

**Detección de fases de las actividades de sentarse y levantarse mediante  
métodos de machine learning**

**Sophia Otálora González**

**Trabajo Dirigido**

**Tutores**

**Carlos Andrés Cifuentes García, PhD.  
Oscar Julián Perdomo Charry, PhD.**



UNIVERSIDAD DEL ROSARIO  
ESCUELA COLOMBIANA DE INGENIERÍA JULIO GARAVITO  
PROGRAMA DE INGENIERÍA BIOMÉDICA  
BOGOTÁ D.C  
2021

## **Agradecimientos**

Quiero agradecer a mi tutor, el Prof. Dr. Carlos A. Cifuentes y a mi co-tutor, el Prof. Dr. Óscar J. Perdomo, por su acompañamiento en el proceso de realización del proyecto. En especial agradezco a todos los miembros del Centro de Biomecatrónica, principalmente a Luis Arciniegas y Felipe Ballén por sus conocimientos y apoyo.

Personalmente quiero agradecer a mis padres Luis Otálora y Leticia González y a mi hermano Santiago Otálora por ser parte de mi proceso académico y por su apoyo en situaciones desafiantes de mi carrera.

## Resumen

Identificar las fases de las actividades de sentarse y levantarse es primordial para el control de un exoesqueleto de miembro inferior. En este estudio, se presentan los métodos más adecuados para reconocer las fases de las actividades sentarse y levantarse utilizando datos de posición del dataset “Kinect Activity Recognition Dataset (KARD)”. Diez sujetos participaron en el estudio, realizando tres veces las dos actividades cada uno. Se analizaron siete de los quince marcadores que hacen referencia a las extremidades inferiores. Según la literatura, se utilizan dos técnicas de machine learning como k vecinos más cercanos (kNN) y máquinas de soporte vectorial (SVM) con sus respectivos kernels (SVM, SVM, SVMg y SVM) para detectar las fases de cada actividad. El rendimiento de cada algoritmo se analiza a través de matrices de confusión y valores como exactitud, recuperación, precisión y puntuación-F1, donde los resultados muestran que SVMp tiene un mejor rendimiento para la actividad de sentarse con un valor de precisión del 86%. kNN presenta mayor precisión para la actividad de levantarse con un valor del 84%. Ambos algoritmos tienen buenos rendimientos para clasificar las fases de cada actividad, sin embargo, SVM es el método más estable con valores altos en ambas actividades en precisión, recuperación y puntuación-F1. Además, para la actividad de sentarse, se debe agregar una fase adicional para evitar confusiones entre la fase 0 y la fase 1, y viceversa.

# Índice general

|  |           |
|--|-----------|
| Agradecimientos . . . . .  | I         |
| Resumen . . . . .  | II        |
| <b>1. INTRODUCCIÓN</b>   | <b>1</b>  |
| 1.1. Motivación . . . . .  | 1         |
| 1.2. K vecinos más cercanos . . . . .                            | 2         |
| 1.3. Máquinas de soporte vectorial (SVM) . . . . .               | 2         |
| <b>2. OBJETIVOS</b>  | <b>4</b>  |
| 2.1. General . . . . .   | 4         |
| 2.2. Específicos . . . . .                                       | 4         |
| <b>3. REVISIÓN DE LA LITERATURA</b>                              | <b>5</b>  |
| <b>4. METODOLOGÍA</b>  | <b>7</b>  |
| 4.1. Fases de las actividades de sentarse y levantarse . . . . . | 7         |
| 4.2. Dataset . . . . .   | 8         |
| <b>5. RESULTADOS</b>   | <b>10</b> |
| 5.1. k vecinos más cercanos (kNN) . . . . .                      | 10        |
| 5.2. Máquina de soporte vectorial (SVM) . . . . .                | 13        |
| <b>6. DISCUSION</b>  | <b>16</b> |
| <b>7. CONCLUSIONES</b>   | <b>17</b> |
| <b>8. RECOMENDACIONES Y TRABAJOS FUTUROS</b>                     | <b>18</b> |
| <b>BIBLIOGRAFÍA</b>  | <b>19</b> |

# Índice de figuras

|  |    |
|--|----|
| 1.1. Ejemplo de clasificación del algoritmo de kNN, donde el círculo verde hace referencia a un nuevo dato ingresado para ser asignado a su grupo más cercano  | 2  |
| 1.2. Hiperplano de margen máximo para una SVM entrenado en dos clases. Las muestras en los márgenes se denominan vectores de soporte . . . . .   | 3  |
| 4.1. (a-c) Representación gráfica de las fases de la actividad de levantarse (d-f) Fases de la actividad de sentarse . . . . .   | 8  |
| 4.2. Quince (15) articulaciones detectadas por Kinect. Los puntos negros hacen referencia a las articulaciones a utilizar (torso, caderas, rodillas y pies) y los puntos blancos son descartados (cabeza, cuello, hombros, codos y manos). . . . | 9  |
| 5.1. Número de k para el algoritmo de KNN en la actividad de (a) sentarse y (b) levantarse. De acuerdo a la gráfica, k=1 y k=3 respectivamente. . . . .  | 11 |
| 5.2. Imagen de ejemplo . . . . .   | 12 |
| 5.3. Confusion matrix of the kNN method for sitting activity. . . . .  | 12 |
| 5.4. Matriz de confusión del método de SVMp para la actividad de sentarse. . . .   | 15 |
| 5.5. Matriz de confusión del método de SVMg para la actividad de levantarse. . . .   | 15 |

# Índice de tablas

|   |    |
|---|----|
| 3.1. Revisión bibliográfica sobre detección de actividades de la vida diaria mediante métodos de machine learning . . . . . | 6  |
| 5.1. Criterios de Algoritmo kNN . . . . .   | 13 |
| 5.2. Criterios de Algoritmo SVMp Y SVMg . . . . .   | 14 |
| 5.3. Exactitud de los Algoritmos . . . . .  | 14 |

# Capítulo 1

## INTRODUCCIÓN

### 1.1 Motivación

Las actividades de la vida diaria (AVD) describen las habilidades fundamentales que se requieren para cuidar de uno mismo de forma independiente. Entre las AVD más comunes se encuentran la higiene personal, vestirse, ir al baño y deambular, lo que incluye sentarse, levantarse, acostarse, caminar, correr, subir y bajar escaleras, que están relacionados con el movimiento de las extremidades inferiores y no realizar estas actividades puede afectar la calidad de vida de una persona [1].

La capacidad de sentarse o levantarse se considera una de las operaciones funcionales más difíciles y mecánicamente exigentes que puede transcurrir una persona durante un día. Sin tener la posibilidad de estas actividades muchos pacientes y personas mayores se verían limitados y por ende perderían su independencia [2].

Para distinguir las diferentes actividades se pueden utilizar métodos de etiquetado de acuerdo con la actividad que se esté evaluando. Pueden ser manuales identificando los componentes biomecánicos de la persona en el vídeo o mediante una herramienta de etiquetado automática observando cada frame del vídeo.

Debido al uso frecuente de exoesqueletos de miembro inferior para asistir o rehabilitar la marcha, se ha vuelto fundamental poder identificar las fases de las actividades de sentarse y levantarse para el control del dispositivo. [3]

Existen algoritmos que mejoran la actuación de un dispositivo robótico utilizando distintos métodos de machine learning, debido a su capacidad de clasificación óptima en AVDs. En un estudio de detección automática de fallas en la marcha atlética, Taborri et al. mediante sensores inerciales, aplicaron los algoritmos de máquinas de soporte vectorial (SVM), k vecinos más cercanos (kNN) y redes neuronales artificiales (ANN), donde los algoritmos con mejor desempeño fueron los de SVM cuadrático (SVMq) con una exactitud del 90 % y kNN siendo el más estable debido a sus bajos valores en desviación estándar y con exactitudes mayores al 80 % [4]. De Falco et al. para la clasificación de diferentes actividades de la vida diaria y caídas aplicaron técnicas de inteligencia artificial basadas en árboles, en discriminantes, SVM, kNN y algoritmos en conjunto con el objetivo de observar cual era el más adecuado para el dataset

utilizado, dando como resultado las mayores macro exactitudes medias en los algoritmos de KNN tipo fine del 83.4 % y el SVM cúbico (SVMc) del 83.1 % [5].

En este estudio se aplican los métodos de machine learning kNN y SVM para clasificar actividades de la vida diaria con los mejores rendimientos de acuerdo a la literatura, para identificar las fases de sentarse o levantarse.

## 1.2 K vecinos más cercanos

El clasificador kNN sirve para clasificar características sin etiquetar asignándolas a la clase de los ejemplos etiquetados más similares. El parámetro k decide cuántos vecinos se van a elegir para el algoritmo. Dependiendo del k se tendrán distintos rendimientos del algoritmo, por ejemplo, un k muy grande corre el riesgo de ignorar un patrón pequeño pero importante a pesar de reducir el impacto de la variación causada por un error aleatorio [6]. En la Figura 1.1 se observa como al ingresar un nuevo dato o característica (estrella amarilla), el algoritmo la asigna al grupo de su vecino más cercano que en este caso sería el grupo del punto rojo.

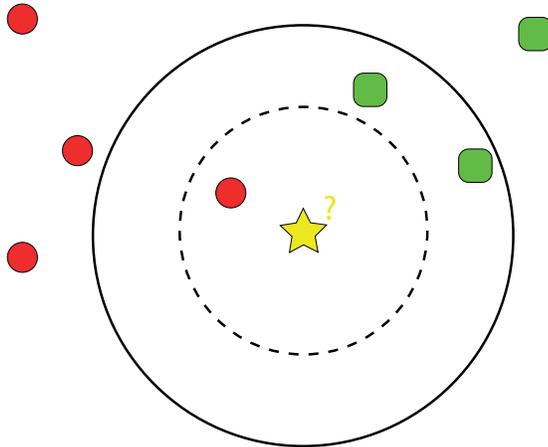


Figura 1.1: Ejemplo de clasificación del algoritmo de kNN, donde el círculo verde hace referencia a un nuevo dato ingresado para ser asignado a su grupo más cercano

## 1.3 Máquinas de soporte vectorial (SVM)

SVM es un algoritmo supervisado y uno de los más utilizados de machine learning. Se define asignando vectores de entrada no lineales a un espacio de alta dimensión donde se construye una superficie de decisión lineal [7] o más conocido como el hiperplano que separa los datos. Se construyen dos hiperplanos paralelos a cada lado del hiperplano que separa los datos como se muestra en la Figura 1.2 y se asume que entre mayor sea la distancia entre los hiperplanos paralelos, mejor será el error del clasificador [8]. Se pueden implementar diferentes kernels que permitan la maximización de estos hiperplanos, por lo tanto, se utilizaron el lineal (SVMl), polinomial (SVMp), rbf (gaussiano) y el sigmoideo.

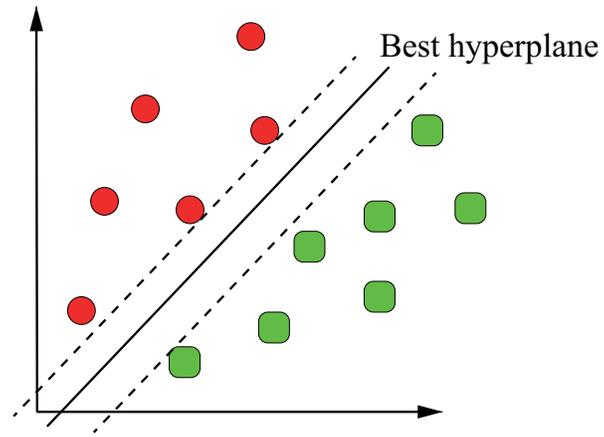


Figura 1.2: Hiperplano de margen máximo para una SVM entrenado en dos clases. Las muestras en los márgenes se denominan vectores de soporte

# Capítulo 2

## OBJETIVOS

### 2.1 General

Clasificar las fases de las actividades de sentarse y levantarse mediante métodos de machine learning.

### 2.2 Específicos

1. Identificar fases de las actividades de sentarse y levantarse de acuerdo a la literatura.
2. Validar los métodos de machine learning para clasificar las fases de las actividades.
3. Establecer los parámetros que van a ser evaluados en los métodos de machine learning.
4. Determinar el método de clasificación de machine learning más adecuado para el dataset de las actividades de sentarse y levantarse.

## Capítulo 3

# REVISIÓN DE LA LITERATURA

En el presente capítulo se muestra la revisión bibliográfica realizada en el estudio de este trabajo dirigido, además para poder determinar las ecuaciones de búsqueda se utilizó la estrategia PICO:

- Criterios de inclusión
  - Estudios con detección de actividades de la vida diaria (AVDs).
  - Estudios relacionados con sujetos sanos.
  - Artículos relacionados con machine learning.
  - Artículos en inglés y español.
- Criterios de exclusión
  - Artículos que incluyan sujetos patológicos.
  - Publicaciones realizadas antes del 2010.
  - Artículos no indexados

Por lo tanto, la pregunta de investigación es: ¿Cuál es la eficiencia de un algoritmo de machine learning para clasificar las fases de las actividades de sentarse y levantarse?. Para la información sobre la detección de las actividades de la vida diaria mediante métodos de machine learning se utilizaron distintas bases de datos como: Springer, PubMed, Sciencedirect, IEEE Xplore and ResearchGate. The literature review included 6 records from these databases and the information used is described below:

1. ('Detection') AND ('Activity of Daily Living')
2. ('Detection') AND ('ADL') AND ('Machine Learning')
3. ('Detection') AND ('Phases') AND ('Sitting') AND ('Standing')

A partir de esto se escogen 2 algoritmos utilizados para la detección de actividades de la vida diaria: el algoritmo de máquina de soporte vectorial (SVM) como lo establecen los autores I. De Falco y J.Kwon al igual que el método de k vecinos más cercanos donde lo utilizan los autores I. De Falco y M. Totty. Estos autores previamente utilizan estos algoritmos para detectar la marcha, los movimientos de los brazos y para las actividades de sentarse y levantarse que es el enfoque del presente estudio.

| Autor                | AVD  | Clasificador  | Sensor                               | Métrica   | Resultado            |
|----------------------|--|---|--------------------------------------|---|----------------------|
| S. Rossi (2018)      | - Pararse<br>- Levantarse<br>- Recostarse<br>- Sentarse                      | - Deep Learning<br>- Modelo de mezcla gaussiana   | Robot móvil (cámara)                 | - Matriz de confusión<br>- Precisión<br>- Puntaje F1<br>- Recuperación    | 84 %                 |
| S. Poularakis (2017) | - Cortar vegetales<br>- Lavar los platos<br>- Secar vegetales                | - Estimación de movimiento basada en flujo óptico<br>- Vectores MPEG.                                   | Cámaras estáticas en color           | - Exactitud promedio<br>- Velocidad promedio<br>- Rendimiento             | 88 %                 |
| S. Rahman (2020)     | - Caminar<br>- Sentarse<br>- Pararse<br>- Andar en bicicleta<br>- Correr     | - Algoritmos de refuerzo (XGB, LGBM, GB, CB y Adaboost (ADA))<br>- Árbol de decisión<br>- Random forest | Sensor inercial basado en smartphone | - Rendimiento   | 93.9 %<br>(GB y ADA) |
| I. De Falco (2020)   | - Pararse<br>- Sentarse<br>- Correr<br>- Subir y bajar escaleras<br>- Caídas | - Árbol discriminante<br>- Máquina de soporte vectorial (SVM)<br>- K vecinos más cercanos (kNN)         | UniMiB SHAR (Teléfonos inteligentes) | - Matriz de confusión<br>- Exactitud<br>- Sensibilidad<br>- Especificidad | 86 %                 |
| J. Kwon (2019)       | - Caminar  | - Máquina de soporte vectorial<br>- Deep Neural Network.  | Sensor de radar Doppler (24GHz)      | - Exactitud<br>- Matriz de confusión<br>- Curva ROC                       | 88.79 %              |
| M. Totty (2017)      | - Movimientos del brazo<br>- Agarrar objetos<br>- Saludar                    | - k vecinos más cercanos.<br>- Validación cruzada   | Brazalete Myo                        | - Exactitud<br>- Activación muscular<br>- Valores promedio                | 89.2 %               |

Tabla 3.1: Revisión bibliográfica sobre detección de actividades de la vida diaria mediante métodos de machine learning

## Capítulo 4

# METODOLOGÍA

### 4.1 Fases de las actividades de sentarse y levantarse

Según autores se puede definir la actividad de levantarse mediante diferentes fases: Gaul-Aláčová et al. analizaron el movimiento de sentarse a levantarse en varias situaciones posturales donde se define el movimiento en tres fases; la fase de extensión se divide en una fase de transferencia de movimiento y una fase de extensión independiente y la fase de flexión [1]. Jeng et al. identificó cuatro fases; la fase de impulso de flexión, la fase de transferencia de impulso, la fase de extensión y la fase de estabilización [9]. En este ciclo se involucran movimientos importantes como la flexión máxima del tronco, el desprendimiento del cuerpo de la silla y la extensión final del tronco. La actividad de sentarse, Blazkiewicz et al. la define en 3 fases: la fase de preparación donde el sujeto se encuentra quieto con todas las articulaciones extendidas, la fase de transición a sentarse donde la velocidad angular disminuye, por último, la fase de sentarse donde el sujeto se encuentra sentado en posición tranquila [10]. Kerr et al. analizaron el movimiento cíclico de sentarse-levantarse-sentarse en sujetos normales mediante características cinemáticas y dividieron la fase de sentarse como el movimiento descendente del tronco, la flexión de la rodilla y la estabilización del tronco [11].

Al utilizar un método de etiquetado manual, se tienen que escoger las fases más identificables y las más comunes según los autores, por lo tanto, en este estudio se dividieron las fases de levantarse en tres: movimiento hacia adelante del tronco con aumento de la flexión de la cadera y tobillo (Figura 4.1a), con una ligera flexión de la rodilla, la extensión de las articulaciones donde el cuerpo se mueve a su posición vertical, la cadera y el tobillo retroceden de la flexión a la extensión con una rápida extensión de la rodilla (Figura 4.1b) y la estabilización donde se encuentran todas las articulaciones extendidas (Figura 4.1c), así mismo las fases de sentarse en tres: el sujeto quieto con una leve flexión de rodilla y el resto de articulaciones extendidas (Figura 4.1d), la fase de transición donde aumentan los valores de los ángulos de todas las articulaciones (Figura 4.1e) y la posición tranquila donde se encuentra totalmente sentado (Figura 4.1f).

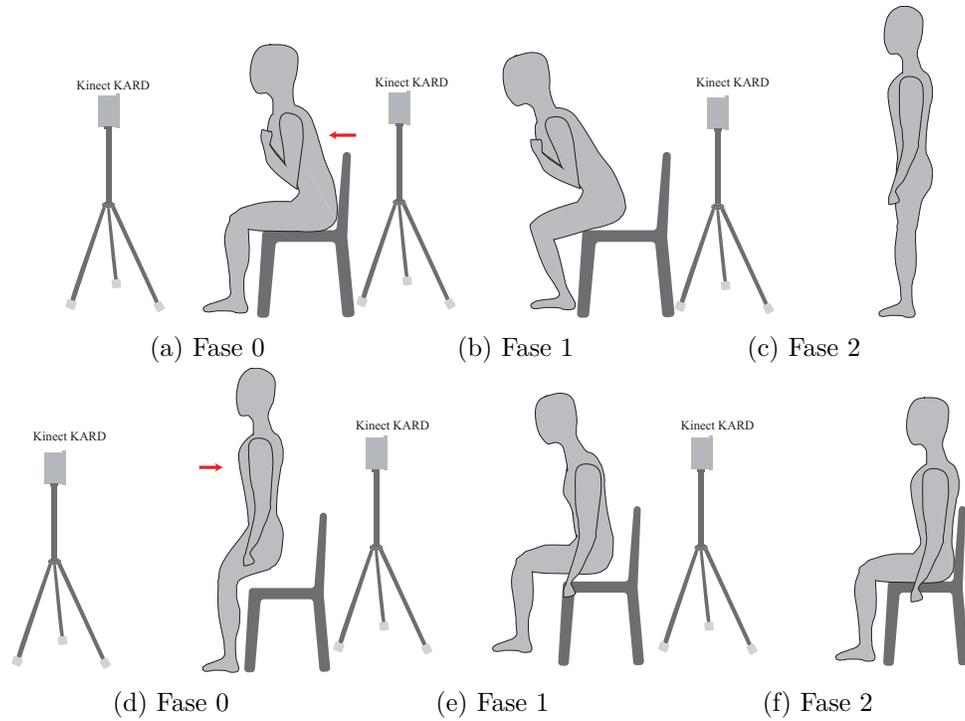


Figura 4.1: (a-c) Representación gráfica de las fases de la actividad de levantarse (d-f) Fases de la actividad de sentarse

## 4.2 Dataset

El estudio se realizó a partir del dataset “Kinect Activity Recognition Dataset (KARD)” [12], el cual contiene 18 actividades, entre ellas diez gestos y ocho acciones, cada una se realiza tres veces por diez sujetos distintos. Las personas involucradas en el dataset (9 hombres y 1 mujer) tienen un promedio de edad entre 20 y 30 años con alturas promedio entre 150 a 185cm. Para el interés de nuestro estudio solamente se analizaron las actividades de sentarse y pararse para un total de 60 videos. Los datos fueron capturados mediante una cámara Kinect que estaba a una distancia de 3m aproximadamente del sujeto. El dataset KARD tiene 540 secuencias de un total de una hora de videos, con resolución de  $640 \times 480$  pixeles a 30 frames/s.

Se tienen en cuenta 15 marcadores en total, equivalentes a las articulaciones del cuerpo humano. Debido al objetivo final del estudio solamente se tuvieron en cuenta las articulaciones de miembro inferior como se observa en la Figura 4.2: Torso, cadera derecha, rodilla derecha, pie derecho, cadera izquierda, rodilla izquierda y pie izquierdo.

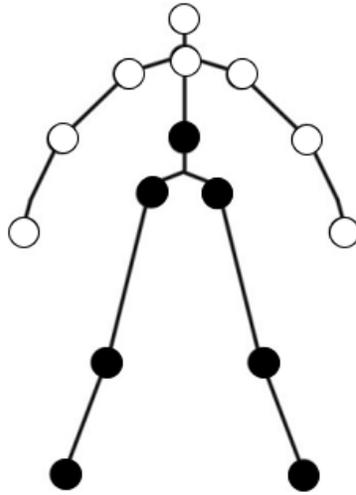


Figura 4.2: Quince (15) articulaciones detectadas por Kinect. Los puntos negros hacen referencia a las articulaciones a utilizar (torso, caderas, rodillas y pies) y los puntos blancos son descartados (cabeza, cuello, hombros, codos y manos).

## Capítulo 5

# RESULTADOS

No se utilizó ningún preprocesamiento para el dataset KARD y se realizó el etiquetado correspondiente de acuerdo con la fase según la actividad de manera manual con respecto a los videos proporcionados. Se utilizaron el 80 % de los datos para el entrenamiento y el 20 % de prueba.

A continuación, se encuentran los resultados de clasificación de las fases de las actividades de sentarse y levantarse, relacionados a los algoritmos de kNN y SVM.

### 5.1 k vecinos más cercanos (kNN)

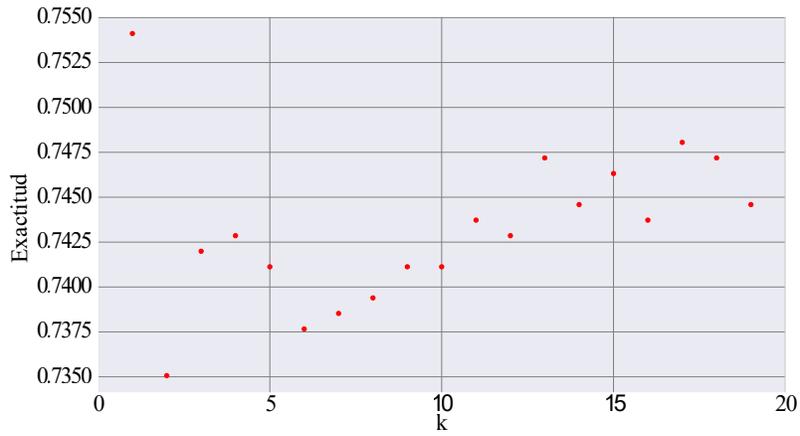
Con el objetivo de escoger el k adecuado para el algoritmo se utilizaron unas gráficas donde de acuerdo con el k se obtenía mayor o menor exactitud en la clasificación de las fases.

En la Figura 5.1a se observa en la actividad de sentarse como al variar el k aumenta o disminuye la exactitud del algoritmo que oscila entre 0.735 y 0.755, de acuerdo con el valor de k que se encuentra en un rango de 0 a 20. Se observa que en k=1 se tiene la mayor exactitud con un valor del 76 % y a medida que incrementa disminuye considerablemente y se dispersan los datos en exactitudes menores a 0.7475.

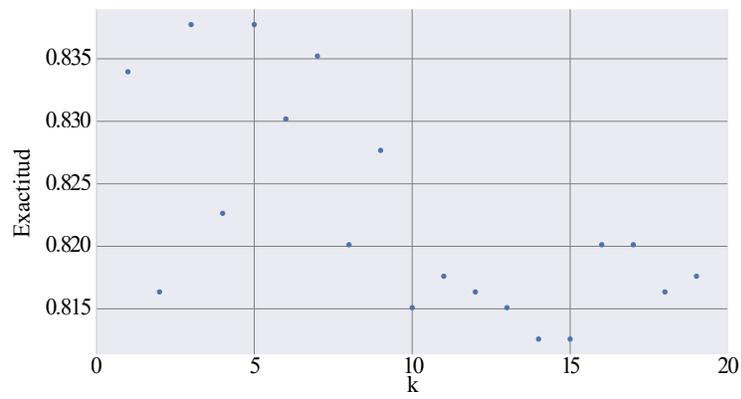
En la Figura 5.1b en la actividad de levantarse se observa la variabilidad de los datos de acuerdo con el k, en un rango de exactitud de 0.815 a 0.835, para 20 valores de k, donde la primera distancia comienza con un valor de 0.834 y la segunda disminuye hasta 0.817. La tercera y la quinta distancia corresponden a la mejor exactitud con un porcentaje aproximado del 84 % y en adelante las mayores distancias tienden a permanecer en las menores exactitudes con respecto a la gráfica.

El desempeño del algoritmo de kNN se evalúa por medio del análisis de las matrices de confusión y diferentes criterios como: exactitud, recuperación, precisión y puntuación-F1.

En la Figura 5.2, se observa la matriz de confusión para la actividad de sentarse, donde se identifican las fases con mejores desempeños y las que el algoritmo tuvo la dificultad de clasificar correctamente. Se obtiene un valor acertado en la fase 0 de 0.94, en la fase 1 de 0.51 y en la fase 2 de 0.85. Y los mayores falsos positivos de la fase 1 con respecto a la fase 2 de



(a) Sentarse



(b) Levantarse

Figura 5.1: Número de k para el algoritmo de KNN en la actividad de (a) sentarse y (b) levantarse. De acuerdo a la gráfica,  $k=1$  y  $k=3$  respectivamente.

0.15 y en la fase 2 con respecto a la fase 1 de 0.39.

En la Figura 5.3, se observa la matriz de confusión para la actividad de levantarse, con valores acertados de la fase 0 con 0.99, la fase 1 con 0.56 y la fase 2 con 0.90.

Por último, en la Tabla 5.1, se observan los criterios de cada fase donde la puntuación-F1, la cual combina las medidas de precisión y recuperación, obtuvo los mejores valores en la fase 0 de cada actividad, con un valor de 0.91 para sentarse y levantarse.

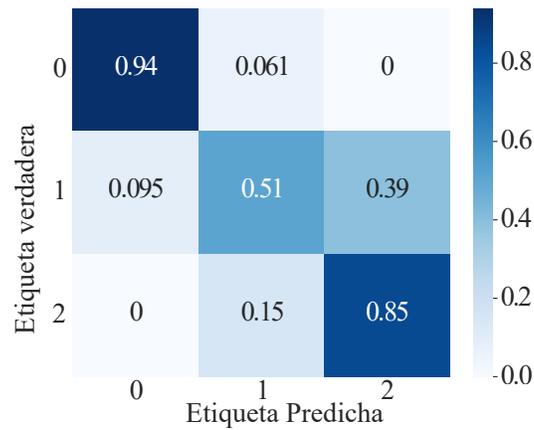


Figura 5.2: Imagen de ejemplo

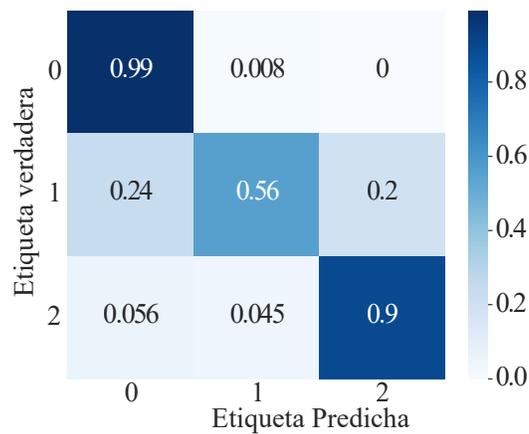


Figura 5.3: Confusion matrix of the kNN method for sitting activity.

| Actividad  | Precisión | Recuperación | Puntuación-F1 |
|------------|-----------|--------------|---------------|
| Sentarse   |           |              |               |
| 0          | 0.88      | 0.94         | 0.91          |
| 1          | 0.70      | 0.51         | 0.59          |
| 2          | 0.71      | 0.85         | 0.77          |
| Levantarse |           |              |               |
| 0          | 0.84      | 0.99         | 0.91          |
| 1          | 0.93      | 0.56         | 0.70          |
| 2          | 0.77      | 0.90         | 0.83          |

Tabla 5.1: Criterios de Algoritmo kNN

## 5.2 Máquina de soporte vectorial (SVM)

En la Tabla 5.2, se obtienen los criterios de precisión, recuperación y puntuación-F1 para los kernels que obtuvieron mejor desempeño en la clasificación de las fases de sentarse y levantarse. Según la Tabla 5.3, que contiene las exactitudes de todos los algoritmos, el kernel polinomial tuvo una exactitud del 86 % y 71 % respectivamente y el kernel gaussiano del 85 % y 75 %.

Se obtienen las matrices de confusión para cada actividad de acuerdo con el mejor desempeño del kernel en el algoritmo. En la Figura 5.4 se observa la matriz de confusión del kernel polinomial en la actividad de sentarse, donde posee valores acertados de 0.98 para la fase 0, 0.94 para la fase 1 y 0.96 para la fase 2. Los valores de falsos positivos mayores se obtienen en la fase 1 con respecto a la fase 2 de 0.036 y en la fase 2 con respecto a la fase 1 con 0.035. Además, se puede observar que no clasificó como fase 0 en la fase 2 y como fase 2 en la fase 0.

En la Figura 5.5 se observa la matriz de confusión para el kernel gaussiano para la actividad de levantarse. Tiene valores acertados de 0.98 en la fase 0, 0.82 en la fase 1 y 0.99 en la fase 2. El falso positivo más significativo representa la fase 2 con respecto a la fase 1 con un valor de 0.11.

| Actividad  | Precisión | Recuperación | Puntuación-F1 |
|------------|-----------|--------------|---------------|
| SVMp       |           |              |               |
| Sentarse   |           |              |               |
| 0          | 0.90      | 0.90         | 0.90          |
| 1          | 0.86      | 0.72         | 0.78          |
| 2          | 0.84      | 0.96         | 0.90          |
| Levantarse |           |              |               |
| 0          | 0.65      | 1.00         | 0.78          |
| 1          | 0.84      | 0.32         | 0.46          |
| 2          | 0.90      | 0.63         | 0.74          |
| SVMg       |           |              |               |
| Sentarse   |           |              |               |
| 0          | 0.89      | 0.91         | 0.90          |
| 1          | 0.88      | 0.67         | 0.76          |
| 2          | 0.82      | 0.98         | 0.89          |
| Levantarse |           |              |               |
| 0          | 0.68      | 1.00         | 0.81          |
| 1          | 0.89      | 0.30         | 0.44          |
| 2          | 0.91      | 0.84         | 0.87          |

Tabla 5.2: Criterios de Algoritmo SVMp Y SVMg

| Actividad  | kNN  | SVMI | SVMp | SVMg | SVMs |
|------------|------|------|------|------|------|
| Sentarse   | 0.75 | 0.85 | 0.86 | 0.85 | 0.45 |
| Levantarse | 0.84 | 0.66 | 0.71 | 0.75 | 0.36 |

Tabla 5.3: Exactitud de los Algoritmos

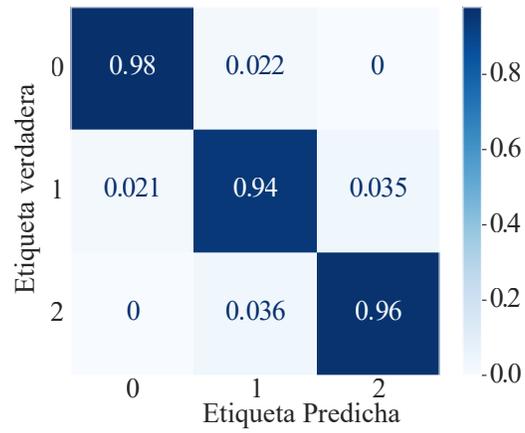


Figura 5.4: Matriz de confusión del método de SVMp para la actividad de sentarse.

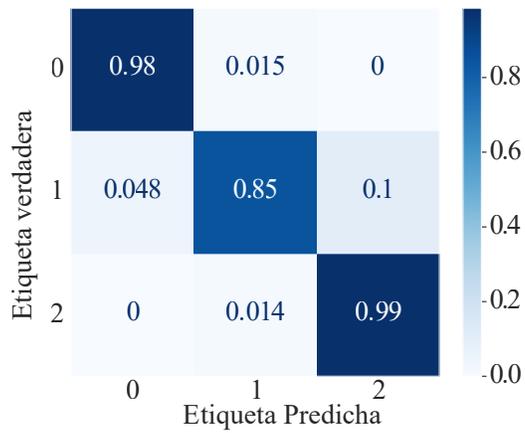


Figura 5.5: Matriz de confusión del método de SVMg para la actividad de levantarse.

## Capítulo 6

# DISCUSION

De acuerdo con los algoritmos de machine learning utilizados se puede observar en la Tabla III, que el método de SVM genera exactitudes más estables en los kernels lineal, polinomial y gaussiano con valores iguales o mayores al 85 % para la actividad de sentarse y mayores al 66 % en la actividad de levantarse. El kernel sigmoideo posee el peor comportamiento con un porcentaje del 45 % para sentarse y 36 % para levantarse.

Con respecto a un estudio sobre la clasificación de actividades como desayunar, planchar la ropa, bañarse y preparar comida, el algoritmo de kNN obtuvo un valor de exactitud del 70.45 % y el algoritmo de SVM con kernel predeterminado un valor del 77.27 % [13], además para clasificar actividades como levantarse, sentarse, correr, subir y bajar escaleras, caminar y saltar se obtuvieron para el algoritmo de kNN exactitudes de 83.4 % y para el algoritmo de SVM cuadrático del 83.1 % [5]. Comparando estos resultados con los desempeños de los clasificadores obtenidos en el actual trabajo, se obtuvieron mejores exactitudes para reconocer las fases de las actividades de sentarse y levantarse.

Según las Figuras 6 y 7 se puede observar que, a mayor valor de k escogido, la exactitud disminuía en un 2 % para los dos métodos y al ser los de mejor exactitud valores pequeños menores a 4, resulta de un menor costo computacional [14].

Para la actividad de levantarse en kNN y en SVM se obtienen valores mayores de falsos positivos en la fase 0 con respecto a la actividad de sentarse, por lo cual es necesario poder separar esta fase en dos en el etiquetado en trabajos futuros.

Además, el método de SVMp muestra los valores de precisión, recuperación y puntuación-F1 altos, indicando la calidad del modelo para clasificar e identificar cada fase de la actividad, siendo la fase uno o fase de transición la más difícil según la matriz de confusión ya que el modelo la confunde con la fase 2 y una puntuación-F1 del 78 %. En esta actividad kNN presenta una exactitud del 75 % y una puntuación-F1 del 59 % en la fase uno. Por otro lado, en la actividad de levantarse el método de kNN posee una mayor exactitud que el de SVM con un valor del 84 %, no obstante, la fase de extensión de las articulaciones o fase 1, presenta problemas para identificar o clasificar los datos debido al valor del 56 % en recuperación y además en la matriz de confusión se observa como el algoritmo confunde la fase 1 en su mayoría con la fase 0 donde el sujeto tiene una leve extensión de sus extremidades.

## Capítulo 7

# CONCLUSIONES

Al evaluar los dos clasificadores más utilizados para detectar las actividades de la vida diaria, mediante matrices de confusión y exactitudes, se identifica que el algoritmo de SVM predice mejor las fases de las actividades de sentarse y levantarse debido a que mantiene estable sus exactitudes de acuerdo con el kernel utilizado y posee valores altos en precisión, recuperación y puntuación-F1.

Se obtuvo una alta exactitud en el algoritmo de kNN para la actividad de levantarse, sin embargo, en ambas actividades se clasifica de manera errónea la fase 2 con valores acertados menores al 56 %. Así mismo, el algoritmo confunde en mayor medida la fase 2 con la 1 y la 0 en ambas actividades.

Para el algoritmo de SVM con kernels gaussiano y polinomial, se obtienen matrices de confusión con valores acertados en promedio del 95% siendo la fase 1 de la actividad de levantarse la más difícil de reconocer debido a un 82% acertado y el restante se divide en su mayoría en la fase 2.

## Capítulo 8

# RECOMENDACIONES Y TRABAJOS FUTUROS

El método de etiquetado manual no permite dar una exactitud alta, debido a que no se tuvieron en cuenta los frames/s y por tanto dan falsos negativos y falsos positivos en las fases 0 y 1, esto puede mejorar utilizando herramientas que permitan etiquetar cada frame del video como por ejemplo Labelbox [31].

Igualmente, ambos algoritmos poseen un buen desempeño para clasificar las fases de las actividades de sentarse y levantarse, no obstante, en trabajos futuros se puede agregar una nueva fase en la actividad de levantarse clasificándolas como:

- Fase 1: flexionar la parte superior del cuerpo para generar impulso e iniciar el movimiento de levantarse.
- Fase 2: : levantar la cadera de la silla y transferir impulso.
- Fase 3: extender completamente el cuerpo hacia arriba.
- Fase 4: mover el cuerpo hacia atrás para mantener la postura [32]. Esto se hace con el propósito de mejorar la exactitud del algoritmo implementado el nuevo método de etiquetado.

# Bibliografía

- [1] P. F. Edemekong, D. L. Bomgaars, S. Sukumaran y S. B. Levy, «Activities of Daily Living.,» eng, en, ene. de 2021.
- [2] P. Gaul-Alácová, P. Ová, J. Opavský, M. Janura, M. Elfmark y J. Stehlíková, «ANALYSIS OF THE SITTING-TO-STANDING MOVEMENT IN VARIOUSLY DEMANDING POSTURAL SITUATIONS.,» *Acta Universitatis Palackianae Olomucensis. Gymnica*, vol. 33, n.º 1, págs. 57-64, 2003, ISSN: 1212-1185.
- [3] M. D. Sánchez Manchola, M. J. Pinto Bernal, M. Munera y C. A. Cifuentes, «Gait Phase Detection for Lower-Limb Exoskeletons using Foot Motion Data from a Single Inertial Measurement Unit in Hemiparetic Individuals.,» eng, *Sensors (Basel, Switzerland)*, vol. 19, n.º 13, jul. de 2019, ISSN: 1424-8220 (Electronic). DOI: 10.3390/s19132988.
- [4] J. Taborri, E. Palermo, S. Rossi y G. Delibra, «Automatic Detection of Faults in Race Walking: A Comparative Analysis of Machine-Learning Algorithms Fed with Inertial Sensor Data.,» *Sensors*, vol. 19, págs. 1-21, mar. de 2019. DOI: 10.3390/s19061461.
- [5] I. Falco, G. De Pietro y G. Sannino, «Evaluation of artificial intelligence techniques for the classification of different activities of daily living and falls.,» *Neural Computing and Applications*, ene. de 2019. DOI: 10.1007/s00521-018-03973-1.
- [6] X. Liu y Q. Wang, «Real-Time Locomotion Mode Recognition and Assistive Torque Control for Unilateral Knee Exoskeleton on Different Terrains.,» *IEEE/ASME Transactions on Mechatronics*, vol. PP, pág. 1, abr. de 2020. DOI: 10.1109/TMECH.2020.2990668.
- [7] B. E. Boser, I. M. Guyon y V. N. Vapnik, «A Training Algorithm for Optimal Margin Classifiers.,» en *Proceedings of the Fifth Annual Workshop on Computational Learning Theory*, ép. COLT '92, New York, NY, USA: Association for Computing Machinery, 1992, págs. 144-152, ISBN: 089791497X. DOI: 10.1145/130385.130401.
- [8] D. Srivastava y L. Bhambhu, «Data classification using support vector machine.,» *Journal of Theoretical and Applied Information Technology*, vol. 12, págs. 1-7, feb. de 2010.
- [9] S. F. Jeng, M. Schenkman, P. O. Riley y S. J. Lin, «Reliability of a clinical kinematic assessment of the sit-to-stand movement.,» eng, *Physical therapy*, vol. 70, n.º 8, págs. 511-520, ago. de 1990, ISSN: 0031-9023 (Print). DOI: 10.1093/ptj/70.8.511.
- [10] M. Błażkiewicz, I. Wiszomirska y A. Wit, «A new method of determination of phases and symmetry in stand-to-sit-to-stand movement.,» *International Journal of Occupational Medicine and Environmental Health*, vol. 27, n.º 4, págs. 660-671, 2014, ISSN: 1896-494X. DOI: 10.2478/s13382-014-0280-x.

- [11] K. M. Kerr, J. A. White, D. A. Barr y R. A. B. Mollan, *Analysis of the sit-stand-sit movement cycle in normal subjects*, 1997. dirección: [http://explore.bl.uk/primo%7B%5C\\_%7Dlibrary/libweb/action/display.do?tabs=detailsTab%7B%5C%7DgatherStatTab=true%7B%5C%7Dct=display%7B%5C%7Dfn=search%7B%5C%7Ddoc=ET0CRN027858480%7B%5C%7Dindx=1%7B%5C%7DrecIds=ET0CRN027858480](http://explore.bl.uk/primo%7B%5C_%7Dlibrary/libweb/action/display.do?tabs=detailsTab%7B%5C%7DgatherStatTab=true%7B%5C%7Dct=display%7B%5C%7Dfn=search%7B%5C%7Ddoc=ET0CRN027858480%7B%5C%7Dindx=1%7B%5C%7DrecIds=ET0CRN027858480).
- [12] S. Gaglio, M. Lo Re y M. Morana, «Human Activity Recognition Process Using 3-D Posture Data.,» *IEEE Transactions on Human-Machine Systems.*, 2014. DOI: 10.1109/THMS.2014.2377111.
- [13] R. Hussain, M. ali Ghazanfar, M. A. Azam, U. Naeem y S. Réhman, «A performance comparison of machine learning classification approaches for robust activity of daily living recognition,» *Artificial Intelligence Review*, págs. 1-23, mar. de 2018. DOI: 10.1007/s10462-018-9623-5.
- [14] S. Nutanong, R. Zhang, E. Tanin y L. Kulik, *The V\*-Diagram*. Proceedings of the VLDB Endowment, 2008, págs. 1095-1106.