas la personas que me brindaron su apoyo durante todo este proceso, sin ustedes no seria posible lograr esta meta.

CONTENIDO

pág.

TÍTULO

CONTENIDO

1. INTRODUCCIÓN	11
1.1. DEFINICIÓN DEL PROBLEMA	12
1.2. JUSTIFICACIÓN	14
1.3. OBJETIVOS	15
1.3.1. Objetivo General	15
1.3.2. Objetivos Específicos	15
2. ESTADO DEL ARTE	17
3. MARCO TEÓRICO	19
3.1. Desviación Estándar	19
3.2. Varianza	19
3.3. Covarianza	20
3.4. Matriz de Covarianza	20
3.5. Eigenvector	21
3.6. Máquinas de vectores de soporte (SVM- <i>Support Vector Machine</i>)	21
3.6.1. Máquinas de vectores de soporte multiclase	22
3.7. Modelos Ocultos de Markov (HMM)	23
3.8. Intervalo de confianza	25
3.9. Análisis de Componentes Principales	25
4. BASE DE DATOS ANOTADA	29

LISTA DE TABLAS

1.	Lista de actividades	30
2.	Etiquetas del SVM para cada postura	33
3.	Características IMU	37
4.	Descriptores estadísticos utilizados	38
5.	Matriz de Confusión SVM-IMU sin PCA	45
6.	Matriz de Confusión SVM-IMU con PCA todos los componentes	45
7.	Matriz de Confusión SVM-IMU con PCA todos los componentes	46
8.	Matriz de Confusión SVM-IMU con PCA - 30 componentes	47
9.	Matriz de Confusión SVM-IMU con PCA - 25 componentes	47
10.	Matriz de Confusión SVM-IMU con PCA - 20 componentes	48
11.	Matriz de Confusión SVM-IMU con PCA - 15 componentes	48
12.	Matriz de Confusión SVM-IMU con PCA - 10 componentes	49
13.	Matriz de Confusión HMM-IMU	50
14.	Matriz de Confusión HMM-IMU con PCA utilizando todos los componentes principales	50
15.	Matriz de Confusión HMM-IMU con PCA para 25 componentes	51
16.	Matriz de Confusión HMM-IMU con PCA para 15 componentes	51
17.	Comparación de las eficiencias para diferentes componentes principales	52

LISTA DE FIGURAS

- 1. Distribución de los sensores (esquema) 30
- 2. Estructura base de datos 31
- 3. Umbrales para asignación de etiquetas 32
- 4. Actividades 1, 2 y 3 33
- 5. Actividades 4 y 5 33
- 6. Diagrama de Segmentación de señales 36
- 7. Número de centroides Vs Eficiencia de Acierto 42
- 8. Análisis de componentes principales para la matriz de entrenamiento 44
- 9. Análisis de componentes principales para la matriz de entrenamiento 44

1. INTRODUCCIÓN

La identificación automática de actividad física humana es un área atractiva de investigación y ha motivado a diferentes investigadores a desarrollar metodologías para la detección automática de actividades [2, 3, 4, 5]. Los sensores más comunes utilizados en esta tarea son las video cámaras , las cámaras de profundidad, los sensores electromiográficos (EMG), los acelerómetros y unidades de masa inercial (IMU-*Inertial Measured Unit*), etc.

Los sensores IMU han demostrado tener ventajas significativas en la detección de actividad, como son la correcta caracterización de las señales y la robustez a oclusiones parciales generadas por los usuarios que son sometidos al análisis [6, 1, 3]. Andrés Calvo [1], en su trabajo investigativo, evidencia que al utilizar una red de 4 sensores IMU, con clasificación SVM (*Support Vector Machine*) para la detección de movimientos primitivos y clasificación HMM (*Hidden Markov Model*) para la detección de actividad, se generan resultados de clasificación del 98 % de acierto. Además, en el trabajo [1], se realiza el análisis de la mínima cantidad de sensores que son necesarios para el reconocimiento de actividad, permitiendo realizar una reducción en el costo computacional del método. Sin embargo, en las conclusiones y recomendaciones de este trabajo, se muestra que es necesario realizar el análisis del conjunto de características que son realmente necesarias para garantizar una detección confiable, con el fin de obtener una reducción el costo computacional de la metodología y hacer viable la implementación de este método en un sistema embebido.

Entonces en este trabajo se realiza un análisis de las características aplicadas en el entrenamiento de detección de movimientos primitivos y se calcula la cantidad mínima de características necesarias para garantizar una que la eficiencia de la detección de movimientos primitivos y detección de actividad física humana, no se reduzca mas de un 5%, utilizando el método de reducción de dimensionalidad de Análisis de Componentes Principales (PCA-*Principal Component Analysis*).

1.1. DEFINICIÓN DEL PROBLEMA

La identificación automática de actividad física humana es un área atractiva de investigación debido a la posibilidad de diseñar aplicaciones en campos como seguridad, salud, deporte, entre muchos otros. El análisis del movimiento humano ayuda en el monitoreo y rehabilitación a pacientes [7], permite la supervisión del estado del adulto mayor [8], evaluar la ejecución de actividades físicas de atletas, gimnastas y deportistas en general; e inclusive analizar comportamientos sospechosos o indebidos en espacios públicos [9].

Reconocer la actividad física humana en la ingeniería apunta a la identificación automática de distintas clases de movimientos físicos utilizando sensores como cámaras de profundidad, cámaras de video, giroscopios, acelerómetros, entre muchos otros. Para un ser humano, reconocer actividad física es una habilidad natural, sin embargo imitar esta habilidad en sistemas de detección automática se considera un gran reto y genera un campo activo de investigación con el fin de crear soluciones a dicho problema [9, 10, 11, 12, 13]. A pesar de que la detección humana puede ser realizada de forma manual, esto es costoso y está sujeto a errores humanos, además de interferir con el desarrollo óptimo de la actividad [9].

En la creación de metodologías automáticas, un planteamiento común es el uso de cámaras con técnicas de procesamiento digital de imágenes y visión por computador [14, 15, 16, 17]. Estas técnicas emplean enfoques como la segmentación de objetivos y extracción de características como color, forma, silueta, para discriminar la actividad [18, 19], sin embargo estos métodos son susceptibles a las condiciones fotométricas de la escena u oclusiones parciales o totales del objetivo observado en la escena. El actual incremento de las cámaras de profundidad ha hecho posible analizar movimiento humano, siendo más popular para este tipo de aplicaciones el Kinect®, este dispositivo permite obtener las coordenadas espaciales del cuerpo humano. Planteamientos como los de las referencias [20, 21, 22, 23] hacen uso de las coordenadas espaciales 3D para el análisis de movimiento, sin embargo este tipo de técnicas son sensibles a oclusiones o auto oclusiones del objetivo, además de tener un rango limitado para la observación [24, 25].

Otros planteamientos emplean sensores de movimiento como acelerómetros, giroscopios o unidades de masa inercial (IMU-*Inertial Measured Unit*), los cuales permiten sensor movimiento físico basándose en las aceleraciones producidas por el movimiento [26, 3, 4, 27]. Este tipo de enfoques, son robustos a las oclusiones parciales o totales del objetivo, debido a que sus sistemas de captura e instrumentación generalmente son inalámbricos, lo que hace robusto cualquier oclusión del objetivo. Las ventajas nombradas anteriormente, hacen que esta modalidad de sensor sea una preferidas para la detección de movimiento. Entonces, algunos enfoques utilizan la información de IMU para la detección de movimientos primitivos y con esta información realizar la detección de actividad. Este enfoque se inspira en las técnicas de reconocimiento automático de voz, donde las frases se dividen en palabras aisladas, para luego dividirse en una secuencia de fonemas. De este modo se detectan los fonemas comunes a todas las palabras construyendo un diccionario o libro de códigos que permite la detección. En 2012 Mi Zhang y Alexander A. Sawchuk [28], utilizan esta idea para obtener un clasificador basado en movimientos primitivos aplicando técnicas de caracterización como Bag-of-Features (BOF) obteniendo un rendimiento significativo. Independiente de la modalidad de sensor usada, el reconocimiento de actividad física humana puede ser formulado como un problema típico de clasificación y al igual que muchos problemas de reconocimiento de patrón, donde la extracción de características juega un papel crucial durante el proceso de reconocimiento [11]. La elección de buenas características es un paso fundamental y depende del problema específico [29, 30], en muchos de los casos, escoger el conjunto mínimo de características hacen viable la implementación de estas metodología en sistemas embebidos, debido a que los costos computacionales temporales son reducidos.

Andrés Calvo [1], en su trabajo investigativo propone una metodología para la detección automática de actividades físicas. En este trabajo se evidencia que se pueden utilizar 4 sensores IMU, con clasificación SVM (*Support Vector Machine*) y clasificación HMM (*Hidden Markov Model*). Esta metodología entrega resultados de clasificación del 98 % acierto para la ejecución de 5 actividades, prometiendo ser una metodología de interés, la cual debe y puede ser más explorada. Sin embargo la metodología de Andrés, ha demostrado requerir de un alto costo

computacional, razón por la cual en su trabajo se realiza el análisis de la mínima cantidad de sensores que son necesarios para el reconocimiento de actividad. Lo anterior permite una reducción en tiempo de cómputo.

Aun que el análisis anterior ayuda a reducir el tiempo de cómputo. En un escenario con un conjunto más amplio de actividades físicas, reducir el número de sensores podría ser un problema y generar falsas detecciones. Por tal razón, también es necesario realizar el análisis del conjunto de características que son utilizadas en el entrenamiento de la clasificación de movimientos primitivos SVM. Esto con el fin de determinar cuántas de estas características son necesarias y cuál es el conjunto mínimo de ellas necesario para garantizar una detección confiable y así obtener una reducción el costo computacional de la metodología. Entonces esto genera la pregunta, ¿sera posible que al utilizar Análisis de Componentes Principales se pueda determinar el conjunto mínimo de características y así reducir el costo computacional del algoritmo sin reducir significativamente la eficiencia del sistema?

1.2. JUSTIFICACIÓN

Debido a la relevancia del reconocimiento de actividades motoras en los distintos campos de investigación y desarrollo, es posible pensar que hay un aumento en el interés en desarrollar aplicaciones que permitan la supervisión y detección de un conjunto grande de actividades físicas humanas. En la literatura [10, 11, 9, 13, 31, 15, 23] han sido desarrollados varios métodos en los cuales se utilizan distintas modalidades de sensores, como son sensores de profundidad, sensores electromiográficos, goniómetros, giroscópicos, acelerómetros, entre varios otros; para la detección automática de la actividad.

Independiente de la modalidad de sensor, el reconocimiento de actividad física humana se considera un problema de clasificación y la etapa de extracción de características es crucial en el proceso clasificación [29, 30]. En la etapa de extracción, se hace posible analizar en el conjunto total de características cuales generan un aporte significativo en la clasificación permitiendo escoger el conjunto mínimo de características que garantiza la reducción del costo computacional temporal permitiendo la implementación de estas metodologías en sistemas

embebidos. Métodos como Análisis de Componentes Principales y Análisis de Componentes Independientes, han garantizando obtener clasificaciones confiables con un conjunto reducido de características [30, 32, 29].

El trabajo de Andrés Calvo[1] ha demostrado ser una metodología interesante para la clasificación de actividades físicas con una red sensores, sin embargo en este trabajo no se llevó a cabo un análisis del aporte de cada característica calculada en la clasificación generando dudas de si es necesario el aporte de todas las características en la clasificación de movimientos primitivos. Esto genera una gran oportunidad, para realizar un estudio comparativo del aporte de cada descriptor en la clasificación de actividad física. Lo anterior permitiría encontrar el mejor desempeño de clasificación con la máxima reducción el costo computacional de la metodología.

1.3. OBJETIVOS

1.3.1. Objetivo General

Aplicar la metodología de Análisis de Componentes Principales para la evaluación de componentes mínimas en el reconocimiento automático de actividades físicas humanas utilizando una red de acelerómetros

1.3.2. Objetivos Específicos

1. Determinar el conjunto de descriptores que caracterizan una red de 4 acelerómetros basado en el trabajo [1] .
2. Implementar la metodología para la identificación de movimientos primitivos utilizando SVM.
3. Implementar la metodología de fusión de datos para la clasificación de actividad utilizando la secuencia temporal de movimientos primitivos basado en el trabajo [1].
4. Determinar el conjunto de componentes mínimas que son necesarias para la clasificación de movimientos primitivos y actividades físicas.

2. ESTADO DEL ARTE

En las ciencias de la computación, se han desarrollado metodologías para el reconocimiento de la actividad física humana. A continuación, se realizará un recorrido por el estado del arte en este tipo de enfoques.

Algunos trabajos se han centrado en el análisis de secuencias de vídeo utilizando técnicas de procesamiento digital de imágenes y visión por computador, en general estos trabajos se basan en etapas de segmentación, extracción de características, clasificación, seguimiento y reconocimiento de actividad [10]. Enfoques como los de los trabajos [33, 34, 35] utilizan el volumen de la persona evaluada durante una ventana de tiempo (STV - *Spatio Temporal Volume*). En las metodologías [18, 19] utilizan técnicas de substracción de fondo de la escena para segmentar el fondo de las personas en movimiento y con estas variaciones de caracterizar y clasificar la actividad.

Otros enfoques utilizan la información de acelerómetros o unidades de masa inercial (IMU- *Inertial Measured Unit*) para el reconocimiento de actividad. En 2004 Bao [4], aplica la transformada rápida de Fourier (FFT-*Fast Fourier Transform*) y adiciona el cálculo de momentos estadísticos media, desviación estándar logrando porcentajes de acierto en la clasificación del 90 %. En 2011, Mi Zhang y Alexander [36], utilizan sensores IMU y caracterizan parámetros físicos del movimiento humano, obteniendo resultados hasta del 90 % de acierto. En 2012 David Martín de Castro [27], propone el uso de la información de los acelerómetros y el GPS de un smartphone para clasificar actividad utilizando como método de aprendizaje redes neuronales artificiales. M. Bocksch y J. Jahn [26], proponen una metodología de clasificación utilizando un sensor IMU de 9 grados de libertad obteniendo resultados entre el 95 % y el 100 % de acierto para algunas de las actividades de la base de datos, pero con alto costo computacional.

Otros enfoques se basan en la detección de movimientos primitivos, inspirados en las técnicas de reconocimiento automático de voz. Donde se reconocen las frases, palabras aisladas y por último una secuencia de fonemas. De este modo se genera un diccionario de fonemas comunes a todas las palabras construyendo los bloques básicos para el reconocimiento automático.

En 2012 Mi Zhang y Alexander A. Sawchuk [28], utilizan este método obtener un clasificador basado en movimientos primitivos caracterizando señales de acelerómetros con *Bag of Features* (BOF) obteniendo resultados mayores al 80 %. Otros enfoques utilizan fusión de datos, para robustecer el desempeño de los sistemas de detección. En [37] se propone un método utilizando la fusión de una red de sensores IMU y un sensor Kinect® , el cual utiliza un sistema MIMO para de la red IMU y fusiona estos datos con la nube de puntos del Kinect® para ser clasificada por una máquina de vectores de soporte (SVM), permitiendo obtener la información que no es visible para el Kinect® cuando se generan auto-occlusiones.

D. García Alvarez [38], propone un método de reconocimiento de patrones utilizando análisis de componentes principales (*PCA-Principal Component Analysis*), este método permite detectar fallos utilizando enfoque de aprendizaje de máquina con un conjunto mínimo de características, permitiendo obtener un método de clasificación liviano desde el punto de vista computacional. Du-Ming Tsai y Wei-Yao Chiu [39], proponen un método para la detección de actividad aplicando análisis de componentes independientes (ICA). El método propuesto no requiere el diseño de función o proceso de modelado. Se puede implementar fácilmente en línea, aplicaciones en tiempo real con dispositivos de gama baja, bajo costo o incluso en teléfonos inteligentes. Los resultados experimentales revelan que es robusto bajo fondos no estructurados donde no solo se mueve el objetivos a seguir si no también el fondo de la escena.

3. MARCO TEÓRICO

Este proyecto utiliza enfoques estadísticos y de aprendizaje de máquina para el reconocimiento de actividad física humana. Para el entendimiento del trabajo es importante la revisión de algunas teorías y conceptos fundamentales alrededor de la clasificación supervisada y análisis del conjunto características en el entrenamiento. En este capítulo inicialmente se enunciarán algunos de los conceptos estadísticos y conceptos de álgebra lineal básicos para el entendimiento de la metodología PCA, posteriormente se explicará las metodologías de clasificación utilizadas y por último se hará énfasis en el análisis de componentes principales para reducción de conjunto de características el cual presente dependencia lineal.

3.1. Desviación Estándar

La desviación estándar es una medida de dispersión de un conjunto de datos, puede ser definida como la variación esperada de los datos con respecto a su media [40]. La desviación estándar σ , se define como:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{N - 1}}$$

Donde:

- x_i es un dato del conjunto analizar.
- \bar{x} es la media del conjunto de datos.
- N es el tamaño de la población.

3.2. Varianza

La varianza es una medida de dispersión que hace uso de todos los datos [41]. Esta está basada en la diferencia entre el valor de cada observación y la media:

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})}{N - 1}$$

Donde:

- x_i es un dato del conjunto analizar.
- \bar{x} es la media del conjunto de datos.
- N es el tamaño de la población.

3.3. Covarianza

La covarianza hace referencia al grado de variación conjunta de dos variables. Este valor es de vital importancia para determinar la dependencia existente entre ambas variables [42].

$$\sigma_{x,y} = \frac{\Sigma(x_i - \mu_x)(y_i - \mu_y)}{N}$$

Donde:

- x_i es un dato del conjunto de la variable x analizar.
- y_i es un dato del conjunto de la variable y analizar.
- μ_x es la media poblacional de variable x.
- μ_y es la media poblacional de variable y.
- N es es tamaño de la población.

3.4. Matriz de Covarianza

Es una matriz que contiene la covarianza de los elementos de un conjunto de una variable. La matriz de covarianza para 3 variables se establece así:

$$C = \begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix}$$

Donde:

- $cov(x, y)$ es la covarianza entre las variables x, y .

3.5. Eigenvector

Los vectores propios o eigenvectores son los vectores no nulos que, cuando son transformados por el operador generan un múltiplo escalar de sí mismos, es decir que un vector $\vec{b} \in \mathbb{R}^n$, tal que $\vec{b} \neq \vec{0}$, es un eigenvector de la matriz \mathbf{A} , si y solo si,

$$\mathbf{A}\vec{b} = \lambda\vec{b}$$

Donde $\lambda \in \mathbb{C}$. Además, se dice que el escalar λ es el eigenvalor de la matriz \mathbf{A} asociado al vector \vec{b} ; de manera recíproca se dice que \vec{b} es un eigenvector \mathbf{A} asociado al eigenvalor λ [43].

3.6. Máquinas de vectores de soporte (SVM-*Support Vector Machine*)

Las máquinas de soporte vectorial son una metodología de clasificación supervisada que permite separar dos clases. Este método tiene como objetivo la estimación de un modelo que permita la clasificación de un evento binario. Una SVM tiene como objetivo encontrar el hiperplano que separe y maximice el margen entre las clases en este espacio [44].

La SVM en su forma básica, presenta un modelo lineal que calcula una etiqueta $y \in \{-1, 1\}$ utilizando el siguiente modelo:

$$y = w^T \phi(x) + b \tag{1}$$

Donde, $\phi(x) : \mathbb{R} \rightarrow H$ es una transformación del conjunto de entrada a un conjunto con igual o mayor dimensión, lo que se supone que facilita la separación de las clases. El vector w define el

hiperplano de separación en espacio $\phi(X)$. b representa el bias o sesgo con respecto al origen de coordenadas. En las SVM se agrega el riesgo empírico (R_{emp}) para relajar la margen de la estimación.

Entonces:

$$R_{emp} = \sum_{i=1}^n \xi_i^\sigma$$

Donde

- $\sigma = 1$ Para clasificación.

Por lo tanto el problema de estimación del hiperplano de separación, se define como la solución al siguiente problema de optimización cuadrático (QP):

$$\min_{w,b,\xi_i} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (2)$$

$$\text{Sujeto a } y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i \quad \forall_i = 1, \dots, n \quad (3)$$

$$\xi_i \geq 0 \quad \forall_i = 1, \dots, n \quad (4)$$

3.6.1. Máquinas de vectores de soporte multiclase

Las SVM solo clasifican problemas binarios, sin embargo en la práctica es común encontrar problemas de más clases, por lo que existen expansiones para lograr que las SVM sean multi-clase.

Entre las metodologías más comunes se encuentran los siguientes enfoques [45]:

Uno contra todos: Esta estrategia consiste en la estimación de una SVM por clase, la cual está en capacidad para distinguir la clase en particular de todas las clases restantes.

Por lo general, una sola clase debe detectar positivo un ejemplo permitiendo que genere una codificación que asigna la etiqueta correcta. Cuando más de un modelo SVM clasifica un conjunto de datos positivo, se calcula la probabilidad de pertenencia a la clase y se escoge la clase con máxima probabilidad.

Uno contra uno: Esta estrategia de clasificación consiste en construir un clasificador por par de clases, la pertenencia a la clase se encoje buscando la clase que recibió la mayoría de votos. En caso de un empate entre dos clases, se calcula la probabilidad de pertenencia a la clase y se escoge la clase con máxima probabilidad. Para implementar esta metodología se requiere de m clasificadores, este método es generalmente más lento que uno contra todos.

3.7. Modelos Ocultos de Markov (HMM)

Los HMM son autómatas de estados finitos que permiten modelar procesos estocásticos, donde la transición a un estado en particular depende de los estados que no son visibles en general y su ocurrencia depende del estado anterior. Esta metodología, asume que el sistema a modelar es un proceso de Markov de parámetros desconocidos y su objetivo es determinar estos parámetros a partir de diferentes observaciones [46]. Un HMM se define como:

$$\lambda = f(O, Q, A, B, \pi)$$

Donde:

- $O = \{O_1, O_2, \dots, O_M\}$ son los estados visibles.
- $Q = \{1, 2, \dots, N\}$ son los estados ocultos.
- $A = \{a_{ij}\}$ es la matriz de transición de estados, donde el elemento a_{ij} es la probabilidad de que genere la transición desde el estado i al estado j .
- $B = \{b_i(k)\}$ se define como la matriz de probabilidad de salida, donde $b_i(k)$ es la probabilidad de emitir el símbolo O_k en el estado i .

- $\pi = \{\pi_i\}$ es el vector de probabilidades del estado inicial, donde π_i es la probabilidad de iniciar en el estado i .

Los tres problemas básicos de los HMM

Cuando se utilizan Modelos ocultos de Markov es necesario plantear tres problemas básicos, donde la solución de ellos permite, que esta metodología sea adecuada para representar la señal [46]:

- **El problema de la evaluación:** Calcular eficientemente $P(O|\lambda)$ la probabilidad de la secuencia de observación O dado el modelo $\lambda = (A, B, \pi)$ y la secuencia de observación $O = \{O_1, O_2, \dots, O_T\}$.
- **El problema de la decodificación:** Encontrar la trayectoria $q = (q_1, q_2, \dots, q_T)$ más probable dado el modelo λ y la secuencia de observación $O = \{O_1, O_2, \dots, O_T\}$. Dado un modelo y una secuencia de observaciones.
- **El problema del aprendizaje:** Ajustar los parámetros A, B, π con el fin de maximizar $P(O|\lambda)$. Para la solución de este problema, se utiliza un procedimiento iterativo llamado Método de Baum-Welch.
- **Libro de Código (codebook):** Es el proceso de transformar el contenido del conjunto de entrenamiento en una representación codificada, donde se analiza cierta cantidad de muestras y se busca elementos que pueda ser agrupados y representados como un solo código. Este procedimiento es llevado a cabo reuniendo los patrones típicos de la señal y designando un código a cada patrón. Para esta tarea, se utilizan algoritmos basados en clustering, la técnica de K-means, permite ubicar y calcular los centroides de los vectores de observación, agrupando estos en torno a K valores medios arrojando como resultado un libro de códigos o codebook [46].

3.8. Intervalo de confianza

Cuando se tiene una variable aleatoria con distribución normal, el intervalo de confianza se define como la posible desviación que una medida normalizada puede presentar dada su valor probable de acierto. La probabilidad de éxito en la estimación se representa con $1 - \alpha$ y se denomina nivel de confianza. En estas circunstancias, α se define como error aleatorio y es una medida de la posibilidad de fallar en la estimación mediante tal intervalo [47].

Entonces el error aleatorio para una confianza para del 95 % se define como:

$$e = 1,96\sqrt{\frac{p(1-p)}{n}}$$

Donde

- p es la probabilidad de acierto normalizada.
- n es la muestra poblacional o el número de datos a tener en cuenta.

El error para una confianza del 99 % se define como:

$$e = 2,575\sqrt{\frac{p(1-p)}{n}}$$

3.9. Análisis de Componentes Principales

El análisis de componentes principales es un técnica de reducción de dimensionalidad que es frecuentemente usada para transformar un conjunto de datos de alta dimensionalidad en un subespacio de menor dimensión, esto previo a ejecutar un algoritmo de aprendizaje de máquina sobre los datos. Esta técnica usa principios de álgebra lineal para transformar un número posible de variables correlacionadas en un número menor de variables no correlacionadas, llamadas componentes principales. Los componentes seleccionados son aquellos que presentan un alto grado de varianza[48].

Se tiene un conjunto de datos que es representado en términos de de una matriz \mathbf{X} de $m \times n$, donde n columnas son las muestras, y m columnas son las variables. Se quiere transformar linealmente la matriz \mathbf{X} en otra matriz \mathbf{Y} , también de dimensiones $m \times n$, entonces, se multiplica por otra matriz $m \times m$, \mathbf{P} :

$$\mathbf{Y} = \mathbf{P}\mathbf{X}$$

Esta ecuación representa un cambio de base. Si se considera que las filas de \mathbf{P} sean los vectores p_1, p_2, \dots, p_m ; y que las columnas de \mathbf{X} sean los vectores x_1, x_2, \dots, x_n ; entonces:

$$\mathbf{P}\mathbf{X} = (P_{X1} \ P_{X2} \ P_{Xn}) = \begin{pmatrix} p_1 \cdot x_1 & p_1 \cdot x_2 & \cdot & \cdot & \cdot & p_1 \cdot x_n \\ p_2 \cdot x_1 & p_2 \cdot x_2 & \cdot & \cdot & \cdot & p_2 \cdot x_n \\ \cdot & \cdot & \cdot & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ p_m \cdot x_1 & p_m \cdot x_2 & \cdot & \cdot & \cdot & p_m \cdot x_n \end{pmatrix} = \mathbf{Y}$$

Tal que,

$$\mathbf{X} \in \mathbb{R}_{m \times n}, \quad \mathbf{x}_i^T \in \mathbb{R}_n$$

Entonces, la siguiente corresponde a la matriz de covarianza:

$$\mathbf{C}_x = \frac{1}{n-1} \mathbf{X}\mathbf{X}^T = \frac{1}{n-1} \begin{pmatrix} \mathbf{x}_1 \mathbf{x}_1^T & \mathbf{x}_1 \mathbf{x}_2^T & \cdot & \cdot & \cdot & \mathbf{x}_1 \mathbf{x}_m^T \\ \mathbf{x}_2 \mathbf{x}_1^T & \mathbf{x}_2 \mathbf{x}_2^T & \cdot & \cdot & \cdot & \mathbf{x}_2 \mathbf{x}_m^T \\ \cdot & \cdot & \cdot & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ \cdot & \cdot & & & & \cdot \\ \mathbf{x}_m \mathbf{x}_1^T & \mathbf{x}_m \mathbf{x}_2^T & \cdot & \cdot & \cdot & \mathbf{x}_m \mathbf{x}_m^T \end{pmatrix}$$

Considerando la matriz de covarianza \mathbf{C}_Y en términos de \mathbf{X} y \mathbf{P} .

$$\mathbf{C}_Y = \frac{1}{n-1} \mathbf{PSP}^T$$

Donde,

$$\mathbf{S} = \mathbf{XX}^T$$

Nótese que \mathbf{S} es una matriz simétrica $m \times m$, ya que $(\mathbf{XX}^T)^T = (\mathbf{X}^T)^T (\mathbf{X})^T = \mathbf{XX}^T$. De los teoremas del álgebra lineal se dice que cada matriz simétrica cuadrada es ortogonalmente diagonalizable. Entonces,

$$\mathbf{S} = \mathbf{EDE}^T$$

Donde \mathbf{E} es una matriz ortogonal $m \times m$ donde sus columnas son eigenvectores ortogonales de \mathbf{S} , y \mathbf{D} es una matriz diagonal que contiene eigenvalores de \mathbf{S} como sus entradas diagonales. El rango, r , de \mathbf{S} es el número de eigenvectores ortogonales que contiene. Si \mathbf{B} resulta tener un rango deficiente, entonces r es menor que m , de la matriz, entonces simplemente se necesita generar $m - r$ vectores ortogonales para llenar las columnas faltantes de \mathbf{S} .

Posteriormente, se transforma la matriz \mathbf{P} , esto me hace escogiendo las filas de \mathbf{P} para ser los eigenvectores de \mathbf{S} , se asegura que $\mathbf{P} = \mathbf{E}^T$ y viceversa. De esta manera, sustituyendo esto en la expresión derivada de la matriz de covarianza \mathbf{C}_Y , resulta:

$$\begin{aligned} \mathbf{C}_Y &= \frac{1}{n-1} \mathbf{PSP}^T \\ &= \frac{1}{n-1} \mathbf{E}^T (\mathbf{EDE}^T) \mathbf{E} \end{aligned}$$

Ahora sabiendo que \mathbf{E} es una matriz ortogonal, se tiene que $\mathbf{EE}^T = \mathbf{I}$, donde \mathbf{I} es una matriz

identidad de $m \times m$. Por lo tanto, para esta selección de \mathbf{P} , se tiene que:

$$\mathbf{C}_Y = \frac{1}{n-1} \mathbf{D}$$

Otro aspecto que se debe tener en cuenta es que, con este método se consigue información importante relativa de cada componente principal a partir de sus varianzas. El mayor valor de varianza determina el primer componente principal, el segundo mayor valor determina el segundo componente principal y se sigue el procedimiento para los demás componentes. Por lo tanto, esto proporciona un método para la organización de datos en la etapa de diagonalización. Una vez obtenidos los eigenvalores y eigenvectores de $\mathbf{S} = \mathbf{X}\mathbf{X}^T$, se posicionan desordenadamente en la diagonal de \mathbf{D} . Entonces, se construye la matriz ortogonal \mathbf{E} posicionando los eigenvectores asociados en el mismo orden para formar las columnas de \mathbf{E} . Con esto se alcanza el objetivo de diagnosticar la matriz de covarianza de los datos transformados. Los componentes principales (las filas de \mathbf{P}) son los eigenvectores de la matriz de covarianza, $\mathbf{X}\mathbf{X}^T$, y las filas se encuentran ubicadas en orden de importancia, diciendo cual componente principal posee mayor importancia[49].

4. BASE DE DATOS ANOTADA

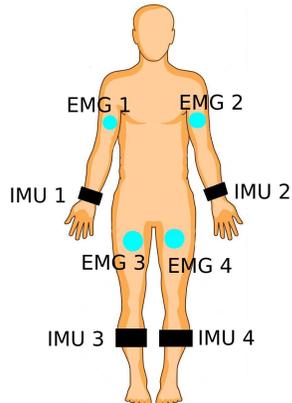
En la literatura se han propuesto diferentes bases de datos anotadas para el análisis de actividad física humana. El análisis de estas acciones requiere de un registro anotado que capture en igualdad de condiciones, los comportamientos de las señales registradas por las diferentes modalidades de sensores. Usualmente, los sensores utilizados para el captura de estas acciones son sensores de movimiento, como acelerómetros, giroscopios, unidades de masa inercial (IMU), sensores electromiográficos (EMG) y dispositivos Kinect.

Según la modalidad de sensor existen diferentes bases de datos, ejemplo de ello son: Human Activity Database – CHAD, KTH, WEIZMANN [50], UCF-Sports [51], Hollywood [52], base de datos UCiI-Smartphones Data Set [53] y RGB-D Human Activity Recognition and Video Database [54]. Aunque existen bases de datos estandarizadas que facilitan el análisis de reconocimiento de actividad, la tesis de Maestría de Andrés Calvo [1], ha creado una base de datos con el registro sincronizado de múltiples fuentes sensoriales como lo son IMU, Kinect y EMG. Aunque en este trabajo no se utiliza fusión de datos multi-sensor, es necesario trabajar con esta base de datos, ya que la metodología aplicada a este trabajo puede ser extendida a cualquiera de las modalidades de sensor descritas en el trabajo [1].

4.1. Sistema de Adquisición para sensores IMU y Almacenamiento de Archivos para la base de datos [1].

Los sensores IMU utilizados en esta base de datos son acelerómetros tri-axiales (a_x, a_y, a_z) - ADXL330 que permiten sensar los cambios de velocidad de los puntos articulados configurados en el experimento. Este sensor permite medir en un rango de $\pm 3g$. El cálculo por software de la aceleración giroscópica *Roll* y *Picth* para transformar el sensor en un medidor IMU de 5 grados de libertad [1]. Esta transformación se explica detalladamente en la sección 5.1. Los datos son capturados con una NI-USB-6008 utilizando LabView y la ubicación de los sensores en el cuerpo se puede observar en la figura 1.

Figura 1. Distribución de los sensores (esquema)



Para garantizar la integridad de los datos, cada experimento de captura fue cuidadosamente configurado de la misma manera para garantizar que la ubicación de los sensores y pose de cada sensor acelerómetro. Esto con el fin, de asumir que las observaciones grabadas tienen las mismas condiciones permitiendo plantear la hipótesis de ser agrupadas por una metodología de aprendizaje de máquina. En la tabla 1 se puede observar la codificación hecha para etiquetar cada actividad ejecutada en la base de datos.

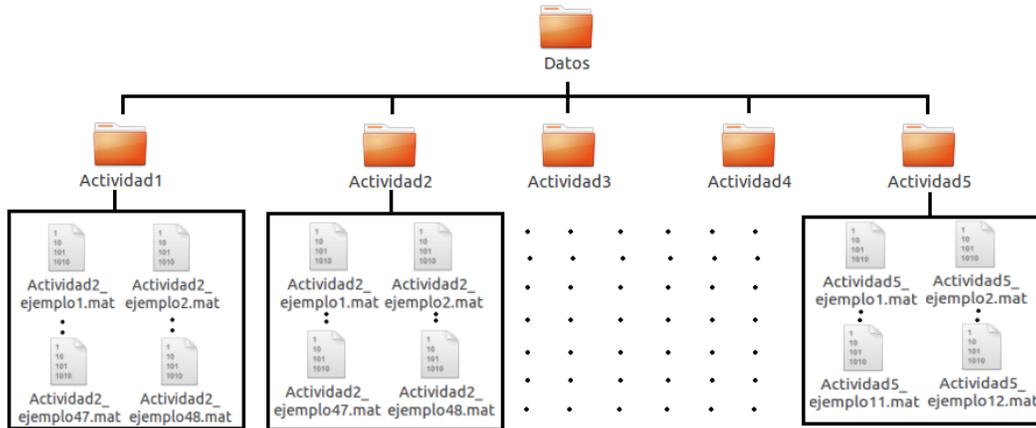
Tabla 1. Lista de actividades

Actividad	Etiqueta
Quedarse quieto	1
Agacharse y levantarse	2
Saltar	3
Levantar mano derecha	4
Trotar	5

En la figura 2 se puede observar la distribución de los archivos en la base de datos. Cada

estructura .mat contiene una celda de dimensión 1×3 , donde es almacenada la información de cada segundo de registro de la información; cada posición de esta celda almacena otra celda, con dimensión 1×3 correspondiente a la información de cada sensor. Los tamaños de las señales obtenidas se especifican en la sección 5.1.

Figura 2. Estructura base de datos



4.2. Base de datos de movimientos primitivos

Los movimientos primitivos son sub-movimientos que se generan en la ejecución de cualquier actividad física humana. Andrés Calvo [1], basa su metodología en la detección de estos sub-movimientos. Por esta razón, en este trabajo se construyó una segunda base de datos anotada basada en la base de datos de actividad física. Las señales de la base de datos, son almacenadas en un archivo con extensión .mat, el cual se codifica de la siguiente manera:

$$\text{Base}\{\text{Ejemplo}\}\{\text{Segundo}\}\{\text{Sensor}\}\{\text{Segmento}\}$$

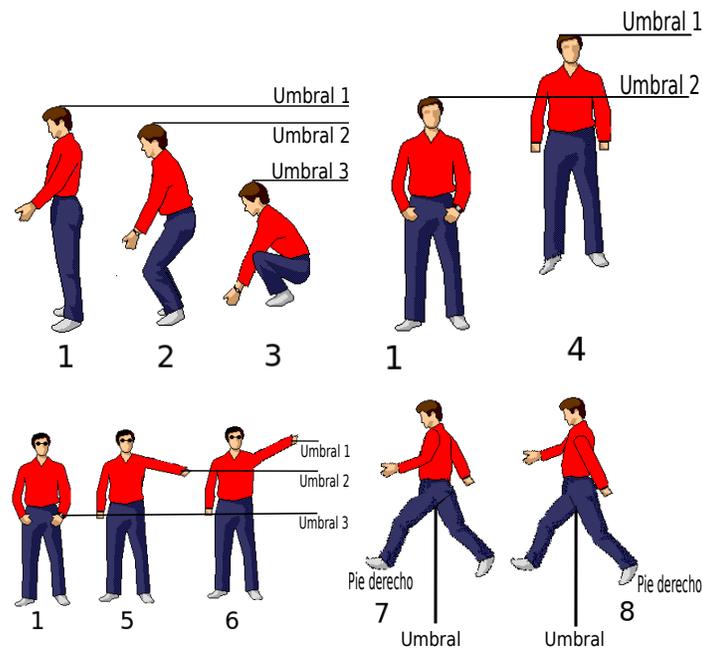
Donde:

- *Ejemplo* corresponde a una celda 1×240 , con la información de cada ejemplo ejecutado en la base de datos.
- *Segundo* corresponde a una celda con dimensión 1×3 , correspondiente a la información de los tres sensores durante cada segundo.

- *Sensor* corresponde a una celda con dimensión 1×3 , correspondiente a la información de cada modalidad de sensor.
- *Segmento* almacena los N arreglos correspondiente a cada submovimiento almacenado.

Para etiquetar esta base de datos, [1] se utilizaron umbrales de las coordenadas espaciales de los puntos articulados del cuerpo (Cabeza y Muñeca) provistos por el Kinect® tal y como se puede observar en la figura 3.

Figura 3. Umbrales para asignación de etiquetas



4.2.1. Etiquetas de movimientos primitivos

En [1], el autor construye el vocabulario de sub-movimientos comunes para el conjunto actividades físicas de la tabla 1. En la tabla 2, se puede observar la codificación de movimientos primitivos propuesto para representar cada actividad. En la figuras 4 y 5, se puede observar la secuencia de movimientos primitivos para cada actividad de la base de datos.

Tabla 2. Etiquetas del SVM para cada postura

Sub-actividad	Etiqueta	Sub-actividad	Etiqueta
Reposo	1	Mano levantada a $1/4$	5
Medio Agachado	2	Mano levantada a $3/4$	6
Totalmente agachado	3	Paso adelante pie derecho	7
Suspendido en el aire $1/4$	4	Paso adelante pie izquierdo	8

Figura 4. Actividades 1, 2 y 3

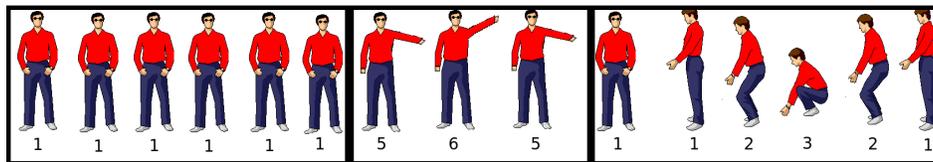
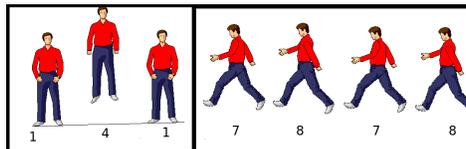


Figura 5. Actividades 4 y 5



5. CLASIFICACIÓN DE MOVIMIENTOS PRIMITIVOS CON PCA

Los movimientos primitivos se inspiran en los métodos de reconocimiento de voz humana [55]. En el reconocimiento de voz, se construyen diccionarios que detectan vocales y consonantes, las cuales permiten detectar fonemas y así con la combinación de ellas clasificar palabras completas [56]. Aplicando esta idea, cada actividad se representa como una secuencia de sub-movimientos generando un código único que permite clasificar actividad. Andrés Calvo [1], propone utilizar una SVM para realizar la detección estos movimientos, en este trabajo se agrega una etapa de reducción de características utilizando el método de PCA, permitiendo así obtener una reducción del costo computacional del entrenamiento y la clasificación de los movimientos primitivos.

5.1. Extracción de características

En esta sección se describirá el proceso de extracción de características para una red de cuatro acelerómetros tri-axiales, el cual es descrito en [1]. Para realizar este proceso es necesario segmentar las señales N ventanas donde que se describe cada movimiento primitivo ejecutado en la acción. Los tamaños de estas ventanas se calcularon en [1] y se concluye que para sensores acelerómetros es necesario una ventana con 3 muestras. En la figura 6 se puede observar un diagrama de las señales capturadas y su segmentación para una ventana de 3 segundos.

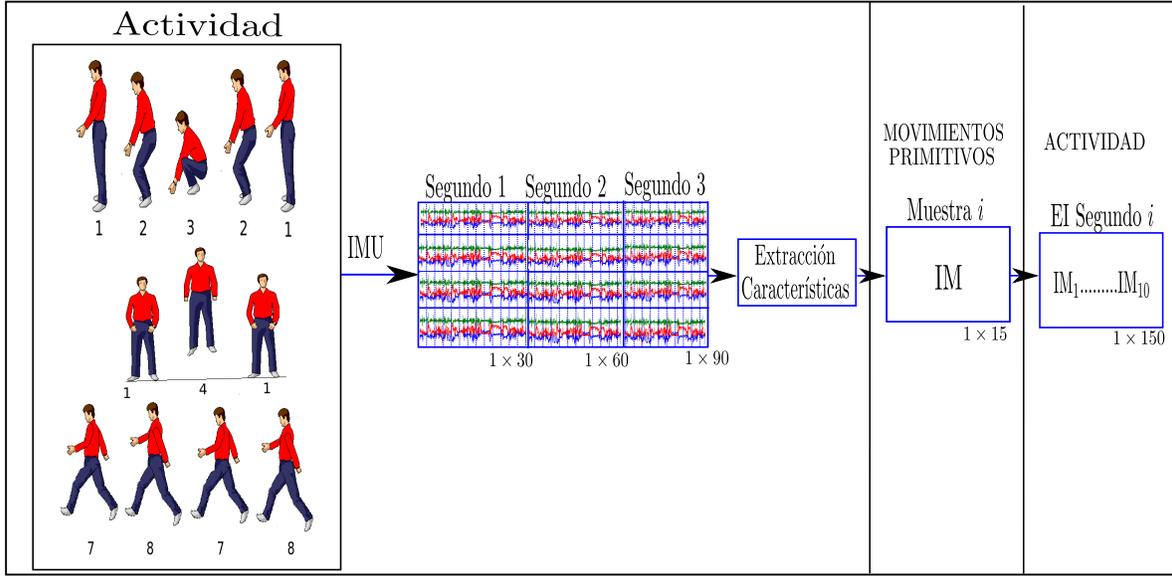
5.1.1. Conversión a sensor de 5 grados de libertad

Para obtener los ángulos de rotación Roll y Pitch se realiza la conversión a coordenadas esféricas utilizando el modelo propuesto en [1] :

La fuerza gravitacional G se define como:

$$G = Raw_{accel} \left[\frac{R}{2^n - 1} \right] \quad (5)$$

Figura 6. Diagrama de Segmentación de señales



Donde:

- n es la resolución del conversor análogo digital.
- R es el rango de del voltaje de entrada del conversión A/D.
- Raw_{accel} es la señal de aceleración del sensor.

Posteriormente se calcula los ángulos de rotación Roll y Pitch utilizando el siguiente modelo:

$$Pitch = \arctan \left(\frac{G_y}{\sqrt{G_x^2 + G_z^2}} \right) \quad (6)$$

$$roll = \arctan \left(\frac{-G_x}{G_z} \right) \quad (7)$$

Esto permite obtener la información de un sensor IMU, el cual se define como:

$$I_k = \left[a_x \quad a_y \quad a_z \quad Pitch \quad Roll \right]_{1 \times 5} \quad (8)$$

Donde, k es el k -ésimo acelerómetro, $k = \{1, 2, 3, 4\}$.

Los sensores IMU tienen una frecuencia de muestreo de 30 Hz, sus datos son agrupados y segmentados en ventanas de tres muestras obteniendo información de movimientos primitivos a una frecuencia de 10 Hz. Entonces la idea, es construir un vector de características I_k el se basa en calculo de los descriptores de la tablas 3 y 4. Donde, k es el k -ésimo acelerómetro, $k = \{1, 2, 3, 4\}$.

Tabla 3. Características IMU

Nombre	Definición
<i>Mean of Movement Intensity (AI)</i>	$AI = \frac{1}{3} \sum_{i=1}^3 MI(i),$ $MI = \ A_{xyz}\ _2$ $A_{xyz} = \begin{bmatrix} a_x & a_y & a_z \end{bmatrix}^T$
<i>Variance of MI (VI)</i>	$VI = \frac{1}{3} \sum_{i=1}^3 (MI(i) - AI)^2$
<i>Normalized Signal Magnitude Area (SMA)</i>	$SMA = \frac{1}{3} \left(\sum_{i=1}^3 a_x(i) + \sum_{i=1}^3 a_y(i) + \sum_{i=1}^3 a_z(i) \right)$
<i>Eigenvalues of Dominant Directions (EVA)</i>	<p>Vectores propios de la matriz de covarianza de la aceleración a lo largo de los ejes x,y,z en cada ventana de observación</p>
<i>Averaged Acceleration Energy (AAE)</i>	<p>Valor medio de la energía a lo largo de tres ejes de aceleración donde la energía es la suma de las magnitudes de los componentes discretos FFT al cuadrado de la señal de cada eje del sensor, normalizado por la longitud de la ventana</p>
<i>Averaged Rotation Energy (ARE)</i>	<p>Valor medio de la energía a lo largo de los ángulos de rotación, para este caso solo Roll y Pitch</p>

Tabla 4. Descriptores estadísticos utilizados

Nombre	Descripción	Nombre	Descripción
Media de a_x	$m_{ax} = \frac{1}{N} \sum_{i=1}^N ax_i$	Varianza de x	$v_{ax} = \frac{1}{N} \sum_{i=1}^N (ax_i - \bar{a}_x)^2$
Media de a_y	$m_{ay} = \frac{1}{N} \sum_{i=1}^N ay_i$	Varianza de y	$v_{ay} = \frac{1}{N} \sum_{i=1}^N (ay_i - \bar{a}_y)^2$
Media de a_z	$m_{az} = \frac{1}{N} \sum_{i=1}^N az_i$	Varianza de z	$v_{az} = \frac{1}{N} \sum_{i=1}^N (az_i - \bar{a}_z)^2$
Media de a_r	$m_{ar} = \frac{1}{N} \sum_{i=1}^N ar_i$	Varianza de r	$v_{ar} = \frac{1}{N} \sum_{i=1}^N (ar_i - \bar{a}_r)^2$
Media de a_p	$m_{a\theta} = \frac{1}{N} \sum_{i=1}^N ap_i$	Varianza de θ	$v_{ap} = \frac{1}{N} \sum_{i=1}^N (ap_i - \bar{a}_p)^2$

Entonces esto permite obtener el vector de características I en cada ventana de 3 muestras.

$$I_k = [AIVISMAEVA AAE ARE m_{ax} m_{ay} m_{az} m_{ar} m_{ap} v_{ax} v_{ay} v_{ar} v_{ap}]_{1 \times 23} \quad (9)$$

Posteriormente se concatena la información de cada sensor obteniendo el vector de características IM

$$IM = [I_1 I_2 I_3 I_4]_{1 \times 92} \quad (10)$$

5.2. Reducción de características con el método PCA y Clasificación de Movimientos con SVM

Para esta etapa se aplica el método de reducción de dimensionalidad PCA, explicado detalladamente en la sección 3.9. Esta metodología permite obtener una representación de la matriz de entrenamiento en un espacio donde sus columnas no son correlacionadas, lo que permite eliminar características de acuerdo a su aporte, garantizando así obtener una matriz de entrenamiento mínima en dimensión. Cada dato debe ser mapeado a este espacio proyectado con el fin de garantizar la dimensionalidad e integridad de los datos analizados. Para la etapa de clasi-

ficación se utilizó una máquina de vectores de soporte multiclase con estrategia de clasificación “*All-pairs*”; este método de aprendizaje utiliza un kernel gaussiano con radio adaptativo. El entrenamiento del SVM se realiza aplicando la técnica de minimización sequential minimal optimization (SMO). Los parametros de la SVM son definidos según el trabajo [1].

Para aplicar el método PCA se utiliza la función PCA de Matula, la cual realiza el Análisis de componentes principales de un sistema de ecuaciones de la forma $Ax = b$. Entonces, la sintaxis de la función es:

$$[coeff, score, latent, \sim, \sim, mu] = pca(A) \quad (11)$$

Donde:

- Coeff: es la matriz de coeficientes del espacio transformado.
- Score: son las observaciones mapeadas al espacio transformado.
- Latent: es vector de pesos de cada componente principal. Evidencia el aporte de cada componente del sistema.
- Mu: Es el vector de medias de la matriz A.

Para transformar una nueva observación al conjunto de datos se aplica la siguiente función de transformación:

$$EpT = \left[coeff^T * [Ep - repmat(mu, length(MIP), 1)]^T \right]^T$$

Donde:

- EpT es la nueva observación en el espacio de transformación PCA.
- Ep es la nueva observación

6. RECONOCIMIENTO DE ACTIVIDAD FÍSICA HUMANA CON HMM

En esta etapa se realiza la clasificación de las actividades físicas utilizando las secuencias de movimientos primitivos generadas por la clasificación SVM. Andrés Calvo [1], propone en su metodología utilizar Modelos ocultos de Markov (HMM) para obtener la clasificación de actividad física. Entonces se debe obtener la información de clasificación SVM durante la ventana de observación de tres segundos y así construir el vector de características que utiliza la HMM para entrenar y clasificar la acción física.

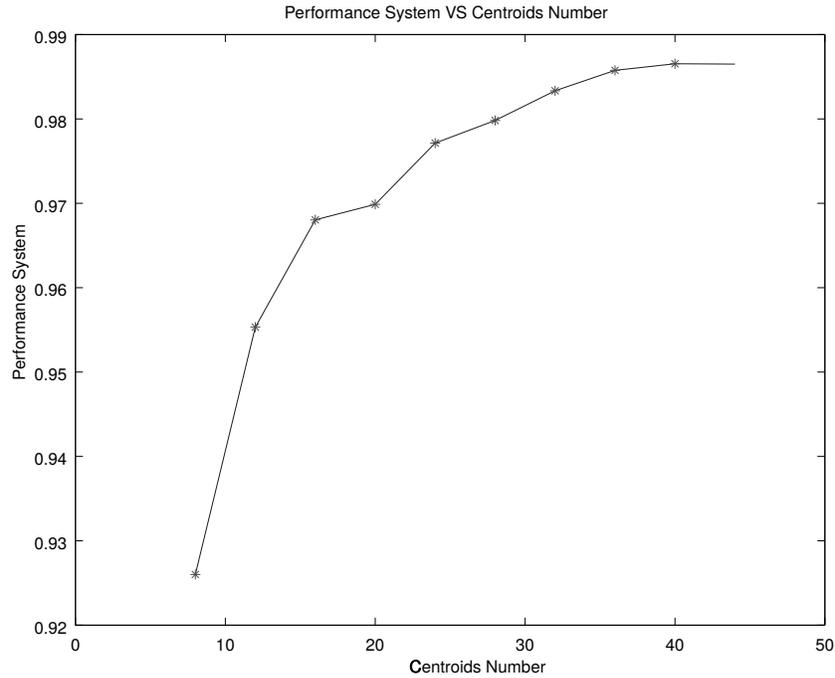
En la sección 5.2 el clasificador SVM genera una etiqueta: EI_k corresponde a la salida de la SVM. Donde k corresponde a la k –ésima muestra durante la ventana de observación de 3 segundos. Entonces para obtener el vector de características EF con el que la HMM debe de ser entrenada, se almacena la respuesta de la SVM durante cada instante de muestreo, obteniendo:

$$EF = [EI_1 EI_2 \dots EI_{30}]_{1 \times 30} \quad (12)$$

6.1. Entrenamiento y validación del modelo

Para el entrenamiento de la HMM se utilizaron 24 estados y 32 centroides en la construcción del libro de códigos; este proceso es iterado hasta que se encuentre un desempeño mayor al 95 % o se cumplan 100 iteraciones. Se escogen 32 centroides, ya que en el trabajo [1], se demuestra que 32 es el número óptimo de centroides en el entrenamiento. Esto se puede observar en la figura 7.

Figura 7. Número de centroides Vs Eficiencia de Acierto



Para realizar el procedimiento de evaluación del modelo se utiliza validación cruzada, seleccionando 70 % de la base de datos para entrenamiento y 30 % para evaluación; este proceso aplica Montecarlo variando aleatoriamente la fracción de entrenamiento y esto se repite de forma iterativa hasta que $\|\text{diag}(M_k) - \text{diag}(M_{k-1})\| < 0,001$, donde $\text{diag}(M_k)$ es la diagonal de la matriz de confusión y k es la iteración promedio actual de Montecarlo. En este experimento se calcula la matriz de confusión la cual indica porcentaje de acierto y error para cada clase, a demás de calcular el acierto promedio del método.

7. EXPERIMENTOS Y RESULTADOS

En esta etapa, se presentan los resultados obtenidos al validar el sistema de clasificación aplicando Montecarlo. Tras aplicar la técnica de validación, se logra demostrar que al proyectar la matriz de entrenamiento a al espacio de componentes principales existen componentes linealmente dependientes que no son necesarias para el entrenamiento y clasificación de movimientos primitivos. También se evidencia comportamiento que presenta la clasificación de actividad con HMM cuando se reduce las componentes principales con las que se entrena el modelo SVM. A demás de los análisis de desempeño, también se analizó la reducción de costo computacional temporal al reducir componentes en el conjunto de de características. A todas las matrices de confusión, se les calcula la desviación utilizando un intervalo de confianza del 99 % con el fin de comparar la eficiencia de los resultados.

En este trabajo se utiliza la base de datos anotada de movimientos primitivos del trabajo [1], donde se realiza inicialmente una etapa de extracción de características ampliamente descrita en la sección 5.1. Esta etapa de extracción permite obtener un conjunto de datos aptos para la clasificación de estos movimientos. Posteriormente se construye la matriz de entrenamiento A , a la cual se le realiza el análisis de componentes principales aplicando el procedimiento descrito en la sección 5.2, permitiendo obtener una representación de la matriz A en componentes principales. Esta nueva matriz entrega el aporte de cada componente permitiendo observar el número de componentes principales necesarias en el entrenamiento. En las figuras 8 y 9, se puede observar el aporte de cada componente después de aplicar PCA para la matriz de entrenamiento de la SVM. Se evidencia que para representar el 100 % del espacio de entrenamiento solo es necesario 70 componentes. Esto indica que el resto de las columnas tiene dependencia lineal y no aportan información importante para representar el espacio.

Figura 8. Análisis de componentes principales para la matriz de entrenamiento

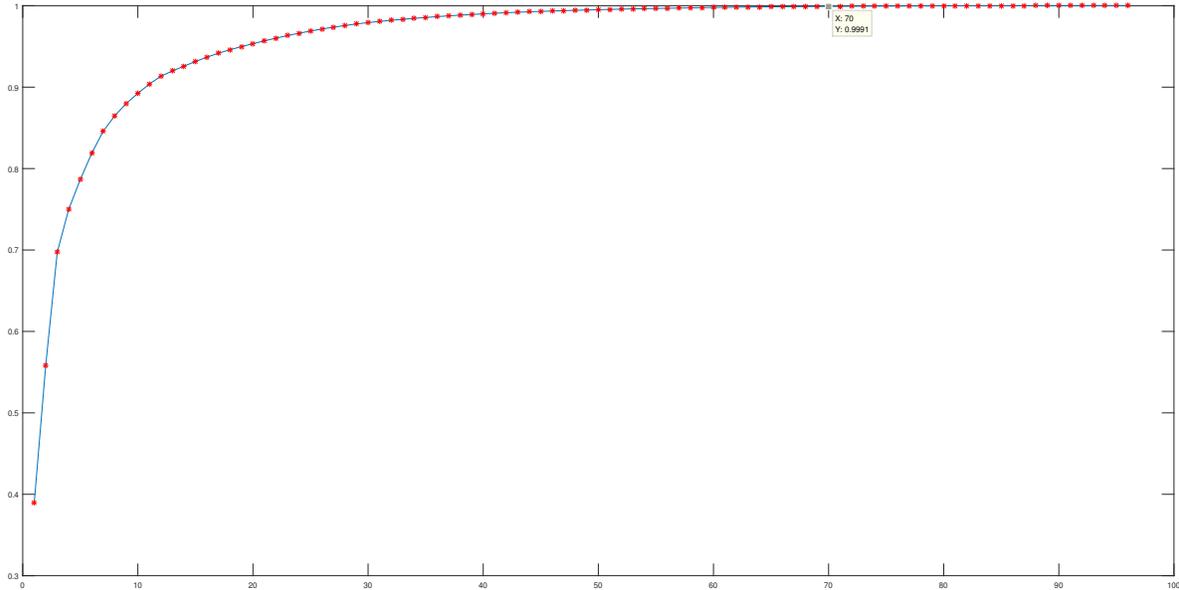


Figura 9. Análisis de componentes principales para la matriz de entrenamiento



Aunque 70 componentes son necesarias para representar el espacio de la matriz de entrenamiento, es necesario verificar si este espacio reducido, produce un rendimiento similar al presentado en 8. Por tal razón, se aplicó la metodología de validación descrita en la sesión 6.1 obteniendo las matrices de confusión para los datos provistos con los sensores IMU. El análisis con los datos provistos por la red de sensores IMU evidencia un comportamiento mayor al 60 % de acierto para el reconocimiento de movimientos primitivos, tal y como se puede observar en la tabla 5. Algunos movimientos primitivos no son reconocidos de forma confiable, debido en gran parte a la naturaleza que tienen estos sensores para brindar información discriminante con actividades con cambios de aceleración similar como lo son las clases 7 y 8. Este análisis se realiza inicialmente para el conjunto de entrenamiento total sin aplicar PCA y se demuestra la repetibilidad de los resultados obtenidos por Andrés Calvo [1].

Tabla 5. Matriz de Confusión SVM-IMU sin PCA

	1	2	3	4	5	6	7	8
1	89.08	1.92	0.18	1.48	1.51	0.32	3.04	2.48
2	7.75	77.61	13.80	0	0	0	0.59	0.24
3	0.67	26.65	71.24	0	0	0	1.22	0.21
4	12.22	0	0	87.07	0	0	0.59	0.13
5	14.36	0	0	0	74.87	13.30	0.47	0
6	0.47	0	0	0	6.47	93.07	0	0
7	8.67	0.16	0.01	0.33	0.03	0	62.28	28.52
8	9.56	0.11	0	0.27	0	0	27.74	62.28

Después de demostrar la repetibilidad en el experimento, se buscó demostrar que la representación PCA con todas las componentes permitía obtener resultados similares a los evidenciados en el experimento anterior. En la tabla 6, se puede observar el desempeño en la detección cuando es aplicado PCA. En este experimento, se toman todas las componentes principales del nuevo espacio de representación y se evidencia que al proyectar la matriz de entrenamiento al espacio PCA el desempeño de la SVM no se reduce significativamente. Por esta razón, se considera que el comportamiento de clasificación es igual. El tiempo que demoró en correr el experimento de clasificación con validación cruzada fue de 498.027 segundos.

Tabla 6. Matriz de Confusión SVM-IMU con PCA todos los componentes

	1	2	3	4	5	6	7	8
1	88.06	1.94	1.18	1.33	1.51	0.28	3.14	2.58
2	7.55	77.81	12.80	0	0	0	0.63	0.30
3	0.53	26.79	71.11	0	0	0	1.32	0.24
4	11.22	0	0	87.03	0	0	1.57	0.18
5	13.33	0	0	0	74.87	14.33	0.47	0
6	0.43	0	0	0	7.51	92.07	0	0
7	8.77	0.06	0.11	1.22	1.04	0	61.28	27.52
8	8.53	1.14	0	0.37	0	0	26.79	62.23

Como ya se demostró que el método PCA garantiza obtener una correcta representación que no genera cambios en la clasificación SVM. Se decidió reducir el conjunto de características utilizando las 70 componentes que permiten obtener un 100% de la representación. En la tabla 7 se puede observar el desempeño en la detección cuando es aplicado PCA con 70

componentes. Este experimento evidencia que el comportamiento es aproximadamente igual al de la tabla 6, por lo que se demuestra que las 30 componentes restantes no son necesarias para el entrenamiento y clasificación con SVM. El tiempo que demoró en correr el experimento de clasificación con validación cruzada fue de 483.011 segundos, esta métrica permite resaltar que el tiempo de computo ha disminuido y la eficiencia se mantiene.

Tabla 7. Matriz de Confusión SVM-IMU con PCA todos los componentes

	1	2	3	4	5	6	7	8
1	88.05	1.95	1.16	1.35	1.56	0.23	3.16	2.56
2	7.59	77.77	12.89	0	0	0	0.56	0.30
3	0.43	27.79	71.01	0	0	0.1	1.33	0.23
4	10.22	0.05	0.05	86.07	0	0	2.53	1.18
5	13.23	0	0	0	74.62	14.68	0.45	0.03
6	0.49	0	0	0	7.41	92.01	0.10	0
7	6.77	0.03	0.14	1.21	1.06	1.0	60.27	28.52
8	8.43	1.21	0	0.40	0	0	27.89	61.13

Con el fin de encontrar el número de componentes óptimo, se decide seguir reduciendo el número de componentes principales. Por esta razón se plantea otro experimento solo tomando 30 de las 92. En la tabla 8, se puede observar la matriz de confusión para la clasificación de movimientos primitivos utilizando la técnica PCA con 30 componentes. Este resultado evidencia un comportamiento similar al de todas las componentes principales. Sin embargo, la clase 3 presenta una disminución significativa al tener un porcentaje de acierto del 64.76 % comparado con el todas las componentes principales que arroja un 71.24%. El tiempo que demoró en correr el experimento Montecarlo fue 440.027 segundos obteniendo una reducción 52.984 segundos con respecto al experimento anterior.

Tabla 8. Matriz de Confusión SVM-IMU con PCA - 30 componentes

	1	2	3	4	5	6	7	8
1	87.1	2.14	0.26	1.64	1.7	0.48	3.57	3.1
2	9.4	72.47	16.12	0	0.01	0	1.35	0.66
3	1.61	28.8	68.19	0.01	0	0	0.94	0.44
4	10.74	0	0.01	85.5	0	0	2.82	0.93
5	15.08	0	0	0	66.55	17.19	0.86	0.32
6	1.19	0	0	0.01	8.86	89.8	0.01	0.13
7	10.35	0.3	0.11	0.41	0.08	0.01	59.02	29.73
8	11.74	0.01	0	0.37	0.01	0.02	32.54	55.28

Aunque el experimento anterior evidencia un baja en la eficiencia del método, se considera que no es significativa por lo que se decide, seguir reduciendo el número de componentes. En la tabla 9, se observa la matriz de confusión para la clasificación movimientos primitivos haciendo uso de PCA pero, esta vez, usando solo 25 componentes de un total de 92. Es posible observar, que a pesar de estar usando menos de la tercera parte de el total de componentes, la eficiencia de la metodología no ha caído más del 10 % en ninguna de las clases con respecto a los experimentos anteriores, los cuales presentar mayor número de componentes. El tiempo que demoró en correr el experimento Montecarlo fue 433.184595 segundos.

Tabla 9. Matriz de Confusión SVM-IMU con PCA - 25 componentes

	1	2	3	4	5	6	7	8
1	85.42	2.29	0.37	1.7	1.66	0.45	4.27	3.83
2	9	70.28	19.61	0	0	0	0.82	0.29
3	3.49	30.77	64.76	0.09	0	0	0.6	0.28
4	8.72	0	0	89.37	0	0	1.81	0.1
5	13.16	0	0	0	70.25	14.83	0.89	0.87
6	0.71	0	0	0	8.48	90.8	0.01	0
7	8.97	0.03	0.03	0.39	0.02	0	60.97	29.58
8	11.34	0.25	0.02	0.26	0	0	30.52	57.61

En este experimento se decide seguir reduciendo el número total de características, por lo que solo se utilizan 20 de las 92 componentes totales. En la tabla 10, se presenta la matriz de confusión para la clasificación movimientos primitivos haciendo uso de PCA. Aunque se estaba realizando el procedimiento de clasificación con menos de la cuarta parte de las componentes,

se puede observar que la efectividad del método sigue sin caer más del 10 % en ninguna de sus clases. Las clases que presentan una mayor reducción de la eficiencia son las clases 3 y 8, donde su rendimiento se ve reducido en un 7 %. El tiempo que demoró en correr el experimento Montecarlo fue 428.345309 segundos. Esta métrica permite seguir resaltando que el tiempo de computo ha disminuido y su eficiencia se mantiene.

Tabla 10. Matriz de Confusión SVM-IMU con PCA - 20 componentes

	1	2	3	4	5	6	7	8
1	85.17	2.48	0.39	1.65	1.63	0.52	4.36	3.8
2	9.28	69.48	19.83	0	0	0	1.09	0.33
3	3.52	31.93	62.45	0.01	0	0	1.08	1
4	9.86	0	0	88.43	0	0	1.39	0.32
5	14.57	0	0	0	68.85	15.18	0.77	0.63
6	0.77	0	0	0	8.63	90.6	0	0
7	10.91	0.3	0.15	0.46	0.14	0	57.74	30.29
8	10.79	0.04	0.01	0.35	0	0.02	32.9	55.89

Se desea reducir aun más el número de componentes. En la tabla 11, se puede observar la matriz de confusión para la clasificación movimientos primitivos haciendo uso del PCA utilizando solo de 15 de las 92 componentes totales. Los resultados presentados en esta tabla, evidencian que, a pesar de haber reducido la cantidad de componentes a menos del 20 %, su rendimiento apenas ha disminuido un 8 % para el peor de los casos. El tiempo que demoró en correr el experimento Montecarlo fue 425.558565 segundos.

Tabla 11. Matriz de Confusión SVM-IMU con PCA - 15 componentes

	1	2	3	4	5	6	7	8
1	84.17	3.48	0.39	1.75	1.43	0.67	4.22	3.7
2	9.25	69.18	19.80	0	0.03	0.10	1.23	0.22
3	3.22	31.93	62.25	0.31	0	0.03	1.25	2.0
4	9.46	0	0	88.25	0	0	1.8	0.49
5	13.37	1.2	0	0	68.35	15.68	0.89	0.51
6	0.78	0	0	0	8.64	90.3	0.3	0
7	10.71	0.3	0.25	0.46	0.34	0	56.24	31.29
8	10.38	0.47	0.01	0.53	0	0.08	32.7	55.83

Finalmente se lleva la clasificación al límite utilizando 10 componentes de las 92 totales. En la

tabla 12, se puede observar la matriz de confusión para la clasificación movimientos primitivos haciendo uso del PCA. Con este experimento se puede observar que el rendimiento de la SVM cayó 11.39 % en la clase 8,(el peor de todos los casos) con respecto al experimento que utiliza todas las componentes principales. Aunque, se comienza a notar una perdida significativa de eficiencia, se debe tener en cuenta que se están usando menos del 11 % de las componentes totales. Al analizar este último hecho, se nota que la eficiencia no cae significativamente, comparada con el número de componentes tomados, donde en alguna aplicaciones, podría hacerse justificable reducir la efectividad del proceso con el fin de reducir el coste computacional del mismo. El tiempo que demoró en correr el experimento Montecarlo fue 367.94637 segundos.

Tabla 12. Matriz de Confusión SVM-IMU con PCA - 10 componentes

	1	2	3	4	5	6	7	8
1	85.89	2.35	0.41	1.65	1.92	0.61	3.97	3.20
2	8.81	71.88	16.74	0.12	0	0	1.00	1.44
3	4.27	29.03	64.88	0	0	0	1.32	0.50
4	11.43	0	0	82.52	0	0	2.82	3.23
5	15.03	0.02	0	0	65.69	18.11	0.94	0.22
6	2.92	0.05	0.01	0	9.24	87.41	0.33	0.03
7	11.86	0.18	0.1	0.4	0.25	0	56.16	31.05
8	12.92	0.39	0.11	1.28	0.07	0	33.81	51.41

7.1. Reconocimiento de actividades físicas

Aunque se ha demostrado la eficiencia de PCA para reducir con conjunto de características en la clasificación de movimientos primitivos, la metodología utilizada en este trabajo propone utilizar una HMM para el reconocimiento de actividad física. Por esta razón es importante analizar el efecto que tiene la reducción en la eficiencia de la etapa SVM al reducir el conjunto de características en su entrenamiento y clasificación. En esta etapa se realizaron experimentos de validación cruzada que permitieron obtener las matrices de confusión correspondientes al reconocimiento de las actividades propuestas en la tabla 1. Inicialmente se realiza el cálculo de metodología de clasificación sin aplicar PCA tomando todo el conjunto de características, donde se puede observar la repetibilidad de los resultados obtenidos por Andrés Calvo [1] en su trabajo investigativo. Posteriormente se realizó los experimentos de clasificación de SVM con

un conjunto de características reducido y se generó el vector de entrenamiento, que necesario para entrenar la HMM.

En la tabla 13, se puede observar un alto desempeño en la clasificación de actividad, donde la clase con menor desempeño (3) presenta una probabilidad de acierto del 96.14%. Este resultado corrobora los datos obtenido por Andrés Calvo [1].

Tabla 13. Matriz de Confusión HMM-IMU

	1	2	3	4	5
1	100	0	0	0	0
2	0	98.37	0.14	0	1.49
3	0	1.89	96.14	0.36	1.61
4	0	0	0	100	0
5	0	0.24	0.13	0.13	97.80

Como los experimentos de la sección anterior, se decide probar la eficiencia de la HMM utilizando una SVM con todas los componentes principales. En la tabla 14, se puede observar la clasificación de actividad física. La tabla anterior, permite validar que el espacio con todas componentes representa la matriz de entrenamiento original y la SVM no presenta un comportamiento diferente al original, permitiendo a la HMM tener vector entrada correcto garantizando la eficiencia reportada.

Tabla 14. Matriz de Confusión HMM-IMU con PCA utilizando todos los componentes principales

	1	2	3	4	5
1	100	0	0	0	0
2	0	98.27	0.23	0	1.50
3	0	1.91	95.15	0.45	1.59
4	0	0	0	100	0
5	0	0.14	0.32	0.14	96.80

Se desea reducir aun más el número de componentes, esto con el fin de observar el efecto sobre la clasificación de actividad. En la tabla 15, se puede observar los resultados de la matriz confusión obtenidos para la clasificación de actividad utilizando la HMM usando PCA con 25 de las 92 componentes totales. Este experimento evidencia un rendimiento similar al de

cuando se usan todas las componentes y solo se esta utilizando una cuarta parte del conjunto de componentes. El peor de los casos se puede observar en la clase 2, donde el rendimiento pasa de 98.37% a 98.03 %.

Tabla 15. Matriz de Confusión HMM-IMU con PCA para 25 componentes

	1	2	3	4	5
1	100	0	0	0	0
2	0	98.03	1.97	0	0
3	0	3.14	96.65	0.02	0.18
4	0	0	0.03	99.97	0
5	0	0.11	0.25	0.12	99.53

Finalmente como en la sección anterior se lleva la clasificación al límite utilizando 10 componentes de las 92 totales. En la tabla 16, se puede observar la matriz de confusión obtenida. En este experimento se evidencia un rendimiento mayor al 95 % para la clasificación de actividad en 4 de las 5 clases totales. Sin embargo en la clase 5, el rendimiento presenta un deterioro del 4% comparado con el de la HMM que hace uso de todas las componentes. Aunque hay una reducción significativa para la última clase se observa que el resultado es del 93.98, el cual se puede considerar un resultado con buena confiabilidad para muchas aplicaciones y solo se utilizan 10 componentes del conjunto total. Lo anterior permite demostrar que es posible reducir el tiempo cómputo sin exista una pérdida significativa de eficiencia.

Tabla 16. Matriz de Confusión HMM-IMU con PCA para 15 componentes

	1	2	3	4	5
1	100	0	0	0	0
2	0	98.46	1.54	0	0
3	0	2.95	96.33	0	0.72
4	0	0	0	99.46	0.54
5	0	0.05	5.97	0	93.98

Con el fin de obtener el conjunto de características principales que garantice reducción en el tiempo de cómputo y eficiencia en la clasificación, se calcula una tabla comparativa de la eficiencias de clasificación con sus respectivos intervalos de confianza a una métrica del 99 %. De la tabla 17 se puede concluir, que el conjunto de características puede reducido hasta el uso de

Número de Componentes	1	2	3	4	5
Sin PCA	100 ± 0	98,37 ± 2,11	96,14 ± 3,21	100 ± 0	97,80 ± 2,45
PCA-25 componentes	100 ± 0	98,03 ± 2,32	96,65 ± 2,99	99,97 ± 0,29	99,53 ± 1,14
PCA-15 componentes	100 ± 0	98,46 ± 2,06	96,33 ± 3,14	99,46 ± 1,23	93,98 ± 3,97

Tabla 17. Comparación de las eficiencias para diferentes componentes principales

25 componentes principales. El criterio utilizado para esta selección es garantizar eficiencias de acierto mayores al 95 %, cifra que se considera estándar para considerar un sistema de clasificación confiable.

8. CONCLUSIONES Y RECOMENDACIONES

8.1. CONCLUSIONES

Se aplicó una metodología de reconocimiento automático de actividad física humana basado en la detección de movimientos primitivos utilizando, análisis de componentes principales, máquinas de vectores de soporte multiclase y clasificadores HMM. Esta metodología la cual tiene la capacidad de reducir el conjunto de características hasta 25 componentes garantizando eficiencias en cada clase mayores al 95 % de acierto en cada experimento de Montecarlo.

Se probó la metodología propuesta en una base de datos anotada, la cual tiene el registro sincronizado de diferentes sensores, permitiendo crear la base para extender el concepto de reducción de dimensionalidad a las otras modalidades de sensores. Esto permitirá obtener una metodología de reconocimiento de actividad con fusión de datos multimodal con dimensión reducida, haciendo cada vez más cercano implementar la metodología del trabajo investigativo de Andrés Calvo [1], en un sistema embebido. Sin embargo, la base de datos todavía debe ser expandida a un conjunto de actividades más amplio, para evaluar el verdadero potencial método con su reducción de dimensionalidad.

Se demostró el poder de caracterización que tienen los descriptores utilizados para cada sensor en el reconocimiento de movimientos primitivos, logrando así recopilar en un solo documento descriptores efectivos para este tipo de tareas y garantizando cuantos de ellos son indispensables en un espacio de transformación PCA.

Con la inclusión de la metodología de reducción de características PCA, se hace posible reducir el conjunto de características no solo para la red de acelerómetros utilizada en el trabajo de Andrés Calvo [1], si no también para el resto de sensores utilizado en este trabajo. Esto permite obtener una posible solución para la reducción del costo computacional en cualquier conjunto de características de un sistema de clasificación.

8.2. RECOMENDACIONES Y TRABAJOS FUTUROS

Este trabajo está centrado en la reducción de dimensionalidad para el reconocimiento de actividades físicas humanas minimizando la pérdida de eficiencia del sistema. Durante el desarrollo del mismo, se observó, que la base de datos tiene un conjunto de actividades con fácil separación por movimientos primitivos impidiendo evaluar el verdadero potencial método con su reducción de dimensionalidad, generando un interrogante en cuanto a la capacidad de separación y si es necesario tomar mas componentes principales cuando este conjunto sea ampliado. Esto permite ver como un trabajo futuro la construcción de una base de datos anota que tenga un conjunto de actividades amplia y que cumpla con los estándares de calidad para el registro de este tipo de trabajos.

Aunque el método de análisis de componentes principales ha demostrado reducir de forma significativa el costo computacional temporal del método, recomienda explorar otras técnicas para este tipo de labores como SVD-*Singular Value Decomposition*, Análisis de Componentes Independientes, entre otros, para realizar una comparación de los diferentes método y su incidencia en el reconocimiento de actividad con la metodología [1]. Por otro lado se recomienda explorar técnicas que no transformen los datos a otro espacio de representación, con el fin de evitar realizar el cálculo de todos los descriptores, si no estas características sean eliminadas antes de calcular matriz de entrenamiento.

BIBLIOGRAFÍA

- [1] CALVO, Andrés Felipe. Reconocimiento Automático de Actividades Físicas Humanas en Sistemas Multimodales. Tesis de Maestría, Facultad de Ingenierías, 2015. (document), 1, 1.1, 1.2, 1, 3, 4, 4.1, 4.2, 4.2.1, 5, 5.1, 5.1.1, 5.2, 6, 6.1, 7, 7, 7.1, 8.1, 8.2
- [2] A.J. BERNHEIM BRUSH, John Krumm y SCOTT, James. Activity Recognition Research: The Good, the Bad, and the Future. En: The Eighth International Conference on Pervasive Computing, 2010. 1
- [3] AKRAM BAYAT, Marc Pomplun y TRAN, Duc A. A Study on Human Activity Recognition Using Accelerometer Data from Smartphones. En: The 11th International Conference on Mobile Systems and Pervasive Computing, 2014. 1, 1.1
- [4] BAO, Ling y INTILLE, Stephen S. Activity Recognition from User-Annotated Acceleration Data. En: in Proceedings of PERVASIVE, 2004, págs. PP 1–17. 1, 1.1, 2
- [5] DOS SANTOS, Diliana Maria Barradas Rebelo. Human Activity Recognition for an Intelligent Knee Orthosis. Tesis de Maestría, Facultad de Ciências e Tecnologia, Universidade Nova de Lisboa, 2012. 1
- [6] MEDIA INFORMATICS GROUP UNIVERSITY OF MUNICH, GERMANY. Multi-Sensor Activity Context Detection for Wearable Computing. Perceptual Computing and Computer Vision ETH Zurich, Switzerland. 1
- [7] D, Leightley, *et al.* Human Activity Recognition for Physical Rehabilitation. En: Systems, Man, and Cybernetics (SMC), 2013 IEEE International Conference on, 2013, págs. 261–266. 1.1
- [8] GYLLENSTEN, Illpha Cuba. Physical Activity Recognition in Daily Life using a Triaxial Accelerometer. Tesis de Maestría, School of Computer Science and Engineering Royal Institute of Technology, 2010. 1.1

- [9] BAÑOS, Oresti; POMARES, Héctor y ROJAS, Ignacio. Hibridación de paradigmas de clasificación en el contexto del reconocimiento automático de actividades físicas cotidianas. En: ESTYLF, Congreso Español sobre Tecnologías y Lógica Fuzzy, 2010. 1.1, 1.2
- [10] JINGEN LIU, Saad Ali y SHAH, Mubarak. Recognizing Human Actions Using Multiple Features. En: Computer Vision and Pattern Recognition, 2008. 1.1, 1.2, 2
- [11] BAO, L. y INTILLE, S. S. Activity recognition from user-annotated acceleration data. En: in Proceedings of the 2nd International Conference on Pervasive Computing, 2004, págs. 1–17. 1.1, 1.2
- [12] LI, Kang y FU, Yun. ARMA-HMM: A New Approach for Early Recognition of Human Activity. 21, 2012, págs. 11–15. 1.1
- [13] ZHANG, Zequn, *et al.* A novel method for user-defined human posture recognition using Kinect. En: Image and Signal Processing (CISP), 2014 7th International Congress on, 2014, págs. 736–740. 1.1, 1.2
- [14] LU, W y LITTLE, J.J. Simultaneous tracking and action recognition using the PCA-HOG descriptor. En: 3rd Canadian Conference on Computer and Robot Vision, 2006. 1.1
- [15] LU, X, Liu Q y S, Oe. Recognizing Non-rigid Human Actions using Joints Tracking in Space-Time. En: Conference on Information Technology: Coding and Computing, 2004. 1.1, 1.2
- [16] SCOVANNER, P Ali, S y M, Shah. A 3-dimensional SIFT Descriptor and Its Application to Action Recognition. En: 15th International Conference on Multimedia, ACM,, 2007. 1.1
- [17] VEERARAGHAVAN, A.; A.K., Roy-Chowdhury y CHELLAPPA, R. Matching shape sequences in video with applications in human movement analysis. En: Pattern Analysis and Machine Intelligence, IEEE Transactions on, tomo 27, nº 12, 2005, págs. 1896–1909. ISSN 0162-8828. 1.1

- [18] A, Dragan M y I., Mocanu. Human Activity Recognition in Smart Environments. En: Control Systems and Computer Science (CSCS), 2013 19th International Conference on, 2013, págs. 495–502. 1.1, 2
- [19] PANVALKAR, Rujuta; VASHI, Ami y KARANI, Ruhina. Human Posture Recognition: Background Subtraction and Skeletonization. En: IOSR Journal of Computer Engineering, tomo 16, 2014, págs. 67–70. 1.1, 2
- [20] LI, W., Zhang Z. y LIU, Z. Action recognition based on a bag of 3d points. En: In Workshop on CVPR for Human Communicative Behavior Analysis, 2010. 1.1
- [21] J. SUNG, C. Ponce, B. Selman y SAXENA, A. Human activity detection from rgb-d images. En: in Plan, Activity, and Intent Recognition, tomo WS- 11-16, 2011. 1.1
- [22] DESTELLE, F., *et al.* Low-cost accurate skeleton tracking based on fusion of kinect and wearable inertial sensors. En: Signal Processing Conference (EUSIPCO), 2014 Proceedings of the 22nd European, 2014, págs. 371–375. 1.1
- [23] WU, Haitao, *et al.* Human activity recognition based on the combined SVM and HMM. En: Information and Automation (ICIA), 2014 IEEE International Conference on, 2014, págs. 219–224. 1.1, 1.2
- [24] XIA, Lu; CHEN, Chia-Chih y AGGARWAL, J.K. Human detection using depth information by Kinect. En: Computer Vision and Pattern Recognition Workshops (CVPRW), 2011 IEEE Computer Society Conference on, 2011. ISSN 2160-7508, págs. 15–22. 1.1
- [25] TAO, G.; ARCHAMBAULT, P.S. y LEVIN, M.F. Evaluation of Kinect skeletal tracking in a virtual reality rehabilitation system for upper limb hemiparesis. En: Virtual Rehabilitation (ICVR), 2013 International Conference on, 2013, págs. 164–165. 1.1
- [26] M. BOCKSCH, J. Seitz y JAHN, J. Pedestrian Activity Classification to Improve Human Tracking and Localization. En: Forth International Conference on Indoor Positioning and Indoor Navigation, 2013. 1.1, 2

- [27] DE CASTRO, David Martín. Aplicación Android para el reconocimiento automático de actividades físicas en tiempo real. Tesis de Maestría, Universidad Carlos III de Madrid Departamento de Informática, 2012. 1.1, 2
- [28] ZHANG, Mi; SAWCHUK y A., Alexander. Motion Primitive-based Human Activity Recognition Using a Bag-of-features Approach. En: Proceedings of the 2Nd ACM SIGHT International Health Informatics Symposium, IHI '12. ACM, New York, NY, USA, 2012. ISBN 978-1-4503-0781-9, págs. 631–640. URL <http://doi.acm.org/10.1145/2110363.2110433>. 1.1, 2
- [29] DE LATHAUWER, L.; DE MOOR, B. y VANDEWALLE, J. Dimensionality reduction in higher-order-only ICA. En: Higher-Order Statistics, 1997., Proceedings of the IEEE Signal Processing Workshop on, 1997, págs. 316–320. 1.1, 1.2
- [30] MISHRA, S., *et al.* Feature reduction using principal component analysis for agricultural data set. En: Electronics Computer Technology (ICECT), 2011 3rd International Conference on, tomo 2, 2011, págs. 209–213. 1.1, 1.2
- [31] FOERSTER, Friedrich y FAHRENBERG. Motion pattern and posture: Correctly assessed by calibrated accelerometers. En: Behavior Research Methods, Instruments, & Computers, 2000. 1.2
- [32] DAI, Yu, *et al.* PCA-based dimensionality reduction method for user information in Universal Network. En: Cloud Computing and Intelligent Systems (CCIS), 2012 IEEE 2nd International Conference on, tomo 01, 2012, págs. 70–74. 1.2
- [33] BLANK, M. Gorelick, L. Shechtman E. Irani M. y BASRI, R. Actions as Space-time Shapes. En: Tenth IEEE International Conference on Computer Vision, 2005. 2
- [34] DOLLÁR, P, Rabaud V Cottrell G y S, Belongie. Behavior Recognition via Sparse Spatio-Temporal Features. En: 2nd Joint IEEE International Workshop on Visual Surveillance and Performance Evaluation of Tracking and Surveillance, 2005. 2

- [35] KE, Y., Sukthankar R. y M, Hebert. Spatio-temporal Shape and Flow Correlation for Action Recognition. En: Conference on Computer Vision and Pattern Recognition, 2007. 2
- [36] ZHANG, Mi y SAWCHUK, Alexander A. A feature selection-based framework for human activity recognition using wearable multimodal sensors. En: In International Conference on Body Area Networks (BodyNets), Beijing, China, 2011. 2
- [37] BAÑOS, O., *et al.* Kinect=IMU? Learning MIMO Signal Mappings to Automatically Translate Activity Recognition Systems across Sensor Modalities. En: Wearable Computers (ISWC), 2012 16th International Symposium on, 2012. ISSN 1550-4816, págs. 92–99. 2
- [38] ALVAREZ, D. García. Estudio comparativo de técnicas de detección de fallos basadas en el Análisis de Componentes Principales (PCA). En: Revista Iberoamericana de Automática e Informática industrial, , nº 8, 2011, págs. 182–185. 2
- [39] TSAI, Du-Ming; WU, Shih-Chieh y CHIU, Wei-Yao. Defect Detection in Solar Modules Using ICA Basis Images. En: Industrial Informatics, IEEE Transactions on, tomo 9, nº 1, 2013, págs. 122–131. ISSN 1551-3203. 2
- [40] GARCÍA PÉREZ, Alfonso. Estadística aplicada: conceptos básicos. En: , 2008. 3.1
- [41] OSTLE, Bernard. Estadística aplicada. Limusa, 1979. 3.2
- [42] SPIEGEL, Murray R, *et al.* Probabilidad y estadística. McGraw-Hill, 2010. 3.3
- [43] JONES, Ian F. Tutorial: transformadas, ortogonalidad, eigenvectores y eigenvalores. En: first break, tomo 31, nº 1, 2013. 3.5
- [44] SCHÖLKOPF, Bernhard, Smola y J, Alexander. Learning with Kernels. MIT Press, 2002. 3.6
- [45] CRAMMER, Koby y SINGER, Yoram. On the Algorithmic Implementation of Multiclass Kernel-based Vector Machines. En: J of Machine Learning Research, 2001. 3.6.1

- [46] RABINER, Lawrence R. A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. En: Proceedings of the IEEE, tomo 77, nº 2, 1989. 3.7
- [47] FISHER, Ronald. Statistical Methods and Scientific Inference. Edinburgh, 1956. 3.8
- [48] SYMS, C. Principal components analysis. En: , 2008. 3.9
- [49] SMITH, Lindsay I. A tutorial on principal components analysis. En: Cornell University, USA, tomo 51, 2002, pág. 52. 3.9
- [50] EPA UNITED STATES ENVIRONMENTAL PROTECTION AGENCY. Consolidated Human Activity Database (CHAD) for use in human exposure and health studies and predictive models. EPA. 4
- [51] UNIVERSITY OF CENTRAL FLORIDA. UCF Sports Action Data Set. Center for Research in Computer Vision. 4
- [52] IVAN LAPTEV. Learning Human Actions from Movies. IRISA INRIA Rennes France. 4
- [53] UCI. Human Activity Recognition Using Smartphones Data Set. Center for Machine Learning and Intelligent Systems. 4
- [54] ILLINOIS. RGB-D Human Activity Recognition and Video Database. Advanced Digital Sciences Center. 4
- [55] GHASEMZADEH, H., *et al.* A phonological expression for physical movement monitoring in body sensor networks. En: Mobile Ad Hoc and Sensor Systems, 2008. MASS 2008. 5th IEEE International Conference on, 2008, págs. 58–68. 5
- [56] HUANG, Xuedong; ACERO, Alex y HON, Hsiao-Wuen. Spoken Language Processing: A Guide to Theory, Algorithm, and System Development. 1^a ed^{ón}. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2001. ISBN 0130226165. 5