

**COMPARACIÓN DE TÉCNICAS DE REDUCCIÓN DE DIMENSIONALIDAD PARA LA
CLASIFICACIÓN DE ACTIVIDADES FÍSICAS HUMANAS UTILIZANDO MÉTODOS
ESTADÍSTICOS**

Jhon Fredy Gallego Rincón

Daniel Fernando Rengifo Almanza

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

Director

Andrés Felipe Calvo Salcedo. Ing. M.Sc.

UNIVERSIDAD TECNOLÓGICA DE PEREIRA

FACULTAD DE INGENIERÍA

PROGRAMA DE INGENIERÍA ELECTRÓNICA

PEREIRA

2016

Nota de Aceptación

Firma del director

AGRADECIMIENTOS

Al inicio de nuestra carrera lo primero que pensamos es en el final de la misma, ya que la ansiedad y el deseo de ser profesionales nos invade, finalmente llega el momento y si se pudiera dar las gracias a todos y cada una de las personas que hicieron parte de este proceso tanto directa como indirectamente de forma personal, no dudaríamos en hacerlo.

Principalmente queremos agradecer a nuestro padre celestial quien fue el que nos indicó el camino correcto a seguir, nos dio el tiempo, salud, paciencia y la perseverancia para continuar este proyecto. Agradecemos también a nuestras familias por el apoyo incondicional en el cumplimiento de nuestros sueños, a nuestro director de trabajo de grado el Ing. Andrés Felipe Calvo salcedo, quien nos acompañó y fue nuestro guía en la culminación de este proyecto que estamos presentando, al grupo de investigación de Automática de la Universidad tecnológica de Pereira quien por medio de su integrante el Ing. Andres Marino Álvarez Meza nos colaboró y oriento en el desarrollo de las diferentes metodologías planteadas, ya que esta investigación analiza información que se adquirió en el marco del proyecto “*Estimación de los parámetros de neuro modulación con terapia de estimulación cerebral profunda en pacientes con enfermedad de Parkinson a partir del volumen de tejido activo planeado*”, aprobado y financiado por Colciencias identificado con el código 1110-657-40687, dentro de la convocatoria No. 657 - 2014 para proyectos de ciencia, tecnología e innovación en salud.

CONTENIDO

AGRADECIMIENTOS	5
CONTENIDO	7
LISTA DE TABLAS	9
LISTA DE FIGURAS	9
LISTA DE GRAFICAS	14
1. INTRODUCCIÓN.....	15
1.2 PLANTEAMIENTO DEL PROBLEMA	15
1.3 JUSTIFICACIÓN.....	17
1.4 OBJETIVOS	18
1.4.1 OBJETIVO GENERAL	18
1.4.2 OBJETIVOS ESPECÍFICOS	18
2. ESTADO DEL ARTE	19
3. MARCO TEÓRICO	20
3.1 Sensor	20
3.2 Sensor IMU (Inertial Measurement Unit).....	20
3.3 Electromiografía (EMG).....	21
3.4 Kinect.....	21
3.5 Estadística de espacios muestreados.	21
3.5.1 Media.....	21
3.5.2 Varianza.....	22
3.5.3 Desviación estándar.....	22
3.5.4 Covarianza	23
3.5.5 Matriz de covarianza	23
3.6 SVM (Support Vector Machine) Máquinas de soporte vectorial	23
3.7 Máquinas de vectores de soporte multiclase.....	24
3.7.1 Uno contra uno.....	24
3.7.2 Uno contra todos	25
3.8 Métodos de reducción de dimensionalidad.....	25
3.8.1 Análisis de componentes principales (PCA - Principal Component Analysis) ..	25
3.8.2 Análisis de componentes principales con kernels (KPCA - Principal Component Analysis)	26
3.9 t-Distribución Estocástica de puntos más cercanos t-SNE (t-Distributed Stochastic Neighbor Embedding).....	26

3.10	El método de Montecarlo.....	26
4.	DESARROLLO METODOLÓGICO.	26
4.1	ANÁLISIS DE LA TESIS DE MAESTRÍA (<i>RECONOCIMIENTO AUTOMÁTICO DE ACTIVIDADES FÍSICAS EN SISTEMAS MULTIMODALES</i>)	26
4.2	ELABORACIÓN DESCRIPTORES ESTADISTICOS DE LOS SENSORES IMPLEMENTADOS (KINECT, IMU)	29
4.2.1	DESCRIPTORES ESTADISTICOS KINECT:.....	29
4.2.2	DESCRIPTORES ESTADISTICOS IMU:	30
4.3	EJECUCIÓN BASE DE DATOS ANOTADA	33
4.4	VISUALIZACIÓN DE LOS DATOS UTILIZANDO LOS DIFERENTES METODOS DE REDUCCIÓN IMPLEMENTADOS.	34
4.4.1	MÉTODOS DE REDUCCIÓN IMPLEMENTADOS:.....	34
4.4.2	VISUALIZACIÓN DE LAS CARACTERISTICAS DEL EMG.....	36
4.4.3	VISUALIZACIÓN DE LAS CARACTERISTICAS DEL IMU.....	39
4.4.4	VISUALIZACIÓN DE LAS CARACTERISTICAS DEL KINECT.	43
4.4.5	VISUALIZACIÓN DE LAS CARACTERISTICAS DEL KINECT-IMU	47
4.4.6	VISUALIZACIÓN DE LAS CARACTERISTICAS DEL SENSOR KINECT – IMU UTILIZADANDO UNICAMENTE EL METODO t-SNE:	51
4.5	CLASIFICACIÓN DE LOS DATOS	52
4.5.1	IMPLEMENTACIÓN DE LOS METODOS DE REDUCCIÓN DE DIMENCIONALIDAD SOBRE UN NUEVA BASE DE DATOS ANOTADA.	57
4.5.2	VISUALIZACIÓN DE LA BASE DE DATOS RECOPIADA POR EL GRUPO DE INVESTIGACIÓN DE AUTOMÁTICA.	57
5.	CONCLUSIONES	63
6.	RECOMENDACIONES Y TRABAJOS FUTUROS	64
7.	BIBLIOGRAFIA.....	65

LISTA DE TABLAS

1. Lista de actividades	27
2. Lista de sub-actividades.....	27
3. Descriptores estadísticos implementados.....	30
4. Características IMU basadas en los parámetros físicos del movimiento humano...32	
5. Descriptores estadísticos implementados.....	33
6. Métodos de reducción implementados.....	34
7. Color de representación etiquetas.....	35
8. Área bajo la curva de los métodos con EMG.....	39
9. Área bajo la curva de los métodos con IMU.....	42
10. Área bajo la curva de los métodos con Kinect.....	46
11. Área bajo la curva de los métodos con Kinect-IMU.....	50
12. Espacio de representación.....	53
13. Datos de cada sensor con su respectivo método.....	53

LISTA DE FIGURAS

1. Diagrama de segmentación de señales.....	28
2. Puntos articulados del cuerpo Kinect.....	29
3. Distribución de sensores.....	31

VISUALIZACIÓN DE LAS CARACTERÍSTICAS DEL EMG.

Considerando PXT = 48.

4. Visualización de método CCA.....	36
5. Visualización de método t-SNE.....	36
6. Visualización de método JSE.....	36
7. Visualización de método KPCA.....	36
8. Visualización de método LEM.....	36
9. Visualización de método NeRV.....	36
10. Visualización de método NLM.....	36
11. Visualización de método NMDS.....	36
12. Visualización de método PCA.....	36
13. Visualización de método SNE.....	36
14. Probabilidades de todos los métodos.....	37

Considerando PXT = 99.

15. Visualización de método CCA.....	37
16. Visualización de método t-SNE.....	37
17. Visualización de método JSE.....	37
18. Visualización de método KPCA.....	37
19. Visualización de método LEM.....	37
20. Visualización de método NeRV.....	37
21. Visualización de método NLM.....	38
22. Visualización de método NMDS.....	38
23. Visualización de método PCA.....	38
24. Visualización de método SNE.....	38
25. Probabilidades de todos los métodos.....	38

VISUALIZACIÓN DE LAS CARACTERÍSTICAS DEL IMU.

Considerando PXT = 48.

26. Visualización de método CCA.....	39
27. Visualización de método JSE.....	39
28. Visualización de método KPCA.....	39
29. Visualización de método LEM.....	39
30. Visualización de método NeRV.....	40
31. Visualización de método NLM.....	40
32. Visualización de método NMDS.....	40
33. Visualización de método PCA.....	40
34. Visualización de método SNE.....	40
35. Visualización de método t-SNE.....	40
36. Probabilidades de todos los métodos.....	40

Considerando PXT = 99.

37. Visualización de método CCA.....	41
38. Visualización de método JSE.....	41
39. Visualización de método KPCA.....	41
40. Visualización de método LEM.....	41
41. Visualización de método NeRV.....	41
42. Visualización de método NLM.....	41
43. Visualización de método NMDS.....	41

44. Visualización de método PCA.....	41
45. Visualización de método SNE.....	41
46. Visualización de método t-SNE.....	41
47. Probabilidades de todos los métodos.....	42

VISUALIZACIÓN DE LAS CARACTERISTICAS DEL KINECT.

Considerando PXT = 48.

48. Visualización de método CCA.....	43
49. Visualización de método JSE.....	43
50. Visualización de método KPCA.....	43
51. Visualización de método LEM.....	43
52. Visualización de método NeRV.....	43
53. Visualización de método NLM.....	43
54. Visualización de método NMDS.....	44
55. Visualización de método PCA.....	44
56. Visualización de método SNE.....	44
57. Visualización de método t-SNE.....	44
58. Probabilidades de todos los métodos.....	44

Considerando PXT = 99.

59. Visualización de método CCA.....	44
60. Visualización de método JSE.....	44
61. Visualización de método KPCA.....	45
62. Visualización de método LEM.....	45
63. Visualización de método NeRV.....	45
64. Visualización de método NLM.....	45
65. Visualización de método NMDS.....	45
66. Visualización de método PCA.....	45
67. Visualización de método SNE.....	45
68. Visualización de método t-SNE.....	45
69. Probabilidades de todos los métodos.....	46

VISUALIZACIÓN DE LAS CARACTERISTICAS DEL KINECT-IMU

Considerando PXT = 48.

70. Visualización de método CCA.....	47
71. Visualización de método JSE.....	47

72. Visualización de método KPCA.....	47
73. Visualización de método LEM.....	47
74. Visualización de método NeRV.....	47
75. Visualización de método NLM.....	47
76. Visualización de método NMDS.....	48
77. Visualización de método PCA.....	48
78. Visualización de método SNE.....	48
79. Visualización de método t-SNE.....	48
80. Probabilidades de todos los métodos.....	48

Considerando PXT = 99.

81. Visualización de método CCA.....	48
82. Visualización de método JSE.....	48
83. Visualización de método KPCA.....	49
84. Visualización de método LEM.....	49
85. Visualización de método NeRV.....	49
86. Visualización de método NLM.....	49
87. Visualización de método NMDS.....	49
88. Visualización de método PCA.....	49
89. Visualización de método SNE.....	49
90. Visualización de método t-SNE.....	49
91. Probabilidades de todos los métodos.....	50

**VISUALIZACIÓN DE LAS CARACTERISTICAS DEL SENSOR KINECT – IMU
UTILIZADANDO UNICAMENTE EL METODO t-SNE**

92. Método t-SNE con PXT=5.....	51
93. Método t-SNE con PXT=10.....	51
94. Método t-SNE con PXT=15.....	51
95. Método t-SNE con PXT=20.....	51
96. Método t-SNE con PXT=25.....	51
97. Método t-SNE con PXT=30.....	51
98. Método t-SNE con PXT=35.....	51
99. Método t-SNE con PXT=40.....	51
100. Método t-SNE con PXT=45.....	52
101. Método t-SNE con PXT=50.....	52

VISUALIZACIÓN DE LA BASE DE DATOS RECOPIADA POR EL GRUPO DE INVESTIGACIÓN DE AUTOMÁTICA

Primer caso ($Y = C_0$)

102.	Método t-SNE con PXT=100.....	58
103.	Método KPCA con PXT=100.....	58
104.	Método t-SNE con PXT=150.....	58
105.	Método t-SNE con PXT=200.....	58

Segundo caso ($Y = C_1$)

106.	Método t-SNE con PXT=100.....	59
107.	Método KPCA con PXT=100.....	59
108.	Método t-SNE con PXT=150.....	59
109.	Método t-SNE con PXT=200.....	59

Tercer caso ($Y = C_2$)

110.	Método t-SNE con PXT=100.....	60
111.	Método KPCA con PXT=100.....	60
112.	Método t-SNE con PXT=150.....	60
113.	Método t-SNE con PXT=200.....	60

Cuarto caso ($Y = C_3$)

114.	Método t-SNE con PXT=100.....	61
115.	Método KPCA con PXT=100.....	61
116.	Método t-SNE con PXT=150.....	61
117.	Método t-SNE con PXT=200.....	61

LISTA DE GRAFICAS

1. Comportamiento de los tres sensores con clasificador KNN.....	54
2. Comportamiento de los tres sensores con PCA y clasificador KNN.....	54
3. Comportamiento de los tres sensores con t-SNE y clasificador KNN.....	55
4. Comportamiento de los tres sensores con JSE y clasificador KNN.....	55
5. Comparación de los métodos.....	56

1. INTRODUCCIÓN

En la actualidad, el análisis de la actividad física humana se ha convertido en un centro de estudio de gran importancia debido a la gran cantidad de campos de investigación, los cuales permiten diseñar aplicaciones en áreas como salud, seguridad, deportes, entre otros.

Los elementos que involucra el análisis del movimiento humano, permite trabajar en algunas aplicaciones como la rehabilitación de pacientes, seguridad, monitoreo y seguimiento de elementos móviles.

En la ingeniería electrónica existe una serie de elementos multimodales que permiten la detección de estas actividades físicas como: cámaras de profundidad, cámaras de video, giroscopios, acelerómetros, sensores electromiográficos (EMG), así como una gran gama de sensores que entregan datos para el análisis de las actividades físicas humanas.

Sin importar la modalidad del sensor, el reconocimiento de una actividad física se considera un problema de clasificación, además la etapa de adquisición de datos es fundamental para obtener información verídica. Por ende, en una aplicación de gran complejidad donde se considera un gran número de sensores, se requiere de métodos diferentes para poder obtener la cantidad de componentes principales de estos y así reducir la dimensionalidad de la clasificación, llegando a tal punto en el que el costo computacional en la implementación de estos sistemas sea mínimo, obteniendo así una aplicación de bajo costo con la posibilidad de implementarse en diferentes ambientes de seguimiento y control.

1.2 PLANTEAMIENTO DEL PROBLEMA

El seguimiento de una actividad o reconocimiento de un patrón físico por medio de sistemas de cómputo se ha convertido en un campo amplio de investigación, dado el gran número de aplicaciones que se tienen en áreas como salud, seguridad, deportes, entre otras. El análisis del movimiento físico ayuda entre otras aplicaciones al monitoreo y rehabilitación de pacientes, analizar comportamientos sospechosos en espacios públicos y hacer seguimiento en la ejecución de actividades de un atleta de alto rendimiento en diferentes especialidades deportivas (fútbol, natación, salto triple, atletismo, entre otras).

El reconocimiento de patrones es una forma natural de figuras repetitivas que describen alguna morfología de repetición. Esto quiere decir que se busca simetría de características a través de traslaciones y rotaciones. Para un ser humano reconocer un patrón es una habilidad

natural, sin embargo, imitar esta habilidad en sistemas de detección se ha convertido en un gran reto [7].

Una de las aplicaciones más relevantes en las investigaciones de reconocimientos de patrones se encuentra en la identificación del rostro, en [8] se plantea un desarrollo de la implementación de una técnica en el reconocimiento de rostros haciendo uso de métodos de reducción de dimensionalidad para determinar la emoción relacionada con la expresión de la imagen, generando aplicaciones en robot socialmente interactivos.

En [1] se plantea una metodología para la detección automática de actividades físicas, haciendo uso de tres clases de sensores multimodales, tales como: cámara de profundidad Kinect, Acelerómetros (IMU - *Inertial Measured Unit*) y sensores EMG. Este método implementa la detección de movimientos primitivos utilizando clasificación SVM (*Support Vector Machine*) [4] y clasificación HMM (*Hidden Markov Model*) [5], definiendo la mínima cantidad de sensores requeridos para obtener una eficiencia del 98% de precisión en la detección de cinco actividades.

Esto aunque permite reducir el costo computacional al disminuir la cantidad de sensores, en una aplicación de mayor complejidad sería muy probable la adquisición errónea de datos, por tal motivo, en [2] se da un estudio de reducción de dimensionalidad planteando el uso del método PCA (*Principal Component Analysis*), lo cual permite definir el uso de 25 componentes principales, garantizando eficiencia en cada actividad mayor al 95%.

Aunque los dos análisis presentados anteriormente permiten la reducción de costo computacional, cabe decir que simplemente se ha implementado una única metodología de reducción en un tipo de sensor (acelerómetros), por tal razón, sería necesario realizar el estudio para los dos tipos de sensores restantes sobre la misma base de datos [1], aplicando diferentes metodologías para la reducción de características haciendo uso de la validación cruzada aplicando técnicas de Montecarlo para la estimación del error. [1, 2, 6]

Por esta razón, la pregunta que surge es: ¿Cuál será la metodología para la reducción de características que garantiza una adecuada clasificación de las cinco actividades definidas en la base de datos recopilada por el Grupo de investigación de ingeniería electrónica (GIIE) [1]?

Aplicando los diferentes métodos de reducción, posiblemente se podría identificar el método óptimo entre los comparados, que pueda reducir el costo computacional a tal punto que se pueda dar la implementación de estos códigos en sistemas inmersos (Microcontroladores,

DSP (*Digital signal processor*), FPGA (*Field programmable gate array*)), ya que esto disminuiría considerablemente el costo de las aplicaciones, permitiendo de igual forma el fácil acceso a una aplicación de estas características a profesionales en áreas relacionadas a la salud, deporte, seguridad, entre otras.

1.3 JUSTIFICACIÓN

Con el avance tecnológico que se ha tenido en los últimos años de forma exponencial y de acuerdo a la gran importancia de desarrollar dispositivos para realizar monitores de actividades físicas y ser aplicados en diferentes campos como la salud, deportes y seguridad, entre otros, se presenta la necesidad de desarrollar aplicaciones que requieren como base principal el reconocimiento de estas actividades.

Varios estudios y metodologías como [23, 24, 25, 26, 27, 28, 29] han realizado diferentes investigaciones basados en la detección automática de actividades físicas humanas, en los cuales utilizan diferentes tipos de sensores para registro de los datos tales como: giroscopios, acelerómetros, cámaras, sensores de profundidad, sensores electromiográficos, kinect, sensores IMU.

En las diferentes investigaciones y adquisición de datos para el reconocimiento de actividad física humana se tiene como inconveniente la clasificación de los mismos y extracción de características [30, 31].

En el proceso de clasificación y extracción de las características principales, con el objetivo de reducir la cantidad de datos a procesar, en los cuales se pueda realizar una selección adecuada e ideal para no perder información fundamental al momento de clasificar la actividad con los datos seleccionados y de esta misma forma reducir el costo computacional al momento de implementar y ejecutar proyectos de este tipo en sistemas inmersos. En anteriores documentos e investigaciones realizadas se puede observar que se han logrado obtener muy buenos resultados después de haber realizado una reducción de características [30, 31, 32].

Dentro de la tesis de maestría del ingeniero Andrés Felipe Calvo Salcedo [1] se ha realizado un trabajo muy importante en la clasificación de actividades físicas humanas utilizando variedad de sensores multimodales, no obstante en este desarrollo no se realizó el análisis detallado del aporte de cada conjunto de datos en el proceso de clasificación, lo cual puede

dar cabida a algunas dudas en las que no se sabe si es o no necesario un aporte total de todas las características en la clasificación de los movimientos primitivos. De esta misma manera en el trabajo del Ingeniero Víctor Alfonso Quintero Gutiérrez [2] se realizó un estudio comparativo con el cual se puede demostrar cual es el aporte que tiene cada descriptor utilizado para cada sensor en el reconocimiento de movimientos primitivo, validando el mejor desempeño de clasificación con una muy buena reducción de datos, mejorando así el costo computacional de esta metodología.

Ya que en este último estudio solo se realizó el estudio comparativo con el método de reducción de PCA, se da la oportunidad en este nuevo trabajo de realizar el estudio comparativo con otras metodologías como (KPCA (*kernel principal component analysis*), t-SNE (*t-distributed stochastic neighbor embedding*), MDS (*mult-idimensional scaling*), entre otros) [34] verificando cuales de estas pueden llegar a ser eficiente en la clasificación de los movimiento primitivos anotados en la base de datos de [1] dentro de su espacio de representación.

1.4 OBJETIVOS

1.4.1 OBJETIVO GENERAL

Comparar y determinar estadísticamente la eficiencia de varias metodologías aplicadas en la reducción de características y componentes principales, utilizadas para la clasificación de actividades físicas humanas.

1.4.2 OBJETIVOS ESPECÍFICOS

1. Analizar la base de datos (*Actividades físicas usando sistemas multimodales*) recopilada en la tesis de maestría (*Reconocimiento automático de actividades físicas en sistemas multimodales*).
2. Aplicar algunos de los diferentes métodos de reducción de dimensionalidad sobre la base de datos analizada, en la definición de características principales.
3. Comparar estadísticamente cada uno de los métodos aplicados para la reducción de dimensionalidad, verificando así la eficiencia en la clasificación haciendo uso del método de clasificación KNN - Késimo Vecino más Cercano [33]
4. Realizar la implementación de los diferentes códigos diseñados en la reducción de dimensionalidad sobre diferentes bases de datos anotadas.

2. ESTADO DEL ARTE

En los diferentes desarrollos y diseños de procesos, programas, prototipos, entre otros es muy importante hacer que estos sean eficientes y óptimos, con el fin de poder minimizar costo de producción, tiempo y espacio. Debido a esto se da el aprendizaje automático o reducción de dimensionalidad, este proceso es el encargado de reducir el número de variables para determinar la eficiencia de un tipo de clasificador ya sea supervisado o no supervisado.

En la diversidad de estudios e investigaciones en los ámbitos como reconocimiento facial, donde se desarrolla el procesamiento digital de imágenes y actividades físicas, en el cual la reducción de dimensionalidad facilita en gran medida la clasificación (conjunto dado de unidades de observación, significa definir en ese conjunto las clases entre las cuales se distribuyen los elementos de este), extracción de características y seguimiento de patrones. Varias técnicas, lineales y no lineales, se han propuesto y utilizado ampliamente para la reducción de dimensionalidad en los sistemas de reconocimiento de rostros. En [8, 9] se realiza el diseño y desarrollo de un sistema de reconocimiento facial mediante la hibridación de técnicas de reconocimiento de patrones en el cual se utiliza PCA (*El Análisis de componentes principales*) para la reducción de características y así realizar reconocimiento de género y acoplar esto a la iteración de robots. Diferentes tipos de investigaciones puede apoyarse con distintos métodos de reducción dimensionalidad o clasificación de características, en [4] se da una recopilación bibliográfica de método para la clasificación de características SVM (*Maquina de soporte vectorial*) y así diferenciar las clases de datos con características similares.

En la clasificación de características que significa asociar a diferentes clases a una serie elementos, es importante poder determinar qué tipo de método utilizar ya que alguno métodos como el HMM (*Hidden Markov Model*), [10, 5] en el cual se puede asumir un proceso de parámetros desconocidos con base a los conocidos, esto con el fin de realizar aplicaciones de reconocimiento de patrones e identificación de actividades físicas, adicional de esto los HMM se puede definir como la red bayesiana más simple, la cual puede ser una interpretación del concepto de probabilidad estadística. En las metodologías [11] se han desarrollado algoritmos, en el cual se construye un *kernel* en el KPCA (*Principal Component Analysis with Kernels*) la cual es una extensión del PCA, donde los datos son enviados mediante una transformación no lineal, a otro espacio, llamado el espacio de características y en este se realiza el método de reducción de PCA, donde se logra la posible extracción de direcciones de

máxima variabilidad en el espacio de características, identificando estas direcciones con las direcciones (no lineales) de variabilidad de los datos en el espacio original.

3. MARCO TEÓRICO

La realización de este proyecto, abarco muchas técnicas tales como: reconocimiento de actividades físicas humanas, reconocimiento de patrones, reducción de características, clasificación y métodos estadísticos, por este motivo es indispensable tener conocimiento de estos métodos usados con el fin de tener claridad sobre el concepto principal de cada una de ellas.

A continuación, se hará mención y definición de algunos métodos tanto de reducción y clasificación de características como elementos y métodos estadísticos usados para obtener el propósito final de este proyecto.

3.1 Sensor

Un sensor es un dispositivo que tiene la capacidad de cambiar el dominio de trabajo, es decir que puede detectar cualquier magnitud tanto física como química y convertirla en un estándar eléctrico correspondiente, lo cual permite su manipulación electrónica y digital, esta señal o magnitud de entrada puede identificarse como la presencia de humedad, calor, movimiento, luz, presión, fuerza, nivel, entre otros, al igual que muchos fenómenos físicos o ambientales. La salida del sensor por lo general debe ser una señal eléctrica la cual debe pasar por varios sistemas o componentes y reflejarse en una pantalla con el cual puede ser legible e interpretado por el usuario o sistema adicional y así tomar una decisión con respecto a los datos reflejados.

3.2 Sensor IMU (Inertial Measurement Unit)

Este dispositivo es ideal ya que con la combinación de acelerómetro y giroscopios tiene la capacidad de medir la fuerza gravitacional, orientación o aceleración, es importante tener en cuenta que este tipo de equipos de masa inercial son esenciales para ser usados en implementaciones de control e instrumentación, en el análisis de vibraciones y estimaciones de la posición y orientación de un objeto [12].

3.3 Electromiografía (EMG)

En la captura y recolección de datos de actividades físicas es importante tener presente que los sensores de electromiografía (EMG) son importantes para medir la actividad eléctrica producida por los músculos esqueléticos, estos sensores están basados en electrodos de superficie que se adhieren a la piel los cuales miden la actividad física muscular, es decir el potencial de acción que producen las unidades musculares que permiten la medida de su contracción mecánica, estas señales son captadas es un promedio de niveles de voltaje y este es detectado solo en los músculos que se contraen o se relajan [13].

3.4 Kinect

Para la iteración y detección de movimientos del usuario con una interfaz gráfica fue desarrollado el dispositivo Kinect, el cual fue fabricado y lanzado al mercado en estados unidos el 4 de noviembre del 2010 por la empresa Microsoft ®. Actualmente este tipo de sensor es comercializado por la firma primesense Israelí y usado en varias consolas de video juegos. Con este dispositivo se puede realizar una recopilación dependiendo el momento y la actividad del usuario, es decir que este dispositivo tiene la capacidad de detectar el mapa de profundidad del espacio actual, los puntos de articulación del usuario, giros realizados y muchas más [13].

3.5 Estadística de espacios muestreados.

3.5.1 Media

La media es muy utilizada en matemática y estadística, la cual también en ocasiones es llamado como el promedio de los datos, la media está definida como el número en común que relaciona a todos los datos, para obtener la media basta solo con realizar una suma de todos los valores numéricos existentes en el proceso y luego dividirla entre la cantidad de números sumados, este proceso es ideal cuando los conjuntos de datos obtenidos son aleatorios.

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{X_1 + X_2 + \dots + X_n}{n} \quad (1)$$

Donde:

\bar{X} = Media.

X_i = Valor de uno de los datos.

n = Cantidad de datos.

3.5.2 Varianza

La varianza es una medida de dispersión, por lo tanto, esta utiliza todos los datos (N), es decir que esta medida es el cuadrado de la desviación de la variable en mención respecto a su media y está definida a continuación [14]:

$$\sigma^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{N} \quad (2)$$

Donde:

X_i = Cada uno de los datos.

\bar{X} = Media aritmética de los datos.

N = Cantidad de datos.

3.5.3 Desviación estándar

La desviación estándar es una medida de dispersión, ya que es la raíz cuadrada de la varianza por lo tanto esta utiliza todos los datos (N), es decir que la desviación estándar es la raíz de la varianza y esta es el cuadrado de la desviación de la variable en mención respecto a su media y está definida a continuación [15]:

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{N}} \quad (3)$$

Donde:

X_i = Cada uno de los datos.

\bar{X} = Media aritmética de los datos.

N = Cantidad de datos.

3.5.4 Covarianza

La covarianza es el grado de variación de 2 variables, es decir que es la media de los productos de las desviaciones de cada una de las variables respecto a sus medias respectivas [16].

$$\sigma_{x,y} = \frac{\sum(x_i - \mu_x)(y_i - \mu_y)}{N} \quad (4)$$

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 el tamaño de la población.

3.5.5 Matriz de covarianza

La matriz está formada por las covarianzas de los elementos del conjunto de datos, la matriz puede contener las variables que sean necesarias, se puede definir así:

$$C = \begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix} \quad (5)$$

Donde:

$cov(x, y)$ = Es la covarianza entre las variables (x,y)

3.6 SVM (Support Vector Machine) Máquinas de soporte vectorial

Para realizar la separación de dos clases de datos mediante un método supervisado, es ideal usar la técnica de máquinas de soporte vectorial SVM. Con el cual se pretende realizar 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 [17].

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

$$y = w^T \phi(x) + b \quad (6)$$

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:

$$R_{emp} = \sum_{i=1}^n \xi_i^\sigma \quad (7)$$

3.7 Máquinas de vectores de soporte multiclase

La SVM común, es ideal al momento de realizar la clasificación de datos binarios, sin embargo, cuando se están realizando diferentes pruebas es muy común tener que resolver algunas situaciones donde son más de 2 clases, para tratar de solucionar este problema existen las expansiones de la SVM es decir las multiclase.

Las SVM multiclase se pueden encontrar a continuación [18]:

3.7.1 Uno contra uno

Este método de clasificación tiene como objetivo realizar la construcción de un clasificador por cada par de clase, la característica principal para esta clase final se define de acuerdo al par de clases utilizadas y de cuál de estas dos se tiene más características.

En el caso extraordinario que ambas clases tengan igual cantidad de características, se debe realizar un cálculo para determinar la probabilidad de pertenencia a las clases y se debe

seleccionar aquella que represente mayor probabilidad. Para poder utilizar este método se debe tener “n” cantidad de clasificadores.

3.7.2 Uno contra todos

El objetivo principal de este segundo método, es realizar una estimación de SVM por cada clase, esta debe estar en capacidad de diferenciar la clase en particular de las clases restantes.

3.8 Métodos de reducción de dimensionalidad

3.8.1 Análisis de componentes principales (PCA - Principal Component Analysis)

En el análisis de datos es importante poder hacer el estudio sobre una cantidad menor de datos a la original, por lo tanto, el método de Análisis de Componente Principales es importante ya que con este se puede realizar una reducción al conjunto de datos originales, siempre y cuando se conserve la cantidad de información necesaria para describir la actividad. Para hacer este proceso se debe realizar una transformación del conjunto original a un nuevo conjunto de variables las cuales no son correlacionadas, donde se deben ordenar y seleccionar las primeras ya que son estas las que muestran la mayor cantidad de variaciones principales del conjunto original de variables [19].

Este método PCA tiene 2 finalidades, la primera es la representación adecuada de los datos originales en un conjunto de datos más pequeño y puedan ser analizados de igual forma que el conjunto original sin perder características importantes, la segunda finalidad es realizar la transformación de las variables originales que generalmente están correlacionadas, en nuevas variables no correlacionadas que facilitan la interpretación [20].

Algoritmo 1 – Cálculo de los componentes principales

- 1 Centralizar la matriz de datos X (hacer que cada variable tenga media cero).
- 2 Obtener la matriz de covarianza $S = \frac{1}{n} X^T X$.
- 3 Calcular los valores propios de la matriz S y sus respectivos vectores propios.
- 4 Ordenar de forma descendente los valores propios.
- 5 Proyectar los datos sobre las direcciones principales luego del ordenamiento de los valores propios.

3.8.2 Análisis de componentes principales con kernels (KPCA - Principal Component Analysis)

Cuando se habla de KPCA (*Análisis de Componentes Principales con Kernels*) este se define como una extensión del PCA (*Análisis de Componentes Principales*) la cual tiene como característica principal el envío de datos a otro lugar por medio de una transformación no lineal que se llama espacio de características donde se implementa PCA. La clave del éxito del KPCA está en lograr la extracción de direcciones de máxima variabilidad en el espacio de las características y luego identificar estas direcciones con las direcciones (no lineales) de variabilidad de los datos en el espacio original [11].

3.9 t-Distribución Estocástica de puntos más cercanos t-SNE (t-Distributed Stochastic Neighbor Embedding)

t-Distribución estocástica de puntos más cercanos (t-SNE) minimiza la divergencia entre dos distribuciones: Una distribución que mide la similitud entre pares de objetos de entradas y una medida de distribución entre parejas similares de los correspondientes puntos de análisis en un espacio de representación implementado de menor dimensión [22], típicamente este espacio de distribución corresponde a 2 o 3 dimensiones.

3.10 El método de Montecarlo

El método de *Montecarlo* es un proceso estadístico numérico secuencial de estados cuya evolución viene determinada por sucesos aleatorios [6]. Este método se fundamenta desde una validación cruzada, ya que permite a partir de un conjunto de repeticiones comprobar la eficiencia del método de clasificación, mediante la selección continua de una matriz de entrenamiento y una matriz de prueba aleatoriamente.

4. DESARROLLO METODOLÓGICO.

4.1 ANÁLISIS DE LA TESIS DE MAESTRÍA (*RECONOCIMIENTO AUTOMÁTICO DE ACTIVIDADES FÍSICAS EN SISTEMAS MULTIMODALES*)

En esta tesis de maestría se desarrolló una metodología de reconocimiento automático de actividades físicas humanas utilizando la fusión de datos proveniente de una red de sensores multimodales IMU, EMG y un sensor de profundidad KINECT.

Inicialmente para poder definir la metodología, se realizó una captura de datos a partir de la elaboración de una base de datos anotada que permitió evaluar en igualdad de condiciones los comportamientos estáticos y dinámicos de las señales registradas por los diferentes sensores multimodales.

Dentro del almacenamiento adecuado de las 5 actividades (tabla 1) que representa la base de datos en mención, se utilizaron 16 voluntarios, los cuales ejecutaron 3 veces cada una de las actividades y en la ejecución se logró almacenar un total de 48 ejemplos por clase.

ACTIVIDAD	ETIQUETA
Quedarse quieto	1
Agacharse y levantarse	2
Saltar	3
Levantar mano derecha	4
Trotar	5

Tabla 1. Lista de actividades

Para un adecuado reconocimiento de los movimientos primitivos dentro de esta investigación se inspiraron en la similitud de la señal de la voz humana con el movimiento humano [36]. En el reconocimiento de la voz, las frases se dividen en palabras aisladas o fonemas generando una secuencia o codificación de cada frase; lo que permite construir un modelo de clasificación de N fonemas compartidos para el conjunto de palabras a reconocer. Siguiendo la misma idea, cada actividad se representó como una secuencia de sub-movimientos (Tabla 2) generando una codificación única que permite obtener un elemento discriminante en la clasificación de cada actividad.

SUB- ACTIVIDAD	ETIQUETA	SUB- ACTIVIDAD	ETIQUETA
Reposo	1	Mano levantada a $\frac{1}{4}$	5
Medio agachado	2	Mano levantada a $\frac{3}{4}$	6
Totalmente agachado	3	Paso adelante pie derecho	7
Suspendido en el aire $\frac{1}{4}$	4	Paso adelante pie izquierdo	8

Tabla 2. Lista de sub-actividades

El proceso de extracción de características se dividió el análisis de los sensores de forma individual, (extracción de características Kinect, extracción de características IMU, extracción de características EMG) a partir de un conjunto de descriptores estadísticos que representan adecuadamente cada modalidad del sensor. Para obtener una señal adecuada en esta etapa, fue necesario segmentar las señales de cada sensor en ventanas más pequeñas permitiendo describir de forma exacta un movimiento, para esto la ventana de segmentación se dividió en observaciones de 3 segundos como se puede observar en la figura 1.

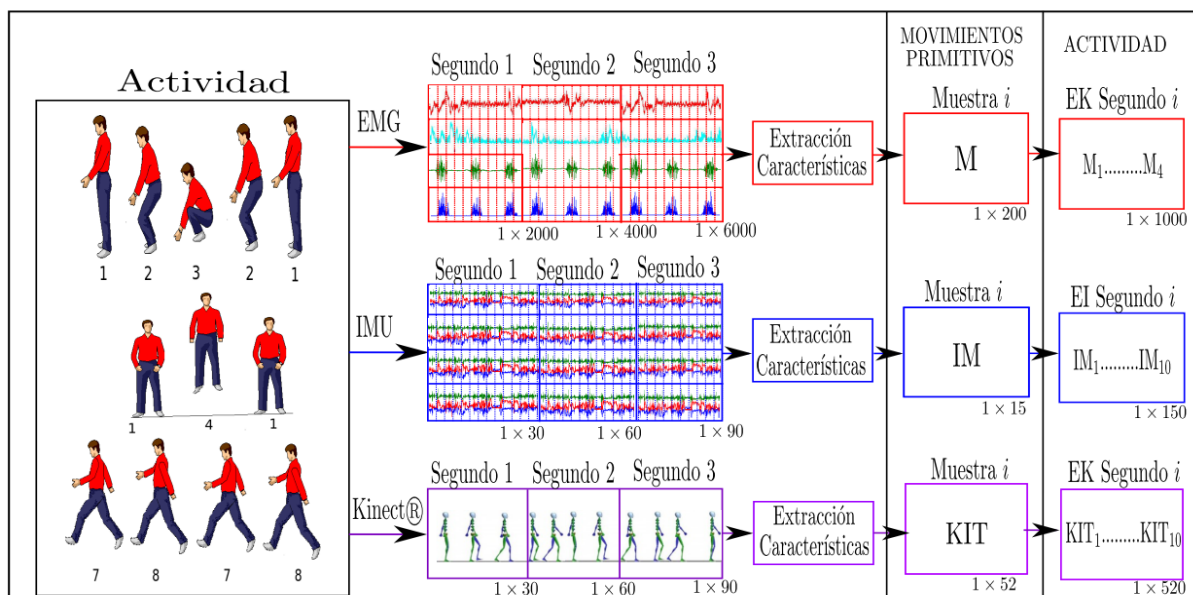


Figura 1. Diagrama de segmentación de señales

En la clasificación de los movimientos primitivos se utilizaron tres máquinas de soporte multiclase con estrategia de clasificación “All – Pairs” aplicada sobre cada tipo de sensores. Lo cual generó un conjunto de etiquetas EI (corresponde a la salida de la SVM con información provista por la red de sensores IMU), EK (corresponde a la salida de la SVM con información provista por el dispositivo Kinect) y EE (corresponde a la salida de la SVM con información provista por la red de sensores EMG).

Por medio de la fusión de datos se generó un vector de características EF con las etiquetas provenientes de los clasificadores SVM durante una ventana de observación de 3 segundos, Permitiendo centralizar la información y haciéndola apta para la etapa de clasificación con HMM, el cual parte de un modelo entrenado que proporciona una separación entre clase.

Se realizó el estudio comparativo del aporte de cada sensor en el reconocimiento de la actividad física, probando diferentes combinaciones de sensores y evaluando el desempeño del método por medio de validación cruzada realizando iteraciones de **Montecarlo**.

Finalmente se evidenció que el mejor desempeño en la clasificación se presentaba en las combinaciones que involucraran sensores IMU. Sin embargo, también se concluyó que al reducir la cantidad de sensores en la etapa de clasificación puede existir una pérdida de información, lo que no garantiza una correcta clasificación de los movimientos.

4.2 ELABORACIÓN DESCRIPTORES ESTADISTICOS DE LOS SENSORES IMPLEMENTADOS (KINECT, IMU)

4.2.1 DESCRIPTORES ESTADISTICOS KINECT:

Para una adecuada caracterización de los datos provenientes de este sensor se considera el cálculo de los siguientes descriptores:

- Características Polares [37]
- Descriptores estadísticos.

El cálculo de las características polares se describe en [1] como una transformación de los puntos articulados de coordenadas cartesianas (vector J) a coordenadas polares (Vector P) considerando que el Kinect es un sistema que reconoce 14 puntos articulados del cuerpo (figura 2), se implementa un método adecuado para poder hacer una correcta transformación de estas coordenadas.




Figura 2. Puntos articulados del cuerpo Kinect.

Dado un vector J:

$$J = [X_1 Y_1 Z_1 \dots X_{14} Y_{14} Z_{14}] \quad (8)$$

1. Se calcula el centro de masa del objetivo evaluado.
2. Se transforma cada articulación a coordenadas polares utilizando como origen de coordenadas el centro de masa, lo que permite obtener el siguiente vector.

$$P_i = [r_1 \theta_1 r_1 \theta_{14} \dots r_{14} \theta_{14}] \quad (9)$$

Donde i corresponde al tamaño de 3 muestras que se implementaron para obtener adecuadamente los datos provenientes del Kinect, $i = \{1, 2, 3\}$

Finalmente se obtiene el siguiente vector de características:

$$KIT = [P_1 P_2 P_3 m_x m_y m_z m_r m_\theta v_x v_y v_z v_r v_\theta]_{1 \times 52} \quad (10)$$

Donde se debe tener presente que el tamaño del vector corresponde a la concatenación de los 3 grupos de características polares en las 3 muestras adquiridas y los descriptores estadísticas indicados en la siguiente tabla.

Nombre	Descripción	Nombre	Descripción
Medida de x	$m_x = \frac{1}{3} \sum_{i=1}^3 x_i$	Varianza de x	$u_x = \frac{1}{3} \sum_{i=1}^3 (x_i - \bar{x})^2$
Medida de y	$m_y = \frac{1}{3} \sum_{i=1}^3 y_i$	Varianza de y	$u_y = \frac{1}{3} \sum_{i=1}^3 (y_i - \bar{y})^2$
Medida de z	$m_z = \frac{1}{3} \sum_{i=1}^3 z_i$	Varianza de z	$u_z = \frac{1}{3} \sum_{i=1}^3 (z_i - \bar{z})^2$
Medida de r	$m_r = \frac{1}{3} \sum_{i=1}^3 r_i$	Varianza de r	$u_r = \frac{1}{3} \sum_{i=1}^3 (r_i - \bar{r})^2$
Medida de Θ	$m_\theta = \frac{1}{3} \sum_{i=1}^3 \theta_i$	Varianza de Θ	$u_\theta = \frac{1}{3} \sum_{i=1}^3 (\theta_i - \bar{\theta})^2$

Tabla 3. Descriptores estadísticos implementados.

4.2.2 DESCRIPTORES ESTADÍSTICOS IMU:

En la elaboración de la base de datos anotada en [1] se utilizó la información de 4 acelerómetros tri-axiales (a_x, a_y, a_z) distribuidos en diferentes partes del cuerpo.

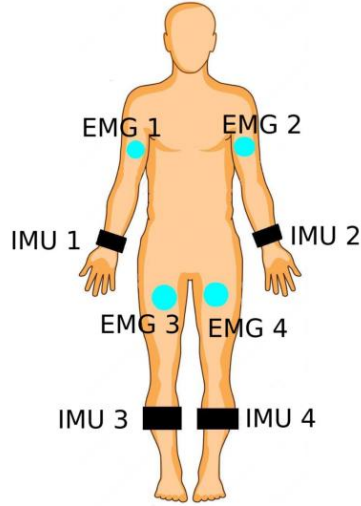


Figura 3. Distribución de sensores.

Considerando que este dispositivo cuenta con 3 grados de libertad, dentro de la tesis de maestría [1] se realizó el cálculo de las orientaciones Roll y Pitch utilizando la conversión a coordenadas esféricas las cuales se basan en la siguiente ecuación:

La fuerza gravitacional G se define como:

$$G = Raw_{accel} \left[\frac{R}{2^n - 1} \right] \quad (11)$$

Donde:

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

$$Pitch = \arctan \left(\frac{G_y}{\sqrt{G_x^2 + G_z^2}} \right) \quad (12)$$

$$Roll = \arctan \left(\frac{-G_x}{G_z} \right) \quad (13)$$

Concatenando estos últimos dos componentes se obtiene el siguiente vector con la información proveniente de los 4 sensores IMU implementados:

$$I_k = [a_x \ a_y \ a_z \ Pitch \ Roll] \quad (14)$$

Donde k corresponde a la información registrada por los 4 acelerómetros, $K = \{1, 2, 3, 4\}$.

Las características del vector I resultante consiste en el cálculo de los siguientes descriptores:

- Características basadas en los parámetros físicos del movimiento humano [38]
- Descriptores estadísticos.

Para el cálculo de las características basadas en los parámetros físicos del movimiento humano se utilizaron las ecuaciones indicadas en la tabla 4 y para los descriptores estadísticos se utilizaron las ecuaciones de la tabla 5.

Obteniendo de esta manera el siguiente vector de características:

$$IM = [AI \ VI \ SMA \ EVA \ AAE \ AER \ m_{ax} m_{ay} m_{az} m_{ar} m_{a\theta} v_{ax} v_{ay} v_{az} v_{ar} v_{a\theta}]_{1 \times 16}$$

Nombre	Definición
Mean of Movement Intensity (AI)	$AI = \frac{1}{3} \sum_{i=1}^3 MI(i), \quad MI = \ A_{xyz}\ _2$ $A_{xyz} = [a_x \ a_y \ a_z]^T$
Variance of MI (VI)	$VI = \frac{1}{3} \sum_{i=1}^3 (MI(i) - AI)^2$
Normalized Signal Magnitude Area (SMA)	$SMA = \frac{1}{3} \left(\sum_{i=1}^3 a_x(i) + \sum_{i=1}^3 a_y(i) + \sum_{i=1}^3 a_z(i) + \right)$
Eigenvalues of Dominant Directions (EVA)	Vectores propios de la matriz de covarianza de la aceleración a lo largo de los ejes x,y,z en cada ventana de observación.
Averaged Acceleration Energy (AAE)	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.
Averaged Rotation Energy (ARE)	Valor medio de la energía a lo largo de los ángulos de rotación, para este caso solo Roll y Pitch.

Tabla 4. Características IMU basadas en los parámetros físicos del movimiento humano.

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

Tabla 5. Descriptores estadísticos implementados.

4.3 EJECUCIÓN BASE DE DATOS ANOTADA

Una vez definidos los descriptores estadísticos de cada uno de los tipos de sensores utilizados para la recopilación adecuada de los datos, se decide crear un archivo con extensión (.mat) la cual cuenta con la siguiente estructura para el adecuado almacenamiento y posterior uso de los datos.

DATA {Ejemplo}{Segundo}{Sensor}{Segmento}

Donde:

- Ejemplo corresponde a una celda 1 x 240, con la información de cada uno de las 5 actividades ejecutadas por los 16 voluntarios.
- Segundo corresponde a una celda con dimensión 1 x 3, el cual contiene la información de los tres sensores durante la ventana correspondiente al segundo analizado.
- Sensor corresponde a una celda con dimensión 1 x 3, la cual contiene la información de cada modalidad del sensor, [la primera columna corresponde a la información del Kinect, la segunda columna corresponde a la información del EMG, la tercera columna corresponde a la información del IMU]
- Segmento corresponde a una celda de 1 x 10 la cual cuenta con la información de cada tipo de sensor según su capacidad de muestreo.

Cabe indicar que los sensores KINECT e IMU tienen una tasa de muestreo de 30 muestras por segundo, mientras que los sensores EMG manejan una tasa de muestreo de 2K muestras por segundo. [1, 2]

Finalmente se obtienen las siguientes tres matrices que corresponden a los datos de cada uno de los tipos de sensores individualmente.

- Datos Kinect corresponde a una matriz de tamaño M_K3 (7200 x 280)
- Datos IMU corresponde a una matriz de tamaño M_I (7200 x 96)
- Datos EMG corresponde a una matriz de tamaño M_E (7200 x 108)

4.4 VISUALIZACIÓN DE LOS DATOS UTILIZANDO LOS DIFERENTES METODOS DE REDUCCIÓN IMPLEMENTADOS.

En esta etapa se pretende dar a conocer el comportamiento de los datos a través de los diferentes métodos de reducción implementados, tales como PCA, t-SNE, MDS (*Multi-Dimensional Scaling*) [3], entre algunos otros, los cuales se pueden visualizar en la tabla 6.

4.4.1 MÉTODOS DE REDUCCIÓN IMPLEMENTADOS:

METODO
PCA - PRINCIPAL COMPONENT ANALYSIS
MDS – MULT-IDIMENSIONAL SCALING
KPCA – KERNEL PRINCIPAL COMPONENT ANALYSIS
LEM - LAPLACIAN EIGENMAPS
SAMMON
CCA - CANONICAL CORRELATION ANALYSIS
SNE - STOCHASTIC NEIGHBOR EMBEDDING
t-SNE - T-DISTRIBUTED STOCHASTIC NEIGHBOR EMBEDDING
NeRV - NEIGHBOR RETRIEVAL VISUALIZER
JSE - JENSEN–SHANNON EMBEDDING

Tabla 6. Métodos de reducción implementados.

Previo a la aplicación de los métodos de reducción, considerando que el costo computacional al operar el tamaño de las matrices mencionadas en el numeral 4.3 para los tres tipos de sensores caracterizados son amplias, se decide implementar un método de agrupamiento que tiene como objetivo la partición del grupo de datos de un conjunto de N observaciones en K grupos, en el que cada observación pertenece al grupo cuyo valor medio es el más cercanos, su principal características es la función K-MEANS [33].

$$X \in \mathbb{R}^{N \times P} \Rightarrow \boxed{\text{Bolsa de palabras}} \Rightarrow \hat{X} \in \mathbb{R}^{N \times P}$$

$$L \in \{1, 2 \dots C\}^{N \times P} \Rightarrow \boxed{\text{Bolsa de palabras}} \Rightarrow \hat{L} \in \{1, 2 \dots\}^{N \times P}$$

Donde:

- X es la matriz con los datos de entrada.
- L es la matriz de etiquetas.
- N es el número de muestras.
- P es el número de características.
- M es el número de muestras reducida a partir del agrupamiento de los datos.
- C es el conjunto máximo de etiquetas.

Algunos métodos tales como t-SNE, NerV (*Neighbor Retrieval Visualizer*) y JSE (*Jensen–Shannon embedding*) [34] requieren de un dato adicional a parte de la matriz de características definido como PXT el cual determina el valor de perplejidad de los métodos que son basados en la divergencia de los datos [34], adicionalmente se puede considerar que a mayor sea el valor del PXT la cantidad de agrupamientos entre vecinos es mayor, siempre y cuando no se exceda un límite en el cual no se puedan relacionar las características entre sí, considerando su ubicación en el espacio de representación inicial.

Para poder analizar adecuadamente la visualización de los datos en las figuras presentes a continuación se decide dar un color a cada una de las 8 etiquetas definidas en la tabla 2, como se puede observar en la tabla 7.

SUB- ACTIVIDAD	ETIQUETA	COLOR DE REPRESENTACIÓN
Reposo	1	Morado
Medio agachado	2	Azul rey
Totalmente agachado	3	Azul
Suspendido en el aire $\frac{1}{4}$	4	Azul aguamarina
Mano levantada $\frac{1}{4}$	5	Verde
Mano levantada $\frac{3}{4}$	6	Café
Pie adelante derecho	7	Naranja
Pie adelante izquierdo	8	Amarillo

Tabla 7. Color de representación etiquetas.

4.4.2 VISUALIZACIÓN DE LAS CARACTERÍSTICAS DEL EMG.

Considerando $PXT = 48$.




Figura 4: Visualización de método CCA.




Figura 5: Visualización de método t-SNE.




Figura 6: Visualización de método JSE.




Figura 7: Visualización de método KPCA.




Figura 8: Visualización de método LEM.




Figura 9: Visualización de método NeRV.




Figura 10: Visualización de método NLM.




Figura 11: Visualización de método NMDS.




Figura 12: Visualización de método PCA.




Figura 13: Visualización de método SNE.




Figura 14: Probabilidades de todos los métodos.

Considerando $PXT = 99$.




Figura 15: Visualización de método CCA.




Figura 16: Visualización de método t-SNE.




Figura 17: Visualización de método JSE.




Figura 18: Visualización de método KPCA.




Figura 19: Visualización de método LEM.

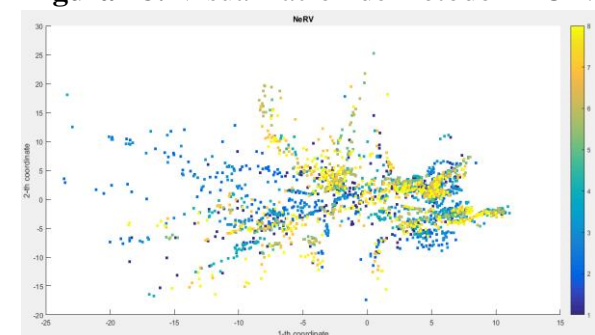


Figura 20: Visualización de método NeRV.




Figura 21: Visualización de método NLM.




Figura 22: Visualización de método NMDS.




Figura 23: Visualización de método PCA.




Figura 24: Visualización de método SNE.




Figura 25: Probabilidades de todos los métodos.

Las figuras 14 y 25 corresponden al rango de vecinos donde se puede determinar qué cantidad de estos se conservan, comparando el conjunto de datos inicial y el conjunto de datos obtenidos tras aplicar los métodos de reducción de dimensionalidad.

El eje de las ordenadas corresponde al porcentaje de vecinos que se mantuvieron y en el eje de las abscisas corresponde a la cantidad de vecinos evaluados, ya que un caso ideal sería que sin importar la cantidad de vecinos evaluados estos se deben conservar en su totalidad, se decide determinar el área bajo la curva de cada uno de las gráficas de representación de los métodos, obteniendo de este modo los valores visualizados dentro de cada una de las figuras

14 y 25 para las características del EMG, donde se puede observar que el método con mayor eficiencia en 2 dimensiones definidas es el t-SNE y el de menor eficiencia es el LEM, ya que este último no presenta convergencia.

METODOS	PXT	AREA BAJO LA CURVA
t-SNE	48	59,8
LEM	48	0.6
t-SNE	99	57,4
LEM	99	31,3

Tabla 8. Área bajo la curva de los métodos con EMG.

Se debe indicar que dentro la visualización de los datos adquiridos con el conjunto de sensores EMG, se observa que estos se encuentran considerablemente traslapados, impidiendo a gran escala que los mismos se puedan clasificar de alguna manera, por ende y considerando la finalidad de este proyecto se decide no considerar las características de los sensores EMG dentro de la etapa de clasificación.

4.4.3 VISUALIZACIÓN DE LAS CARACTERÍSTICAS DEL IMU.

Considerando $PXT = 48$.

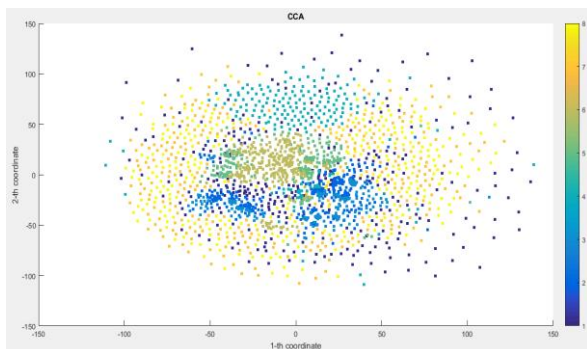


Figura 26: Visualización de método CCA.




Figura 27: Visualización de método JSE.




Figura 28: Visualización de método KPCA.




Figura 29: Visualización de método LEM.




Figura 30: Visualización de método NeRV.




Figura 31: Visualización de método NLM.




Figura 32: Visualización de método NMDS.




Figura 33: Visualización de método PCA.




Figura 34: Visualización de método SNE.




Figura 35: Visualización de método t-SNE.




Figura 36: Probabilidades de todos los métodos.

Considerando $PXT = 99$.




Figura 37: Visualización de método CCA.




Figura 38: Visualización de método JSE.




Figura 39: Visualización de método KPCA.




Figura 40: Visualización de método LEM.




Figura 41: Visualización de método NeRV.




Figura 42: Visualización de método NLM.




Figura 43: Visualización de método NMDS.




Figura 44: Visualización de método PCA.




Figura 45: Visualización de método SNE.




Figura 46: Visualización de método t-SNE.




Figura 47: Probabilidades de todos los métodos.

Al igual que con las características de los sensores EMG, se decide implementar los diferentes métodos de reducción de dimensionalidad haciendo uso de la base de datos adquirida mediante el sensor IMU, obteniendo así la visualización en el comportamiento de los datos que se presentan en las figuras (26 – 46) y la eficiencia de cada uno de los métodos en relación al agrupamiento de vecinos conservados entre la matriz de datos de entrada y la matriz resultante (figuras 36 y 47).

METODOS	PXT	AREA BAJO LA CURVA
t-SNE	48	49,7
LEM	48	0,7
t-SNE	99	50,2
LEM	99	1,8

Tabla 9. Área bajo la curva de los métodos con IMU.

Aunque los métodos de reducción presentaron mayor eficiencia con las características del sensor EMG que con las del IMU, se debe considerar la visualización de este último dentro de las imágenes resultantes, ya que como se puede observar las diferentes etiquetas identificadas presentan un mayor agrupamiento y una mayor facilidad de aplicación en el proceso de clasificación.

Por otro lado, el espacio al cual se están representando las nuevas características corresponde a 2 dimensiones, lo cual están impidiendo que el método LEM converja a un valor deseado para el conjunto de características IMU (Figuras 29 y 40).

Se puede observar que métodos como PCA (figuras 33 y 44), NLM (figuras 31 y 42) y CCA (figura 26 y 37) planteados en 2 dimensiones, no presentan una correcta distribución de las características seleccionadas, ya que como se puede visualizar en las figuras estos datos presentan un gran traslape lo que no permite un agrupamiento adecuado entre los mismos, a comparación de otros métodos como t-SNE (figura 35 y 46) y JSE (figura 27 y 38) los cuales presentan un mejor agrupamiento de características en este espacio de representación, considerando la posibilidad de que en este espacio la clasificación de las características pueda resultar optima implementando estos dos métodos de reducción.

4.4.4 VISUALIZACIÓN DE LAS CARACTERÍSTICAS DEL KINECT.

Considerando $PXT = 48$.




Figura 48: Visualización de método CCA.




Figura 49: Visualización de método JSE.




Figura 50: Visualización de método KPCA.




Figura 51: Visualización de método LEM.




Figura 52: Visualización de método NeRV.




Figura 53: Visualización de método NLM.




Figura 54: Visualización de método NMDS.




Figura 55: Visualización de método PCA.




Figura 56: Visualización de método SNE.




Figura 57: Visualización de método t-SNE.




Figura 58: Probabilidades de todos los métodos.

Considerando PXT = 99.



Figura 59: Visualización de método CCA.




Figura 60: Visualización de método JSE.



Figura 61: Visualización de método KPCA.




Figura 62: Visualización de método LEM.




Figura 63: Visualización de método NeRV.




Figura 64: Visualización de método NLM.




Figura 65: Visualización de método NMDS.




Figura 66: Visualización de método PCA.




Figura 67: Visualización de método SNE.




Figura 68: Visualización de método t-SNE.




Figura 69: Probabilidades de todos los métodos.

Al igual que con las características de los sensores EMG y IMU, se decide implementar los diferentes métodos de reducción sobre el sensor multimodal restante (Kinect) (figuras 48 – 68), el cual presenta los siguientes valores de eficiencia en tanto a la conservación de los datos una vez se hace la reducción (figuras 68 – 69).

METODOS	PXT	ÁREA BAJO LA CURVA
t-SNE	48	48
LEM	48	1,4
t-SNE	99	48,1
LEM	99	2,5

Tabla 10. Área bajo la curva de los métodos con Kinect.

De forma similar a las características del IMU, la visualización presentada de las características del KINECT presenta un comportamiento adecuado para una correcta clasificación de cada una de las etiquetas seleccionadas, esto se puede observar en la representación que se tienen de los datos tras aplicar los métodos t-SNE (figuras 57 y 68) y JSE (figuras 49 y 60).

Los demás métodos de reducción de dimensionalidad implementados no presentan una respuesta adecuada en tanto a la representación en la distribución de los datos en un espacio de representación de 2 dimensiones.

Adicionalmente, se debe tener presente que a mayor sea el valor del PXT, se tiende a conservar una mayor cantidad de vecinos entre los espacios comparados, permitiendo de esta forma mantener constante la distribución de los datos.

Considerando que las características que presentan los mejores comportamientos son las que corresponde a los datos del Kinect e IMU, se decide realizar una fusión de datos concatenando la información de ambas matrices de la siguiente manera:

$$X = [M_{K3} \ M_I]$$

4.4.5 VISUALIZACIÓN DE LAS CARACTERÍSTICAS DEL KINECT-IMU

Considerando $PXT = 48$.




Figura 70: Visualización de método CCA.




Figura 71: Visualización de método JSE.




Figura 72: Visualización de método KPCA.




Figura 73: Visualización de método LEM.




Figura 74: Visualización de método NeRV.




Figura 75: Visualización de método NLM.




Figura 76: Visualización de método NMDS.




Figura 77: Visualización de método PCA.




Figura 78: Visualización de método SNE.




Figura 79: Visualización de método t-SNE.




Figura 80: Probabilidades de todos los métodos.

Considerando PXT = 99.




Figura 81: Visualización de método CCA.




Figura 82: Visualización de método JSE.




Figura 83: Visualización de método KPCA.




Figura 84: Visualización de método LEM.




Figura 85: Visualización de método NeRV.




Figura 86: Visualización de método NLM.




Figura 87: Visualización de método NMDS.




Figura 88: Visualización de método PCA.




Figura 89: Visualización de método SNE.




Figura 90: Visualización de método t-SNE.




Figura 91: Probabilidades de todos los métodos.

Al evaluar los métodos seleccionados t-SNE y LEM con relación a su eficiencia aplicando la fusión de datos entre las características del Kinect y el IMU se obtiene lo siguientes valores:

METODOS	PXT	AREA BAJO LA CURVA
t-SNE	48	47,3
LEM	48	4
t-SNE	99	47,5
LEM	99	3,3

Tabla 11. Área bajo la curva de los métodos con Kinect-IMU.

Se debe considerar, que, aunque el área bajo la curva del método t-SNE es menor que el obtenido con las características del EMG, el comportamiento de los datos utilizando la fusión de los mismos tienden a una mayor distribución, facilitando aún mucho más el proceso de clasificación que tomando cada característica de los sensores de forma individual y aumentando así la probabilidad de acierto del mismo.

De tal modo que se decide considerar como base datos principal para el análisis de clasificación, la concatenación de las características del Kinect y el IMU.

Por tal motivo se realiza un análisis más detallado del comportamiento de los mismos, bajo el método de reducción de dimensionalidad con mayor eficiencia (t-SNE) y variando el valor del PXT de 5 en 5 hasta 50, considerando esto, como suficiente para poder demostrar la adecuada separación de las etiquetas determinadas para el método de clasificación.

4.4.6 VISUALIZACIÓN DE LAS CARACTERÍSTICAS DEL SENSOR KINECT – IMU UTILIZADANDO UNICAMENTE EL METODO t-SNE:




Figura 92: Método t-SNE con PXT=5.




Figura 93: Método t-SNE con PXT=10.




Figura 94: Método t-SNE con PXT=15.




Figura 95: Método t-SNE con PXT=20.




Figura 96: Método t-SNE con PXT=25.




Figura 97: Método t-SNE con PXT=30.




Figura 98: Método t-SNE con PXT=35.




Figura 99: Método t-SNE con PXT=40.




Figura 100: Método t-SNE con PXT=45.




Figura 101: Método t-SNE con PXT=50.

4.5 CLASIFICACIÓN DE LOS DATOS

Para la etapa de clasificación se decide implementar un algoritmo en el cual se pretende a partir del conjunto de datos definidos en el numeral 4.4 aplicar el método de clasificación supervisado KNN - Késimo Vecino más Cercano [35], con el fin de poder determinar a partir de los métodos de reducción de dimensionalidad, cuál podría ser el óptimo para el conjunto de datos recopilados en [1] o si por lo contrario la representación total de los mismos es necesaria, realizando una verificación por medio de validación cruzada.

Para la implementación de esto se decide tomar la matriz de datos principal del Kinect, IMU y la fusión de datos Kinect_IMU y realizar el procedimiento de agrupamiento descrito en la sección 4.4.1 donde se reduce el tamaño de la matriz de entrada de tal modo que el costo computacional en el análisis de los datos sea menor. Dentro del procedimiento de validación cruzada se decide realizar un número de 10 repeticiones considerando que cada vez que se ingrese dentro de una repetición se toma el 70% de los datos para el entrenamiento del clasificador y el 30% para la evaluación del mismo.

Los métodos de reducción implementados fueron el t-SNE, PCA y JSE, ya que t-SNE presentó el mejor comportamiento de visualización en 2 dimensiones, JSE tiene un comportamiento estable y PCA se tomaría como el método adecuado para determinar si con una mayor cantidad de dimensiones puede mejorar su comportamiento de separación.

Considerando que t-SNE y JSE requieren como parámetros de entradas un valor de PXT determinado y una dimensión seleccionada se decide realizar las siguientes consideraciones:

1. Dentro de la validación que se realizó en la visualización de los datos se determinó que entre mayor es el valor del PXT, mayor cantidad de vecinos dentro del espacio

obtenido es conservado, por ende, se decide tomar un valor de PXT de 100, considerando este valor adecuado para una correcta distribución de los mismos.

2. Para determinar la dimensión de los métodos se decide implementar el modelo de PCA. El cual a partir de su curva características determinar cuáles columnas tiene dependencia lineal y no aportan información importante para representar el espacio [2].

SENSOR	ESPACIO DE REPRESENTACIÓN OPTIMA (DIMENSIÓN)
KINECT	41 componentes
IMU	30 Componentes
KINECT+IMU	65 Componentes

Tabla 12. Espacio de representación.


Para poder determinar un análisis adecuado en la eficiencia de cada uno de los métodos seleccionados, se implementa un análisis inicial con el conjunto de datos definidos, considerando el espacio de representación de cada tipo de sensor y posteriormente se implementan los métodos de reducción de dimensionalidad seleccionado, considerando los espacios de representación óptimos definidos en la tabla 11.

Los resultados obtenidos al validar los métodos de reducción de dimensionalidad con cada conjunto de datos y aplicando el método de clasificación supervisado KNN son los presentes la tabla 13.

MÉTODO DE REDUCCIÓN IMPLEMENTADO	TIPO DE SENSOR	ACIERTO DE CLASIFICACIÓN	TIEMPO PROMEDIO DE PROCESO
NINGUNO	KINECT	77,50 ± 1,19 %	7,24 [s]
	IMU	67,48 ± 1,7 %	6,18 [s]
	KINECT+IMU	78,40 ± 1,29 %	7,33 [s]
PCA	KINECT	76,81 ± 1,51 %	8,98 [s]
	IMU	67,54 ± 1,99 %	7,47 [s]
	KINECT+IMU	79,63 ± 1,98 %	7,61 [s]
t-SNE	KINECT	71,44 ± 1,31 %	655,25 [s]
	IMU	64,14 ± 1,29 %	868,77 [s]
	KINECT+IMU	74,24 ± 2,13 %	711,99 [s]
JSE	KINECT	72,98 ± 1,79 %	706,38 [s]
	IMU	64,87 ± 2,01 %	537,89 [s]
	KINECT+IMU	74,41 ± 2,45 %	968,62 [s]


Tabla 13. Datos de cada sensor con su respectivo método.

Comportamiento del clasificador KNN, haciendo uso de los tres tipos de sensores sin aplicar ningún método de reducción de dimensionalidad.




Grafica 1. Comportamiento de los tres sensores con clasificador KNN.

Comportamiento del clasificador KNN, haciendo uso de los tres tipos de sensores aplicando el método de reducción PCA.




Grafica 2. Comportamiento de los tres sensores con PCA y clasificador KNN.

Comportamiento del clasificador KNN, haciendo uso de los tres tipos de sensores aplicando el método de reducción t-SNE.




Grafica 3. Comportamiento de los tres sensores con t-SNE y clasificador KNN.

Comportamiento del clasificador KNN, haciendo uso de los tres tipos de sensores aplicando el método de reducción JSE.



Grafica 4. Comportamiento de los tres sensores con JSE y clasificador KNN.

Se procede a realizar la comparación utilizando los resultados de los tres métodos de reducción aplicados sobre la base de datos que presento el mejor comportamiento, la fusión de datos entre el Kinect y el IMU.



Grafica 5. Comparación de los métodos.

Realizando el análisis comparativo, se puede comprobar que el mejor método de reducción implementado sobre el clasificador KNN y considerando los parámetros de implementación descritos es PCA para la matriz de datos del Kinect e IMU, con un criterio de acierto del 79,63% entre las matrices de entrenamiento y evaluación, esto puede deberse a que el conjunto de características seleccionadas para la clasificación representaban la mayor independencia lineal y conservan el mayor peso en la descripción de los movimientos.

Adicionalmente se puede observar que el comportamiento de los datos es mucho mejor cuando se tiene la fusión de los mismos, obteniendo una probabilidad de acierto superior al 74% dentro de los tres métodos de reducción implementados y sin aplicar ninguno de los métodos.

Cabe decir que el método de PCA consume menos costo computacional debido a su facilidad de iteración, al ser un método de reducción lineal y al considerar que el número de dimensiones es mayor a 2, la separación entre clases puede determinar que la distancia entre los datos evaluados sea menor, permitiendo una rápida selección y clasificación de los mismos.

4.5.1 IMPLEMENTACIÓN DE LOS MÉTODOS DE REDUCCIÓN DE DIMENSIONALIDAD SOBRE UN NUEVA BASE DE DATOS ANOTADA.

Como parte final del trabajo de investigación se decide implementar los diferentes métodos de reducción evaluados en la sección 4.4, en este caso haciendo uso de la base de datos recopilada por el grupo de investigación de automática de la Universidad tecnológica de Pereira en el proyecto de investigación (“A kernel-based approach for deep brain stimulation parameter estimation”) [35].

Dentro de la base de datos recopilada por este grupo de investigación se cuenta con la matriz de entrada $X_{N \times P}$ la cual contiene los parámetros del espacio VTA (*volume of tissue activated*), y la matriz de etiquetas $Y_{N \times Q}$, la cual contiene el vector de parámetros DBS (*Deep brain stimulation*).

$$Y = [D_A D_W c_0 c_1 c_2 c_3]_{1000 \times 6}$$

Donde:

- N corresponde al número de muestras, en esta base de datos corresponde a 1000 ejemplos.
- P corresponde al número de características, en este caso se tiene un total de 174.048 características.
- Q corresponde a los parámetros del vector Y, en esta base de datos se tiene que $Q = 6$
- $D_A \in R^+$ se refiere a la amplitud de la medida.
- $D_W \in R^+$ se refiere al ancho de pulso de la medida.
- C_r con $r = [0 \ 1 \ 2 \ 3]$ corresponden a las condiciones de contacto, las cuales posteriormente serán utilizadas para pintar los parámetros de la base de datos VTA implementada.

4.5.2 VISUALIZACIÓN DE LA BASE DE DATOS RECOPIADA POR EL GRUPO DE INVESTIGACIÓN DE AUTOMÁTICA.

A continuación, se presenta el comportamiento de los datos haciendo uso de los métodos t-SNE, y KPCA.

Primer caso ($Y = C_0$)

Considerando PXT = 100




Figura 102: Método t-SNE con PXT=100.




Figura 103: Método KPCA con PXT=100.

Considerando PXT = 150




Figura 104: Método t-SNE con PXT=150.

Considerando PXT = 200




Figura 105: Método t-SNE con PXT=200.

Segundo caso ($Y = C_1$)

Considerando PXT = 100




Figura 106: Método t-SNE con PXT=100.




Figura 107: Método KPCA con PXT=100.

Considerando PXT = 150




Figura 108: Método t-SNE con PXT=150.

Considerando PXT = 200




Figura 109: Método t-SNE con PXT=200.

Tercer caso ($Y = C_2$)

Considerando PXT = 100




Figura 110: Método t-SNE con PXT=100.




Figura 111: Método KPCA con PXT=100.

Considerando PXT = 150




Figura 112: Método t-SNE con PXT=150.

Considerando PXT = 200




Figura 113: Método t-SNE con PXT=200

Cuarto caso ($Y = C_3$)

Considerando PXT = 100




Figura 114: Método t-SNE con PXT=100.




Figura 115: Método KPCA con PXT=100.

Considerando PXT = 150




Figura 116: Método t-SNE con PXT=150.

Considerando PXT = 200




Figura 117: Método t-SNE con PXT=200.

Se puede observar entre las figuras 102 y 117 el comportamiento de la información correspondiente a la base de datos VTA una vez aplicado los dos métodos de reducción, con las cuales se puede realizar una comparación entre las base de datos analizadas y concluir que la diferencia en el comportamiento de la información se debe a las siguientes 2 razones:

1. Se puede visualizar una mayor facilidad de separación de los datos en la información recopilada en VTA que en la base de datos elaborada en [1], ya que esta primera contiene una caracterización más robusta de la información, lo que permite tener una mayor separabilidad entre las clases.
2. Dado el número de clases que se representan en la base de datos recopilada en [1] y debido a que su caracterización no es muy robusta, presentan un mayor traslape los puntos graficados, lo que permite que la aplicación de un método de clasificación sobre la base de datos VTA sea más eficiente, dada su gran facilidad de separación y menor número de clases.

5. CONCLUSIONES

- Se implementó una metodología de visualización de los métodos de reducción de dimensionalidad existentes actualmente en la literatura sobre el reconocimiento de actividades físicas humanas, determinando de este modo el comportamiento de los datos recopilados por el Ing. Andrés Felipe Calvo Salcedo dentro de sus tesis de maestría [1], donde se pudo establecer que el mejor comportamiento de los datos se presenta en la combinación de las diferentes características recopiladas por los sensores multimodales al aplicar fusión de datos.
- Se debe considerar que 2 dimensiones no es un criterio adecuado para realizar una clasificación de una base de datos en la cual su adquisición inicial corresponde a un número mayor de características, por ende, la etapa de visualización es un aspecto importante para entender el comportamiento de los datos, mas no define cual método presenta el mejor comportamiento en la clasificación.
- Se determinó la eficiencia en el agrupamiento y reconocimiento del conjunto de características evaluadas en cada uno de los métodos de reducción implementados, realizando una comparación entre los datos provenientes de cada uno de los sensores multimodales por separado y aplicando fusión de datos, determinando de este modo que al tener una mayor cantidad de características provenientes de diferentes sensores se aumenta la facilidad de visualización y posterior clasificación de los mismos.
- Se realizó la comparación estadística usando validación cruzada y definiendo la probabilidad de aciertos que tiene el método de clasificación supervisado KNN sobre el reconocimiento de movimientos primitivos, haciendo uso de los métodos de reducción de dimensionalidad implementados, obteniendo una probabilidad de acierto mayor del 70% en la clasificación, verificando de este modo la veracidad de los mismos.
- Con la inclusión de las diferentes metodologías planteadas en este proyecto, se pudo reducir el conjunto de características utilizadas a una representación adecuada tal que al hacer uso de un clasificador supervisado como KNN se tiene un porcentaje de acierto sobresaliente y que puede servir como elemento de partida en la implementación de un entorno de seguimiento y control con los sistemas multimodales analizados con el fin de generar una reducción en el costo computacional del procesamiento de esta información.

6. RECOMENDACIONES Y TRABAJOS FUTUROS

El énfasis de este trabajo se centra en la aplicación de diversas metodologías de reducción de dimensionalidad sobre diferentes bases de datos con el fin de visualizar el comportamiento de los mismos y una posterior clasificación utilizando KNN, sin embargo, abre la brecha a qué se puedan a partir de los diferentes métodos identificados ser aplicados junto a este clasificador, identificando así la probabilidad de acierto y cual podría llegar a tener el mejor comportamiento de clasificación.

Adicionalmente, se pueden generar nuevos trabajos de investigación los cuales incluyan los tres tipos de modalidades de sensores analizados e implementar metodologías de clasificación supervisadas tales como, máquinas de soporte vectorial (SVM), HMM, entre otros. Con los cuales se pueda definir una óptima clasificación y determinar qué metodología presenta el mejor comportamiento en el reconocimiento de los movimientos primitivos.

Finalmente se recomienda considerar las diferentes metodologías aquí planteadas para verificar el comportamiento de los datos previo a la aplicación de un método de clasificación, de este modo se puede verificar el estado de la información y que tan eficiente puede ser aplicar un tipo de clasificador u otro.

7. BIBLIOGRAFIA

- [1] Salcedo, Andrés F. Calvo.: Reconocimiento automático de actividades físicas humanas en sistemas multimodales. Tesis de maestría, facultad de ingeniería, Universidad Tecnológica de Pereira, 2015.
- [2] Gutiérrez, Víctor A. Quintero.: Definición de componentes mínimas para el reconocimiento automático de actividades físicas humanas utilizando una red de acelerómetros, documento tesis pregrado ingeniería electrónica, facultad de ingeniería Universidad Tecnológica de Pereira. 2015.
- [3] Daza, Genaro S.: Metodología de reducción de dimensión para sistemas de reconocimiento automático de patrones sobre bioseñales, Universidad Nacional de Colombia, facultad de ingeniería y arquitectura, 2006.
- [4] Betancourt, Gustavo. A.: Las máquinas de soporte vectorial (SVM). Scientia et Technica, vol. XI, No. 27, Universidad Tecnológica de Pereira, Abril (2005)
- [5] Narayanan Ramanathan.: Applications of Hidden Markov Models. University of Maryland, CMSC 828J – Spring 2006.
- [6] Illana, José. I.: Métodos Montecarlo. Departamento de física teórica y del cosmos universidad de granada. 26, Ene. (2013).
- [7] Seijas. Leticia María: Reconocimiento de patrones utilizando técnicas estadísticas y conexiones aplicadas a la clasificación de dígitos manuscritos, Universidad de buenos aires, (2011).
- [8] Gualdrón. Oscar Eduardo: Diseño de un sistema de reconocimiento de rostros mediante la hibridación de técnicas de reconocimiento de patrones, visión artificial e IA, enfocado a la seguridad e interacción robótica social. Universidad de Pamplona, Edición. 6, pp. 16-28, Noviembre (2013).
- [9] Hernández, Roger Gimeno: Estudio de técnicas de reconocimiento facial, Universidad

politécnica de Catalunya, Mayo (2010).

[10] Blunsom, Phil: Hidden Markov Models, Agosto 19 de 2004.

[11] Rivas, Aurora Montano: un algoritmo genético para selección de kernel en análisis de componentes principales con kernels, Facultad de Estadística e Informática, Universidad Veracruzana, (2014).

[12] EETIMES. GPS system with IMUs tracks rst responders. R. Colin Johnson.

[13] GIRALDO S, Eduardo y OROZCO GUTIÉRREZ, Alvaro A. Sistema automatizado efectivo y apropiado de caracterización y clasificación de señales electromiográficas para el control de prótesis y brazos robóticos. Inf. téc., Colciencias Colombia., 2008.

[14] OSTLE, Bernard. Estadística aplicada. Limusa, 1979.

[15] García Pérez, Alfonso. Estadística aplicada: conceptos básicos. En: 2008.

[16] SPIEGEL, Murray R, et al. Probabilidad y estadística. McGraw-Hill, 2010.

[17] Schölkopf, Bernhard, Smola y J. Alexander. Learning with Kernels. MIT Press, 2002.

[18] CRAMMER, Koby y SINGER, Yoram. On the Algorithmic Implementation of Multiclass Kernel-based Vector Machines. En: J of Machine Learning Research, 2001.

[19] I. T. Jolliffe, Principal component analysis, 2nd ed., ser. Springer series in statistics. New York, NY, USA: Springer, 2002.

[20] D. Peña, Análisis de datos multivariantes, C. F. Madrid, Ed. Madrid, España: McGraw-Hill, 2002.

[21] Sawchuk, Alexander A., Zhang, Mi., Sawchuk Motion Primitive-Based Human Activity Recognition Using a Bag-of-Features Approach, Signal and Image Processing Institute Ming Hsieh Department of Electrical Engineering University of Southern California

Los Angeles, CA 90089 USA

- [22] Maaten, Laurens van der: Visualizing Data using t-SNE. Revista de investigación de aprendizaje de máquina 1 (2008) 1-48.
- [23] JINGEN LIU, Saad Ali y SHAH, Mubarak. Recognizing Human Actions Using Multiple Features. En: Computer Vision and Pattern Recognition, 2008.
- [24] 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.
- [25] 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.
- [26] ZHANG, Zequn, et al. A novel method for user-dened human posture recognition using inect. En: Image and Signal Processing (CISP), 2014 7th International Congress on, 2014, págs. 736-740.
- [27] FOERSTER, Friedrich y FAHRENBERG. Motion pattern and posture: Correctly assessed by calibrated accelerometers. En: Behavior Research Methods, Instruments, & Computers, 2000.
- [28] 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.
- [29] WU, Haitao, et al. Human activity recognition based on the combined SVM amp;HMM. En: Information and Automation (ICIA), 2014 IEEE International Conference on, 2014, págs. 219-224.
- [30] 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.

[31] 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.

[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.

[33] Mount, David M., An Efficient k-Means Clustering Algorithm: Analysis and Implementation, IEEE transactions on pattern analysis and machine intelligence, vol. 24, No. 7, July 2002.

[34] Lee, John A., Renard, Emilie., Type 1 and 2 mixtures of Kullback–Leibler divergences as cost functions in dimensionality reduction based on similarity preservation, Neurocomputing 112 (2013) 92–108.

[35] Gómez, V., Cuellar, J., A kernel-based approach for deep brain stimulation parameter estimation, Automatic Research Group, Universidad Tecnológica de Pereira, Colombia.

[36] 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

[37] 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, 1.2, 2.1.1, 5.2.1

[38] 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. 1.1, 2.2.1, 5.2.2