

Algoritmo para la comparación de movimientos periódicos humanos en el contexto de la enseñanza y el aprendizaje de habilidades motrices

Tesis Doctoral en Ingeniería Telemática



Universidad
del Cauca

Autor:

Marlon Felipe Burbano Fernández

Director:

Dr. Gustavo Ramírez González


Universidad del Cauca

FACULTAD DE INGENIERÍA ELECTRÓNICA Y
TELECOMUNICACIONES

PROGRAMA DE DOCTORADO EN INGENIERÍA TELEMÁTICA

28 de enero de 2022

Página de Aceptación

 Universidad del Cauca*	Gestión Administrativa y Financiera Gestión de Admisiones, Registro y Control Académico Acta para Sustentación Pública de Trabajo de Grado	
	Código: PA-GA-4.2-FOR-13	Versión: 2

Trabajo de Investigación (X)	Pasantía ()	Seminario ()
Práctica Social ()	Monografía ()	Preparatorios ()

Fecha: 28 de enero de 2022 Facultad: Ingeniería Electrónica y Telecomunicaciones

Lugar: Virtual <https://meet.google.com/piu-tgtg-ryj> Hora: 15:00

Programa :	Doctorado en Ingeniería telemática		
1. Alumno: Marlon Felipe Burbano Fernández	C.C: 10297491	Código: 69_10297491	

Nombre del Director: Gustavo Adolfo Ramírez González
Nombre del Trabajo: Algoritmo para la comparación de movimientos periódicos humanos en el contexto de la enseñanza y el aprendizaje de habilidades motrices

INFORME SOBRE LA SUSTENTACIÓN

<p>Cumplimiento de Objetivos: Se cumplieron los cuatro objetivos específicos y el general, las contribuciones por objetivos fueron:</p> <ul style="list-style-type: none"> • Se evaluaron alternativas de dispositivos para la captura de datos generados a partir de movimientos del cuerpo humano. • Se construyó de un data set a partir de patrones de movimientos periódicos generados por expertos y capturados a través del(os) dispositivo(s) seleccionados al primer objetivo. • Se desarrolló un algoritmo comparador de datos generados a partir de movimientos periódicos del cuerpo humano. • Se realizó un experimento que uso del algoritmo comparador. • Con lo anterior se consigue el objetivo general al lograr comparar con un algoritmo las habilidades motrices periódicas de dos muestras a partir de la captura de datos con tecnologías wearable

<p>Desarrollo Metodológico: Se llevó a cabo el desarrollo propio de una tesis doctoral:</p> <ul style="list-style-type: none"> - Mapeo científico del dominio del conocimiento a abordar. - Se desarrolló una arquitectura con base en el modelo 4+1 vistas. - Se desarrolló una aproximación metodológica para el desarrollo de dispositivos wearable. - Se desarrolló un prototipo de un dispositivo wearable. - Se creó un Data set de pasos de baile de salsa. - Se desarrolló un algoritmo para la comparación de movimientos periódicos. - Se establecieron niveles de comparación de movimientos periódicos a partir del algoritmo de comparación de movimientos.

Logros del Trabajo o Aportes:


- Se publicaron 6 artículos científicos, ubicados en índices nacionales e internacionales.
- Se creó una herramienta para el análisis de corpus con lenguaje R para análisis bibliométrico.
- Se definió una arquitectura para la integración de dispositivos wearable con una plataforma para hacer realimentación en el aprendizaje de habilidades motrices periódicas en un contexto virtual.
- Se creó un marco metodológico para el desarrollo de dispositivos wearable en un contexto académico.
- Se desarrolló un prototipo.
- Se creó un Data set de pasos de baile de salsa.
- Se implementó un algoritmo para la comparación de movimientos periódicos.

Se considera el Trabajo de Grado de alto valor académico para que se le

confiera: MENCION HONORÍFICA SI (X) NO ()

CALIFICACIÓN DE LAUREADO SI () NO ()



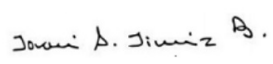

 Universidad del Cauca*	Gestión Administrativa y Financiera Gestión de Admisiones, Registro y Control Académico Acta para Sustentación Pública de Trabajo de Grado	
	Código: PA-GA-4.2-FOR-13	Versión: 2 Fecha de Actualización: 22-01-2019


Otorgadas respectivamente por los Consejos de Facultad y Académico.

Sustentar brevemente: (Si es del caso ampliar el concepto por escrito, con Vº Bº del Depto. Anexo que debe hacer llegar al Consejo de Facultad):

CALIFICACIÓN FINAL		OBSERVACIONES ADICIONALES
APROBADO	X	
APROBADO CON CONDICIONES		
APLAZADO		
NO APROBADO		

JURADOS

NOMBRE: Jovani Alberto Jimenez	NOMBRE: Jorge Gomez Gomez
 FIRMA:	 FIRMA:
C.C. N°: 15510904	C.C. N°: 78749375

NOMBRE: Mario Fernando Solarte	NOMBRE:
FIRMA: 	FIRMA:
C.C. N°: 76319313	C.C. N°:



Agradecimientos

A Dios por todos los favores recibidos.

A Gustavo Ramírez por su mentoría y amistad.

A Jhoana Sandoval y Arturito, nuestro hijo por nacer, por todo el amor, apoyo y compañía.

A mis padres Hebert y Ena por todos los consejos dados.

A mis hermanos Adrián y Fabio, tías, tíos, primas y primos por creer en mí.

A todos los profesores que me acompañaron, en especial a Mario Muñoz Organero, Yilton Riascos y Mario Fernando Solarte por todo lo que aportaron en mi formación.

A mis compañeros de doctorado, sobre todos a los «Gustavo's PhD students» por todos sus aportes.

A «Ángela Chantre, Raquel, Teresa, Paula, Elizabeth y Alice» y a «Tatiana, Patricia, Antonio, Jorge, Alexis, Marcus, Cristian, Sebastian, Emanuel y Nacho de Osos» por hacer muy ameno mi paso por España.

A mis viejos amigos y a mis amigos de UWR en los Clubes Octopus de Popayán y Osos de Madrid por hacer agradable el camino.

Y a todas las personas que me acompañaron y que no he mencionado.

Resumen Estructurado

Este documento inicialmente aborda la necesidad que existe en encontrar como realizar realimentación en la enseñanza y aprendizaje de habilidades motrices en un contexto virtual. Se observa que comúnmente las personas usan el vídeo para aprender alguna habilidad motriz bajo el principio de aprendizaje por imitación, pero no se establece una forma de realizar realimentación sin acudir a dispositivos de alto costo o el uso de laboratorios. Para ello se procede a realizar una búsqueda de antecedentes que demuestra la relevancia de esta investigación y con aplicaciones en contextos reales. A partir del planteamiento de una arquitectura se propone un sistema que se fundamenta en el principio del aprendizaje por imitación. El sistema establece recopilar datos asociados a los movimientos periódicos realizados por una persona y a partir de ellos se realiza un análisis que permita indicar si los movimientos son similares. Se opta por usar medidas de aceleración para la captura de datos de los movimientos a través de dispositivos wearables. Para el análisis se parte de realizar una comparación de datos entre los movimientos realizados por una persona experta y una persona no experta. Se establece el estudio de señales bajo el concepto de series temporales, para lo cual, las medidas de aceleración se toman como univariantes a partir del cálculo de los datos de la magnitud de los datos de la señal. Se plantea un algoritmo que usa el principio de correlación de Pearson para encontrar la ciclicidad de las señales, técnicas de filtrado y normalización para ajustar las señales y en miras de compararlas, se emplea el algoritmo Dynamic Time Warping y regresión lineal. Con el algoritmo se encuentran cuatro niveles de comparación que establecen la similitud o diferencia de los movimientos.

Índice general

1. Introducción	13
1.1. Planteamiento del problema	13
1.2. Antecedentes	15
1.2.1. Análisis de investigaciones del año 2017 al 2021	15
1.2.2. Investigaciones que emplean vídeo o kinect	20
1.2.3. Investigaciones que involucran el uso de dispositivos para el análisis de movimientos	22
1.2.4. Investigaciones que se centran en realimentación de movimientos realizados	25
1.3. Objetivos	28
1.3.1. Objetivo General	28
1.3.2. Objetivos Específicos	28
1.4. Resultados obtenidos	28
1.5. Contribuciones	29
2. Marco Teórico	31
2.1. Arquitectura con base en el Modelo 4+1 Vistas	31
2.2. Planteamiento inicial de la Solución	38
2.3. Dispositivos wearable	38
2.3.1. Prototipo wearable	38
2.3.2. Aplicación	47
2.4. Series de tiempo	50
2.5. Correlación Lineal	51
2.6. DTW Dynamic Time Warping	54
2.7. Regresión Lineal	55
3. Algoritmo para la comparación de movimientos	61
3.1. Parámetros Generales	61
3.2. Planteamiento inicial del algoritmo	63
3.3. Importación de datos	65
3.4. Iteraciones de Pearson	66
3.5. Ajuste de datos	68
3.6. Filtrado de datos	72
3.7. Normalización	76

3.8. Análisis por DTW	76
3.9. Análisis comparativo a partir de DTW y regresión lineal	79
3.10. Algoritmo desarrollado	80
4. Validación del algoritmo y casos de estudio	85
4.1. Planteamiento del Experimento	85
4.2. Creación del set de datos	86
4.3. Resultados del algoritmo	89
4.3.1. Las muestras son semejantes	89
4.3.2. Las muestras son diferentes $R - Squared < 0,9$; Regresión < 10	91
5. Disposiciones Finales	99
5.1. Discusión y análisis	99
5.2. Conclusiones	101
5.2.1. Conclusiones capitulo 1	101
5.2.2. Conclusiones capitulo 2	101
5.2.3. Conclusiones capitulo 3	101
5.2.4. Conclusiones capitulo 4	102
5.3. Trabajos futuros	102
A. Código en lenguaje R para análisis de corpus	3
A.1. Código en lenguaje R aplicativo para análisis de corpus	3
B. Arquitectura Propuesta	9
B.1. Propuesta Arquitectónica con base al modelo 4+1 vistas	10
B.1.1. Vista lógica	10
B.1.2. Vista de Desarrollo	13
B.1.3. Vista de Procesos	13
B.1.4. Vista Física	14
B.1.5. Vista de escenarios	14
C. Código en lenguaje R del algoritmo para comparación de movimientos	17
C.1. Código fuente main	17
C.2. Código fuente functions	21
D. Publicaciones	27

Índice de tablas

2.1. Requisitos prototipado dispositivo wearable	57
2.2. Dispositivos wearable encontrados	58
2.3. Elementos seleccionados para dispositivo wearable	58
2.4. Caracterísitcas Dispositivo YJ-16009-NRF-51822	59
3.1. Matriz de costos	77
4.1. user characteristics	87
4.2. User video salsa steps	87

Índice de figuras

1.1.	Izquierda: Nube de palabras correspondiente a la cadena de búsqueda <i>Wearable AND Movement AND Analysis</i> . Centro: Nube de palabras correspondiente a la cadena de búsqueda <i>dynamic time warping AND movement</i> . Derecha: Nube de palabras correspondiente a la cadena de búsqueda <i>kinect AND Movement</i>	17
1.2.	Izquierda: Dendograma correspondiente a la cadena de búsqueda <i>Wearable AND Movement AND Analysis</i> . Centro: Dendograma correspondiente a la cadena de búsqueda <i>dynamic time warping AND movement</i> . Derecha: Dendograma correspondiente a la cadena de búsqueda <i>kinect AND Movement</i>	18
2.1.	Componentes del sistema	32
2.2.	Modelo del Negocio	33
2.3.	Arquitectura de Alto Nivel	34
2.4.	Casos de Uso del Sistema	35
2.5.	Diagrama de secuencia	36
2.6.	Diagrama de clases	37
2.7.	Diagrama de componentes	37
2.8.	Diagrama de actividades	39
2.9.	Diagrama de despliegue	39
2.10.	Modelo Desarrollo Prototipo Wearable	40
2.11.	Dispositivo YJ-16009-NRF-51822	42
2.12.	Diagrama de componentes NRF51822	43
2.13.	Algoritmo clase BLEService	48
2.14.	Accelerometer meter interfaz graph	49
2.15.	Ejemplo de archivo entregado por aplicación Accelerometer meter	50
2.16.	Componentes de una Serie de Tiempo	51
2.17.	DTW	55
3.1.	Idea general del algoritmo para la comparación de movimientos.	63
3.2.	Diagrama General del Algoritmo	64

3.3. Ejemplo Serie de Tiempo	66
3.4. Ejemplo Serie de Tiempo Ampliado	67
3.5. Ejemplo serie de tiempo	69
3.6. Ejemplo Resultados Iteracion de Pearson	69
3.7. Ejemplo Resultados Iteracion de Pearson contra datos	70
3.8. Ejemplo de serie de tiempo, en negro v y en rojo u	73
3.9. Iteraciones de Pearson para los vectores v' y u'	73
3.10. Vectores v y u_{adj}	74
3.11. Filtro del vector v	75
3.12. Ejemplo DTW	78
3.13. Ejemplo DTW - Señales	78
3.14. Ejemplo DTW - Señales ideales	79
3.15. Ejemplo DTW y regresión lineal	80
4.1. Ubicación de dispositivo wearable	88
4.2.	88
4.3. Ejemplo DTW - Señales ideales	89
4.4. Ejemplo data set	90
4.5. Señales cuando las muestras son similares	91
4.6. Resultados cuando las muestras son similares	92
4.7. Señales cuando las muestras son diferentes cuando $R - Squared < 0,9$; Regresión < 10	93
4.8. Resultados cuando las muestras son diferentes cuando $R - Squared < 0,9$; Regresión < 10	93
4.9. Resultados cuando las muestras son diferentes cuando $R - Squared > 0,9$; Regresión > 10	95
4.10. Resultados cuando las muestras son diferentes cuando $R - Squared > 0,9$; Regresión > 10	95
4.11. Señales cuando las muestras tienen diferente periodo	96
4.12. Resultados cuando las muestras tienen diferente periodo	97
B.1. Arquitectura de Alto Nivel	10
B.2. Diagrama de clases	11
B.3. Diagrama de secuencia	12
B.4. Diagrama de Paquetes	13
B.5. Diagrama de componentes	14
B.6. Diagrama de actividades	15
B.7. Diagrama de despliegue	15
B.8. Casos de Uso del Sistema	16

Capítulo 1

Introducción

Resumen del capítulo

El capítulo 1, se orienta al desarrollo del planteamiento del problema, donde se muestra la necesidad de encontrar una forma de re-alimentación en un contexto de educación virtual para el aprendizaje de habilidades motrices, en este caso, movimientos de tipo periódico. Luego se muestran los principales antecedentes encontrados y que evidencian la relevancia de esta investigación. Se abordan los objetivos, los resultados asociados por cada objetivo y se listan las contribuciones realizadas en esta tesis doctoral.

1.1. Planteamiento del problema

Actualmente, el estudio de movimientos y el aprendizaje de habilidades motrices es muy llamativo. En este ámbito, se pueden encontrar numerosos estudios y productos comerciales que muestran la existencia de dispositivos para el acompañamiento o seguimientos en las actividades físicas. Estos brindan información relevante y de importancia para diferentes usuarios que tienen como objetivo aprender, hacer seguimiento o tener registro de las actividades motrices que realizan.

Por su parte, en un contexto del aprendizaje, tiene relevancia el “Aprendizaje por imitación”¹ el cual tiene su base en imitar las acciones que realiza una persona. Para el caso del aprendizaje por medios electrónicos, generalmente éste se presenta a través de un vídeo donde se realizan ciertas acciones con el cuerpo humano, y que una persona intenta “imitar” (cursos deportivos, habilidades motoras, de danza, etc). Si se da una mirada a un contexto de la enseñanza y aprendizaje de habilidades motrices de manera presencial, se observa que el aprendiz ve los movimientos que realiza una persona experta, luego intenta realizar éstos bajo la mirada de un “instructor”, quien determina las habilidades que se están realizando de forma correcta o errónea para luego entregar recomendaciones de cómo hacer de forma adecuada del movimiento.

¹Aprendizaje por imitación: Este proceso se refiere a una técnica de enseñanza que consiste en repetir la conducta de un modelo [1]

En este sentido, dando a un vistazo a la Biomecánica ², se encuentra que una de sus tantas clasificaciones está enmarcada en la periodicidad de los movimientos, donde existen actividades que se pueden catalogar como *movimientos periódicos*, los cuales se caracterizan por ser aquellas habilidades motrices en las que se repite varias veces un mismo movimiento, por ejemplo caminar, correr, nadar, montar bicicleta, etc. Esta característica, los vuelve de especial interés y muy atractivos en el ámbito investigativo, puesto que supone pensar en la posibilidad de lograr la captura de un patrón que surge con base en datos monitoreados del cuerpo humano.

En el contexto del IoT y en un plano educativo o de entrenamiento deportivo, se encuentra el uso de vídeo y de dispositivos wearable³. Generalmente se emplea el vídeo como herramienta para entregar instrucciones y los dispositivos wearables para determinar si el usuario realiza algún tipo de actividad o enviar alarmas a los usuarios para recordarles que deben retomar actividad física. [5]

En este caso, el sistema involucrado solo brinda comunicación unidireccional a través de vídeo y la realimentación se realiza a través de dispositivos que indican la ejecución de la actividad física o usan un sistema de alarma para recordar que no se ha realizado la actividad física *pero no analizan los movimientos realizados ni determinan recomendaciones o correcciones para hacer los movimientos de forma adecuada*.

Esto conlleva a pensar que se puede explorar alternativas que impliquen realizar una comunicación bidireccional entre la persona que está interesada en aprender habilidades motrices a través de un entorno en línea. En este aspecto se llega a la siguiente pregunta: ¿Cómo se puede realizar una tarea de comunicación garantizando bidireccionalidad en procesos virtuales en línea que impliquen la enseñanza o aprendizaje de habilidades motrices?

Los dispositivos wearables permiten pensar en que a través de ellos se puede realizar apoyo en los procesos de enseñanza y/o aprendizaje de habilidades motrices. Ellos pueden soportar y pueden enviar información concerniente a los movimientos de la persona que los use. Así pues, se cree que es posible seguir el modelo presencial de aprendizaje por imitación mencionado anteriormente, donde se realicen movimientos por un experto, un estudiante intente imitarlos *y un sistema determine si los movimientos son correctos o incorrectos entregando recomendaciones con base a la COMPARACIÓN de los movimientos de una persona experta respecto a una que esté aprendiendo*. En este caso surgen varios cuestionamientos: ¿Existen los dispositivos para tal fin? ¿Cómo enviar información relevante haciendo uso de wearables para soportar procesos que impliquen movimiento? ¿Cómo esta información puede ser empleada? ¿Qué tipo de análisis se requiere

²Biomecánica: Es la disciplina que estudia los movimientos del cuerpo humano, es decir, los aspectos fisiológicos y mecánicos implicados en el movimiento [2]

³Dispositivos “wearable”: que hacen parte de la IoT, y los cuales, entre varias de sus características, destacan principalmente que estos se pueden encontrar siempre con el usuario y éste puede en todo momento enviar o ejecutar comandos, aun cuando se encuentre en movimiento o realizando sus actividades cotidianas [3]. Según Vandrico Inc [4], el dispositivo wearable ideal debe contar con las siguientes características: vertible, debe ser usado en el cuerpo; controlable, el dispositivo debe ser controlable por el usuario de forma activa o pasiva; brindar mejoras, el dispositivo debe aumentar el conocimiento, facilitar el aprendizaje o mejorar la experiencia; movilidad, el dispositivo debe dar a los usuarios la libertad de actuar naturalmente y no limitarse a un área fija.

a partir de la información capturada?

En forma general, hay un problema en la bidireccionalidad en un entorno de aprendizaje en línea para habilidades motrices, por lo que se piensa que es posible el uso de dispositivos wearables a través de un contexto de IoT para capturar datos a partir de movimientos periódicos en el cuerpo humano. Esto pensando en un modelo de aprendizaje por imitación de habilidades motrices donde una persona experta realice un movimiento y el cual se intente replicar por otra. A partir de esto, surge la siguiente pregunta como punto de partida para una investigación que involucra varios de los cuestionamientos previos. **¿Cómo realizar análisis comparativo de habilidades motrices periódicas que garanticen realimentación de la actividad?** Con base en este cuestionamiento se plantea la siguiente hipótesis: *“Es posible la integración de IoT desde la perspectiva de dispositivos wearables para la captura de datos asociados a habilidades motrices periódicas y posterior análisis comparativo a partir de un algoritmo para garantizar realimentación”*.

Se propone entonces el desarrollo de un sistema a partir del aprendizaje por imitación que involucre el uso de dispositivos wearable para obtener los datos asociados a movimientos periódicos humanos para su posterior análisis. En general se pretende obtener los datos con una persona experta que alimente un banco de datos (dataset), luego, con éste banco se pueda “comparar” datos con los recolectados de una persona que desee aprender a realizar este movimiento y finalmente con el sistema brindar algún tipo de calificación o recomendación.

1.2. Antecedentes

En miras de contextualizar en el ámbito científico los tópicos relacionados con esta tesis, en este apartado se realizó una recopilación de investigaciones que involucran el uso de dispositivos wearable, detección de movimiento y algoritmos empleados. Para esta aproximación, se encuentra que los artículos se pueden agrupar en tres grupos temáticos. En primer lugar, se encuentran los artículos que emplean sensores en el cuerpo. En segundo lugar encontramos los artículos que emplean vídeo o kinect para el análisis de los movimientos y finalmente los que emplean algoritmos para realizar realimentación en las habilidades motrices, en este caso, se realizó a partir del algoritmo Dynamic Time Warping.

1.2.1. Análisis de investigaciones del año 2017 al 2021

Realizando una contextualización acorde a las investigaciones que se han desarrollado en los últimos 5 años, a partir de un análisis de corpus de textos se buscaron las palabras más relevantes para tres conjuntos de datos. Estos se obtienen a través de una revisión con la base de datos bibliográfica *Web of Science (WoS)*, ubicando las búsquedas en las temáticas descritas bajo las cadenas de búsqueda $TS=(Wearable\ AND\ Movement\ AND\ Analysis)$; $TS=(kinect\ AND\ Movement)$ y $TS=(“dynamic\ time\ warping”\ AND\ movement)$. Para la búsqueda referente a wearable,

se encontraron 694 documentos relacionados con la temática, en el caso de Kinect, se encontraron 464 documentos relacionados y para el caso de DTW, se tienen un total de 112 documentos.

Los siguientes son los primeros 100 documentos que se hayan a partir de la cadena de búsqueda *Wearable AND Movement AND Analysis*: [6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, 76, 77, 78, 79, 80, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 92, 93, 94, 95, 96, 97, 98, 99, 100, 101, 102, 103, 104, 105].

A continuación se muestran los primeros 100 documentos encontrado bajo la cadena de búsqueda *kinect AND Movement*: [106, 107, 108, 109, 110, 111, 112, 113, 114, 115, 116, 117, 118, 119, 120, 121, 122, 123, 124, 125, 126, 127, 128, 129, 130, 131, 132, 133, 134, 135, 136, 137, 138, 139, 140, 141, 142, 143, 144, 145, 146, 147, 148, 149, 150, 151, 152, 153, 154, 155, 156, 157, 158, 159, 160, 161, 162, 163, 164, 165, 166, 167, 168, 169, 170, 171, 172, 173].

Estos, corresponde a los documentos encontrados bajo la cadena de búsqueda "dynamic time warping" AND *movement*: [174, 175, 176, 177, 178, 179, 180, 181, 182, 183, 184, 185, 186, 187, 188, 189, 190, 191, 192, 193, 194, 195, 196, 197, 198, 199, 200, 201, 202, 203, 204, 205, 206, 207, 208, 209, 210, 211, 212, 213, 214, 215, 216, 217, 218, 219, 220, 221, 222, 223, 224, 225, 226, 227, 228, 229, 230, 231, 232, 233, 234, 235, 236, 237, 238, 239, 240, 241, 242, 243, 244, 245, 246, 247, 248, 249, 250, 251, 252, 253, 254, 255, 256, 257, 258, 259, 260, 261, 262, 263, 264, 265, 266, 267, 268, 269, 270, 271, 272, 273, 274, 275, 276, 277, 278, 279, 280, 281, 282, 283, 284, 285]

Para encontrar y contextualizar tópicos de investigación del año 2017 al 2021 bajo las cadenas de búsqueda mencionadas, se hizo un análisis de corpus haciendo uso del lenguaje R. Esta idea surge a partir de un conjunto de colaboraciones realizadas en análisis de datos en el contexto del turismo [286] [3] [287] y la construcción propia de los antecedentes en esta investigación dada en la publicación [288]. Para ello, se uso el campo *Abstract* desde los registros obtenidos en WoS. Con los abstracts, se crean un banco de datos de corpus haciendo uso de las palabras que los componen. En este caso se descartan pronombres, palabras de uso cotidiano, las palabras propias usadas en la búsqueda y algunas palabras que se enmarcan en los corpus, pero que no son representativas ni relevantes para el tema (por ejemplo verbos o números escritos en letras). Con esto se puede encontrar un listado de palabras con su frecuencia de repetición y dendogramas en el que se asocian palabras según la proximidad entre ellas. Con estas agrupaciones se puede deducir que temáticas son relevantes en las investigaciones para el periodo comprendido entre el año 2017 al 2021.

El algoritmo utilizado a partir de una matriz de términos por documento [289], encuentra el peso de cada palabra según la cantidad de documentos en que se encuentra, su frecuencia de uso y el peso de estas respecto a otras palabras a partir de la formación de una matriz de distancias, que encuentra la distancia entre cada palabra del corpus (el código fuente en lenguaje R se encuentra en el Apéndice A).

Para la frecuencia de utilización de las palabras, el algoritmo entrega como resultado para su




Figura 1.1: Izquierda: Nube de palabras correspondiente a la cadena de búsqueda *Wearable AND Movement AND Analysis*.

Centro: Nube de palabras correspondiente a la cadena de búsqueda *dynamic time warping AND movement*.

Derecha: Nube de palabras correspondiente a la cadena de búsqueda *kinect AND Movement*

representación, un gráfico de nube de palabras, que muestra para las cien palabras más relevantes encontradas en los diferentes corpus. En las imágenes, su tamaño, color y centralidad obedecen a la frecuencia de utilización de cada palabra, donde para las palabras que se repiten con mayor frecuencia se miran en la parte central del gráfico y con un tamaño más grande, mientras que las palabras menos usadas tienden a ubicarse en los límites del gráfico y de un tamaño menor.

Por otro lado, haciendo uso de un algoritmo de agrupamiento a partir de una matriz de distancias para los diferentes abstracts encontrados, El algoritmo determina las palabras que componen la matriz se puede representar con el uso de dendogramas, que según la proximidad de las distancias se encuentran asociaciones que representan las temáticas tratadas en las investigaciones encontradas con las cadenas de búsquedas.

En las figura 1.1, se muestra las nubes de palabras encontradas para las cadenas de búsqueda correspondiente. Así mismo, en la figura 1.2, se ilustran los dendogramas correspondientes a las cadenas de búsqueda.

Cadena de búsqueda: Wearable AND Movement

Para esta cadena de búsqueda, se se descartan las palabras: also, may, however, use, two, can, wearable, coi, analysis, using, movement y movements.

En la figura 1.1, en la izquierda se encuentra que las palabras mas frecuentes que se encuentran en los abstract son data, sensors, system, gait, results, study, patients, human, motion y device.

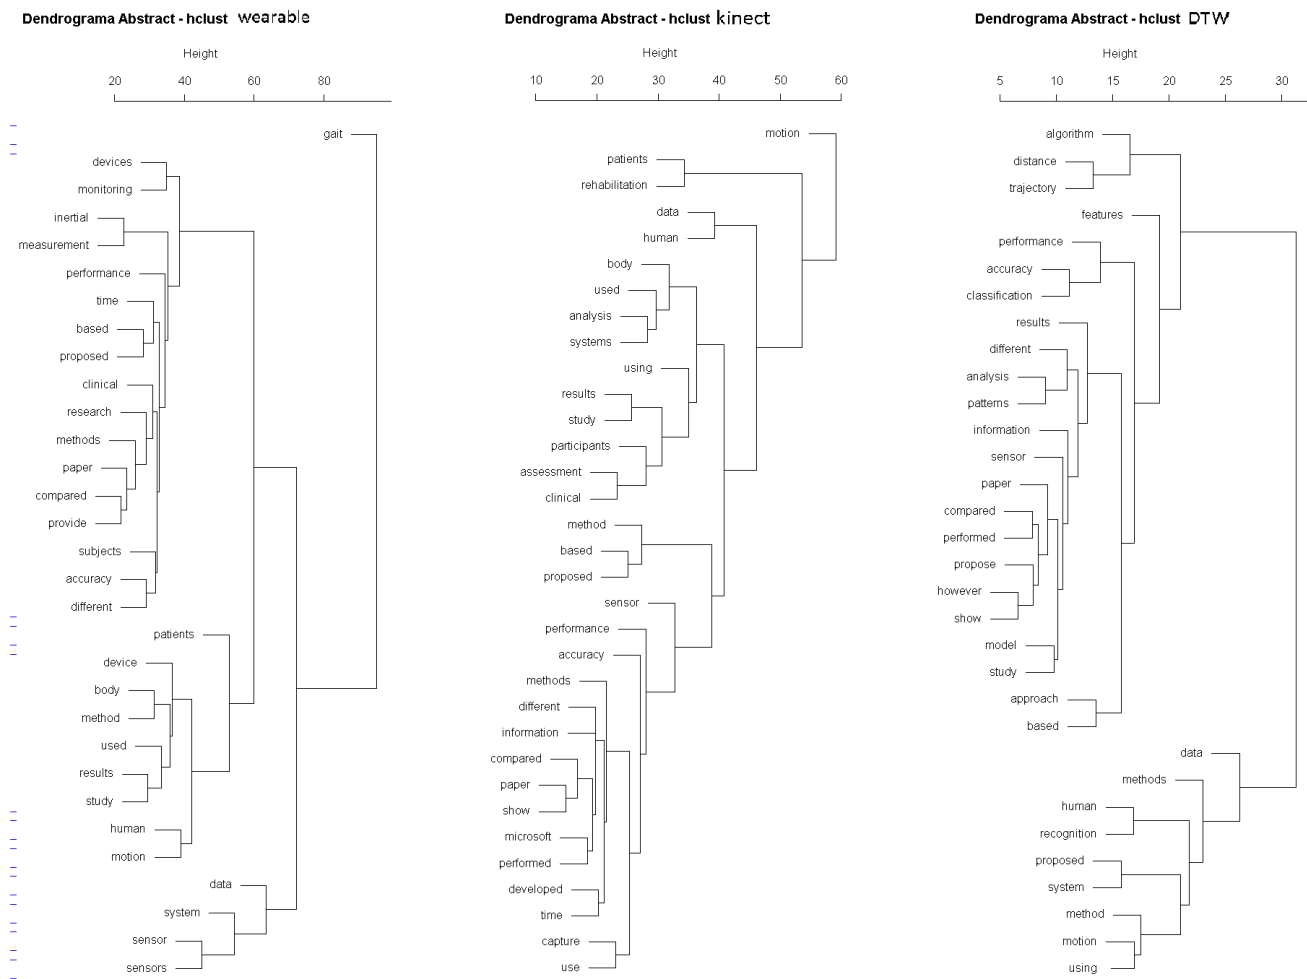


Figura 1.2: Izquierda: Dendrograma correspondiente a la cadena de bus queda *Wearable AND Movement AND Analysis*.

Centro: Dendrograma correspondiente a la cadena de busqueda *dynamic time warping AND movement*.

Derecha: Dendrograma correspondiente a la cadena de búsqueda *kinect AND Movement*

En este sentido se muestra que los trabajos analizados para este periodo se basan en estudios que implican el manejo de datos, sistemas que incluyen el uso de sensores y dispositivos, el análisis de marcha, análisis de desempeño y los resultados correspondientes para estas áreas.

Por su lado, los dendogramas ubicados en la figura 1.2, ubicado en la parte izquierda, muestran grupos de palabras asociadas, en este caso se observan tres grandes grupos, todos asociados a la palabra marcha. El primero, que asocia mayor numero de palabras relaciona dispositivos para el monitoreo con medidas inerciales, desempeño a partir de factores tiempo, desempeño en investigaciones clínicas y desempeño en la precisión. La segunda asociación de palabras que se encuentra en el dendograma, muestra relaciones de pacientes con métodos para el uso de dispositivos en el cuerpo, resultados de estudios y movimientos humanos. Finalmente, se tiene que el ultimo grupo de palabras asocia la palabra datos con sistemas de sensores.

Cadena de búsqueda: kinect AND Movement

En este caso, se excluyen las palabras: kinect, system, two, one, however, can, also, movement y movements.

En la figura 1.1, en su parte central, se observan la frecuencia de las palabras para la búsqueda de "kinect AND Movement". Acorde a la gráfica generada, se mira que las palabras con mayor frecuencia son movimiento, usos, datos, resultados, propuestas, pacientes, métodos, rehabilitación, sensores, análisis, reconocimiento, entrenamiento, modelos, cuerpo, desempeño. Esto conlleva a pensar que en el caso de estas temáticas, los estudios se inclinan principalmente al estudio de movimiento a partir de datos obtenidos con sensores en mayor medida en rehabilitación de pacientes o estudios de análisis de movimientos para entrenamiento deportivo.

En la figura 1.2, en su parte central, se encuentra dos grandes grupos de palabras relacionadas. En el primer caso, se encuentra en los niveles mas altos, las palabras algoritmo, distancia y trayectoria, asociada a la palabra características. Observando que es de interés para esta búsqueda los temas que tratan acerca de las características con el desempeño y precisión en la clasificación. Se observa también las características en los resultados a partir de diferentes análisis en patrones y características en la información de sensores para la comparación en el estudio de modelos. Por otra parte, se encuentra en el segundo grupo que las temáticas están asociadas al estudio de datos y métodos para el reconocimiento en movimientos de humanos, propuestas de sistemas y métodos para movimientos.

Cadena de búsqueda: Dynamic Time Warping AND movement

Para este caso, se excluyen las palabras: dynamic, time, warping, movement, can, use, used, movements, dtw, two, first y also.

En la figura 1.1, en su apartado derecho se muestra el resultado para la cadena de búsqueda "Dynamic Time Warping AND movement", se observa en la figura que las palabras con mayor

frecuencia para ésta búsqueda son usos, métodos, datos, propuesta, base, sistemas y resultados. En menor medida, reconocimiento, humano, movimientos, algoritmos, desempeño, trayectorias, aproximación, diferencias, precisión, características y clasificación. En este sentido se observa que las palabras se centran en el uso de datos a partir de movimientos humanos y el desempeño de los algoritmos para diferentes propósitos como reconocimiento de diferentes trayectorias y aproximaciones en las analíticas.

En la figura 1.2, en su parte derecha, se encuentran tres agrupaciones visibles, todos en relación con la palabra movimientos. El primero hace referencia a trabajos relacionados con la rehabilitación de pacientes a partir de el uso de datos capturados de humanos. El segundo grupo, se relaciona principalmente con el uso de datos a partir del cuerpo humano con sistemas de análisis, evaluación y resultados de estos en estudios clínicos y la propuesta de diferentes métodos para este propósito. el tercer grupo, muestra que el usos de sensores mirando su desempeño y su precisión para el desarrollo de diferentes métodos en la captura de información para realizar y mostrar comparaciones.

En las tres búsquedas, se observa que la captura y estudio de los datos en movimientos humanos es pieza fundamental en la literatura para los últimos cinco años. En este aspecto, el manejo de los datos se puede dar a partir de sistemas de sensores, sistemas para el reconocimiento de movimientos, sistemas para clasificación de movimientos y sistemas para el análisis de estos datos. Lo anterior conlleva a pensar que la temática de esta investigación se encuentra enmarcada en tópicos relevantes que se están desarrollando en el periodo comprendido entre 2017 y 2021, dando pie a que los resultados obtenidos son actuales, interesantes y relevantes.

A continuación, a partir de un mapeo sistemático realizado en WOS y Scopus, se muestra en resumen las investigaciones con relevancia para los propósitos de ésta investigación que se encontraron en el campo.

1.2.2. Investigaciones que emplean vídeo o kinect

Compressive sensing based recognition of human upper limb motions with kinect skeletal data [290] En este artículo, se propone un método de reconocimiento de movimiento de las extremidades superiores basado en la detección de datos esqueléticos de kinect. Para este estudio se seleccionaron participantes y se les solicitó que realizaran tres acciones de las extremidades de las extremidades superiores, que se capturaron mediante un sensor kinect. Los datos esqueléticos del sensor kinect elegido para la tarea de reconocimiento se convierten inicialmente en una imagen RGB (Red, Green, Blue) comprimidas. Las imágenes alimentan a una red neuronal convolucional de retroalimentación para aprender y reconocer acciones directamente en el dominio comprimido evitando la necesidad de utilizar algoritmos de descompresión.

Novel data fusion strategy for human gait analysis using multiple kinect sensors [291] El análisis de la marcha humana utilizando el sensor Kinect de microsoft es un área de investigación intrigante. La fusión de los datos de varios sensores para el análisis clínico de la marcha mediante

instrumentos calibrados ayuda a producir resultados más precisos. En este artículo se propone e implementa una técnica novedosa para la calibración espacial. Este artículo hace hincapié en una técnica novedosa de utilizar cinco sensores Kinect V2 (cuatro clientes y un servidor) y métodos de fusión de datos para crear esqueletos unificados para el análisis de la marcha por sujeto. Estos erradican los problemas de posos del esqueleto inexactas causados por oclusiones o fallas de seguimiento de un solo kinect que, de lo contrario, sigue siendo un problema en la mayoría de los sistemas de detección basados en visión. Se comparan dos métodos para estimar de sistemas lineales de tiempo discreto. El primero es el filtrado clásico de Kalman, que proporciona resultados precisos cuando se supone que las perturbaciones de estado son ruidos blancos gaussianos y ruidos de medición y se pueden obtener las propiedades estadísticas. En segundo lugar, se utiliza un filtro Set - Membership que también se basa en el principio de predicción y corrección. Se propone un nuevo enfoque de filtrado de pertenencia al conjunto en el que el ruido de medición se modela mediante la función de densidad de probabilidad gaussiana multivariante limitada por 1 a +1. Con base en nuestras observaciones de los marcos lineales unidas con la investigación de intervalos, las dos fases del estimador se realizan de manera productiva. Ambas técnicas de fusión se prueban en datos sobre el suelo y en cinta rodante y los resultados se validan y comparan con la verdad del suelo obtenida mediante los sistemas de captura de movimiento de Qualisys. El enfoque propuesto también se compara cuantitativamente con los métodos más avanzados.

A Design and Implementation of Fitness Application Based on Kinect Sensor [292] Este artículo se centra en KINESS, una aplicación de windows que retroalimenta la precisión de los movimientos de fitness basados en sensores kinect. La característica de esta aplicación es utilizar la cámara de kinect y el sensor de reconocimiento de articulaciones para dar retroalimentación al usuario para que se ejercite en la posición correcta de fitness. En este momento, la distancia entre el usuario y el Kinect se mide utilizando el emisor de infrarrojos y el sensor de profundidad de infrarrojos de Kinect y se miden la articulación, que es la posición de la articulación del usuario, y los datos del esqueleto de cada articulación. Con estos datos, se calcula una cierta distancia para cada posición articular y postura del usuario, y se determina la precisión de la postura. Y está implementado para que los usuarios puedan verificar su postura a través de la cámara RGB de Kinect. Es decir, si la postura del usuario es correcta, la información del esqueleto se muestra como una línea verde, y si no es correcta, la parte inexacta se muestra como una línea roja para informar intuitivamente. A través de esta aplicación, el usuario recibe retroalimentación sobre la precisión de la posición de ejercicio, para que pueda ejercitarse en la posición correcta. Esta aplicación clasifica el área de ejercicio en tres áreas: cuello, cintura y pierna, y aumenta la tasa de reconocimiento de Kinect al excluir posiciones que Kinect no reconoce debido a las articulaciones superpuestas en la posición de cada área de ejercicio. Y al final de la aplicación, el último ejercicio se muestra como una imagen durante 5 segundos para inspirar una sensación de logro y para ejercitarse continuamente.

Markov chain modeling and simulation of breathing patterns [293] En este artículo se, analiza un movimiento periódico, como es la respiración, a partir de la captura de datos por vídeo y su procesamiento para clasificación a partir de cadenas de Markov en tiempo continuo (CTMC). El patrón de frecuencia respiratoria (FR), estimado por los signos vitales medidos de los pacientes

monitorizados en el hospital, se aproxima como un CTMC, cuyos estados y parámetros se seleccionan mediante un análisis estadístico apropiado. Luego, se proponen dos simuladores, basados en software y hardware que se prueban con algoritmos basados en vídeo para la estimación de la FR y la detección de eventos de apnea. Los resultados, muestran que los patrones de FR realistas, incluidos los trastornos respiratorios específicos, pueden describirse con precisión mediante el modelo propuesto; además, los simuladores pueden reproducir patrones de respiración prácticos para el análisis de vídeo. El modelo estadístico CTMC presentado en esta investigación, puede ser estratégico para describir patrones de respiración realistas y diseñar simuladores útiles para desarrollar y probar sistemas de monitoreo basados en procesamiento de vídeo novedosos y efectivos.

“Training classifiers with shadow features for sensor-based human activity recognition” [294], en este caso, el empleo de kinect es fundamental para la captura de datos, pero a su vez emplean un sensor en un dispositivo wearable, donde logran capturar datos para el uso de un algoritmo de clasificación a partir del aprendizaje supervisado. En este trabajo se propone un proceso de entrenamiento/prueba para construir/utilizar un modelo de clasificación basado en el reconocimiento de la actividad humana (HAR). Tradicionalmente, el HAR se ha realizado mediante un clasificador que aprende las actividades de una persona entrenando con datos esqueléticos obtenidos de un sensor Kinect. Estos datos esqueléticos son las coordenadas espaciales (x, y, z) de diferentes partes del cuerpo humano. La información numérica forma series de tiempo de las secuencias de movimiento, que pueden utilizarse para entrenar el clasificador. Los rasgos se infieren a partir de la dinámica de los movimientos corporales, modelando así el impulso subyacente de las actividades realizadas. Proporcionan dimensiones adicionales de información para caracterizar las actividades en el proceso de clasificación y, por tanto, mejoran significativamente la precisión de la clasificación.

1.2.3. Investigaciones que involucran el uso de dispositivos para el análisis de movimientos

“Decision-tree-based human activity classification algorithm using single-channel foot-mounted gyroscope” [295], Este documento presenta un método basado en un árbol de decisiones a partir de características temporales para diferenciar entre las zancadas individuales de caminar, correr, subir y bajar escaleras utilizando un solo canal de un giroscopio montado en el pie. El método es adecuado para su implementación en hardware con recursos limitados. Los resultados demuestran que un sistema de clasificación ligero pero robusto es factible para su implementación en hardware integrado para la monitorización diaria en tiempo real.

“Open dataset for the automatic recognition of sedentary behaviors” [296], En el artículo, se muestra como se construye y evalúa un dataset para el reconocimiento automático (clasificación) de los comportamientos sedentarios. Lo hace a través de dispositivos wearables y smartphones y finalmente compara técnicas de clasificación de minería de datos bien conocidas con el fin de identificar el método más preciso para la clasificación de comportamientos definidos.

“Physical human activity recognition using wearable sensors” [297] En este documento se presen-

ta una revisión de las diferentes técnicas de clasificación utilizadas para reconocer las actividades humanas a partir de datos de sensores inerciales. Para ello se emplean cuatro técnicas de clasificación supervisada: “k-Nearest Neighbor (k-NN)”, “Support Vector Machines (SVM)”, “Gaussian Mixture Models (GMM)”, y “Random Forest (RF)”.

“A novel saccade signals detection algorithm for EOG-based Human Activity Recognition (HAR)” [298] Este artículo, propone un algoritmo de “detección de señales sacadicas para HAR basado en Electrocardiograma (EOG)”, que apunta a mejorar el rendimiento del sistema HAR. En el algoritmo propuesto, se utilizó el Patrón Espacial Común (CSP) para construir filtros espaciales, y luego usarlo para procesar señales EOG multicanal originales. Para validar el rendimiento del algoritmo propuesto, se eligió una Máquina de Vector de Soporte lineal (SVM).

“Activity classification using a single chest mounted tri-axial accelerometer” [299] Usa un acelerómetro triaxial para recopilar datos de actividades guiadas de la vida diaria (AVD) como sentarse, pararse, caminar y numerosas transiciones posturales realizadas bajo condiciones supervisadas donde investigan la capacidad de discriminar estas AVD.

“Human activity recognition using thigh angle derived from single thigh mounted IMU” [300], Este documento presenta un enfoque novedoso para detectar actividades humanas basadas en el ángulo del muslo calculado utilizando datos de una sola Unidad de Medición Inercial (IMU). Este algoritmo utiliza técnicas simples de procesamiento de señales que incluyen detección de picos, detección de cruce por cero y temporizadores para identificar la actividad.

“Light sport exercise detection based on smartwatch and smartphone using k-Nearest Neighbor and Dynamic Time Warping algorithm” [301]. Esta investigación propone un sistema de detección de actividad deportiva liviana que se puede realizar fácilmente por persona. El sistema utiliza acelerómetros en un smartphone y un smartwatch. Los datos de la serie de tiempo del valor del acelerómetro se procesarán mediante el método de ventana deslizante con el algoritmo k-Nearest Neighbor y Dynamic Time Warping como un algoritmo de clasificación principal.

“The use of smartphone for gait analysis” [302], Éste estudio utiliza un acelerómetro de un smartphone para cuantificar las características del movimiento humano a partir de cuatro pasos del diseño y desarrollo del sistema: operación de adquisición de datos, algoritmo de extracción de características, diseño del clasificador y estrategia de toma de decisiones. Es posible extraer características del acelerómetro de un teléfono inteligente utilizando un algoritmo de detección de picos.

“Human movement recognition based on the stochastic characterisation of acceleration data” [3]. En este artículo, se propone y evalúa un algoritmo para detectar movimientos básicos humanos a partir de datos medidos con un dispositivo wearable. El algoritmo propuesto está diseñado para minimizar los requisitos computacionales mientras se logran niveles de precisión aceptables basados en la caracterización de algunos puntos particulares en la serie temporal obtenida de un único sensor, para este caso un acelerómetro triaxial.

“*Sports wearable device design and health data monitoring based on wireless Internet of things*” [303] diseña un sistema remoto que permite monitorear nivel de glucosa, presión de la sangre, temperatura del cuerpo y nivel de saturación de oxígeno, todo lo anterior en marco de la preparación del atleta. Estos parámetros son utilizados para detectar un patrón particular y con ello evitar una potencial lesión en un programa de entrenamiento deportivo específico. Usa Red de área local (WLAN) y personal (WBAN). La tecnología se ha agregado a las soluciones de conectividad IoT normales que son Wi-Fi y Bluetooth por otra parte solo se centra en recolectar parámetros fisiológicos generales, dejando una brecha a la hora de sensar parámetros específicos.

“*Wearable heart rate monitoring intelligent sports bracelet based on Internet of things*” [304] ofrece un sistema que captura datos de monitoreo de signos vitales fácil de usar durante el entrenamiento por parte de un deportista. A través de la tecnología de IoT, el sensor inalámbrico ZigBee, Bluetooth y otras tecnologías de comunicación, se transmiten datos a una computadora personal o a un teléfono móvil para el monitoreo, almacenamiento y análisis en tiempo real. Después del procesamiento y análisis de los datos, los datos anormales recibirán una alarma en tiempo real para realizar el seguimiento del estado de salud de la frecuencia cardíaca durante el entrenamiento. Este sistema permite incorporar la funcionalidad de dar alarmas con base al análisis de los datos recolectados pero solo se centra en un parámetro fisiológico.

“*Continuous health monitoring of sports person using IoT devices based wearable technology*” [305] ofrece un sistema que permite caracterizar la salud de los deportistas permitiendo generar servicios médicos eficaces para mejorar el rendimiento del deportista. Con dispositivos de seguimiento portátiles para recopilar detalles y seguimiento de los registros de ejercicio se analiza y monitorea la optimización efectiva de la salud del deportista. Se introducen técnicas de machine learning, el uso de un clasificador profundo bayesiano (Ensemble Bayesian Deep Classifier). Se utiliza la información del conjunto de datos de mHealth para analizar el proceso de monitoreo de salud basado en los tres sensores que utiliza el atleta. Ofrece un proceso usando dispositivos wearable, IoT, machine learning para crear un sistema de monitoreo de salud deportiva pero está diseñado únicamente para el uso en el campo de la salud, lo cual implica una nula interacción por parte de un atleta que quiera mejorar su técnica.

“*Wearable human motion posture capture and medical health monitoring based on wireless sensor networks*” [306] tuvieron en cuenta cómo capturar las señales fisiológicas y la transmisión remota de información con el fin de clasificar e identificar los movimientos diarios de los objetos monitorizados para garantizar un desarrollo óptimo con base a los dispositivos wearable y redes WBAN, el sistema captura movimientos estáticos es decir posiciones dejando los movimientos instantáneos o de precisión de lado.

“*Computational efficient wearable sensor network health monitoring system for sports athletics using IoT*” [307] han hecho un gran seguimiento al monitoreo inalámbrico de los parámetros corporales enfocados a diversas aplicaciones como la realidad virtual, la rehabilitación, la ciencia médica, la ciencia del deporte y la vigilancia. Es de notar que la red de sensores (WBAN) y su funcionamiento ha llamado la atención entre la comunidad científica, tecnológica y de investigación.

El dispositivo wearable está en la capacidad de: mostrar, registrar y rastrear los datos pertinentes en la intemperie; la solución que este proyecto propuso es utilizar el modelo de red de sensores inalámbricos basados en una red WBAN con todos los nodos de sensores transmitiendo de forma inalámbrica al regulador basado en el protocolo de red Wi-Fi, por otra parte el costo es algo que preocupa por lo que no es asequible para cualquier persona.

1.2.4. Investigaciones que se centran en realimentación de movimientos realizados

Real-time biomechanical biofeedback effects on top-level rifle shooters [308] El objetivo de este proyecto se basó en examinar los efectos del entrenamiento con biofeedback biomecánico en tiempo real sobre la técnica y el rendimiento de los tiradores de rifles. Los tiradores de alto nivel fueron asignados aleatoriamente a dos grupos diferentes, el primer grupo fue asistido con biofeedback y el segundo grupo fue el grupo de control. El sistema utilizado para la captura de datos fue el software EVaRT5.0 (Motion Analysis Corporation), el cual incluye cámaras de captura de movimiento y placas de fuerza en el piso para medir fuerza y distribución de peso. Se pudo identificar que el grupo que recibió biofeedback auditivo individualizado la estabilidad en la postura del cuerpo y del cañón, mejoraron sus rendimiento, el estudio respalda que la biorretroalimentación proporciona una herramienta de entrenamiento innovadora que puede permitir a los atletas desarrollar sus habilidades para mejorar el rendimiento.

Use of audio biofeedback to reduce tibial impact accelerations during running [309] En el 2014 Wood hace uso de los sistemas de biorretroalimentación auditivas con el fin de reducir el pico positivo de aceleración (PPA) en la tibia de corredores deportivos, el propósito de este estudio fue investigar la viabilidad de utilizar la biorretroalimentación para reducir los PPA mientras se está corriendo, los resultados obtenidos afirman que los corredores que utilizaron el sistema pudieron disminuir significativamente el PPA durante la carrera. El sistema de biorretroalimentación utilizado por Wood realiza la captura de movimiento por medio de sensores inerciales, y la conexión es una red de área corporal inalámbrica, la retroalimentación es suministrada por medio auditivo, lo que permite una mayor movilidad. Wood propone el desarrollo tecnológico de sistemas de biorretroalimentación que aprovechan otras tecnologías inalámbricas (unidades de medición inercial y/o iPods).

A Wearable Biofeedback Control System Based Body Area Network for Freestyle Swimming [310] Este documento presenta un prototipo de un sistema de biorretroalimentación wearable diseñado para la natación de estilo libre con enfoque en la medición de la rotación del tronco denominado ISWIM. El sistema consiste en un sensor inercial de nueve grados de libertad, incorporado en una unidad central de recopilación y procesamiento de datos, y dos motores de vibración para proporcionar retroalimentación. Estos dispositivos forman una red de área corporal (BAN). Este sistema fue probado por cuatro nadadores recreativos en dos series de natación estilo libre, una de control y otra con retroalimentación. Los resultados demuestran que existió una mejora en el rendimiento de los nadadores reduciendo un 4.5 % en el tiempo de la sesión. El sistema propuesto

por Li en 2016, utiliza una unidad de procesamiento y almacenamiento de datos, sistemas de telecomunicación y baterías de alimentación en un módulo que va montado sobre el atleta.

Automatic Classification of Knee Rehabilitation Exercises Using a Single Inertial Sensor: a Case Study [311]. En 2018 Bevilacqua hacen uso de unidades de medición inercial para el registro de la aceleración y la velocidad angular de algunas extremidades humanas durante las actividades físicas. Comúnmente esta técnica es utilizada en los programas de rehabilitación con ejercicios después de una cirugía ortopédica. Lo que plantea este proyecto es el desarrollo de un sistema de bioretroalimentación con técnica de aprendizaje automático que permita el análisis los datos recogidos por la unidad de medición inercial y luego evaluar si cada repetición del ejercicio se ejecutó correctamente o no.

A Novel Method to Estimate the Full Knee Joint Kinematics Using Low Cost IMU Sensors for Easy to Implement Low Cost Diagnostics[312]. Este trabajo presenta un método novedoso y exhaustivo para inferir el movimiento relativo completo de la articulación de la rodilla, incluyendo la flexión/extensión, el varo/valgo y la rotación interna/externa, utilizando únicamente unidades de medición inercial (IMU) de bajo costo conectadas a la parte superior e inferior de la pierna. Además, los sensores pueden colocarse de forma arbitraria y sólo requieren una corta calibración, lo que hace que sea una herramienta de análisis clínico fácil de usar y portátil, los resultados obtenidos fueron prometedores al ser comparados con técnicas más elaboradas basadas en cámaras de última generación y es escalable a otros segmentos del cuerpo.

A Dynamic Time Warping Approach to Real-Time Activity Recognition for Food Preparation. [313] Pham y otros en el 2010, presentaron un sistema de clasificación de las actividad humana realizadas en la cocina, el sistema integran IMU en los utensilios de la cocina. La técnica de reconocimiento se basó en un clasificador basado en la deformación dinámica del tiempo (DTW) que segmenta y reconoce con éxito diez actividades de cocina de bajo nivel, Logrando excelentes resultados de clasificación incluso si sólo se dispone de un pequeño número de muestras de entrenamiento, lo que es especialmente relevante para los escenarios del mundo real.

Affordable eRehabilitation Monitoring Platform. [314] Las personas que han sufrido una discapacidad de la función motora necesitan participar en tratamientos de rehabilitación apropiados. Los sensores inerciales dan la facilidad de ser llevados puestos y proporcionar una serie de medidas cuantitativas del movimiento humano. Janidarmian, Roshan, Radecka, y Zilic presentan en este documento una plataforma de rehabilitación electrónica de bajo costo que emplea algoritmos eficientes para proporcionar una retroalimentación de alta precisión.

AR based Self-sports Learning System using Decayed Dynamic Time Warping Algorithm [315]. Este documento propone un sistema de aprendizaje deportivo que proporciona a los usuarios información multimodal en tiempo real sobre las diferencias entre los movimientos desarrollados por el usuario y el de un experto. El sistema hace uso del algoritmo Decayed Dynamic Time Warping, el cual permite la variación en la velocidad de movimiento de forma dinámica. El estudio concluye que el algoritmo posee una carga computacional baja, lo que permite su uso en dispositivos con

baja potencia de cálculo.

Quantitative Parameters Developing for Estimation of Rehabilitation Exercising on The Basis of IMU Sensor Device [316] Este documento plantea el desarrollo de un sistema de bioalimentación enfocado en proceso de rehabilitación de pacientes controlando la ejecución de un ejercicio físico. Se hace uso de los sensores MEMS de los teléfonos inteligentes, el objetivo principal es comparar el patrón de movimiento adquirido haciendo uso del algoritmo DTW como método de estimación de la medida de similitud de los dos patrones.

Segmentation of Exercise Repetitions Enabling Real-Time Patient Analysis and Feedback Using a Single Exemplar [317]. Los sistemas de rehabilitación física asistida por tecnología, proporcionan una plataforma para que el paciente realice ejercicios de rehabilitación, además de reducir la carga de tiempo del fisioterapeuta, disminuyen los costos y mejoran la salud mediante la retroalimentación. Desde el punto de vista de los algoritmos, las principales dificultades para la clasificación de los movimientos físicos, son la baja gama de movimiento, el ruido de los sensores, la inestabilidad en los movimientos y la varianza en los movimientos. Sarsfield propone en este documento un algoritmo práctico para su funcionamiento en tiempo real, que clasifica las repeticiones de ejercicios sorteando las dificultades mencionadas, incluyendo los que tienen patrones de movimiento anormales y movilidad limitada.

En los tres tópicos de investigación seleccionados como los antecedentes de el presente trabajo de investigación, en varios de los documentos encontrados se observa que los esfuerzos están encaminados a la clasificación, detección o reconocimiento de movimientos. Para ello hacen uso de análisis de vídeo, kinect o diversos sensores que pueden ser colocados en diferentes partes del cuerpo.

Los estudios para la captura de datos a través de dispositivos wearables son avanzados, y para el caso de esta investigación, conlleva a que se pueda emplear éstas técnicas, en concreto se seleccionan los dispositivos que capturen datos inerciales de aceleración.

Ya en el plano del análisis de datos y los algoritmos estudiados en los trabajos, se observan que las diferentes investigaciones apuntan a un interés en dos áreas: la detección y la clasificación de los movimientos. En el caso de esta investigación, se logra encontrar una brecha de investigación respecto a la literatura estudiada ya que se requiere hacer una comparación entre los datos generados a partir de movimientos de dos personas diferentes, es decir, *se necesita un análisis comparativo entre los datos generados por una persona experta y los datos generados por una persona que desee aprender este tipo de movimientos*, siguiendo el modelo dado por el aprendizaje por imitación descrito en el planteamiento del problema.

El interés es el análisis de los movimientos periódicos, en el caso de la literatura encontrada, los esfuerzos apuntan generalmente al análisis de marcha (gait análisis) en términos de detección y clasificación, los parámetros encontrados se emplean para observar el número de pasos, largo de la zancada, pasos respecto al tiempo y otros parámetros. Para el caso de esta investigación, se

encuentra una segunda brecha al no solo desear hacer análisis de la marcha, *sino explorar otras alternativas de habilidades motrices periódicas como deportes o baile, detectar los parámetros a analizar en estos otros casos y hacer un análisis más refinado respecto a los datos arrojados por los sensores con el propósito de poder realizar una comparación.*

Finalmente se puede concluir respecto a los artículos encontrados, que es de gran relevancia los estudios de análisis de datos generados a partir de movimientos y que estos presentan grandes avances en las áreas de reconocimiento y clasificación, en su mayoría a partir de machine learning, pero que en términos de algoritmos o sistemas que realicen *comparación* de datos, no se encuentran estudios que lo hagan, por lo tanto, una investigación en este campo puede ser de gran relevancia y trae consigo aportes muy interesantes.

1.3. Objetivos

Para el desarrollo de esta investigación, se plantean los siguientes objetivos.

1.3.1. Objetivo General

Proponer un modelo para la comparación de habilidades motrices periódicas a partir de la captura de datos con tecnologías wearable.

1.3.2. Objetivos Específicos

1. Caracterizar y evaluar alternativas de dispositivos para la captura de datos generados a partir de movimientos del cuerpo humano.
2. Construcción de un dataset a partir de patrones de movimientos periódicos generados por expertos y capturados a través del(os) dispositivo(s) seleccionados al primer objetivo.
3. Diseñar, seleccionar o modificar un algoritmo comparador de datos generados a partir de movimientos periódicos del cuerpo humano.
4. Proponer experimento que permita hacer uso del algoritmo comparador para su evaluación.

1.4. Resultados obtenidos

Resultados asociados al objetivo 1

Para conseguir el alcance del primer objetivo, se planteó una aproximación metodológica que parte desde un análisis de funcionalidad, consumo de batería y wearability para el diseño de un dispositivo wearable con fines académicos. A partir de lo desarrollado en la aproximación se hace la selección de sensores que capturen datos de aceleración y la creación de un dispositivo. También

se propone el uso de una aplicación en un smartphone que acceda al sensor de aceleración, y el uso de este dispositivo a modo de dispositivo wearable para capturar los datos necesarios.

Resultados asociados al objetivo 2

Con el dispositivo creado para la captura de datos de aceleración, se realizan diferentes pruebas. A partir de ellas y pensando en algo novedoso, se opta por seleccionar tres pasos básicos de baile de salsa que al ser repetitivos se encasillan en movimientos periódicos. Tres personas de diferentes academias de salsa realizan los pasos de baile seleccionados y con ello se logra consolidar un dataset que es empleado a lo largo de esta investigación.

Resultados asociados al objetivo 3

Conociendo las características de los datos, se plantea un algoritmo que tiene dos entradas, una que corresponde a los datos capturados de movimientos periódicos de una persona experta y otro que corresponde a los datos capturados de movimientos periódicos de una persona que desea aprender. El algoritmo presenta como salida una comparación entre los datos de entrada que muestra si los movimientos son similares.

Resultados asociados al objetivo 4

Haciendo uso el data set creado y el algoritmo planteado, se hacen pruebas con el algoritmo y se consigue determinar cuatro niveles de comparación.

1.5. Contribuciones

- Se crea un aplicativo que a partir de un análisis de corpus de los abstracts de publicaciones.
- Se desarrolla una aproximación metodológica para el desarrollo de dispositivos wearable.
- Se crea un dispositivo wearable para la captura de datos de aceleración.
- Se crea un dataset de pasos de baile de salsa.
- Se crea una arquitectura con base en el modelo 4+1 vistas.
- Se crea un algoritmo para la comparación de movimientos periódicos.
- Se establecen 4 niveles de comparación de movimientos periódicos a partir del algoritmo de comparación de movimientos.

Capítulo 2

Marco Teórico

Resumen del capítulo

En el capítulo 2, se definen los diferentes conceptos abordados en el desarrollo del proyecto. Se muestra como fue desarrollada la arquitectura a partir de un modelo de 4+1 vistas que resume el funcionamiento y despliegue del sistema. Como componentes de alto nivel se obtiene que el proyecto se puede dividir en tres partes generales: el componente wearable, el componente de integración y el componente de plataforma. Partiendo de los tres componentes generales, primero se muestra como se realiza la captura de datos a partir de dos alternativas, una forma a partir de un prototipo wearable o una aplicación en un dispositivo móvil que cuente con un acelerómetro. Se entregan como insumo datos que se pueden tomar en forma de series de tiempo. Los datos se recopilan en el componente de integración, que en este caso corresponde a un dispositivo móvil. Finalmente, pensando en el componente de plataforma, se abordan los conceptos encaminados al tratamiento de datos a partir análisis de series de tiempo y el uso del algoritmo Dynamic Time Warping.

2.1. Arquitectura con base en el Modelo 4+1 Vistas

Para desarrollar esta investigación, como punto de partida, se proponen tres componentes que muestran el funcionamiento del sistema en una vista de alto nivel, [318]. Ellos son: el componente de integración, el componente wearable y el componente de plataforma como se observa en la figura 2.1. De estos componentes, se consolidó una arquitectura de software desarrollada mediante el modelo 4 + 1 vistas [319].

Componente de integración:

El componente de integración está destinado a ser una interfaz del lado del usuario, que recibe los datos enviados por el dispositivo portátil, realiza algún tipo de procesamiento y finalmente envía estos datos a una plataforma, que se espera que a futuro se implemente en un sistema de E-learning. El componente de integración está destinado a ser utilizado a través de un dispositivo móvil (tableta o teléfono inteligente) que está conectado a través de Bluetooth al dispositivo wearable.




Figura 2.1: Componentes del sistema

Este componente recibe los datos generados por el usuario y, después del procesamiento preliminar, los datos se envían a una plataforma. En este caso, se utiliza la potencia de procesamiento del dispositivo móvil y se proporciona interacción con el usuario a través de una aplicación.

Componente wearable

El componente wearable es responsable de obtener datos sobre los movimientos realizados mediante el uso de sensores ubicados en el cuerpo del usuario, detectar estos movimientos y transmitirlos a través de Bluetooth al componente de integración. En el caso de este trabajo, también es considerado el uso de aplicaciones que permitan emplear un smartphone a modo de dispositivo wearable, accediendo a sus sensores inerciales como pueden ser el acelerómetro y giroscopio integrados al dispositivo móvil.

Componente Plataforma

En esta parte del sistema, la plataforma debe ser capaz de recibir la información enviada a través del componente de integración, y ésta se procesa y almacena para evaluación y retroalimentación.

Arquitectura

Como se muestra en el planteamiento del problema en el capítulo 1, la enseñanza y el aprendizaje de las habilidades motoras en un ambiente virtual, se realizan de manera general, a través de vídeos que conllevan a una acción comunicativa de forma unidireccional, donde una persona experta que generalmente es un docente, presenta un vídeo para que sea visto por un estudiante, y éste a su vez, imita los movimientos vistos en el vídeo. La Figura 2.2, representa el modelo del negocio inicial a partir de un diagrama de casos de uso que resume la operación convencional de estos sistemas.

Análisis de requisitos

En este caso, se espera que el sistema a implementar logre una comunicación bidireccional, proporcionando una mayor interacción a partir de una realimentación en el proceso de enseñanza

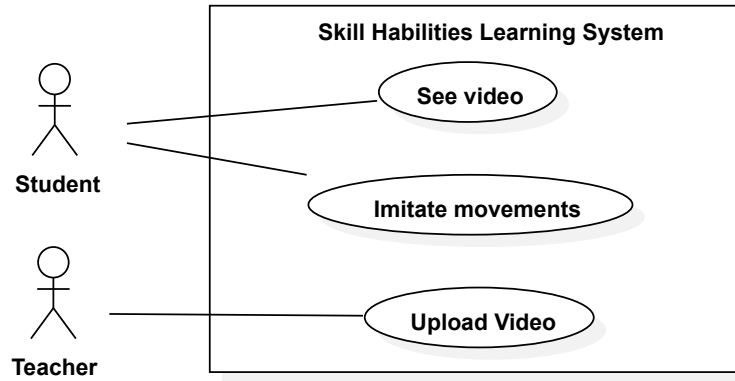


Figura 2.2: Modelo del Negocio

y aprendizaje de habilidades motrices, en particular en un contexto que involucre movimientos periódicos. Por ello se plantean los siguientes requisitos para el sistema:

- El sistema debe registrar los movimientos del usuario, tanto para el profesor como para el alumno.
- El sistema debe enviar los datos grabados a una plataforma.
- El sistema debe almacenar los datos recopilados en los movimientos.
- El sistema debe *comparar* los movimientos enviados por el alumno con los enviados por el profesor.
- El sistema debe mostrar los resultados de la comparación tanto para el alumno como para el profesor.

Arquitectura de alto nivel

La propuesta arquitectónica de alto nivel se da a conocer en la figura 2.3. Ésta utiliza como modelo inicial del sistema a proponer. Aquí se muestra un usuario empleando dispositivo wearable. Este dispositivo wearable envía información a través de Bluetooth a partir de los movimientos realizados por el usuario. Los datos son recibidos por el componente de integración, que consiste en una tableta o un teléfono inteligente. El componente de integración, a demás de recopilar los datos generados por el dispositivo wearable, también interactúa con el usuario sirviendo de interfaz. Una vez que esta información está disponible, se envía a través de Internet al componente plataforma. En la plataforma, la información se utiliza para monitorear al usuario, dar retroalimentación y evaluar el progreso a partir de una comparación con los movimientos realizados por una persona experta. Finalmente a partir de lo descrito, se procede a diseñar una arquitectura con base en el modelo 4+1 vistas.

Arquitectura basada en el modelo 4 + 1 vistas

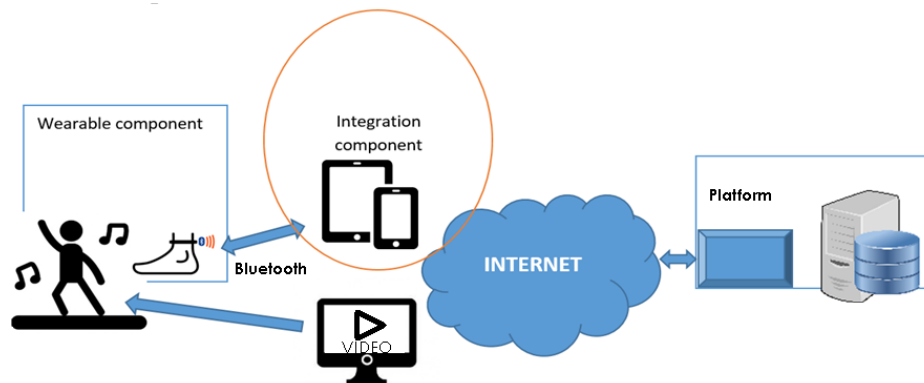


Figura 2.3: Arquitectura de Alto Nivel

El modelo 4+1 vistas se utiliza para describir la arquitectura del sistema basado en el uso de múltiples puntos de vista. En el Apéndice B, se realiza una descripción detallada de la arquitectura.

- *Vista de escenarios:* La Figura 2.4 modelo de caso de uso del sistema, resume el funcionamiento del sistema, donde se presentan 3 actores: el alumno, el maestro o docente y el componente de integración. El diagrama muestra que el maestro carga un vídeo y sube sus movimientos usando un dispositivo wearable. Del mismo modo, el estudiante también usa el dispositivo wearable y registra los movimientos que surgen cuando imita los movimientos que se ven en el vídeo. Una vez que se registran los movimientos, se envían a través del componente de integración para que se puedan comparar, y esta comparación se puede mostrar tanto para el alumno como para el profesor.
- *Vista lógica:* Esta vista muestra la funcionalidad del sistema a través de la figura 2.5 Diagrama de secuencia del sistema, y de la figura 2.6 Diagrama de clases del sistema. El diagrama de secuencia muestra que el sistema comienza cuando el maestro carga un vídeo en el sistema y carga los movimientos. Los datos generados por los movimientos del profesor se envían a través del componente de integración y se guardan para su uso posterior. Luego, el estudiante usa el dispositivo portátil para capturar los datos generados al imitar los movimientos que ve en el vídeo. A través del dispositivo portátil, estos datos se envían al componente de integración y luego se almacenan. Se comparan los datos almacenados del profesor y del alumno y se muestran los resultados de la comparación, tanto al profesor como al alumno.

La Figura 2.6 muestra el diagrama de clases del sistema. la clase Sensores, es la responsable de recopilar los datos que se generan con los movimientos del usuario. La clase Wearable se encarga de sincronizar los datos recopilados por los sensores, también adapta la información para que pueda enviarse y, envía los datos a través de Bluetooth. La clase Componente de integración debe estar sincronizada con la clase Wearable; debe mostrar la información a modo de interfaz de usuario y envía la información ya preprocesada a la plataforma a través de Internet. La clase Plataforma debe almacenar la información generada por el profesor y el

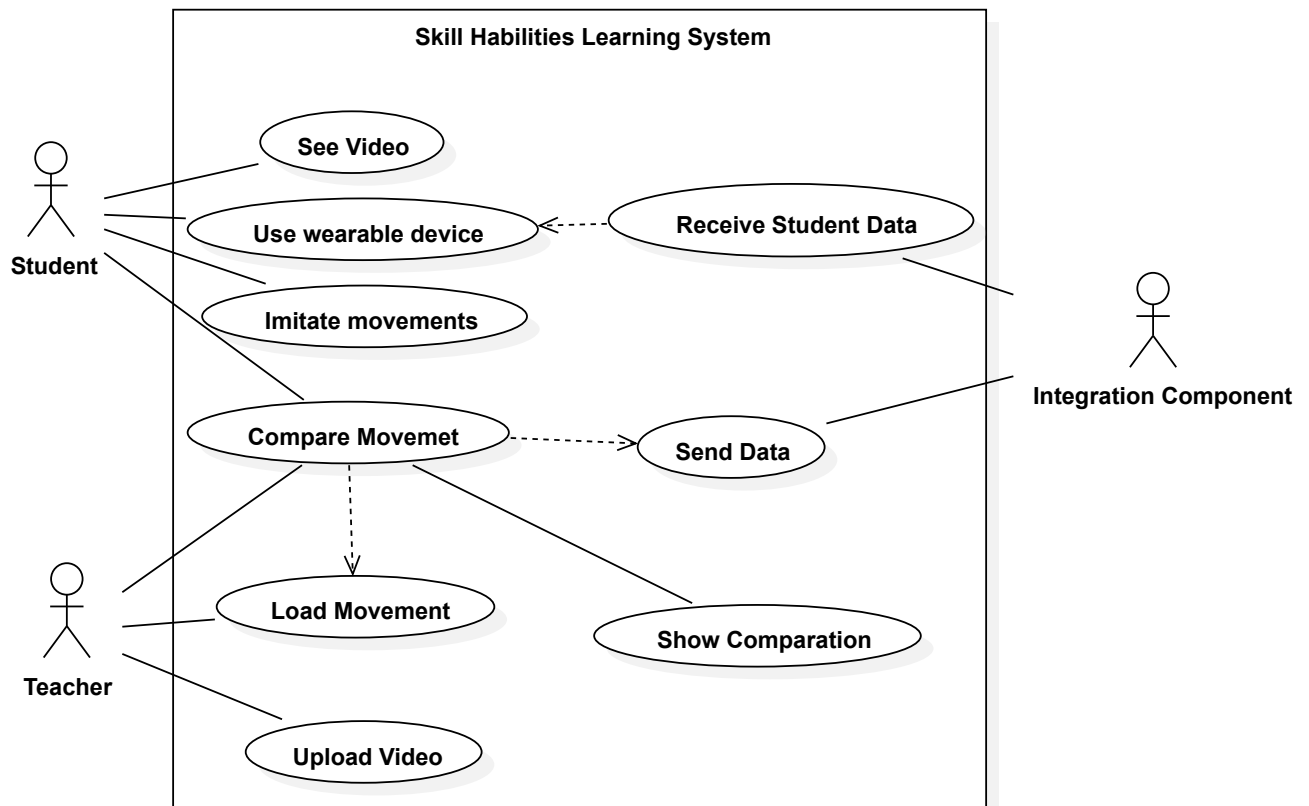


Figura 2.4: Casos de Uso del Sistema

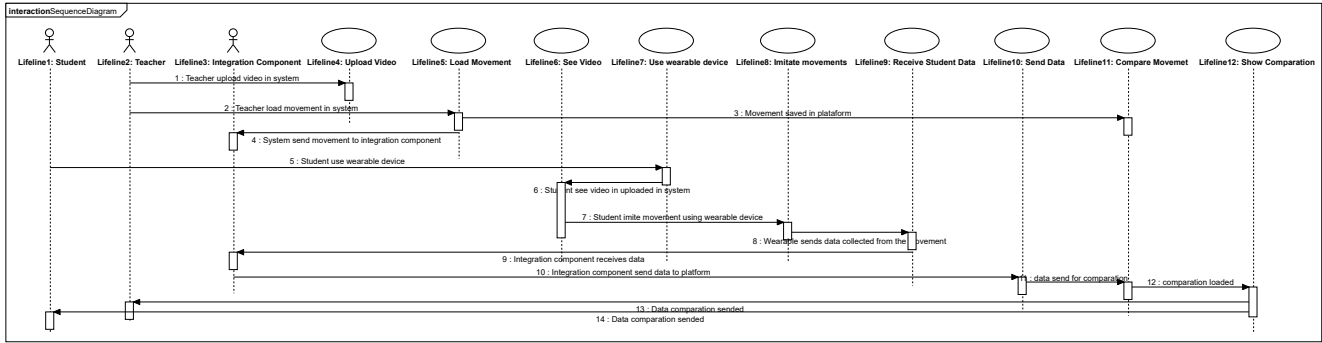


Figura 2.5: Diagrama de secuencia

alumno. La clase de comparación utiliza esta información almacenada para poder compararla y mostrarla. Finalmente, tenemos la clase Usuario, que hereda sus atributos a tres clases: Admin, Profesor y Estudiante, quienes representan a los usuarios del sistema y son los responsables de cargar los datos que surgen a partir de movimientos al sistema.

- Vista de desarrollo:* en este caso la figura 2.7, muestra que las clases se observan en tres componentes principales; el componente wearable, el componente Dispositivo (inicialmente llamado componente de integración) y el componente de plataforma. Se espera que se desarrollen con baja codependencia entre ellos, lo que permite que su realización sea de forma independiente. El componente wearable contiene sensores, que logran generar datos a partir de movimientos del cuerpo humano, en este caso, son datos de aceleración. Asimismo, este componente contiene un dispositivo wearable que será usado por el usuario y que debe ser capaz de capturar la información sobre los movimientos realizados por el usuario y también de realizar algún preprocesamiento de dicha información, para que esta pueda ser utilizada. El componente Dispositivo se desarrollará a través de una aplicación para un dispositivo móvil, inicialmente se piensa en Android. Debe servir como una puerta de enlace entre el componente wearable y el componente de Plataforma. También debe proporcionar al usuario una interfaz adecuada en la que se puedan mostrar los datos obtenidos y sus resultados. Finalmente, el componente de Plataforma es responsable de recopilar la información almacenada en una base de datos y también es donde debe llevarse a cabo todo el procesamiento, que culmina en la comparación de dicho movimiento con otro previamente almacenado en la plataforma. En este caso, la comunicación entre el componente wearable y el componente del dispositivo se realizará a través de Bluetooth Low Energy. Y la comunicación entre el componente Dispositivo y el componente Plataforma se realizará a través de Internet.
- Vista del proceso:* En este caso, el diagrama de actividad de la figura 2.8 muestra los aspectos dinámicos del sistema. En este caso, el proceso comienza con el profesor cargando un vídeo instructivo. Luego, el maestro usa el dispositivo portátil para cargar los movimientos al sistema y luego se envían a través del componente de integración a la plataforma. A su vez, el

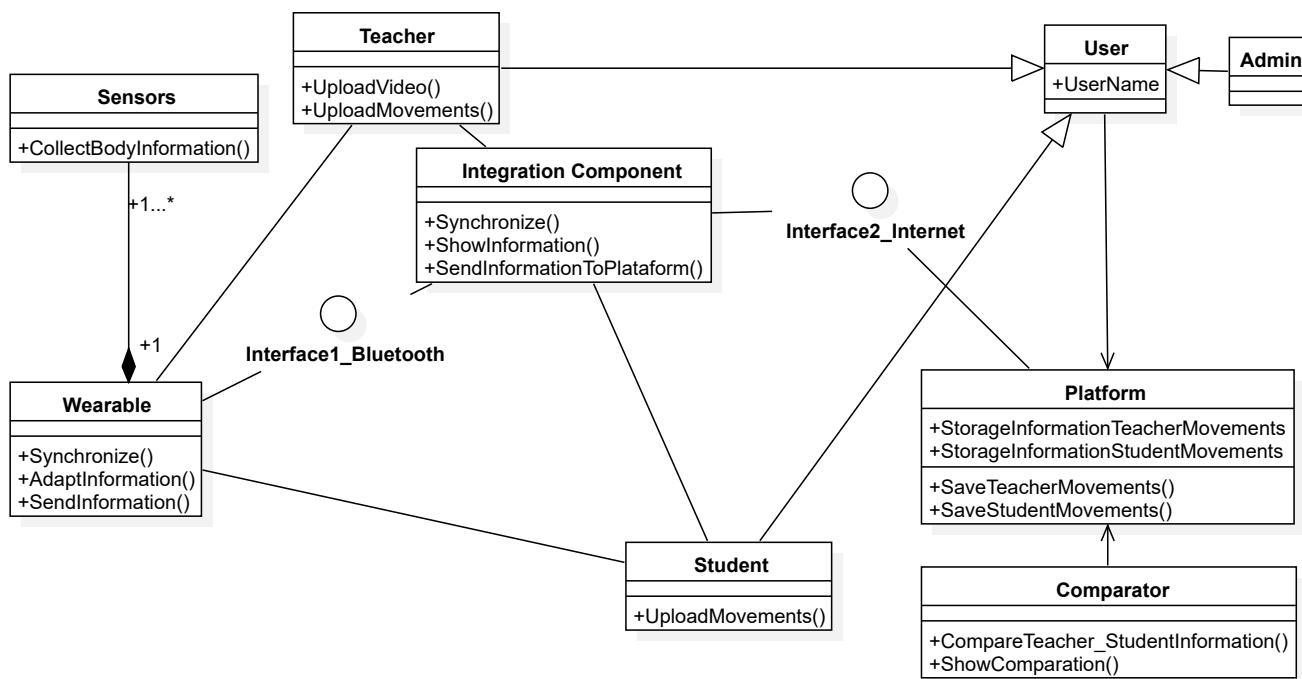


Figura 2.6: Diagrama de clases

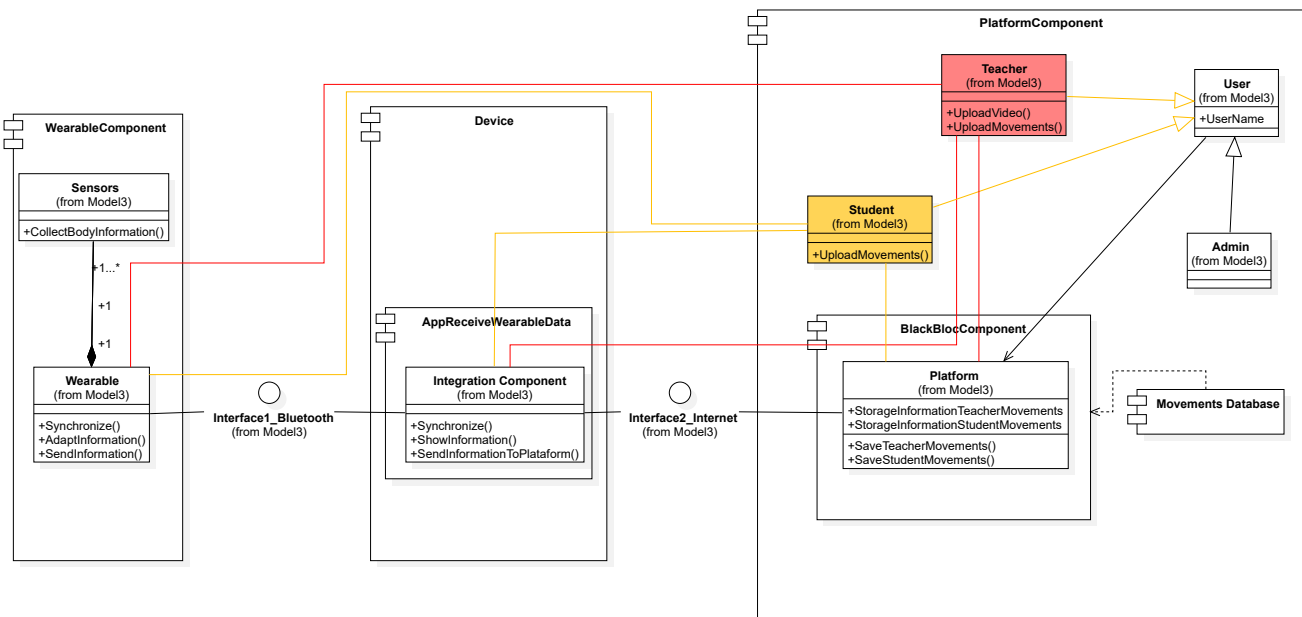


Figura 2.7: Diagrama de componentes

estudiante también carga estos movimientos con el dispositivo portátil y estos movimientos se envían a la plataforma a través del componente de integración. Para ambos casos, los movimientos se almacenan en la plataforma. El sistema carga ambos movimientos para poder compararlos y, una vez comparados, se muestran mediante la integración al alumno o al profesor, según corresponda.

- *Vista física:* La Figura 2.9 Diagrama de implementación, muestra la implementación física del sistema, donde está el dispositivo portátil, que se comunica a través de Bluetooth con el componente de integración, que está alojado en un teléfono inteligente o tableta que, a su vez, se comunica a través de Internet con la plataforma, que está alojada en un servidor. Debe notarse que los resultados de la comparación se muestran a través de una interfaz web.

2.2. Planteamiento inicial de la Solución

Visto desde el diagrama de componentes (figura 2.7), el diagrama de despliegue (figura 2.9) y los componentes del sistema (figura 2.1) se plantean tres módulos independientes e interoperables. En primer lugar se busca el desarrollo un dispositivo wearable que cumpla con los requerimientos dados en esta sección. En este caso consta de un dispositivo que tenga la capacidad de realizar la captura de datos generados a partir de movimientos. Luego se realiza el desarrollo de una aplicación en un dispositivo móvil que sea capaz de recibir y realizar un preprocesamiento de los datos generados a partir de los sensores del dispositivo wearable. Finalmente se plantea un algoritmo con el que se analizan los datos generados por el dispositivo wearable y preprocesados por el dispositivo móvil, el algoritmo debe ser capaz de comparar éstos datos con otros realizados por una persona experta con el fin que en trabajos futuros pueda ser implementado en una plataforma.

2.3. Dispositivos wearable

Para este caso se encontraron dos alternativas para el empleo de dispositivos wearable. En primer lugar se realizó un desarrollo dispositivo a modo de prototipo con base a una metodología propuesta para el desarrollo de dispositivos wearable [320]. Por otra parte se propone también emplear la aplicación *accelerometer meter*, usando el dispositivo móvil directamente como wearable. [321]

2.3.1. Prototipo wearable

Para el desarrollo del prototipo según lo desarrollado en la aproximación metodológica propuesta por [320], donde se parte desde un análisis de *funcionalidad, consumo de batería y "wearability" (portabilidad)* para el desarrollo de un dispositivo wearable. el modelo se resume en la figura 2.10.

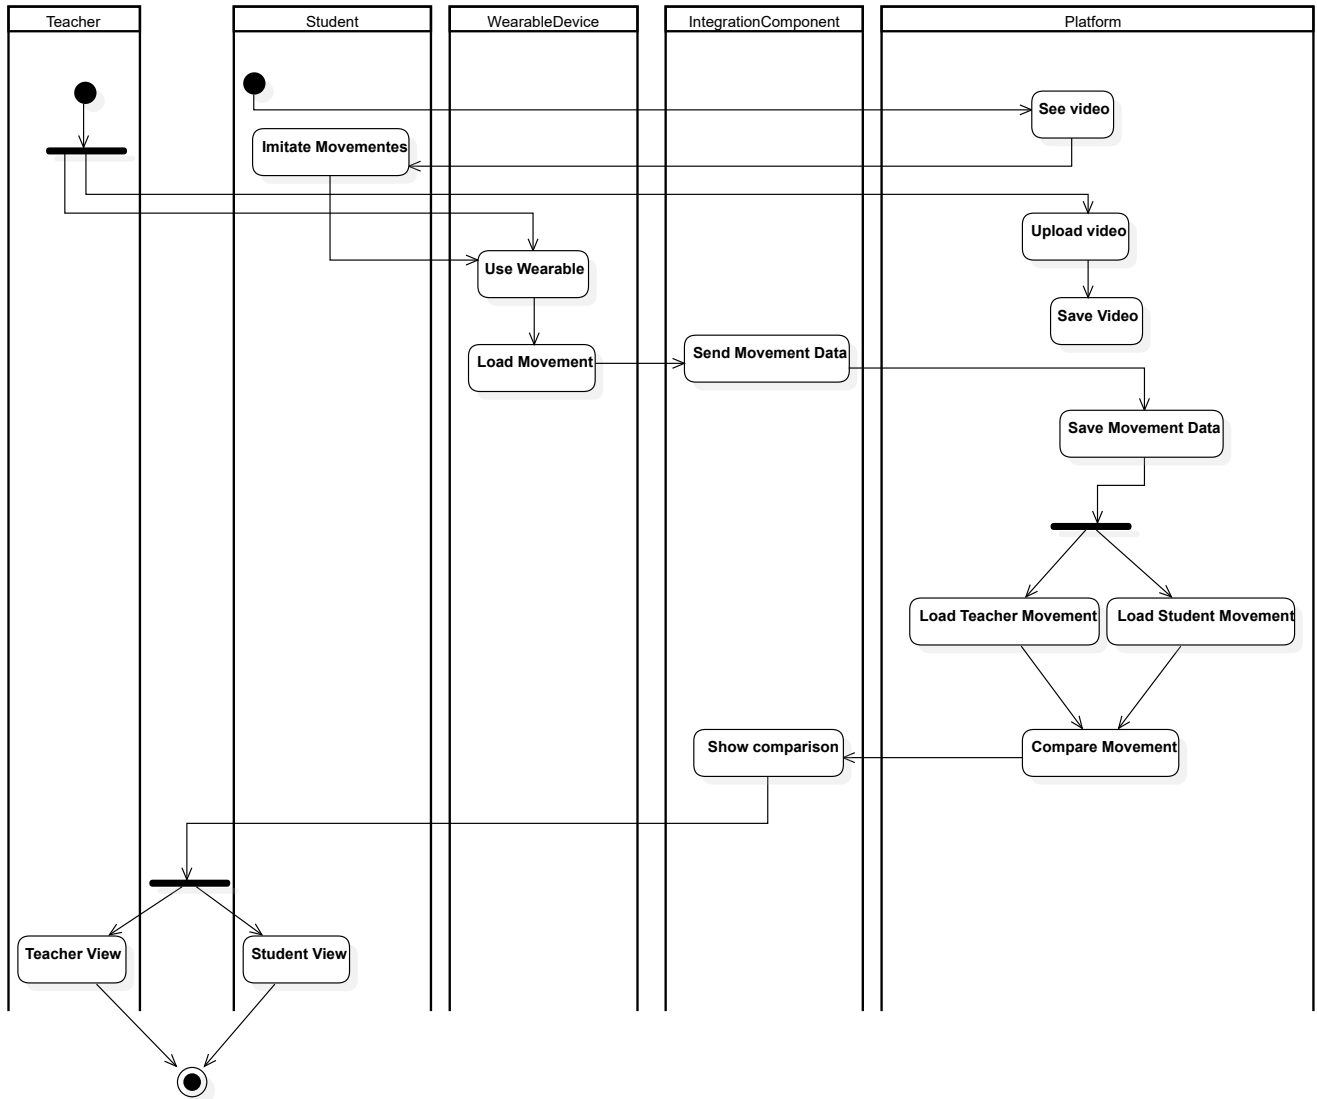


Figura 2.8: Diagrama de actividades




Figura 2.9: Diagrama de despliegue

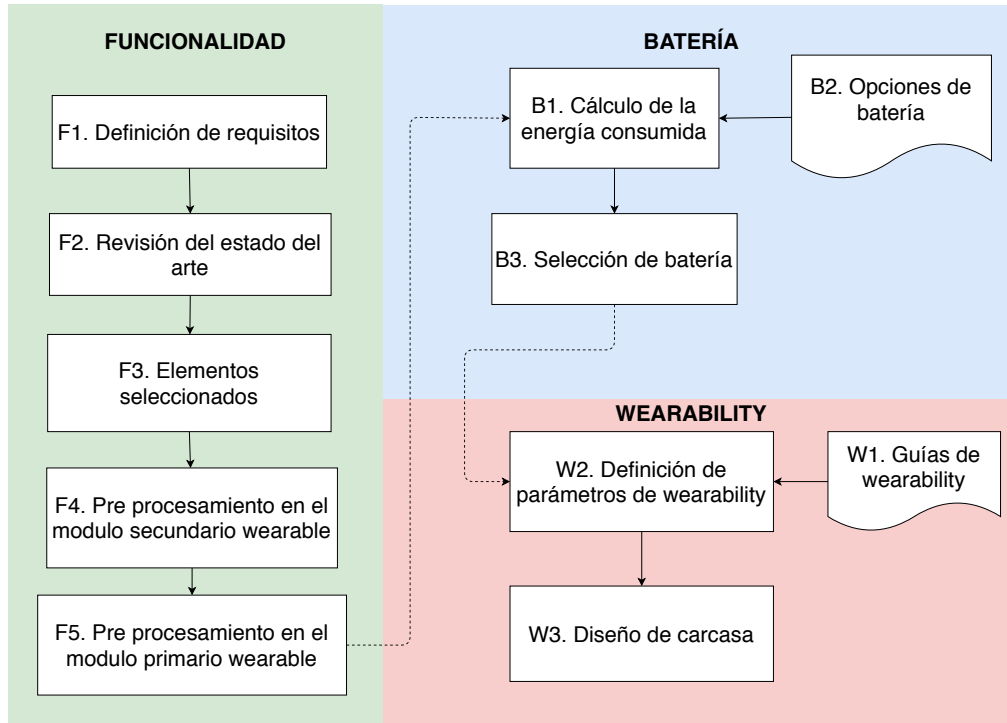


Figura 2.10: Modelo Desarrollo Prototipo Wearable

Funcionalidad

La funcionalidad se refiere a una categoría en el modelo propuesto donde con base a la captura de requisitos, la revisión del estado del arte y la selección de elementos se realiza el diseño de los módulos primarios y secundarios, siendo el módulo primario, el encargado del procesamiento de la información y el secundario, el encargado de la recolección de datos y envío de estos al módulo primario. En resumen, el módulo primario corresponde a una aplicación en un dispositivo móvil y el módulo secundario corresponde al dispositivo wearable.

Definición de requisitos

El diseño del dispositivo con base a la arquitectura propuesta busca la captura de movimientos del cuerpo humano donde se requiere que el dispositivo logre capturar datos generados a partir de movimientos periódicos para personas adultas y se espera que lo haga a lo largo de un minuto. El resumen de los requerimientos se encuentra en las tabla 2.1.

Revisión del estado del arte

Este apartado hace referencia a realizar una inspección de los dispositivos que se encuentran en el mercado o que pueden ser empleados para un desarrollo tecnológico, acorde a los requerimientos propuestos previamente. Para ello después de indagar los sensores que se requieren para

la captura de movimientos de forma sencilla y eficaz, se piensa en cuales dispositivos puedan ser empleados para ello. Se cree entonces que esta actividad se puede realizar a partir de acelerómetros, magnetrónomos y/o giroscopios. Un acelerómetro es capaz de medir la aceleración generada por su movimiento. El magnetrónomo, es capaz de medir campos magnéticos encontrados en el espacio. Y finalmente, un giroscopio, mantiene la misma orientación, muestra la dislocación en su eje y con ello brinda la posición exacta en relación con un punto de partida. En nuestro caso, optamos por el empleo de las medidas de aceleración como medida para la captura de datos y en este sentido pretendemos emplear dispositivos que contengan acelerómetros para el desarrollo. Luego, se definen dispositivos que pueden emplearse para la captura de los datos de aceleración. La tabla 2.2 resume los dispositivos explorados y seleccionados como para tal fin.

Elementos seleccionados

De acuerdo a los requerimientos y el estado del arte, se selecciona como dispositivo wearable el YJ-16009-NRF51822 Low power Bluetooth. En este caso el dispositivo cuenta con las características para la captura de datos a partir del acelerómetro y al ser apto para desarrollo hardware y software, se puede adaptar a las necesidades propias de los requisitos descritos previamente. La tabla 2.3 resume las justificaciones para su selección.

Pre procesamiento en el Módulo Secundario Wearable

El módulo secundario hace referencia al dispositivo de muestreo de datos, encargado de la recolección, codificación y envío de datos. Esta unidad debe estar equipada de componentes aptos para la obtención de datos a partir de movimientos del cuerpo humano, tecnologías de comunicación inalámbrica y conexión con periféricos externos. Debe tener como características un nivel adecuado de procesamiento y tamaño conveniente para no crear algún tipo de interferencia con los movimientos del usuario. De acuerdo a la revisión del estado del arte descrita, se evalúan dispositivos posiblemente útiles para el desarrollo del prototipo planteado y se selecciona el dispositivo YJ-16009-NRF-51822, (figura) donde para éste caso a una frecuencia de muestreo de 50 Hz con una tiempo de envío de 60 ms. Las principales características del dispositivo se encuentran en la tabla 2.4 [322]

Una vez seleccionado el dispositivo a utilizar en nuestro prototipo, se procede a programar este hardware con ayuda de Nordic Semiconductor Infocenter [322], el cual es una biblioteca integral que contiene documentación técnica para soluciones y tecnologías actuales. En esta biblioteca se encuentra información importante para crear y administrar adecuadamente los entornos de desarrollo. Además, provee un completo rango de herramientas hardware y software como los Kits de Desarrollo de Software (SDK), con ejemplos para facilitar el desarrollo de firmware para diferentes dispositivos y aplicaciones.

A continuación, se presenta una breve descripción del desarrollo de la aplicación, la cual es programada en nuestro dispositivo. En la figura 2.12 se observa un diagrama de componentes básicos que proporciona una visión general de la estructura del sistema. Muestra la organización




Figura 2.11: Dispositivo YJ-16009-NRF-51822

de los componentes software, sus interfaces y las dependencias entre ellos.

El desarrollo del sistema se programa en el lenguaje de programación C, utilizado en los SDK de Nordic. Dispone tanto de estructuras comunes de lenguajes de alto nivel, como de construcciones que permiten un control a muy bajo nivel. Como todo programa en C se compone de un conjunto de funciones, donde la función principal `main` es la primera que se ejecuta. En seguida, se detallan en forma resumida los componentes del sistema, los cuales como se observa en la figura 2.12, pueden ser código fuente (archivos fuente `.c`), código binario, librerías con interfaz definida (archivos de cabecera `.h`), tabla de bases de datos, ejecutables o un documento. El programa está dividido en módulos y cada clase en dos ficheros, los archivos de cabecera (`.h`) y los archivos fuente (`.c`). Además contiene definición de estructuras, definición de tipos (`typedef`), prototipos de funciones, variables globales, constantes, macros (`#define`), directivas (`#pragma`) que forman parte del interfaz pública del módulo.

El módulo secundario wearable se encarga de recolectar datos del acelerómetro con una frecuencia de muestreo de 50 Hz y mandarlos mediante BLE a la unidad primaria wearable, Se seleccionó esta frecuencia por parámetro de Nyquist ya que las frecuencias de movimiento del cuerpo humano llegan hasta los 25 Hz en las manos y una frecuencia menor en el resto del cuerpo [323], las funciones utilizadas para esto son: `Main.c`: Es la función principal, desde aquí se llaman todas las demás funciones que componen nuestro programa. Incluye el archivo de cabecera `includes.h`. Implementa las siguientes funciones: `app timer init()`, `ble stack init()`, `gap params init()`, `advertising init()`, `gatt init()`, `services init()`, `conn params init()`, `accelerometer init()`, `advertising start()`.

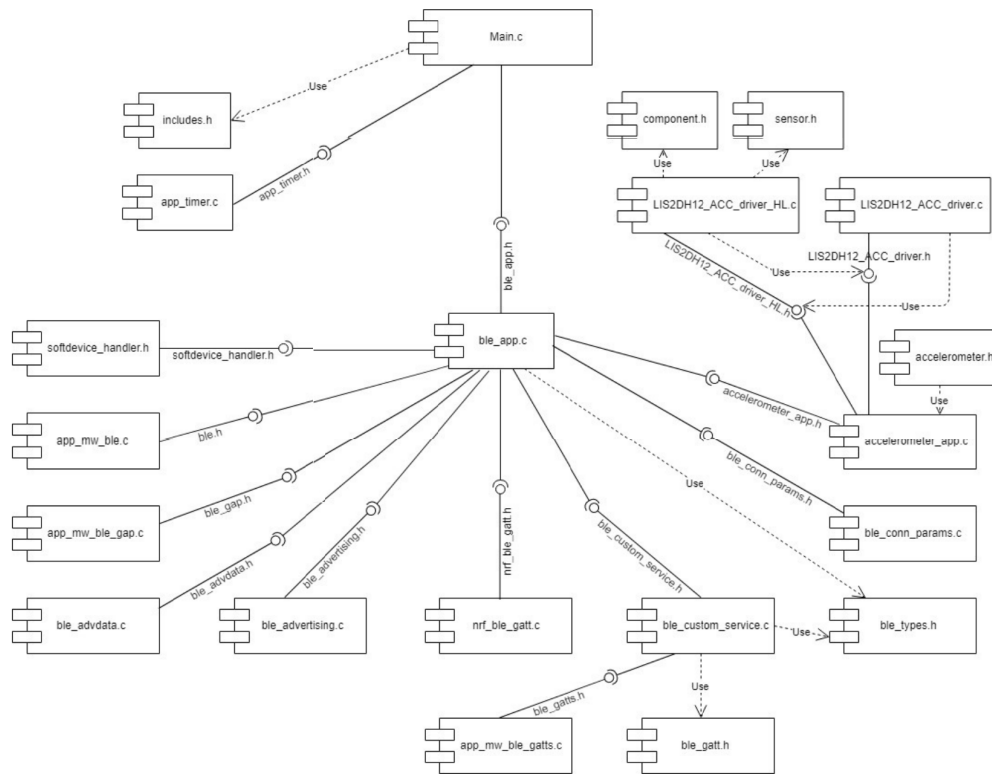


Figura 2.12: Diagrama de componentes NRF51822

`Includes.h`: Proporciona todas las librerías las cuales proveen las funciones que se requiere para la realización de las tareas del programa. Entre ellas están: `ble.h`, `ble advdata.h`, `ble advertising.h`, `ble conn params.h`, `softdevice handler.h`, `app timer.h`, `nrf ble gatt.h`, `ble conn state.h`, `ble app.h`, `accelerometer app.h`, `ble custom service.h`. Además, se definen constantes del módulo `timer`, tales como:

```
APP_TIMER_PRESCALER = 0
APP_TIMER_MAX_TIMERS = 6
APP_TIMER_OP_QUEUE_SIZE = 4
```

`App timer.c`: Inicializa el módulo del temporizador de la aplicación. Maneja el dimensionamiento y la asignación del búfer de memoria requerido por el temporizador.

`Ble app.c`: Es el archivo fuente donde se implementan la mayoría de funciones señaladas en la función `main` específicamente los dirigidos a comunicación BLE, funcionalidad de advertising, conexión GATT, parámetros de conexión, servicios y demás. Define en su interfaz `ble app.h` variables y constantes para la comunicación BLE y datos de manufactura, algunas de estas son: Número de enlaces centrales y periféricos usados por la aplicación.

```
CENTRAL_LINK_COUNT = 0
PERIPHERAL_LINK_COUNT = 1
Nombre del dispositivo.
DEVICE_NAME = "Thesis"
Intervalo de advertising.
APP_ADV_INTERVAL = 1000 (ms)
Tiempo de espera de advertising.
APP_ADV_TIMEOUT_IN_SECONDS = 0
Intervalos de conexión.
MIN_CONN_INTERVAL = 50 (ms)
MAX_CONN_INTERVAL = 70 (ms)
Latencia esclava.
SLAVE_LATENCY = 0
Tiempo de espera de supervisión de conexión.
CONN_SUP_TIMEOUT = 4000 (ms)
Identificador de la compañía, en este caso, Nordic Semiconductor ASA.
APP_COMPANY_IDENTIFIER = 0x0507
Tipo de dispositivo. En este caso, refiere a Beacon.
APP_DEVICE_TYPE = 0x02
```

`Softdevice handler.c`: Inicializa y deshabilita el `softdevice`, recibe eventos del `softdevice` y los reenvía a la aplicación usando las funciones de interfaz. Trabaja con el `softdevice S130` que tiene funcionalidades BLE y ANT.

`App mw ble.c`: A través de su interfaz define los tipos de estructura para la inicialización de

parámetros BLE (comunes, GAP y GATTS)

App mw ble gap.c: Dentro de su interfaz ble gap.h están las definiciones y prototipos para la interfaz GAP tales como identificadores únicos de eventos que vienen de la pila de la aplicación, los roles, banderas de advertising, intervalo mínimo y máximo de advertising posibles, modos de seguridad de conexión, entre otros.

Ble advdata.c: Implementa funciones para codificar datos en el formato de datos de advertising y respuesta de escaneo y para pasar los datos a la pila. Define el tipo de nombre de datos de advertising, la estructura de los tipos de lista UUID, rango de intervalo de conexión, datos específicos de manufactura, datos de advertising, etc.

Ble advertising.c: Es el módulo de advertising donde se maneja la conexión, inicialización y puesta en marcha del advertising en cualquiera de los modos, los cuales se pueden configurar para adaptarse a la mayoría de los casos de uso típicos. En su interfaz define los modos y eventos de advertising.

Nrf ble gatt.c: Módulo GATT. Desarrolla funciones para la inicialización del módulo GATT. Define la estructura GATT que contiene información del estado para el módulo, número por defecto del máximo de enlaces centrales, periféricos y combinados.

Ble custom service.c: Código fuente para la implementación de servicios y características personalizadas, funciones para el manejo del evento conectado, desconectado, escribir, entre otros. Envía valores de aceleración si está conectado y habilitadas las notificaciones. Define en su interfaz los valores de las propiedades de las características, la UUID del servicio y característica personalizada, estructura de los datos de aceleración (datos de los 3 ejes X, Y, Z).

App mw ble gatts.c: Provee funciones para agregar una declaración de servicio, característica y descriptor a la tabla de atributos. Define el tipo de estructura de los parámetros de inicialización y atributos de BLE GATT.

Ble gatt.h: Definiciones y prototipos comunes para las interfaces GATT, como los formatos de presentación y propiedades de las características, códigos de estado.

Ble types.h: Interfaz que provee los tipos comunes y definiciones macro para el softdevice BLE. Especifica UUID genéricos, aplicables a todos los servicios, tipos de UUID, valores de apariencia bluetooth, entre otros. Además establece el tipo y valor de una UUID específica.

Ble conn params.c: Módulo que contiene todas las opciones y datos necesarios para iniciar y ejecutar un procedimiento de negociación de parámetros de conexión. También define el tipo de evento del módulo de parámetros de conexión, indicando si falló o si tuvo éxito.

Accelerometer app.c: Implementa las funciones de inicialización del acelerómetro. Configura

parámetros del sensor de aceleración, establece el modo de resolución. Se crea una instancia del timer con su debida identificación, modo repetitivo con el fin de que se reinicie cada vez que caduque y la función que se ejecuta. Esta función recolecta un paquete de tres datos de cada uno de los tres ejes del acelerómetro. Al momento de habilitar las notificaciones, pone en marcha el timer y así mismo lo detiene cuando se deshabilitan las notificaciones.

Accelerometer.h: Define la estructura del controlador del acelerómetro, los datos específicos del componente y características hardware.

LIS2DH12 ACC driver HL.c: En su interfaz se definen prototipos de función privada, estructura del controlador acelerómetro LIS2DH12, estructura interna de las características extendidas del controlador. Se realizan funciones para la inicialización del LIS2DH12, habilitar el modo FIFO, establecer la velocidad de datos de salida (ODR, 50 hz por defecto), el modo de energía (Baja potencia por defecto), full scale (2G), habilitar los ejes, entre otros. Además, se implementan funciones para chequear la identificación del Who Am I del sensor, obtener los valores de los ejes del sensor de aceleración, etc.

Component.h: Precisa la estructura de contexto del componente, tales como identidad, datos, configuración del tipo de protocolo de comunicación (I2C o SPI), dirección I2c del sensor, instancia del sensor, habilitado o deshabilitado y si el componente consta de más sensores.

Sensor.h: Interfaz que proporciona la definición de la estructura de datos de los ejes del sensor, define a través de números la velocidad de datos de salida del sensor y el full scale del sensor.

LIS2DH12 ACC driver.c: Este driver es dado por el fabricante del acelerómetro, especifica con numeración diferentes tipos de datos como constantes, tales como habilitar o deshabilitar el LIS2DH12, el ODR, modo de energía, modos de filtro pasa alta, frecuencia de corte del filtro, full scale, modo FIFO. Además de definir prototipos de funciones de configuración del sensor descritas en LIS2DH12. En esta sección se configura el acelerómetro con una frecuencia de muestreo de 50 Hz y con una sensibilidad de 2g.

Procesamiento en el Módulo Primario Wearable

En la sección procesamiento en el módulo primario wearable, que se encuentra en el marco de la funcionalidad dentro de la metodología propuesta, se desarrolla una aplicación Android, la cual se puede desplegar en un dispositivo móvil (para éste caso se empleó un smartphone). El desarrollo de la aplicación para la recepción de datos se hizo en Android Studio 3.2, en donde se diseñó una API la cual es capaz de escanear dispositivos BLE, conectarse mediante el protocolo BLE al módulo secundario, interpretar los paquetes de bytes enviados y almacenar en la base de datos SQLite los datos obtenidos. Los datos son finalmente almacenados en un archivo .csv para su posterior procesamiento.

En éste caso se implementan o modifican las siguientes clases.

Clase BLEService.java Clase java proporcionada por Android, donde se implementa la funcionalidad BLE, para crear conexiones, manejar llamadas, decodificar la información recibida y verificar servicios y características; en esta función se convierte el paquete de entrada de dieciocho bytes en nueve valores de aceleración, los cuales corresponden a tres muestras por cada eje X, Y, Z; su algoritmo se ve en la figura 2.13 parte izquierda

ACCELERATION VECTOR: Esta función es capaz de obtener la característica física de la magnitud de la aceleración total, obteniendo la raíz de la suma al cuadrado la aceleración en el eje X, Y, Z; algoritmo en la figura 2.13 parte derecha.

2.3.2. Aplicación

Otra forma de captura de datos a partir de los movimientos del cuerpo humano, se realiza a través de la aplicación *accelerometer meeter*, [321]. La aplicación se puede usar en dispositivos móviles que tengan sensores de aceleración y sistema operativo Android. Con la aplicación se puede ver o registrar la salida de datos del acelerómetro del dispositivo móvil. La aplicación tiene diversas opciones de visualización como lo muestra la figura 2.14, izquierda:

- Meter: Esto muestra la salida del acelerómetro y los valores mínimos y máximos registrados.
- Graph: Traza la salida de los datos acelerómetro a lo largo del tiempo. Permite la opción para guardar datos.
- Spectrum: Muestra el espectro de frecuencia de los datos recientes del acelerómetro. Se usa para encontrar frecuencias resonantes.
- Light: A partir de la salida del acelerómetro genera un color, es decir, el color cambia con el movimiento del dispositivo.
- Music: Muestra un instrumento musical que sus notas están basadas en la orientación del dispositivo.
- Info: Esta pantalla proporciona información sobre su sensor, como proveedor, versión, resolución y rango. También muestra información para otros sensores en su dispositivo.

En nuestro caso empleamos la opción Graph de la aplicación. Esta pantalla le permite hacer el registro y guardar los datos a partir del acelerómetro.

La figura 2.14 derecha, da a conocer la interfaz de la aplicación, donde se observa que en la parte superior despliega la memoria utilizada en relación con el total reservado (3000 registros de datos), el marcador azul muestra la posición actual de los datos que se están registrando. Si la memoria está llena, se ajustará y comenzará a sobrescribir los datos más antiguos. La visualización principal contiene un gráfico a modo de histograma de la salida de datos del sensor. El histograma genera hasta con seis líneas dependiendo de los parámetros $(X, Y, Z, R, \theta, \phi)$. Cada

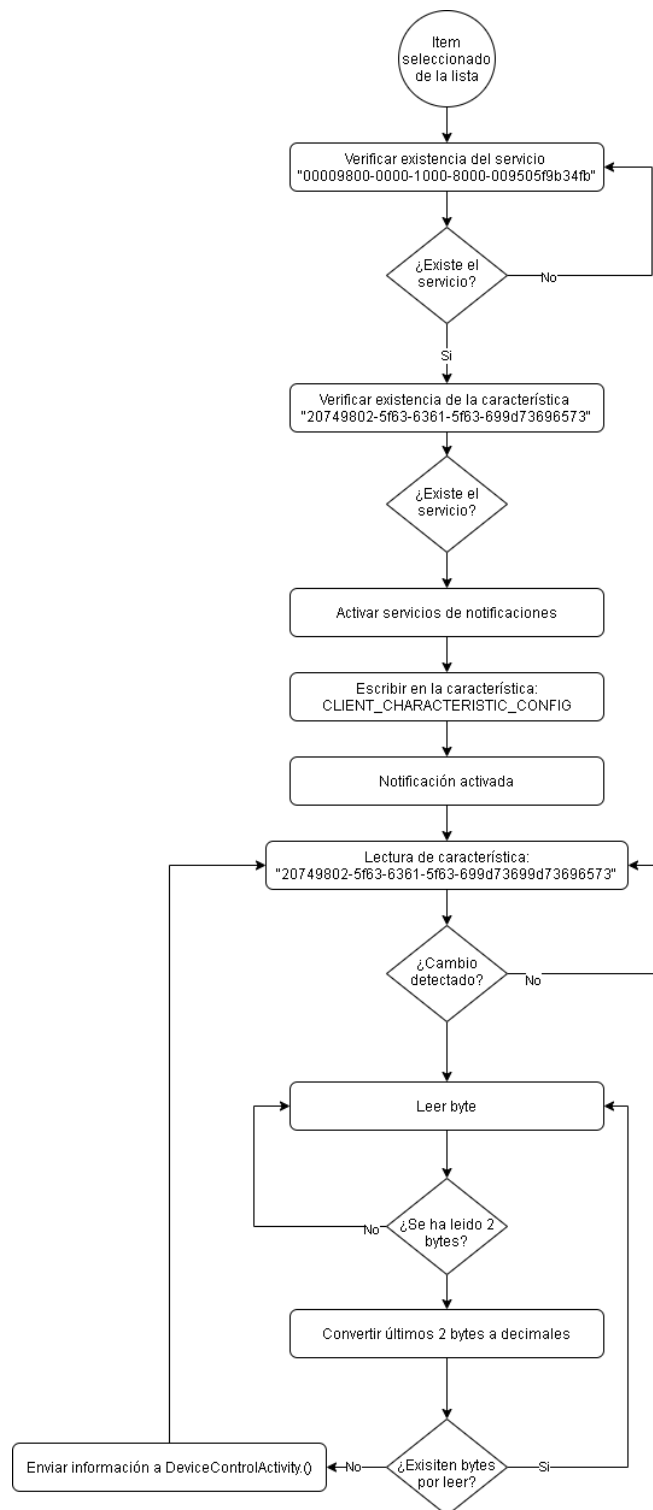


Figura 2.13: Algoritmo clase BLEService

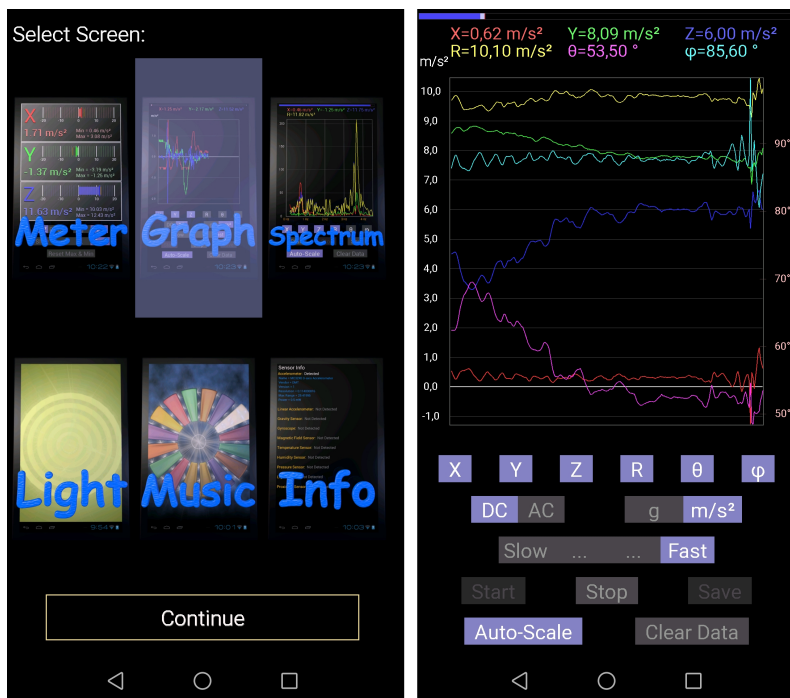


Figura 2.14: Accelerometer meter interfaz graph

línea tiene su propio color único e indica la última lectura sobre el gráfico. El eje y izquierdo es para valores de aceleración. El eje derecho es para grados. En la parte superior se puede observar los valores que genera el acelerómetro en tiempo real sobre los ejes X, Y y Z. Los botones X , Y , Z , R , θ , ϕ , $DC|AC$, $g|m/s^2$, $Slow|...|...|Fast$, $Start$, $Stop$, $Save$, $Auto - Scale|ClearData$ de ajuste se encuentran abajo del histograma.

Los botones X , Y , Z , R , θ , y ϕ activan la visualización del acelerómetro en sus respectivos ejes; R , muestra la magnitud de la aceleración; y θ y ϕ muestran el ángulo generado entre $Y - X$ y $Y - Z$. Las opciones $DC|AC$ permiten realizar un acoplamiento de la señal que se visualiza en el histograma de visualización. Los botones $g|m/s^2$ g , permiten seleccionar las opciones de la lectura de los datos en medidas de gravedades o en medida de metros por segundo al cuadrado. $Slow|...|...|Fast$, se usa para seleccionar la velocidad a la que el acelerómetro devuelve datos. Con los botones $Start$, $Stop$ y $Save$; $Start$, reinicia el registro de datos si éste se encuentra en pausa. $Stop$, detiene y pausa el registro de datos, el registro de datos debe estar en pausa para que se pueda emplear la opción $Save$. $Save$, guarda los datos en un archivo de texto delimitado por comas que contiene Tiempo, X , Y , Z , R , θ y ϕ . El archivo se guarda en el directorio raíz del dispositivo con el nombre de archivo "Accelerometer Data YYYY-MM-DD HH-MM-SS" donde AAAA, MM y DD son la Fecha y HH-MM-SS da la hora, un ejemplo se observa en la figura 2.15. $Auto - Scale$ ajusta la visualización de los datos con una escala automática si está encendido. Si está apagado, el histograma suele superar la escala de visualización. Y finalmente $ClearData$, borra los datos grabados para que se pueda comenzar una nueva prueba.

```

Accelerometer Data 2020-04-29 16-58-10: Bloc de notas
Archivo Edición Formato Ver Ayuda
Keuwl Accelerometer Data File
2020-04-29 16-58-10

Time (s), X (g), Y (g), Z (g), R (g), Theta (deg), Phi (deg)
0.000000,0.120076,0.843462,0.519354,0.997785,58.633743,81.897751
0.0050062,0.118124,0.842486,0.522282,0.998255,58.453175,82.018669
0.0100109,0.120076,0.841509,0.524235,0.998688,58.336914,81.879204
0.0150172,0.119100,0.842486,0.524235,0.999394,58.361862,81.953568
0.0200219,0.116171,0.842486,0.524235,0.999049,58.349682,82.148933
0.0249969,0.113243,0.844438,0.524235,1.000361,58.395966,82.361977
0.0300016,0.112266,0.845414,0.520330,0.999036,58.611908,82.435692
0.0350078,0.106409,0.855177,0.520330,1.006674,58.876785,82.907188
0.0400141,0.101528,0.858105,0.523259,1.010174,58.802582,83.252350
0.0450188,0.096647,0.847367,0.526187,1.002120,58.326752,83.493233
0.0500234,0.093718,0.823937,0.527164,0.982628,57.555416,83.510834
0.0549984,0.088837,0.859082,0.531069,1.013877,58.412525,84.096085
0.0600047,0.082979,0.865915,0.530092,1.018672,58.642525,84.526138
0.0650094,0.072241,0.872749,0.527164,1.022160,58.953400,85.268181
0.0700156,0.066384,0.873725,0.521306,1.019589,59.250175,85.655151
0.0750219,0.063455,0.877630,0.521306,1.022752,59.355151,85.864563
0.0800266,0.065407,0.880559,0.516425,1.022916,59.678204,85.751907
0.0850000,0.062479,0.888368,0.510568,1.026538,60.173958,85.977028
0.0900062,0.064431,0.894226,0.506663,1.029805,60.527958,85.878822
0.0950125,0.068336,0.898131,0.504710,1.032493,60.736481,85.648918
0.1000187,0.071265,0.900083,0.501782,1.032963,60.937122,85.473007
0.1050234,0.076146,0.903012,0.499829,1.034919,61.120804,85.179977
0.1099969,0.076146,0.905940,0.499829,1.037476,61.198643,85.195480
0.1150031,0.076146,0.907893,0.494948,1.036842,61.486805,85.205765
0.1200076,0.077122,0.910822,0.490067,1.037164,61.802864,85.160133
0.1250141,0.079075,0.909845,0.487138,1.035073,61.924671,85.032913
0.1300187,0.082979,0.908809,0.482257,1.032231,62.147381,84.783379
0.1350250,0.089813,0.906917,0.476400,1.028358,62.402176,84.344368
0.1400000,0.096647,0.904964,0.467614,1.023212,62.805954,83.904137

```


Figura 2.15: Ejemplo de archivo entregado por aplicación Accelerometer meter

2.4. Series de tiempo

Una serie tiempo es una secuencia de observaciones, medidos en determinados momentos del tiempo, ordenados cronológicamente y, espaciados entre sí de manera uniforme, así los datos usualmente se denominan como X_t , donde $t = 1, 2, \dots, n$.

El análisis clásico de las series temporales se basa en la suposición de que los valores que toma la variable de observación es la consecuencia de tres componentes, cuya actuación conjunta da como resultado los valores medidos, estos componentes son (figura 2.16):

- **Componente tendencia.**- Se puede definir como un cambio a largo plazo que se produce en la relación al nivel medio, o el cambio a largo plazo de la media. La tendencia se identifica con un movimiento suave de la serie a largo plazo.
- **Componente estacional.**- Muchas series temporales presentan cierta periodicidad o dicho de otro modo, variación de cierto período (semestral, mensual, etc.). Por ejemplo las Ventas al Detalle en Puerto Rico aumentan por los meses de noviembre y diciembre por las festividades navideñas. Estos efectos son fáciles de entender y se pueden medir explícitamente o incluso se pueden eliminar de la serie de datos, a este proceso se le llama desestacionalización de la serie.
- **Componente aleatoria.**- Esta componente no responde a ningún patrón de comportamiento, sino que es el resultado de factores fortuitos o aleatorios que inciden de forma aislada en una serie de tiempo.



(Fuente: Sapag 2000, pág. 96)

Figura 2.16: Componentes de una Serie de Tiempo

- **Componente cíclico.** -Esta componente refleja comportamientos recurrentes, aunque no tienen por qué ser exactamente periódicos.

2.5. Correlación Lineal

La correlación lineal es un método estadístico que estudia la relación lineal existente entre dos variables. La correlación cuantifica cuán relacionadas están dos variables. El cálculo de la correlación entre dos variables es independiente del orden o asignación de cada variable a X e Y , mide únicamente la relación entre ambas sin considerar dependencias. A nivel experimental, la correlación se suele emplear cuando ninguna de las variables se ha controlado, simplemente se han medido ambas y se desea saber si están relacionadas. En el caso de estudios de regresión lineal, es más común que una de las variables se controle (tiempo, concentración de reactivo, temperatura...) y se mida la otra. Por norma general, los estudios de correlación lineal preceden a la generación de modelos de regresión lineal.

La regresión lineal consiste en generar una ecuación (modelo) que, basándose en la relación existente entre ambas variables, permita predecir el valor de una a partir de la otra. Primero se analiza si ambas variables están correlacionadas y, en caso de estarlo, se procede a generar el modelo de regresión [324].

Para estudiar la relación lineal existente entre dos variables continuas es necesario disponer

de parámetros que permitan cuantificar dicha relación. Uno de estos parámetros es la covarianza, que indica el grado de variación conjunta de dos variables aleatorias.

$$\text{Covarianza muestral} = \text{Cov}(X, Y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{N - 1}$$

Siendo \bar{x} e \bar{y} la media de cada variable y x_i e y_i el valor de las variables para la observación i . La covarianza depende de las escalas en que se miden las variables estudiadas, por lo tanto, no es comparable entre distintos pares de variables. Para poder hacer comparaciones se estandariza la covarianza, generando lo que se conoce como coeficientes de correlación. Existen diferentes tipos, de entre los que destacan el coeficiente de Pearson, Rho de Spearman y Tau de Kendall. Todos ellos varían entre +1 y -1. Siendo +1 una correlación positiva perfecta y -1 una correlación negativa perfecta. Se emplean como medida de fuerza de asociación:

- 0: asociación nula.
- 0.1: asociación pequeña.
- 0.3: asociación mediana.
- 0.5: asociación moderada.
- 0.7: asociación alta.
- 0.9: asociación muy alta.

Las principales diferencias entre estos tres coeficientes de asociación son:

- La correlación de Pearson funciona bien con variables cuantitativas que tienen una distribución normal. En el libro *Handbook of Biological Statistics* [325] se menciona que sigue siendo bastante robusto a pesar de la falta de normalidad. Es más sensible a los valores extremos que las otras dos alternativas.
- La correlación de Spearman se emplea cuando los datos son ordinales, de intervalo, o bien cuando no se satisface la condición de normalidad para variables continuas y los datos se pueden transformar a rangos. Es un método no paramétrico.
- La correlación de Kendall es otra alternativa no paramétrica para el estudio de la correlación que trabaja con rangos. Se emplea cuando se dispone de pocos datos y muchos de ellos ocupan la misma posición en el rango, es decir, cuando hay muchas ligaduras.

Coefficiente de Pearson

El coeficiente de correlación de Pearson es la covarianza estandarizada, y su ecuación difiere dependiendo de si se aplica a una muestra, Coeficiente de Pearson muestral (r), o si se aplica la población Coeficiente de Pearson poblacional (ρ).

$$\rho = \frac{Cov(X, Y)}{\sigma_x \sigma_y}$$

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Condiciones:

- La relación que se quiere estudiar entre ambas variables es lineal (de lo contrario, el coeficiente de Pearson no la puede detectar).
- Las dos variables deben de ser cuantitativas.
- Normalidad: ambas variables se tienen que distribuir de forma normal. Varios textos definen su robustez cuando las variables se alejan moderadamente de la normal.
- Homocedasticidad: La varianza de Y debe ser constante a lo largo de la variable X.

Características

- Toma valores entre $[-1, +1]$, siendo $+1$ una correlación lineal positiva perfecta y -1 una correlación lineal negativa perfecta.
- Es una medida independiente de las escalas en las que se midan las variables.
- No varía si se aplican transformaciones a las variables.
- No tiene en consideración que las variables sean dependientes o independientes.
- El coeficiente de correlación de Pearson no equivale a la pendiente de la recta de regresión.
- Es sensible a outliers, por lo que se recomienda en caso de poder justificarlos, excluirlos del análisis.

Coefficiente de Spearman (Spearman's rho)

El coeficiente de Spearman es el equivalente al coeficiente de Pearson pero con una previa transformación de los datos a rangos. Se emplea como alternativa cuando los valores son ordinales, o bien, cuando los valores son continuos pero no satisfacen la condición de normalidad requerida por el coeficiente de Pearson y se pueden ordenar transformándolos en rangos. Al trabajar con rangos, es menos sensible que Pearson a valores extremos. Existe una diferencia adicional con respecto a Pearson. El coeficiente de Spearman requiere que la relación entre las variables sea

monótona, es decir, que cuando una variable crece la otra también lo hace o cuando una crece la otra decrece (que la tendencia sea constante). Este concepto no es exactamente el mismo que linealidad.

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2-1)},$$

Siendo d_i la distancia entre los rangos de cada observación (x_i, y_i) y n el número de observaciones.

Coefficiente Tau de Kendall

Trabaja con rangos, por lo que requiere que las variables cuya relación se quiere estudiar sean ordinales o que se puedan transformar en rangos. Al ser no paramétrico, es otra alternativa al Coeficiente de correlación de Pearson cuando no se cumple la condición de normalidad. Parece ser más aconsejable que el coeficiente de Spearman cuando el número de observaciones es pequeño o los valores se acumulan en una región por lo que el número de ligaduras al generar los rangos es alto.

$$\tau = \frac{C-D}{\frac{1}{2}n(n-1)},$$

Siendo C el número de pares concordantes, aquellos en los que el rango de la segunda variable es mayor que el rango de la primera variable. D el número de pares discordantes, cuando el rango de la segunda es igual o menor que el rango de la primera variable.

2.6. DTW Dynamic Time Warping

DTW es un algoritmo que es comúnmente aceptado en la comparación de series temporales. Se utiliza para medir la similitud entre dos secuencias que pueden variar en el tiempo o el espacio, la similitud se mide calculando la distancia entre las dos series temporales. Originalmente fue creado para el reconocimiento de voz, pero se ha aplicado en un gran número de aplicaciones como la biometría, la verificación de huellas dactilares, la escritura a mano, la minería de datos, etc. [326]. Su principal antecedente es el trabajo de [327] en el marco de la resolución de problemas vinculados al reconocimiento de voz. El planteamiento inicial surge cuando dos personas pronuncian la misma frase, pero utilizando distintos períodos de tiempo, las dos representaciones tendrán globalmente la misma forma, pero con deformaciones a lo largo del eje del tiempo. La idea es eliminar esas diferencias temporales, permitiendo incluso la alineación entre un punto de una serie con varios de la otra (figura 2.17).

Para cada punto, c_k sea

$$d(c_k) = d(i_k, j_k) = a(i_k) - b(j_k)$$

La distancia entre los valores de ambas series fueron alineados. Dada una trayectoria F , definimos la suma ponderada de dichas distancias.

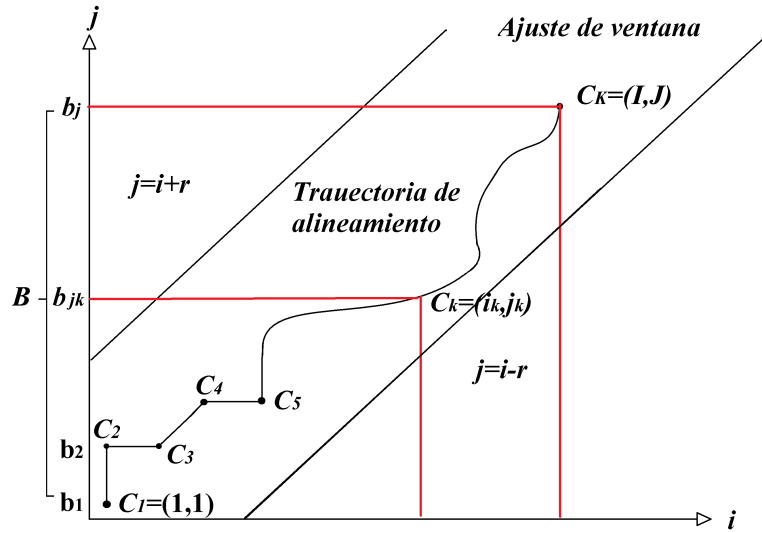


Figura 2.17: DTW

$$S(F) = \sum_{k=1}^{k=K} d(c_k)w_k \text{ con } w_k \geq 0$$

Retomando la figura 2.17, en donde las dos series temporales se encuentran variantes en el tiempo, en la medida que se escoge la trayectoria F , que eliminan esas diferencias temporales, obtenemos sumas $S(F)$ menores. Una vez eliminadas todas las diferencias debidas a “deformaciones” en el tiempo, es razonable pensar que se encuentra la trayectoria óptima F_{opt} y que la suma resultante $S(F_{opt})$ es la “verdadera” distancia entre ambas series.

Lo anterior, motiva la siguiente definición, de medida de similitud DTW entre dos series A y B :

$$DTW(A, B) = \min F \left\{ \frac{S(F)}{\sum_{k=1}^{k=K} w_k} \right\}$$

En donde el denominador, se introduce para compensar el efecto de la cantidad de puntos K que tiene cada trayectoria F .

2.7. Regresión Lineal

La regresión está dirigida a describir como es la relación entre dos variables X e Y , de tal manera que incluso se pueden hacer predicciones sobre los valores de la variable Y , a partir de los de los valores que corresponden a X . La regresión supone que hay una variable fija, que es la variable independiente y otra que no está controlada denominada dependiente.

La regresión lineal simple. Se trata de una técnica estadística que analiza la relación entre dos variables cuantitativas, tratando de verificar si dicha relación es lineal. Si tenemos dos variables

hablamos de regresión simple, si hay más de dos variables regresión múltiple.

Su objetivo es explicar el comportamiento de una variable Y , que denominaremos variable dependiente, a partir de otra variable X , que llamaremos variable independiente. Después de observar una posible relación lineal entre las dos variables, nos proponemos encontrar la ecuación de la recta que mejor se ajuste a la nube de puntos. Esta recta se denomina recta de regresión. [328]

En general, el objetivo de la regresión lineal es encontrar la línea que mejor predice Y a partir de X . La regresión lineal hace esto al encontrar la línea que minimiza la suma de los cuadrados de las distancias verticales de los puntos desde la línea.[329]

El modelo relaciona la variable dependiente Y con K variables explícitas X_k ($k = 1, \dots, k$)

$$Y = \sum \beta_k X_k + \varepsilon$$

donde ε es el ruido aleatorio que recoge todos aquellos factores no controlables y es la que confiere al modelo su carácter estocástico. En el caso más sencillo, la representación corresponde a una recta.

El modelo de regresión lineal simple se describe de acuerdo a la ecuación:

$$Y = \beta_0 + \beta_1 X_1 + \varepsilon$$

Siendo β_0 la ordenada en el origen, β_1 la pendiente y ε el error aleatorio.

POBLACIÓN OBJETIVO	
<i>Item</i>	<i>Características</i>
Edad	Personas entre 15 y 80 años
Peso	entre 50 y 100 kilo gramos
Estatura	mayor a 1.50 metros
Limitaciones	Ninguna
Sexo	Femenino y másuclino
ACTIVIDADES FÍSICAS A ESTUDIAR	
<i>Movimiento</i>	<i>Características</i>
Extremidades del cuerpo humano y zona abdominal o lumbar	movimientos realizados y recopilados por el dispositivo. Se espera ubicar el dispositivo en cualquiera de las extremidades, puede ser en muñecas y tobillos a modo de pulsera o en la cintura o espalda a modo de cinturón a modo los movimientos para éste caso se dejan abiertos a criterio de los casos de estudio
VARIABLES ESPERADAS DE LA ACTIVIDAD FÍSICA	
<i>Variables</i>	<i>Descripción</i>
Aceleración	Se Requiere que el dispositivo realice medición de la aceleración y su magnitud
Interfaz gráfica	Se Requiere que el dispositivo tenga una interfaz gráfica que permita acceder a los datos y mediciones realizadas
Almacenamiento	Se Requiere que el dispositivo almacene los datos que son generados
Pre-procesamiento	Se Requiere que el dispositivo realice un procesamiento de la información generada y almacenada para que luego se pueda analizar de una forma profunda
Epoch	En este caso se propone que el prototipo tenga un tiempo de uso para captura de datos de un minuto, pero cada ciclo será definido acorde al algoritmo que será propuesto posteriormente. En este caso, para el prototipo tendrá un epoch de un minuto.

Tabla 2.1: Requisitos prototipado dispositivo wearable

<i>Nombre</i>	<i>Tipo</i>	<i>Características</i>	<i>Procesador y memoria</i>	<i>Conectividad</i>	<i>Batería</i>	<i>Programación</i>
Microsoft Band	Commercial Band	accelerometer, GPS, Gyroscopy, H R Sensor, U V Sensor, Sensor skin temperature, Sensor Capacitive, Barometer.	1x Cortex M4 a 0.2 GHz	Bluetooth 4.0 (low energy)	Dual 100mAh rechargeable lithium-ion polymer batteries	Android, IOS, Visual studio
SAMSUNG Gear Fit	Commercial Band	GPS, HR, Accelerometer, Gyroscope, Barometer	Gear S2 SoC	Bluetooth 4.2	200mA	Tizen STUDIO
Garmin Smart Watch (vivovactive)	Comercial Smart Watch	Accelerometer GPS Barometer Compass HR Sensor	N/A	Bluetooth 4.0 (low energy)	200mA	Linux VIRB (IOS, Android, Mac, Windows)
YJ-16009-NRF51822 Low power Bluetooth	Printed Circuit Board	Beacon accelerometer movement sensor	32-bit CPU ARM Cortex M0 con 256kB/128kB flash + 32kB/16kB RAM	Bluetooth 4.0 (low energy)	CR2032	Arduino Android C
SparkFun's NRF52832 Breakout+IMU	Printed Circuit Board	IMU: Accelerometer Magnetometer Gyroscope	ARM Cortex-M4F	Bluetooth low energy ANT Nordic's proprietary 2.4GHz ultra low-power wireless communication	External 3,3V	Arduino Android C

Tabla 2.2: Dispositivos wearable encontrados

<i>Tecnología</i>	<i>Razón/justificación</i>
Acelerómetro	Como visto en la figura 4.4 el acelerómetro es una constante en casi todos los elementos dedicados al estudio de movimientos en las piernas
Bluetooth 4.0 BLE	La tecnología bluetooth en su versión 4.0, trae las funcionalidades BLE, las cuales maximizan el consumo de energía de los dispositivos y es apta para la transferencia de datos en una tasa baja de envío.
Batería desechable o no recargable tipo moneda	las ventajas de la batería tipo moneda se encuentran acorde a su compatibilidad con la tecnología de comunicación BLE.

Tabla 2.3: Elementos seleccionados para dispositivo wearable

Banda de Frecuencia	C2.4 GHz ISM
Tasa de datos en el aire	250 Kbps, 1 Mbps o 2 Mbps
Modulación	GFSK
Micro controlador	ARM C�rtex M0 de 32 bits
Memoria flash	256/128 kB
Memoria RAM	32/16 kB
Puertos GPIO	31 Configurables
Perif�ricos	Convertor Anal�gico Digital de 10 bits (ADC), Generador de N�meros Aleatorios (RNG), Relojes en Tiempo Real (RTC), Sensor de Temperatura
Temporizadores/Contadores	2 de 16 bits, 2 de 24 bits, RTC
Regulador de Voltaje	1.8 a 3.6 voltios
Aplicaciones	Wearable, Beacons, Perif�ricos de computadora, Controles remotos para televisi�n, Set Top Box y sistemas multimedia, Sensores deportivos y de estado f�sico, Sensores de salud y estilo de vida, Controladores de juegos para computadoras, Electrodom�sticos inteligentes

Tabla 2.4: Caracter sticas Dispositivo YJ-16009-NRF-51822

Capítulo 3

Algoritmo para la comparación de movimientos

Resumen del capítulo

En el capítulo 3, se realiza el desarrollo del algoritmo para la comparación de movimientos. En este caso, primero se determinan los parámetros generales para el desarrollo del algoritmo. Luego el planteamiento inicial del algoritmo donde se muestra la estructura general. Después se muestra el desarrollo de cada uno de los componentes del algoritmo: Importación de datos, Iteraciones de Pearson, Ajuste de datos, Filtrado de datos, Normalización, Análisis por DTW, y Análisis comparativo a partir de DTW y regresión lineal. Finalmente se integran los apartados del algoritmo y es mostrado a partir de pseudocódigo.

3.1. Parámetros Generales

En miras de encontrar una forma en que sea posible realizar una comparación entre dos personas que realizan la misma habilidad motriz, donde una persona haga las veces de experta en los movimientos y la otra persona intente replicar este movimiento, el punto de partida se da en encontrar una forma de obtener datos que puedan ser analizados. El desarrollo del algoritmo se muestran en el artículo [330].

En este caso, como se mencionó en el capítulo 2, los datos pueden ser obtenidos a partir de un dispositivo wearable o móvil, en ambos casos partiendo del principio que los dispositivos no interrumpen el libre movimiento del usuario.

En el caso particular, se selecciona las medidas de aceleración como los datos que concentran la información de los movimientos realizados. Los datos obtenidos, por su propia naturaleza tienen una forma de serie de tiempo, en el caso de los datos de aceleración en su forma más bruta, son de forma multivariante, donde se tiene básicamente el intervalo de tiempo t y los datos de la aceleración en los ejes x, y y z en medidas de g o m/s^2 .

Sin embargo, para facilitar el análisis, los datos son convertidos en una series univariantes al emplear el módulo de los componentes de la aceleración. El módulo es calculado bajo la fórmula $v = \sqrt{x^2 + y^2 + z^2}$. La principal razón del empleo del módulo de la aceleración, es porque los datos en los diferentes ejes pueden variar respecto a la posición del dispositivo en la persona. Es decir, el eje vertical del acelerómetro, en un caso ideal debería coincidir exactamente con la alineación de la atracción terrestre. Pero este parámetro es muy difícil de aplicar en un contexto poco controlado, puesto que no todas las personas van a poder realizar dicha alineación. Para solventar este problema se puede optar por dos caminos. La primera es hacer un ajuste de forma matemática en los ejes, donde se tome un tiempo cero en el que no hayan movimientos, para que se haga la compensación de forma calculada en los ejes. La segunda forma, es convertir la serie multivariante a univariante partiendo del uso del módulo. Para este caso se opta por la segunda opción.

Ya con los datos ajustados, se debe encontrar la forma de compararlos, en este caso el problema se traslada en encontrar como comparar dos series de tiempo. De forma gráfica es fácilmente detectable a simple vista si su comportamiento es similar, lo que traslada ahora el problema en que tan similares pueden llegar a ser este par de señales implicando diversos factores a superar. Uno de ellos es que debido a la segunda ley de Newton, la aceleración varía inversamente dependiendo de la masa ((Fuerza/masa)=aceleración). Esto se puede ver reflejado en que dos personas de peso y talla diferentes, pueden realizar el mismo movimiento, pero la lectura de sus datos puede llegar a ser diferente. Otro factor se puede presentar en que es indispensable controlar el parámetro temporal, puesto que al realizar movimientos que sean periódicos (pasos de baile, caminar, correr, nadar, pedalear, etc), se debe controlar la cantidad de muestras obtenidas por unidad de tiempo. En este caso se pueden presentar dos situaciones, la primera es que el movimiento sea independiente de la frecuencia que se necesita, por ejemplo, se pueden tomar dos muestras de una persona que realiza 60 pasos por minuto, y otra que realiza 30 pasos en una muestra de una caminata, o en el caso de la natación, que una persona realice 50 brazadas y otra 40 en el mismo tiempo, sin que ello represente relevancia en la imitación del movimiento. Pero existen otros casos en donde la frecuencia del movimiento sí representa relevancia, por ejemplo en el caso del baile, donde se requiere de una medida temporal que indique en que momento se realiza correctamente el movimiento, comúnmente esto lo realizan a partir del compás de la música o con el uso de metrónomos. Finalmente un tercer parámetro a tener en cuenta, es la realización en sí del movimiento de forma correcta, donde los datos arrojados deben determinar si los movimientos se realizan de forma similar a partir de los datos.

Ahora bien, al tratarse de series temporales, con base en la participación en las publicaciones [331] y [332], se puede pensar en el uso de sus características para su estudio. Las series temporales tienen los componentes de *Estacionalidad* (patrón de cambio, regularmente recurrente a través del tiempo), *Tendencia* (determina crecimiento o declinación), *Ciclicidad* (fluctuaciones en forma de onda o ciclos) y *Aleatoriedad* (comportamiento irregular está compuesto por fluctuaciones causadas por sucesos impredecibles o no periódicos). Se puede pensar que a partir de estas características se pueden determinar valores útiles para la comparación, por ejemplo, la aleatoriedad y tendencia, están relacionados con la realización propia del movimiento. Y La ciclicidad, la

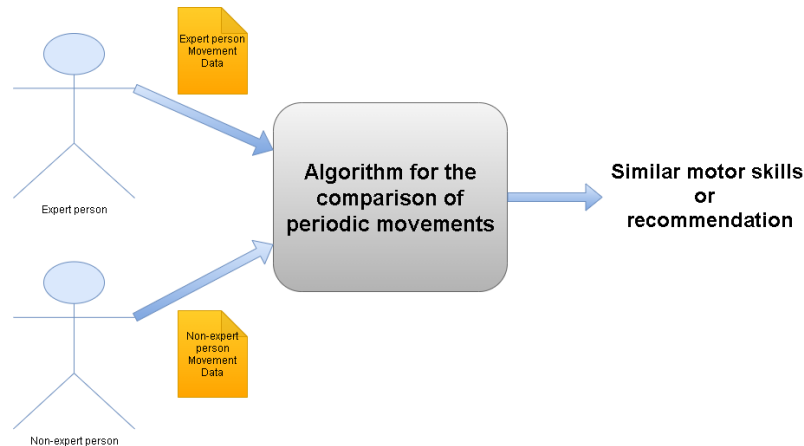


Figura 3.1: Idea general del algoritmo para la comparación de movimientos.

estacionalidad se ven reflejado en las características temporales y de repetición del movimiento.

Desde el punto de vista funcional, los usuarios, independientemente que sean los usuarios expertos o quien realiza a modo de imitación el movimiento, necesitan un sistema de recomendaciones que básicamente les indique si los movimientos comparados son iguales o diferentes y con base en ello reciban cierto tipo de re alimentación, a modo de recomendaciones para un próximo intento. Por otro lado, se puede pensar también en otro tipo de aplicaciones que pueden tomarse en cuenta para el uso del algoritmo, por ejemplo en comparar los movimientos a partir de muestras tomadas en diferentes momentos de una persona que esté realizando una recuperación deportiva por una lesión. Comparar el movimiento entre una persona que emplea algún tipo de prótesis y una persona normal. Detectar a partir de la comparación del movimiento falencias propias en atletas o encontrar movimientos óptimos.

Viéndolo como una caja negra en la Figura 3.1 , el algoritmo para la comparación de movimientos, recibiría dos series de tiempo univariantes, e internamente a partir de las características propias de las series de tiempo realizará procesos que permitan indicar si los movimientos son similares, pero de no serlo, brinde una recomendación para lograr la similaridad de los movimientos.

3.2. Planteamiento inicial del algoritmo

Se plantea entonces una estructura general para el algoritmo de comparación de movimientos que se representa en la figura 3.2. En la imagen, se muestra que el algoritmo planteado se comporta de forma lineal y paralela con base en los datos ingresados por dos personas que desean comparar algún tipo de movimiento periódico. Como se mencionó previamente, se requiere que los datos a ingresar se encuentren en primera medida, recolectados con la misma tasa de muestreo y en la misma unidad de medida, g ó m/s^2 .

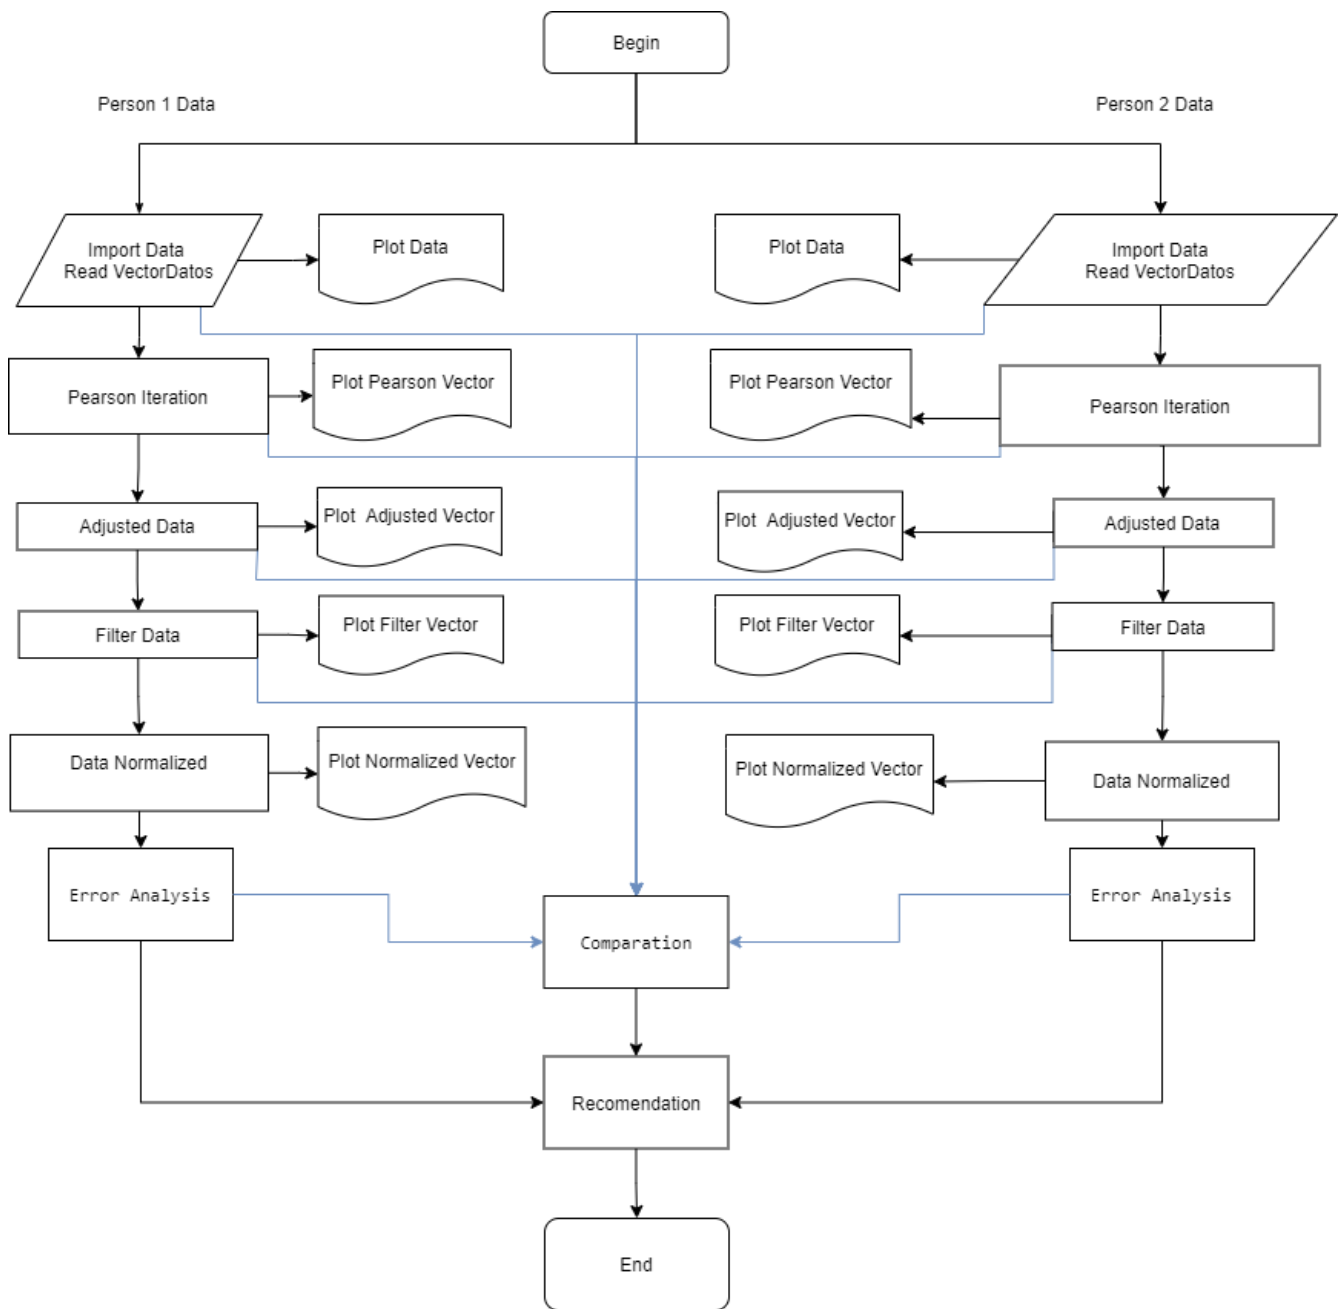


Figura 3.2: Diagrama General del Algoritmo

En General, cada módulo que compone el algoritmo se encarga de realizar un ajuste a los datos originales de forma lineal, es decir, los datos ingresan a cada módulo y tras algún tipo de procesamiento entrega los datos procesados según se requiera, para mostrarlos de forma gráfica y realizar una análisis comparativo por cada módulo.

El modulo *ImportData*, realiza la lectura de los datos en el algoritmo y los coloca en formato de vector, $v = [x_1, x_2, x_3, \dots, x_n]$, donde x_i corresponde a la lectura del acelerómetro en cada instante.

El módulo *AjustedData*, realiza un ajuste para que los vectores generados en el modulo *ImportData* inicien de forma similar y se ajusten en una misma fase. A partir de éste modulo se considerarán los vectores de datos como señales, debido a su naturaleza de representación a partir de un plano cartesiano. El modulo *PearsonIteration*, se encarga de determinar la periodicidad de las señales y compararlas en términos del periodo encentrado en cada una. El módulo *FilterData*, suaviza las señales en miras de eliminar ruido que se pueda presentar en los datos. El modulo *DataNormalized*, realiza un ajuste de la escala de las señales para facilitar la comparación de los datos. El modulo *ErrorAnalysis*, determina a partir de un analisis de regresion lineal y su error la proximidad entre una señal y otra para determinar su grado de similitud. El modulo *Comparison*, realiza la comparación de las señales que se van generando a lo largo del algoritmo. Y finalmente el modulo *Recommendation* entrega un resultado del algoritmo traducido en una recomendación a seguir para que los movimientos tengan un grado alto de similitud o reconocer su similitud.

3.3. Importación de datos

Retomando lo planteado en el Capitulo 2, los datos recolectados se dan a partir de dispositivos wearable o con una aplicación que usan sensores para capturar información de la aceleración que realizan las personas al realizar un movimiento. Los datos deben ser capturados en forma de serie de tiempo univariante, donde se emplean los valores de aceleración a través del tiempo. En este caso se toma la magnitud de la aceleración como valor a ingresar al algoritmo y se representa bajo la nomenclatura x_t (ver capitulo 2, 2.4 Series de tiempo)

Debido a que las medidas de aceleración pueden variar de acuerdo a la nomenclatura empleada, bien sea en gravedades g o metros por segundo cuadrado m/s^2 , se debe asegurar que las medidas que ingresan al algoritmo se encuentren en las mismas unidades. Por otra parte, hay que tener en cuenta que la frecuencia de captura del wearable o de la aplicación correspondan en los dispositivos usados por las dos personas que realizan la captura, es decir, si se hace una captura de 20 datos por segundo para una persona x, otra persona y, quien desea comparar el movimiento, debe también considerar un total de 20 datos por segundo.

La figura 3.3, muestra un ejemplo de los datos obtenidos y representados en forma de una señal a partir de un dispositivo wearable, donde en el eje vertical se tiene la magnitud de la aceleración, en este caso en $(m/s^2 * 100)$ (donde se hace el ajuste de 100, para tener un margen mayor en las unidades empleadas). Y en el eje horizontal, las muestras tomadas a través del tiempo, en el caso




Figura 3.3: Ejemplo Serie de Tiempo

particular de la figura 3.3, se toman un total de 1000 muestras.

3.4. Iteraciones de Pearson

Recordando lo establecido en el capítulo 2, se define las correlaciones como correspondencia entre dos señales, en el caso de Pearson, toma valores entre -1 y 1, donde 1 es una correlación lineal positiva perfecta y -1 una correlación lineal negativa perfecta. Bajo este principio, si dos señales que contengan el mismo número de muestras, son iguales, su correlación de Pearson será 1, o si son parecidas, su valor será próximo a 1.

Recordemos que al evaluar movimientos periódicos, la respuesta lógica esperada, es que se refleje en las señales la periodicidad. Si retomamos el ejemplo dado en la figura 3.3, a una escala mayor (figura 3.4), a simple vista se puede ver que existe la repetición de un patrón.

Bajo las dos premisas anteriores, podemos pensar en el uso del coeficiente de Pearson para determinar esta ciclicidad. Para ello, definimos el término *Iteraciones de Pearson*, donde se realiza iteraciones de una señal sobre si misma para determinar la ciclicidad de la señal.




Figura 3.4: Ejemplo Serie de Tiempo Ampliado

Supongamos la señal que representa un comportamiento periódico v , compuesta por los datos $x_1, x_2, x_3, x_4, \dots, x_n$, es decir, podemos definir el vector

$$v = [x_1, x_2, x_3, x_4, \dots, x_n].$$

A partir del vector v , podemos hacer un corrimiento de las datos de la señal en forma de carrusel y definir los vectores

$$v_1 = [x_n, x_1, x_2, x_3, \dots, x_{n-1}]$$

$$v_2 = [x_{n-1}, x_n, x_1, x_2, \dots, x_{n-2}]$$

$$v_3 = [x_{n-2}, x_{n-1}, x_n, x_1, \dots, x_{n-3}]$$

.

.

.

$$v_n = [x_1, x_2, x_3, \dots, x_{n-1}] v_{n+1} = [x_n, x_1, x_2, x_3, \dots, x_{n-2}]$$

Definimos la correlación de Pearson de los vectores x y y como $\rho_{x,y}$

donde $\rho_{x,y} = 1$ si $x = y$

de forma que $\rho_{v,v} = 1$ y también $\rho_{v,v_{n+1}} = 1$

Ahora bien, podemos realizar correlaciones de Pearson entre el vector v y los vectores $v_1, v_2, v_3, v_4, \dots, v_n$; es decir:

$$P_1 = \rho_{v,v_1}$$

$$P_2 = \rho_{v,v_2}$$

$$P_3 = \rho_{v,v_3}$$

$$P_4 = \rho_{v,v_4}$$

.

.

.

$$P_n = \rho_{v,v_n}$$

A partir de esto, podemos crear el vector $P = [P_1, P_2, P_3, P_4, \dots, P_n]$, que corresponde al vector de *iteraciones de Pearson*.

Al ser señales de forma cíclica, se espera que cada vez que se cumpla un ciclo, se pueda observar un valor máximo P_{max} entre -1 y 1 , y a medida que se desliza la señal para hacer la siguiente iteración, el valor puede ir decreciendo, para luego subir para obtener de nuevo un valor máximo, de forma que si conocemos el numero de iteraciones que se presentan entre máximo y máximo, podemos establecer el periodo de la serie de tiempo a partir de los datos.

Retomemos el ejemplo de la figura 3.4, donde a partir de la captura de datos de un acelerómetro, podemos realizar la operación definida previamente con las iteraciones de Pearson.

En `User2SetepForwardBackward/Sample_1` se observa que para este caso, v contiene 3000 muestras (figura 3.5), y el resultado de las iteraciones de Pearson se da en `User2StepForwardBackwardPearsonS` y se muestran en la figura 3.6.

Si es ampliada la imagen y se contrastan las muestras contra el resultado de las iteraciones de Pearson, se puede observar que en este caso, cada 125 iteraciones se tienen un valor máximo, con lo cual podemos concluir, que cada 125 muestras se repite el periodo. Esto se puede observar en la figura 3.8, en la parte superior de la figura, se observa la señal de la muestra y en la parte inferior, el gráfico a partir de las iteraciones de pearson y los periodos se enmarca en rectángulos rojos.

3.5. Ajuste de datos

Recordemos que el algoritmo debe recibir dos conjuntos de datos, con la sección anterior, a partir de las iteraciones de Pearson, es posible determinar si las señales que ingresan al algoritmo




Figura 3.5: Ejemplo serie de tiempo




Figura 3.6: Ejemplo Resultados Iteracion de Pearson




Figura 3.7: Ejemplo Resultados Iteracion de Pearson contra datos

son periódicas o no, y determinar cada cuantas muestras se repite el comportamiento. Al ser señales diferentes, es necesario determinar si el inicio de ambas señales coincide.

Para ello, se busca que las dos señales inicien con un comportamiento similar y que la cantidad de datos sea la misma para las dos muestras.

En este orden de ideas, retomamos nuestro vector $v = [x_1, x_2, x_3, x_4, \dots, x_n]$, como nuestra primera muestra. Y $u = [y_1, y_2, y_3, y_4, \dots, y_m]$ como el segundo conjunto de datos y la muestra a comparar y que tiene un comportamiento periódico similar a los datos del vector v .

Teniendo en cuenta que previamente se haya determinado el periodo a partir de las iteraciones de Pearson, y que a su vez, ellas contengan el mismo periodo, la idea general es partir desde el primer máximo del primer ciclo para ambas muestras y luego, cortar el número de muestras en la que tenga menor número para que se pueda realizar la comparación con igual número de datos.

Para que las muestras inicien en el primer máximo, tomamos los vectores $v' = [x_1, x_2, x_3, x_4, \dots, x_{n'}]$ y $u' = [y_1, y_2, y_3, y_4, \dots, y_{m'}]$ donde $n' = m'$ y corresponden al número de muestras para un ciclo.

Haciendo uso de las iteraciones de Pearson, podemos hacer la correlación de Pearson, desplazando un vector y fijando el segundo, es decir, definimos un vector R como las iteraciones de Pearson entre los datos del primer ciclo entre los vectores v' y u' de forma que, en este caso se fija el vector v' y se desplaza el vector u' , de forma que:

$$\begin{aligned} v' &= [x_1, x_2, x_3, x_4, \dots, x_{n'}] \\ u' &= [y_1, y_2, y_3, y_4, \dots, y_{n'}] \\ u'_1 &= [y_{n'}, y_1, y_2, y_3, \dots, y_{n'-1}] \\ u'_2 &= [y_{n'-1}, y_{n'}, y_1, y_2, \dots, y_{n'-2}] \\ &\vdots \\ &\vdots \\ &\vdots \\ &Y \end{aligned}$$

$$R_0 = \rho_{v', u'}$$

$$R_1 = \rho_{v', u'_1}$$

$$R_2 = \rho_{v', u'_2}$$

$$R_3 = \rho_{v', u'_3}$$

\vdots
 \vdots
 \vdots

Así que

$$R = [R_1, R_2, R_3, R_4, \dots, R_{n'}]$$

Definimos la función $max()$ como aquella que determina el valor máximo en un conjunto de datos y su posición, de forma que $max(R) = (R_{max}, P_{R_{max}})$ donde R_{max} es el valor máximo alcanzado en el conjunto de datos y $P_{R_{max}}$, corresponde a la posición donde se encuentra el valor máximo. Una vez se conoce esta posición, es posible deslizar los datos del vector u , hasta un vector que se denomina u_{adj} , para que coincidan con la iteración de Pearson más alta y de forma que la coincidencia en los datos sea mayor, es decir:

$$v = [x_1, x_2, x_3, x_4, \dots, x_n]$$

y

$$u_{adj} = [y_{P_{R_{max}}}, y_{(P_{R_{max}}+1)}, y_{(P_{R_{max}}+2)}, y_{(P_{R_{max}}+3)}, \dots, y_{(m-P_{R_{max}})}]$$

Una vez realizado esto, se debe asegurar que coincidan en numero de datos para los dos conjuntos. En este caso, se debe determinar cual es el conjunto de datos con la cantidad menor de datos, es decir, determinar si $n < (m - P_{R_{max}})$ o $(m - P_{R_{max}}) < n$. En tal caso, denominemos a $p = n$ si n es el menor valor o $p = (m - P_{R_{max}})$ en el caso que $P_{R_{max}}$ sea el menor valor, de forma tal que descartamos los datos que se encuentren después de la posición p , bien sea en el conjunto v o u_{adj} garantizando que los dos conjuntos de datos contengan l misma cantidad. Es decir, los datos ajustados corresponden a:

$$v = [x_1, x_2, x_3, x_4, \dots, x_p]$$

Y

$$u_{adj} = [y_{P_{R_{max}}}, y_{(P_{R_{max}}+1)}, y_{(P_{R_{max}}+2)}, y_{(P_{R_{max}}+3)}, \dots, y_p]$$

Retomamos el ejemplo, donde asignamos datos a v , ahora definimos el vector u , que tiene a simple vista un comportamiento similar a v como se observa en la figura 3.8.

Como se menciona en el procedimiento, tomamos solamente el primer ciclo para ambos vectores, donde los ciclos se repiten cada 125 datos, conformando los vectores v' y u' .

En este caso se realiza el proceso mencionado en este apartado y teniendo como resultado el vector R , cuyos valores se resumen en la figura 3.9 que muestra que el valor máximo encontrado para las iteraciones de Pearson se da en la posición 120, de tal forma que se desplaza el vector u , las 120 posiciones para conformar el vector u_{adj} de tal forma que ambos vectores coincidan en sus ciclos. En este caso, los vectores se ven en la figura 3.10, que muestra las señales sincronizadas en comparación con la figura 3.8

3.6. Filtrado de datos

Con miras de minimizar el ruido que se presenta en las señales, es decir, suavizar las señales, definimos un filtro por promedio donde se toma cinco grados para la media. El filtro emplea una ventana deslizante que recorre los datos del vector tomando cinco elementos consecutivos y cal-




Figura 3.8: Ejemplo de serie de tiempo, en negro v y en rojo u




Figura 3.9: Iteraciones de Pearson para los vectores v' y u'




Figura 3.10: Vectores v y u_{adj}

cula su media para definir cada elemento de un nuevo vector. En este caso, tomamos el vector $v = [x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}, \dots, x_n]$, de forma tal que encontramos los promedios de cada 5 elementos a partir de una ventana que recorre el vector y define cada nuevo elemento del vector de filtrado, esto se muestra a continuación:

$$v = [x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9, x_{10}, \dots, x_n]$$

A partir del vector v , se definen los términos del vector filtrado:

$$x_{f1} = \frac{(x_1 + x_2 + x_3 + x_4 + x_5)}{5}$$

$$x_{f2} = \frac{(x_2 + x_3 + x_4 + x_5 + x_6)}{5}$$

$$x_{f3} = \frac{(x_3 + x_4 + x_5 + x_6 + x_7)}{5}$$

$$x_{f4} = \frac{(x_4 + x_5 + x_6 + x_7 + x_8)}{5}$$

$$x_{f5} = \frac{(x_5 + x_6 + x_7 + x_8 + x_9)}{5}$$

.

.


.

$$x_{f(n-5)} = \frac{(x_{n-4} + x_{n-3} + x_{n-2} + x_{n-1} + x_n)}{5}$$

De forma que el vector filtrado es:

$$v_f = [x_{f1}, x_{f2}, x_{f3}, x_{f4}, x_{f5}, \dots, x_{f(n-5)}]$$

El inconveniente en este tipo de filtro, se presenta en que se pierden los cuatro últimos datos del conjunto de muestras, pero en comparación con los datos que se esperan que ingresen al algo-

Figura 3.11: Filtro del vector v

ritmo, no afectan en el análisis realizado.

Retomando el ejemplo, para el vector v aplicamos el filtro por promedio y el resultado se puede observar en la figura 3.11. En este caso, se observa que la señal v_f , que se encuentra en la parte inferior de la imagen, tiene un comportamiento mas suave en comparación con la señal v , que se encuentra en la parte superior de la figura, así mismo en comparación, el numero de elementos del vector v es de 2989, y el numero de elementos para la señal filtrada v_f es de 2985, donde se pierden los 4 últimos elementos debido al filtraje, pero solo equivale en este caso al 0,1338 % y que debido al volumen de los datos, no tiene afectación en el comportamiento de la señal analizada.

3.7. Normalización

Debido a que tenemos como ingreso al algoritmo dos fuentes de datos, una para las muestras capturadas por una persona experta, y otra de las muestras dadas por una persona no experta, se pueden tener diferencias en los valores de las muestras debido a que la fuerza puede variar o debido a la talla de las personas pueden ser diferentes. En miras que la comparación realizada por el algoritmo, no se vea afectada por lo descrito, se emplea una normalización, que para el caso, consistirá en que la escala de las dos muestras de datos sea la misma.

En este caso, definimos para el vector v , $x_{n_{max}}$ como la muestra con el valor más alto, y $x_{n_{min}}$, como la muestra con el valor mínimo. Definimos v_{norm} como el vector en donde sus elementos están dados bajo la fórmula

$$x_{i_{nor}} = \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

Ahora bien, la normalización entregada, ofrece que los valores se den entre -1 y 1. Para que la escala sea mayor, reajustamos la fórmula y lo ajustamos a valores entre -10000 y 10000, al multiplicarla por 10000, de forma que cada muestra normalizada se dará por:

$$x_{i_{nor}} = 10000 * \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

3.8. Análisis por DTW

Los anteriores pasos se enmarcan en el algoritmo dentro del ajuste de la señal y determinar los ciclos de la muestra. Así pues, retomando el concepto de serie de tiempo, se realiza un análisis en tres aspectos, a partir de las iteraciones de Pearson, se determina el componente cíclico y estacional de la señal, con el filtro aplicado a las señales se reduce el ruido y finalmente con la normalización, se pretende aportar a simplificar la comparación entre muestras al manejar entre ellas la misma escala.

El análisis por DTW tiene por objeto realizar una comparación propiamente, esto se realiza a partir de la determinación de la menor distancia entre las dos muestras y su aproximación a una recta de pendiente uno.

Para definir este proceso del algoritmo, definimos dos vectores $v = [x_1, x_2, x_3, x_4, \dots, x_n]$ y $u = [y_1, y_2, y_3, y_4, \dots, y_n]$, los cuales tienen la misma escala, son cíclicas con igual número de muestras por ciclo.

Si revisamos las distancias entre cada muestra de los dos conjuntos de datos, se puede crear una matriz de distancias, que se puede observar en la tabla 3.1. Para el caso, se define como la matriz de costos o matriz de distancias. En este caso existen distancias altas y distancias pequeñas.

y_n	$y_n - x_1$	$y_n - x_2$	$y_n - x_3$	$y_n - x_4$	\dots	$y_n - x_{(n-2)}$	$y_n - x_{(n-1)}$	$y_n - x_n$
$y_{(n-1)}$	$y_{(n-1)} - x_1$	$y_{(n-1)} - x_2$	$y_{(n-1)} - x_3$	$y_{(n-1)} - x_4$	\dots	$y_{(n-1)} - x_{(n-2)}$	$y_{(n-1)} - x_{(n-1)}$	$y_{(n-1)} - x_n$
$y_{(n-2)}$	$y_{(n-2)} - x_1$	$y_{(n-2)} - x_2$	$y_{(n-2)} - x_3$	$y_{(n-2)} - x_4$	\dots	$y_{(n-2)} - x_{(n-2)}$	$y_{(n-2)} - x_{(n-1)}$	$y_{(n-2)} - x_n$
\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot
\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot
\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot	\cdot
y_4	$y_4 - x_1$	$y_4 - x_2$	$y_4 - x_3$	$y_4 - x_4$	\dots	$y_4 - x_{(n-2)}$	$y_4 - x_{(n-1)}$	$y_4 - x_n$
y_3	$y_3 - x_1$	$y_3 - x_2$	$y_3 - x_3$	$y_3 - x_4$	\dots	$y_3 - x_{(n-2)}$	$y_3 - x_{(n-1)}$	$y_3 - x_n$
y_2	$y_2 - x_1$	$y_2 - x_2$	$y_2 - x_3$	$y_2 - x_4$	\dots	$y_2 - x_{(n-2)}$	$y_2 - x_{(n-1)}$	$y_2 - x_n$
y_1	$y_1 - x_1$	$y_1 - x_2$	$y_1 - x_3$	$y_1 - x_4$	\dots	$y_1 - x_{(n-2)}$	$y_1 - x_{(n-1)}$	$y_1 - x_n$
	x_1	x_2	x_3	x_4	\dots	$x_{(n-2)}$	$x_{(n-1)}$	x_n

Tabla 3.1: Matriz de costos

Cuando las distancias son pequeñas, las muestras son similares, y si las distancias son altas, las muestras son distantes.

Con la matriz de costos se define el camino más eficiente, es decir, se busca recorrer los datos de la matriz donde el costo sea menor. En este caso, la forma es partiendo de un punto $c = (i, j)$, se desea hacer un paso k para otro punto $c_k = (i_k, j_k)$, para lo cual se busca en sus tres lados adyacentes el valor mínimo de tal forma que vaya registrándose el mejor camino, considerando que el costo menor entre los datos representa la cercanía entre los datos en los conjuntos de datos. En caso de valores similares, el salto se realiza hacia su diagonal superior derecha. En este caso, partiendo desde la posición

$$(x_1, y_1) = (y_1 - x_1), \text{ que corresponde a la posición } c = (i, j)$$

$$\text{Sus lados adyacentes son } (x_2, y_1) = (y_1 - x_2), (x_2, y_2) = (y_2 - x_1), (x_1, y_2) = (y_2 - x_1);$$

Donde el salto $c_k = (i_k, j_k)$, se hará hacia el valor mínimo de estos lados adyacentes. es decir: $\min((y_1 - x_2), (y_2 - x_1), (y_2 - x_1))$

Si retomamos el ejemplo, con los datos iniciales para los vectores v y u , dados en el Apéndice C, para los primeros 125 datos, se puede observar el recorrido mencionado en la figura 3.12.

En este sentido se puede ver el acercamiento entre las dos señales, donde cada línea que unen las señales representa el camino óptimo encontrado en la matriz de costos, se ve en la figura 3.13

Hay que tener en cuenta que los ejemplos mostrados en este apartado, corresponden a las señales sin aplicarles filtros, sin normalizar ni ajustar, por lo cual se ven los saltos verticales y horizontales en el inicio y fin del recorrido encontrado por la matriz de costos.




Figura 3.12: Ejemplo DTW




Figura 3.13: Ejemplo DTW - Señales




Figura 3.14: Ejemplo DTW - Señales ideales

3.9. Análisis comparativo a partir de DTW y regresión lineal

Partiendo que la matriz de costos, podemos considerar que cuanto mayor es la aproximación entre dos señales, teniendo en cuenta que entre mas se aproximen las dos señales, el camino optimo encontrado de la matriz de costos tenderá a una diagonal secundaria, que en caso de representarlo en un plano similar a la figura 3.12.

Un caso ideal, donde los valores de una señal v , sean iguales a los valores u , tanto en el numero de datos, como en su comportamiento, la matriz de costo tendrá una diagonal secundaria con valores mínimos, y al mapearlos en un plano, esta tenderá a una recta $y = x$. Bajo esta idea, podemos hacer el análisis por DTW para el vector v sobre si mismo, y como resultado para los primeros 125 datos, se puede ver la figura 3.14. En este caso se superpone la recta con el mapeo en el plano.

A partir del mapeo encontrado por el camino optimo, podemos realizar una regresión lineal para describir el comportamiento de las dos señales. En este caso, se realiza a partir del método de mínimos cuadrados. La figura 3.12 y la figura 3.14, pueden asociarse desde la estadística a diagramas de dispersión, donde a partir de ellos se puede ver a simple vista, que en ambos casos, los datos tienen un comportamiento creciente y que se puede resumir al trazo de una recta. Con estas características, es posible hallar una recta de la forma $y = mx + b$, donde y toma el papel de la variable dependiente y x el de la variable independiente. En este caso, b corresponde al intercepto




Figura 3.15: Ejemplo DTW y regresión lineal

con el eje Y, y m corresponde a la pendiente de la recta. Para el caso de la regresión por mínimos cuadrados, la distancia entre la recta y cada uno de los puntos de dispersión de forma vertical debe ser la mínima posible. Así pues, la distancia entre cada punto de dispersión y la recta estimada, se conoce como error. Para el caso de la figura 3.12 que sale a partir de v y u para las primeras 125 muestras, se puede observar la regresión lineal generada en la figura 3.15. En este caso, la recta encontrada obedece a la ecuación $y = 0,9898x + 24,4590$, que se gráfica con la recta de color verde.

De esta forma podemos concluir que para que dos señales obedecen a un comportamiento similar, siempre y cuando la recta generadas a partir de la regresión lineal del mapeo del camino óptimo en un plano cartesiano, se aproximan al camino ideal, que corresponde a la recta $y = x$.

3.10. Algoritmo desarrollado

Acorde a lo mostrado en la figura 3.2, el primer paso es el importe de los datos y mostrarlos de forma gráfica.

- `Data.Vector.1[] <- Datos de la persona experta`
- `Data.Vector.2[] <- Datos de la persona no experta`

- `Plot(Data.Vector.1[],Data.Vector.2[])`

Luego, Se realiza el análisis de Pearson para cada señal y como resultado se obtiene la señal resultado de las iteraciones de Pearson y el periodo de la señal, es decir, cada cuantos datos

hay una repetición del movimiento. En este caso, si los periodos de las dos señales son iguales, corresponde a que las dos personas realizan el mismo numero de movimientos en el mismo tiempo y da pie a continuar con el análisis comparativo. En este caso se muestra el resultado de las señales generadas con las iteraciones de Pearson.

- *PearsonNumberCicle1; PearsonSignal1[] <- PearsonIteration(Data.Vector1[])*
- *PearsonNumberCicle2; PearsonSignal2[] <- PearsonIteration(Data.Vector2[])*
- *Plot(PearsonSignal1[], PearsonSignal2[])*
- *if (PearsonNumberCicle1 = PearsonNumberCicle2)*
{
CicleEqual <- PearsonNumberCicle1 = PearsonNumberCicle2
Continue... }
Else {
"The period of the samples is different" }

Si el periodo de las muestras es igual, se procede a sincronizar los datos a partir del análisis de Pearson mostrado en la sección de "ajuste de datos" de las dos señales. Por otro lado, procedemos a que ambas señales inicien en el primer máximo acorde a las iteraciones de Pearson y que las dos señales tengan el mismo numero de elementos.

- *...Continue*
- *Data.Vector1; Data.Vector2 <- PearsonSync(Data.Vector1[], Data.Vector2[], CicleEqual)*
- *Aux1[] <- Data.Vector1[1:CicleEqual]*
- *Aux2[] <- Data.Vector2[1:CicleEqual]*
- *PosMaxAux1 <- Position where the maximum value is found for Aux1[]*
- *PosMaxAux2 <- Position where the maximum value is found for Aux2[]*
- *Tam1 <- number of samples from Data.Vector1[]*
- *Tam2 <- number of samples from Data.Vector2[]*
- *Data.Vector1[] <- Data.Vector1[PosMaxAux1: Tam1]*

- *Data.Vector2[] <- Data.Vector2[PosMaxAux2: Tam2]*

- *if (Tam1 < Tam2)*
 - {*
 - Tam <- Tam1*
 - } else{*
 - Tam <- Tam2*
 - }*

- *Data.Vector1[] <- Data.Vector1[1: Tam]*
- *Data.Vector2[] <- Data.Vector2[1: Tam]*

Una vez las señales se encuentran sincronizadas y del mismo número de muestras, se realiza el filtrado de las señales para eliminar el ruido y se realiza la normalización de las señales para ajustar los datos a una misma escala según el procedimiento mostrado en las secciones "Filtrado de datos" y "Normalización". En este punto se muestran las señales resultantes.

- *Data.Vector.1[] <- NormalizedData(Data.Vector.1[])*
- *Data.Vector.2[] <- NormalizedData(Data.Vector.2[])*

- *Data.Vector.1[] <- FilterData(Data.Vector.1[])*
- *Data.Vector.2[] <- FilterData(Data.Vector.2[])*

- *Plot(Data.Vector1[], Data.Vector2[])*

Lo anterior obedece a la importación y ajuste de las señales. ahora, se debe realizar la comparación como tal, para lo que se acude al algoritmo DTW. En este caso, según la sección anterior, en Análisis por DTW, se obtiene a partir de una matriz de diferencias, el camino con los menores valores, y que en este caso se pueden representar a partir de una regresión lineal. En este caso, la función de comparación nos entrega como insumos para la comparación, los valores de m y b para la representación de la recta ($y = mx + b$). Por otro lado, el valor de "R-squared", quien determina si los valores se aproximan a la recta en mayor o menor medida, así como su representación gráfica.

Es importante mencionar, que lo descrito para la comparación se puede realizar tanto al principio (para las muestras originales) y al final (para las muestras ajustadas). Recordemos que cuando dos señales son iguales, la recta corresponde $y = x$. Así que debemos determinar que tanto se aproxima la recta de regresión encontrada a ésta, de forma tal que nuestro parámetro que determina si los movimientos realizados son semejantes se da cuando la diferencia entre cada punto que compone nuestra recta de regresión, contra la recta ideal, tienden a cero y cuando el R-squared

tiende a uno. Hay que tener en cuenta que el análisis se debe realizar solo con una muestra de toda la señal generada, así que para ello determinamos de forma aleatoria realizar el análisis de la señal solo para uno de los ciclos de cada muestra.

- *SampleLimit* <- (*WholePart(Tam)/CicleEqual*)-1
- *Initial.Sample* <- (*RandomSample(1:SampleLimit)*)**CicleEqual*
- *Final.Sample* <- *Initial.Sample* + *CicleEqual*
- *m;b;R-squared* <- *DTWFunction(Data.Vector.1[Initial.Sample:Final.Sample]; Data.Vector.2[Initial.Sample:Final.Sample])*
- *Dif[]* <- Valor absoluto de la diferencia entre la recta $y = mx + b$ y ya recta $y = x$ para cada punto
- *DiferenceMesur* <- *mean(Absolute Value(Dif))*
- *if (DiferenceMesur \doteq 0 AND R-squared \doteq 1)*
 - {
 - "The movements are similar"*
 - } else{
 - "the movements are different"*
 - }
- *Plot(straight lines, Difference of signals)*

Capítulo 4

Validación del algoritmo y casos de estudio

Resumen del capítulo

En el capítulo 4 se explora la validación del algoritmo planteado en el capítulo 3 a partir de datos obtenidos en un entorno controlado. Para ellos primero se realiza el planteamiento del experimento, donde se muestra las características de los participantes. Luego se explica como se realizó la creación del set de datos, el sitio web donde se pueden descargar junto con los vídeos capturados y los movimientos realizados. Finalmente se muestran los resultados del algoritmo cuando las muestras son semejantes y cuando las muestras son diferentes.

4.1. Planteamiento del Experimento

El sistema propuesto se basa en la arquitectura resumida en el capítulo 2 y vista a profundidad en el Apéndice B donde proponen el componente wearable, el componente de integración y el componente de plataforma para la recolección y análisis de los datos. Recordemos que, el componente wearable es responsable de obtener datos sobre los movimientos realizados mediante el uso de sensores ubicados en el cuerpo del usuario, detectar estos movimientos y transmitirlos a través de Bluetooth al componente de integración. El componente de integración, a través de un dispositivo móvil (tableta o teléfono inteligente) conectado a través de Bluetooth al dispositivo wearable recibe los datos generados por el usuario y, después del procesamiento preliminar, los datos se envían a una plataforma. En este caso, se utiliza la potencia de procesamiento del dispositivo móvil y se proporciona interacción con el usuario a través de una aplicación. El componente de plataforma debe ser capaz de recibir la información enviada a través del componente de integración, y ésta se procesa y almacena para realizar retroalimentación.

El funcionamiento del sistema planteado se resume en la figura 2.8 donde, el proceso comienza con el profesor cargando un vídeo instructivo. Luego, el profesor usa el dispositivo portátil para cargar los movimientos al sistema para después enviar a través del componente de integración a la plataforma. A su vez, el estudiante también carga estos movimientos con el dispositivo portátil y estos movimientos se envían a la plataforma a través del componente de integración. Para ambos

casos, los movimientos se almacenan en la plataforma. El sistema carga ambos movimientos para poder compararlos y, una vez comparados, se muestran los resultados.

4.2. Creación del set de datos

Para este caso se encontraron dos alternativas la captura de los datos a partir de los movimientos del cuerpo. En primer lugar se realizó un desarrollo dispositivo a modo de prototipo con base a una metodología propuesta para el desarrollo de dispositivos wearable [320]. Por otra parte se propone también emplear la aplicación *accelerometer meter*, usando el dispositivo móvil directamente como wearable. [321].

El dispositivo wearable desarrollado a modo de prototipo se realizó con el uso del dispositivo YJ-16009-NRF-51822, el cual es capaz de recolectar los datos a partir de un acelerómetro integrado. Los datos se tomaron con una frecuencia de muestreo de 50Hz y una frecuencia de envío de 60ms. Estos datos son enviados a través de Bluetooth Low Energy (BLE) para finalmente ser recolectados con una aplicación alojada en un dispositivo móvil, en este caso, desarrollado en un entorno android.

Otra forma de captura de datos a partir de los movimientos del cuerpo humano, se realiza a través de la aplicación *accelerometer meeter*, (keuwl, 2018), versión 1.3 o superior. La aplicación se puede usar en dispositivos móviles que tengan sensores de aceleración y sistema operativo Android 2.3 o superior y está disponible de forma gratuita en Playstore de Android. Con la aplicación se puede ver o registrar la salida de datos del acelerómetro del dispositivo móvil.

En ambos caso, el resultado entrega información de los datos capturados a partir de la aceleración generada por los los movimientos del cuerpo. Los datos recolectados tienen un comportamiento a modo de serie de tiempo multivariante, donde se tiene por cada intervalo de tiempo t , los datos de la aceleración en los ejes x , y y z en medidas de g o m/s^2 .

En esta experiencia se emplea el dispositivo YJ-16009-NRF-51822.

Para la creación del dataset, se pone a consideración un contexto de enseñanza/aprendizaje de una habilidad motriz que involucre movimientos periódicos. Se escoge así tres pasos del baile de salsa como movimientos para la creación del dataset.

Para la captura de los movimientos, se seleccionan tres personas, que son instructores de baile y cuyas características se resumen en la tabla 4.1

El baile de salsa, consta de pasos que se realizan acorde al ritmo de la canción con la cual se realice el baile, pero para efectos prácticos, en este caso se toma como medida 96 BPM, que es la frecuencia empleada para la enseñanza de los movimientos básicos para este baile. Para ello se toma la ayuda de una aplicación *Metronome beats*, la cual determina la velocidad del movimiento

	User 1	User 2	User 3
Age	28	25	21
Height	174cm	166cm	179cm
Weight	86Kg	66Kg	75Kg

Tabla 4.1: user characteristics

Step forward - backward	User 1	https://youtu.be/edGEdkCaSwM
	User 2	https://youtu.be/AStaTSjhMgU
	User 3	https://youtu.be/8bcM9MrA5Z8
Step back - back	User 1	https://youtu.be/KgBHLQuLmio
	User 2	https://youtu.be/BZz5Nm8zivs
	User 3	https://youtu.be/qyIjId91_5U
Step slide - slide	User 1	https://youtu.be/LRs7FhQZVeI
	User 2	https://youtu.be/tPPCZ3zAFD0
	User 3	https://youtu.be/gWcUhOwcf1w

Tabla 4.2: User video salsa steps

durante la prueba, el comienzo y el final de cada paso. Las muestras se tomaron en un tiempo de 1 minuto, por cada paso se tomaron 3 muestras. En la tabla 4.2, se encuentran los links de acceso a los videos capturados en la experiencia de los diferentes pasos y las personas que los realizaron.

Para garantizar uniformidad en las muestras, se colocan marcas en el piso, una marca en el lado izquierdo, una en el lado derecho, una en el frente, otra en el centro y tres atrás. Cada marca tiene una distancia de 30 cm con respecto a la central, para así delimitar la zona de acción, es decir, el golpe del pie al realizar el paso de baile. El sensor, en este caso se ubica en el tobillo derecho de las personas que realizaron los pasos de baile (figura 4.1). El montaje para las tres personas se puede observar en la figura 4.2

Los pasos de baile son "paso lateral", "Paso adelante-atrás" y "Paso atrás-atrás", que se representan a través de la figura 4.3. La convención indica que la silueta del pie oscura, representa que toda la parte oscura se encuentra en contacto con el suelo, mientras que la silueta donde solo la punta del pie está oscuro, representa que la parte gris del pie se encuentra en el aire, es decir, hace un levantamiento leve de la planta del pie, flexionando la rodilla y dejando la punta del pie sobre el suelo. Cada recuadro representa cada momento que se marca a partir del sonido del metrónomo.

De acuerdo a lo anterior, se consigue recopilar un conjunto de datos a partir de estos tres pasos. Cada persona involucrada realizó tres muestras de cada paso y los datos quedan registrados en documentos en formato .csv para su posterior análisis. Cada documento consta de tres campos que corresponden a los ejes "x", "y" y "z"

La estructura de los datos se puede observar en la figura 4.4. Se observa que cada registro corresponde a lecturas realizadas por el acelerómetro en cada instante de tiempo. Se obtienen los datos para el eje x en la columna AXX , el eje y en la columna AYY y el eje z en la columna



Figura 4.1: Ubicación de dispositivo wearable



Figura 4.2:




Figura 4.3: Ejemplo DTW - Señales ideales

AZZ . En este caso se encuentra en unidades de $100 * m/s^2$. En la columna ACC_TOTAL , se encuentra la magnitud que se da a partir de los datos x , y y z bajo la fórmula $\sqrt{x^2 + y^2 + z^2}$

4.3. Resultados del algoritmo

El dataset recopilado, se emplea para realizar comparación entre las muestras y determinar que tanto grado de proximidad hay entre ellas acorde al algoritmo planteado [330]. Para este caso, se propone que la diferencia entre las rectas de regresión se estime a valores menores a 10 y que el R-squared sea mayor a 0,9. Las comparaciones que se den bajo estos parámetros indicará la similitud en los movimientos. Del data set se tomará como muestra del experto, los movimientos correspondientes al Usuario 1, y como personas no expertas el Usuario 2 y Usuario 3.

Se mostrarán los casos encontrados al correr el algoritmo.

4.3.1. Las muestras son semejantes

Los datos se obtienen en el dataset de:

DatasetExpertSample : User1BackBackSample1

DatasetNon - ExpertSample : User2BackBackSample3

	AXX	AYY	AZZ	ACC_TOTAL
1				
2	-751	678	101	1016.8018489361632
3	-702	724	120	1015.568806137723
4	-682	748	107	1017.8786764639488
5	-700	725	95	1012.2499691281794
6	-665	729	83	990.2297713157285
7	-684	711	67	988.8710734974504
8	-697	711	50	996.9102266503238
9	-712	711	40	1007.0079443579381
10	-708	691	37	990.0070706818209
11	-731	697	36	1010.6760113903961
12	-707	722	40	1011.3026253303212
13	-698	727	14	1007.9330334898247
14	-717	735	8	1026.8290997045224
15	-745	744	23	1053.1334198476468
16	-773	821	36	1128.213632252332

Figura 4.4: Ejemplo data set

El análisis por las iteraciones de Pearson muestra que las dos muestras tienen el mismo periodo de repetición, y que las muestras se repiten cada 124 datos, por lo tanto cumple el primer criterio de semejanza.

$$PearsonNumberCicle1 = 124$$

$$PearsonNumberCicle2 = 124$$

El valor aleatorio en este caso arroja que las muestras se tomaran entre:

$$Initial.Sample = 372$$

$$Final.Sample = 496$$

La figura 4.5 muestra en la parte izquierda el resultado de las iteraciones de Pearson realizadas. En el centro las señales originales, en azul la señal correspondiente a la persona experta y en negro, la señal de la persona no experta. A la derecha muestra las señales después de sincronizarlas, filtrarlas y normalizarlas.

La figura 4.6 muestra en su parte izquierda la recta generada a partir del análisis por DTW en color verde. En color rojo, se muestra la recta ideal y en negro, las coordenadas generadas por los puntos encontrados a partir del DTW. En la parte derecha se muestra la representación de las distancias encontradas para las dos señales con el ajuste dado por el algoritmo DTW.

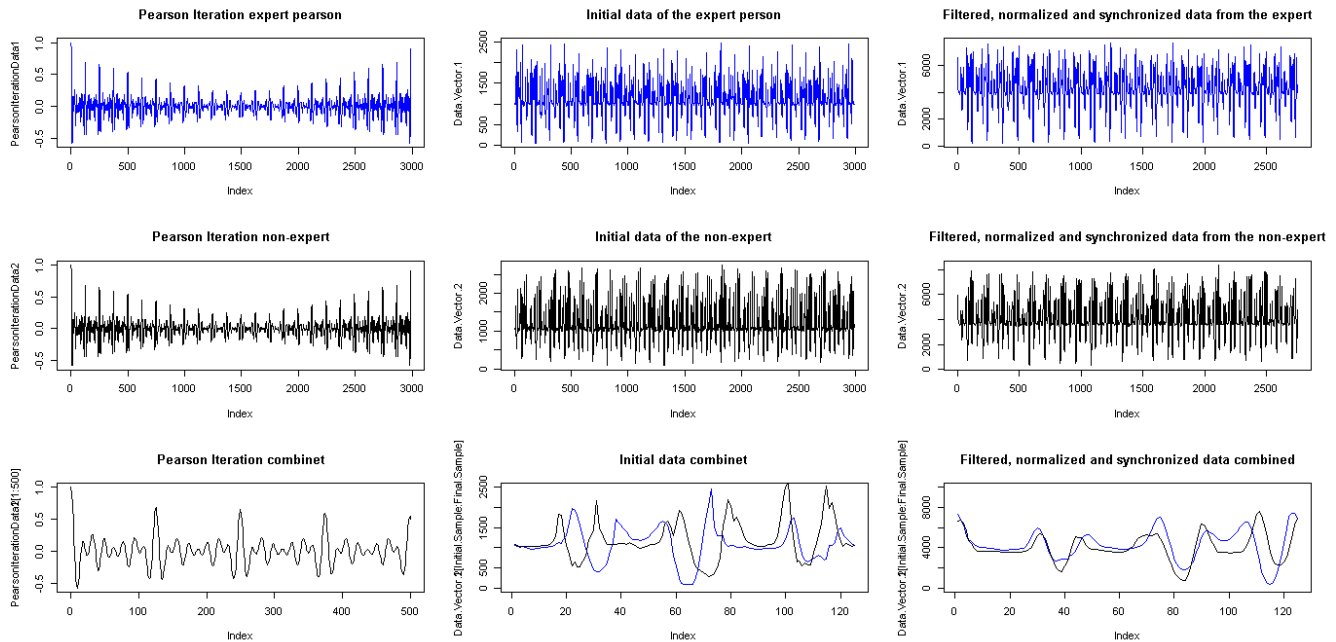


Figura 4.5: Señales cuando las muestras son similares

Como resultado tenemos que:

$$R - Squared = 0,9867$$

$$Diferenciaentre las rectas = 0,903803$$

En este caso se cumplen las tres condiciones, las señales son periódicas y su periodo se da cada 124 muestras; su R-Squared es mayor que 0,9 y la diferencia de las rectas es menor que 10. Por lo tanto, se puede deducir que los movimientos son similares.

4.3.2. Las muestras son diferentes $R - Squared < 0,9$; Regresión < 10

Los datos se obtienen en el dataset de:

DatasetExpertSample : User1BackBackSample1

DatasetNon - ExpertSample : User2BackBackSample1

El análisis por las iteraciones de Pearson muestra que las dos señales se repiten cada 124 datos, por lo tanto cumple el primer criterio de semejanza.




Figura 4.6: Resultados cuando las muestras son similares

$PearsonNumberCicle1 = 124$

$PearsonNumberCicle2 = 124$

El valor aleatorio en este caso arroja que las muestras se tomaran entre:

$Initial.Sample = 744$

$Final.Sample = 868$

La figura 4.7 muestra las señales de las iteraciones de Pearson, las Señales iniciales y las señales después de procesarlas.

La figura 4.8 la representación del resultado de la comparación.

Como resultado tenemos que:

$R - Squared = 0,8482$

$Diferenciaentrelasrectas = 6,355008$

Al no cumplir con el criterio definido, en este caso, los movimientos son diferentes.

Las muestras son diferentes $R - Squared > 0,9$; $Regresin > 10$

Los datos se obtienen en el dataset de:

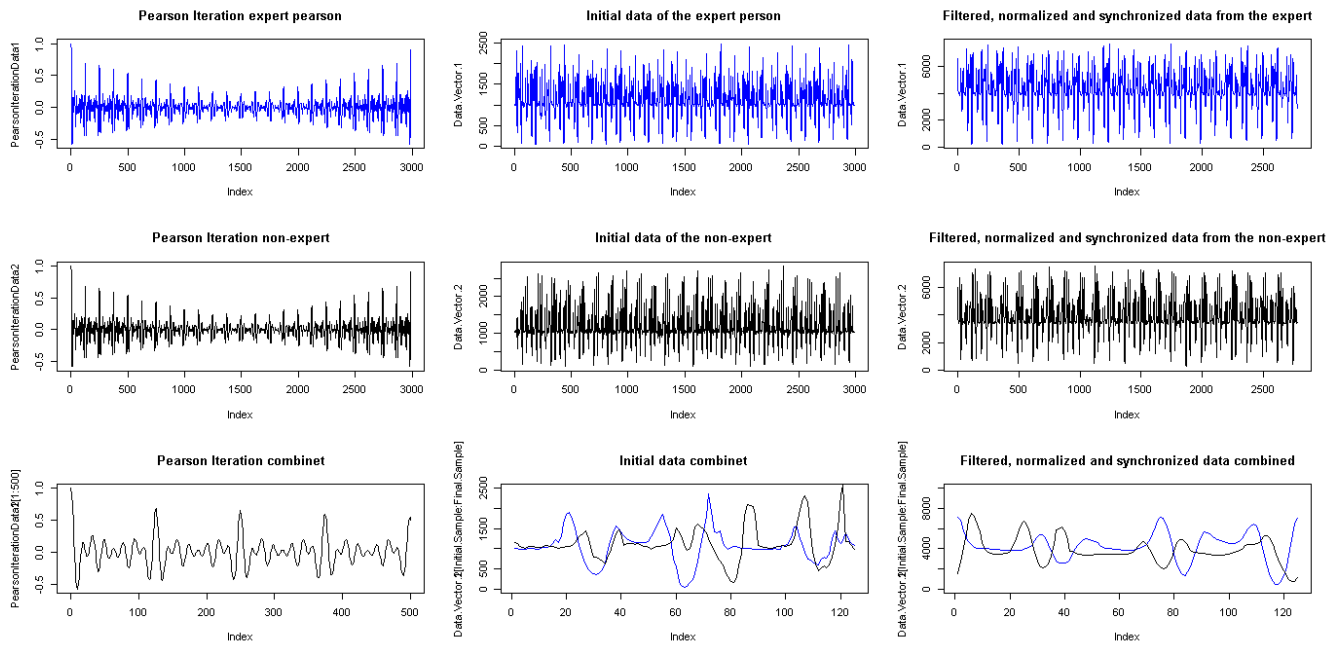


Figura 4.7: Señales cuando las muestras son diferentes cuando $R - Squared < 0,9$; Regresión < 10




Figura 4.8: Resultados cuando las muestras son diferentes cuando $R - Squared < 0,9$; Regresión < 10

DatasetExpertSample : User1ForwardBackwardSample1

DatasetNon – ExpertSample : User3ForwardBackwardSample2

El análisis por las iteraciones de Pearson muestra que las dos señales se repiten cada 125 datos, por lo tanto cumple el primer criterio de semejanza.

PearsonNumberCicle1 = 125

PearsonNumberCicle2 = 125

El valor aleatorio en este caso arroja que las muestras se tomaran entre:

Initial.Sample = 1625

Final.Sample = 1750

La figura 4.9 muestra las señales de las iteraciones de Pearson, las Señales iniciales y las señales después de procesarlas.

La figura 4.10 la representación del resultado de la comparación.

Como resultado tenemos que:

R – Squared = 0,9099

Diferenciaentrelasrectas = 15,80045

Al no cumplir con el criterio definido, en este caso, los movimientos son diferentes.

Las muestras son diferentes, las muestras tiene periodos diferentes

Los datos se obtienen en el dataset de:

DatasetExpertSample : User1ForwardBackwardSample3

DatasetNon – ExpertSample : User2ForwardBackwardSample2

El análisis por las iteraciones de Pearson muestra que las dos señales tienen diferente periodo.

PearsonNumberCicle1 = 13

PearsonNumberCicle2 = 124

La figura 4.11 muestra las señales de las iteraciones de Pearson, las Señales iniciales y las señales después de procesarlas.

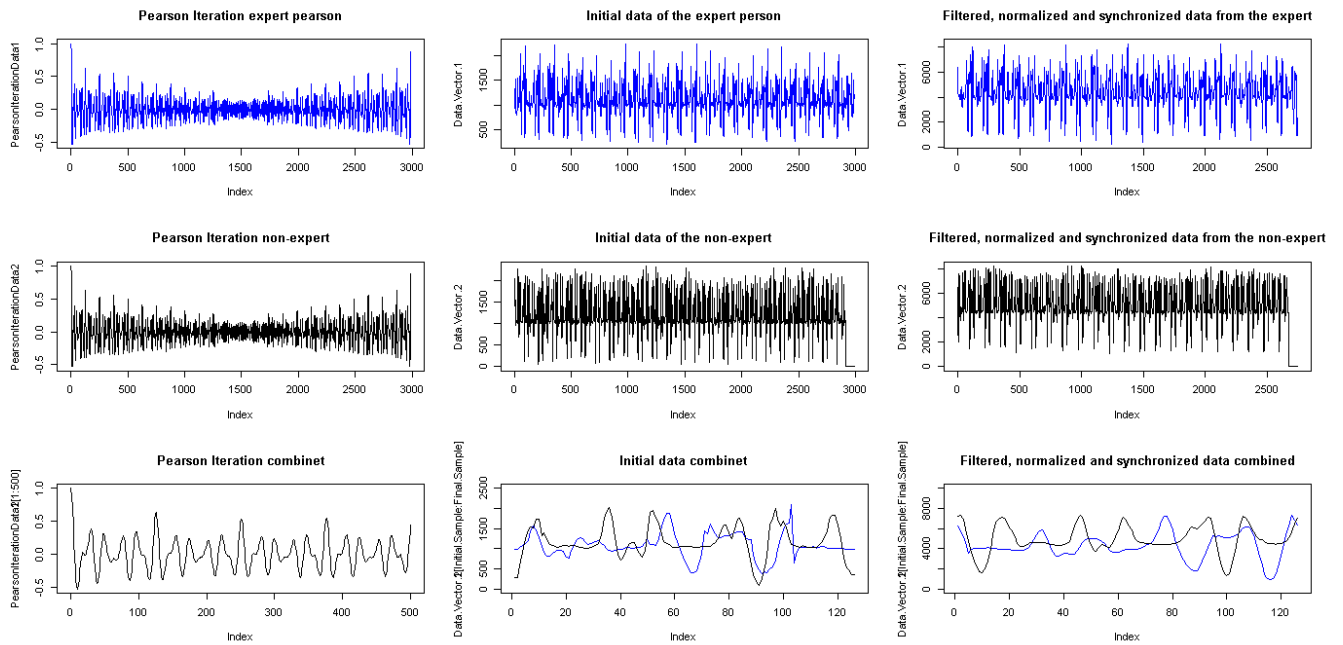


Figura 4.9: Resultados cuando las muestras son diferentes cuando $R-Squared > 0,9$; $Regresin > 10$




Figura 4.10: Resultados cuando las muestras son diferentes cuando $R-Squared > 0,9$; $Regresin > 10$

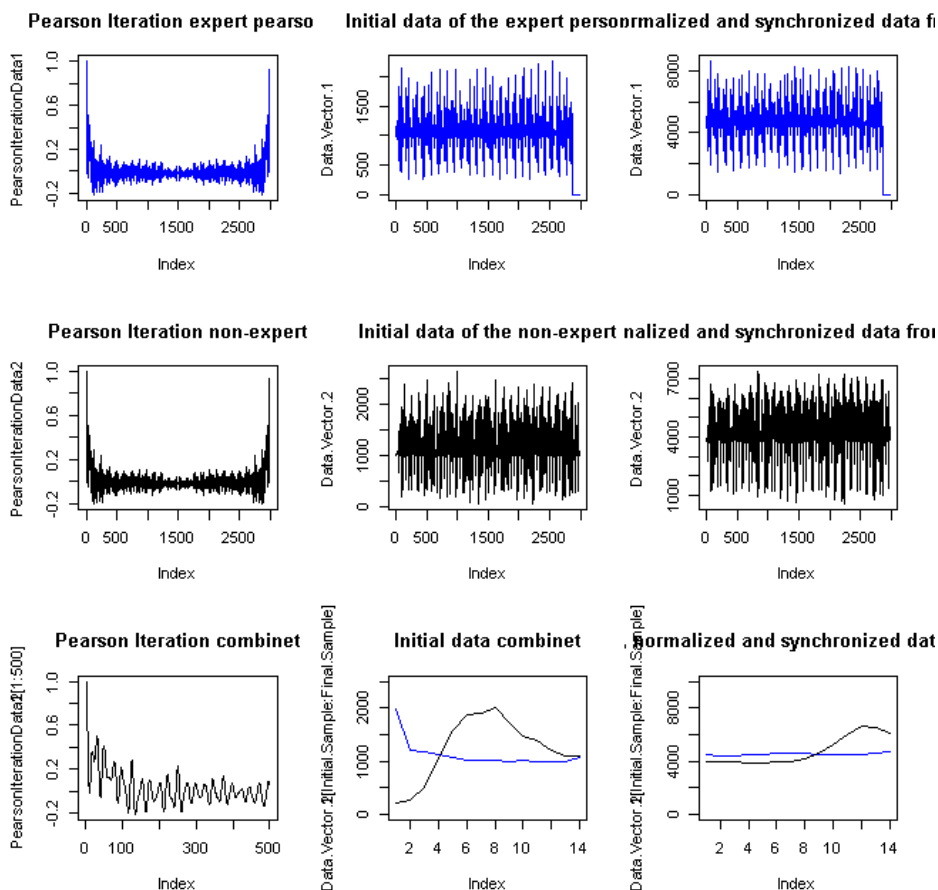


Figura 4.11: Señales cuando las muestras tienen diferente periodo

La figura 4.12 la representación del resultado de la comparación.

Como resultado tenemos que:

$$R - Squared = 0,5407$$

$$Diferenciaentrelasrectas = 2,126166$$

Al no cumplir con el criterio de periodos iguales, los movimientos son diferentes.

En el primer caso, donde "las muestras son semejantes", la figura 4.5, que mapea las diferencias menores a partir de DTW, se observa que este mapeo tiende a la recta ideal, por lo tanto la regresión lineal también tiende a esta recta ideal, de allí que m tiende a 1 y b tiende a 0. el R -Squared tiende a 1, por lo que se observa que las diferencias no se alejan de la regresión lineal. La figura 4.6, corrobora que las dos señales se aproximan bastante una a la otra y por lo tanto los movimientos son semejantes.




Figura 4.12: Resultados cuando las muestras tienen diferente periodo

En el segundo caso, donde las muestras son diferentes $R\text{-squared} < 0,9$ y la Diferencia de rectas < 10 , se puede observar que la recta generada a partir de la regresión lineal se aproxima a la recta ideal, pero el $R\text{-Squared}$ se aleja de 1, lo que implica que los datos se encuentran dispersos respecto a la recta de regresión. Esta dispersión implica que el algoritmo realiza saltos sobre un mismo punto para lograr un valor óptimo, que conlleva valores altos. En la figura 4.8 en la parte derecha muestra lo anteriormente mencionado, donde se observa un distanciamiento alto entre las dos señales. Este distanciamiento muestra que entre picos y valles, la correspondencia se da en diferentes momentos para cada señal, que se puede traducir en que los movimientos se pueden estar haciendo, pero en momentos diferentes. En el caso particular mostrado, se puede observar que las señales difieren en el centro, principalmente, lo que indicaría que en estos momentos se distorsiona el movimiento. Mientras que en el extremo izquierdo, hasta cerca del valor 50, las señales se aproximan bastante. En el extremo derecho, cerca del valor 100 a 124, vuelven a aproximarse las señales. La lectura implicaría que el usuario debe corregir los movimientos que se encuentran en la mitad de la actividad, ya que estos inician y terminan de la forma correcta.

En el tercer caso, donde las muestras son diferentes con $R\text{-squared} > 0,9$, y la diferencia entre la recta ideal y la recta de regresión es > 10 . En este caso, al ser alta la diferencia entre las dos rectas, implica que la regresión lineal no representa el movimiento de la persona experta y que por ende los movimientos son diferentes. Esto se corrobora en la figura 4.10, en la parte izquierda, donde se observa que las dos señales no corresponden. En este caso, el usuario debe mejorar el movimiento.

En el cuarto caso, las muestras tienen periodos diferentes, por lo tanto los movimientos no son semejantes, lo que se muestra en las figuras 4.11 y 4.12. Aquí se observa que no se generan las iteraciones de Pearson en forma regular, como en los casos anteriores. Las señales tampoco coinciden. En este caso, el usuario debe en primer instancia intentar de tener la misma periodicidad en los movimientos que los observados en la persona experta.

Capítulo 5

Disposiciones Finales

Resumen del capítulo

En el capítulo 5, aborda la discusión y análisis al redor de las contribuciones desarrolladas en esta tesis doctoral. Luego plantea las diferentes conclusiones a las que se llega a partir de la investigación doctoral y finalmente se plantea una serie de trabajos futuros en miras de dar continuidad a esta investigación.

5.1. Discusión y análisis

La investigación propuesta parte del interés de encontrar una forma de realimentación adecuada en un contexto de la enseñanza y aprendizaje de habilidades motrices, donde se encuentra un nicho de investigación atractivo para abordar. Por casualidad, en el momento que se abordaba este trabajo, en el año 2020 surge la crisis sanitaria mundial a raíz del COVID 19, que obligó prácticamente al mundo entero en tomar medidas para combatir la pandemia, siendo una de ellas el aislamiento social, donde gran parte de las personas fueron obligadas a permanecer en sus hogares. Es aquí donde se intensifica el aprendizaje autónomo en lo que concierne a habilidades motrices, donde muchas personas bien sea por entretenimiento, pasatiempos, salud, entrenamiento deportivo u otra razón, tomaron como medio para recibir y seguir instrucciones para ello los televisores, tabletas, smartphone o computadoras, bien sea a través de videoconferencia con un instructor o simplemente, retomando el aprendizaje por imitación, imitando los movimientos que ven en los dispositivos. En todo caso, se muestra que la impersonalidad y la falta de realimentación en estos casos, se vivió día a día en esta emergencia sanitaria. Esta acción fortalece aún más los principios de esta investigación de encontrar formas de realimentar a las personas que desean tener un aprendizaje en un entorno virtual.

En el análisis de antecedentes, para el desarrollo de este trabajo, cobró relevancia el uso de software para análisis bibliométrico. En este caso, se emplearon distintas herramientas con las que se hicieron pruebas y se obtuvieron resultados empleados en la investigación. En la actualidad la gran cantidad de información encontrada en el campo y en las bases de datos de la literatura

especializada, da pie a que se busquen formas de sistematizar ésta. De allí nace la idea de indagar en los diferentes abstracts que se hace un aporte interesante en el uso de lenguaje R para hacer un análisis de corpus con los abstracts encontrados logrando de esta forma sintetizar la información y mostrarla a través de los gráficos de nubes de palabras y dendogramas. A través de esta acción se realiza una contextualización en el área de interés y es un aporte interesante que abre posibilidades para su uso en futuras investigaciones que requieran abordar un alto número de documentos para analizar los antecedentes y construir el estado del arte.

En el desarrollo del dispositivo empleado, es importante mencionar que a partir del trabajo desarrollado en el marco de esta tesis doctoral, la aproximación metodológica expuesta abre un gran número de posibilidades para el desarrollo de dispositivos a partir de diferentes requerimientos. Además de ello, otra brecha que se encuentra en la literatura, se da en el alto costo que conlleva la investigación en realimentar habilidades motrices en un contexto virtual, puesto que se encuentran diferentes investigaciones que lo consiguen, pero bajo entornos de laboratorios o el uso de dispositivos con alto costo y no accesibles al común de las personas. Un aporte importante en este trabajo se da en el empleo de tecnologías de bajo costo y que sean al alcance del común de las personas. En este caso, el algoritmo es independiente a la forma en que se capturen los datos, solamente se condiciona a que los datos que sean capturados tengan el mismo epoch y que la frecuencia de captura de datos sea la misma. Lo anterior abre la puerta para que se puedan capturar datos a partir de diferentes dispositivos. Así pues una alternativa que se plasma en esta investigación, es que la captura se da a través de una aplicación en un smartphone y este a su vez pueda ser anclado al cuerpo de una persona a modo de dispositivo wearable. Pero también es posible, emplear dispositivos wearables comerciales como smartband o smartwatch, o diseño a través de otras tecnologías de fácil programación y acceso como Arduino para hacer la captura de los datos. A la fecha de esta publicación, se está indagando en el uso de smartband y smartwatch con programación abierta para la captura de datos.

En las investigaciones halladas en este contexto, se observa una marcada tendencia a emplear algoritmos de machine learning para hacer reconocimiento y clasificación de los movimientos. En el caso de esta investigación, otra brecha es abordada al encontrar que el algoritmo utilizado haga una comparación entre los movimientos realizados por dos personas. En este caso, en términos prácticos, el algoritmo desarrollado no requiere que se tenga un conjunto de datos para hacer la comparación, es decir, no se requieren datos de entrenamiento para su uso. El uso de los datos se puede hacer de forma inmediata, de forma tal que se puede usar en muchos contextos en los que no se tengan previamente almacenados datos. Esta característica da pie a pensar en que el algoritmo desarrollado no solamente puede encontrar un uso práctico en un contexto educativo, sino que puede brindar posibilidades de estudio en campos como entrenamiento deportivo, la recuperación de lesiones, pruebas para adecuar el uso de prótesis y otros campos en el que la comparación de los datos abra posibilidades de estudios.

5.2. Conclusiones

A partir del trabajo realizado en este trabajo de investigación se puede concluir lo siguiente:

5.2.1. Conclusiones capítulo 1

- En la literatura indagada muestra que los esfuerzos se vienen desarrollando en la temática de realimentación en la enseñanza y aprendizaje en habilidades motrices, se encaminan a la clasificación, detección o reconocimiento de movimientos.
- La literatura conlleva a que es relevante hacer un estudio a partir de la captura de datos inerciales asociados a movimientos humanos.
- El contexto en las investigaciones indagadas apunta a costos elevados y uso de laboratorios para conseguir datos para hacer una realimentación, lo que abre una posibilidad de investigación en el indagar formas para conseguir datos accesibles a personas del común.
- La literatura muestra que hay una oportunidad de investigación al usar el aprendizaje por imitación en un contexto virtual y en este sentido buscar un algoritmo que se base en la comparación.

5.2.2. Conclusiones capítulo 2

- Es necesario el uso de arquitecturas software para abordar este tipo de sistemas. Una arquitectura permite abordar problemáticas complejas para concretar formas de abordarlas. Se propone entonces, una la arquitectura que resume el planteamiento inicial de la solución. En ella se indaga diferentes soluciones en términos de requerimientos y desarrollo del sistema en forma general.
- La captura de datos asociadas al movimiento de las personas es posible hacerlo a través de dispositivos wearables que cuenten con los sensores inerciales adecuados. En este caso se presentan la opción de desarrollar el dispositivo ó emplear una aplicación de un smartphone.
- En esta investigación, el estudio de las series de tiempo, se vuelve la base fundamental para lograr una comparación a partir de los datos recolectados por un dispositivo wearable.

5.2.3. Conclusiones capítulo 3

- Se acuña el termino de iteraciones de Pearson como procedimiento para determinar la ciclicidad del las series temporales que provienen de movimientos periódicos.
- Es necesario un procesamiento que adecue las señales preparándolas para conseguir una resultados adecuados en una comparación. Se deben sincronizar las dos series de tiempo periódicas, filtrarlas para reducir el ruido y normalizarlas para adecuar su escala.

- A partir de DTW y regresión lineal se consigue realizar una comparación entre dos series de tiempo periódicas.

5.2.4. Conclusiones capítulo 4

- Los resultados encontrados conllevan a 4 niveles de comparación. El primero es cuando las muestras son semejantes. El segundo caso se da cuando las muestras difieren, pero en este caso, los movimientos son realizados pero en momentos diferentes. El tercer caso, a pesar que los periodos en que se realizan los movimientos coinciden, los movimientos son diferentes. Finalmente el cuarto caso se da cuando las señales no coinciden puesto que los periodos no coinciden.

5.3. Trabajos futuros

En miras de continuar la investigación, se plantean los siguientes trabajos a futuros:

- Se hace necesario indagar en realizar la captura de movimientos a partir de dispositivos wearable comerciales como smartphone o smartband.
- A demás de medidas inerciales, se puede pensar en integrar para hacer estudios otras señales que pueden arrojar los dispositivos wearables, por ejemplo integrar las señales HR que dan los smartwatch o smartband.
- Se propone hacer el estudio en un ámbito con señales multivariantes, por ejemplo a demás de las medidas inerciales de aceleración, integrar las señales que provengan de un giroscopio.
- Se propone que a futuro se pueda optimizar el algoritmo para que se pueda implementar en condiciones de inmediatez como el tiempo real.

Bibliografía

- [1] Albert Bandura y Ángel Rivière. “Teoría del aprendizaje social”. En: (1982).
- [2] Acero José y col. *Biomecánica deportiva y control del entrenamiento*. Vol. 4. Funámbulos Editores, 2009.
- [3] Mario Munoz-Organero y Ahmad Lotfi. “Human movement recognition based on the stochastic characterisation of acceleration data”. En: *Sensors* 16.9 (2016), pág. 1464.
- [4] Vandrico-Inc. *Wearable Technology Database*. Nov. de 2017. URL: <http://vandrico.com/wearables/wearable-technology-database>.
- [5] Ilona Buchem, Agathe Merceron, Jörn Kreutel, Marten Haesner y Anika Steinert. “Designing for User Engagement in Wearable-technology Enhanced Learning for Healthy Ageing.” En: *Intelligent Environments (Workshops)*. 2015, págs. 314-324.
- [6] Wentao Dong, Lin Yang, Raffaele Gravina y Giancarlo Fortino. “ANFIS fusion algorithm for eye movement recognition via soft multi-functional electronic skin”. English. En: *INFORMATION FUSION* 71 (2021), 99-108. ISSN: 1566-2535. DOI: {10.1016/j.inffus.2021.02.003}.
- [7] Alejandro Zulbaran-Rojas, Bijan Najafi, Nestor Arita, Hadi Rahemi, Javad Razjouyan y Ramyar Gilani. “Utilization of Flexible-Wearable Sensors to Describe the Kinematics of Surgical Proficiency”. English. En: *JOURNAL OF SURGICAL RESEARCH* 262 (2021), 149-158. ISSN: 0022-4804. DOI: {10.1016/j.jss.2021.01.006}.
- [8] Ekaterina Kovalenko, Aleksandr Talitckii, Anna Anikina, Aleksei Shcherbak, Olga Zimniakova, Maksim Semenov, Ekaterina Bril, Dmitry V. Dylov y Andrey Somov. “Distinguishing Between Parkinson’s Disease and Essential Tremor Through Video Analytics Using Machine Learning: A Pilot Study”. English. En: *IEEE SENSORS JOURNAL* 21.10 (2021), 11916-11925. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3035240}.
- [9] Anat Mirelman, Mor Ben Or Frank, Michal Melamed, Lena Granovsky, Alice Nieuwboer, Lynn Rochester, Silvia Del Din, Laura Avanzino, Elisa Pelosin, Bastiaan R. Bloem, Ugo Della Croce, Andrea Cereatti, Paolo Bonato, Richard Camicioli, Theresa Ellis, Jamie L. Hamilton, Chris J. Hass, Quincy J. Almeida, Maidan Inbal, Avner Thaler, Julia Shirvan, Jesse M. Cedarbaum, Nir Giladi y Jeffrey M. Hausdorff. “Detecting Sensitive Mobility Features for Parkinson’s Disease Stages Via Machine Learning”. English. En: *MOVEMENT DISORDERS* (). DOI: {10.1002/mds.28631}.

- [10] Alessandro Stefanini, Davide Aloini, Peter Gloor y Federica Pochiero. “Patient satisfaction in emergency department: Unveiling complex interactions by wearable sensors”. English. En: *JOURNAL OF BUSINESS RESEARCH* 129 (2021), 600-611. ISSN: 0148-2963. DOI: {10.1016/j.jbusres.2019.12.038}.
- [11] Ahmed Salem, Amr Hassan, Markus Tilp y Abdel-Rahman Akl. “Antagonist Muscle Co-Activation during Kettlebell Single Arm Swing Exercise”. English. En: *APPLIED SCIENCES-BASEL* 11.9 (2021). DOI: {10.3390/app11094033}.
- [12] Xiaopeng Sha, Guanghua Wei, Xueliang Zhang, Xianshou Ren, Shuyu Wang, Zhonghai He y Yuliang Zhao. “Accurate Recognition of Player Identity and Stroke Performance in Table Tennis Using a Smart Wristband”. English. En: *IEEE SENSORS JOURNAL* 21.9 (2021), 10923-10932. ISSN: 1530-437X. DOI: {10.1109/JSEN.2021.3060914}.
- [13] Yong Chul Choi, Batbayar Khuyagbaatar, Maro Cheon, Temuujin Batbayar, Sukyoung Lee y Yoon Hyuk Kim. “Kinematic Comparison of Double Poling Techniques Between National and College Level Cross-Country Skiers Using Wearable Inertial Measurement Unit Sensors”. English. En: *INTERNATIONAL JOURNAL OF PRECISION ENGINEERING AND MANUFACTURING* (). DOI: {10.1007/s12541-021-00511-3}.
- [14] Alireza Farrokhi, Reza Farahbakhsh, Javad Rezazadeh y Roberto Minerva. “Application of Internet of Things and artificial intelligence for smart fitness: A survey”. English. En: *COMPUTER NETWORKS* 189 (2021). ISSN: 1389-1286. DOI: {10.1016/j.comnet.2021.107859}.
- [15] Monica Kaushik, Sindhu Hak Gupta y Vipin Balyan. “An approach to detect human body movement using different channel models and machine learning techniques”. English. En: *JOURNAL OF AMBIENT INTELLIGENCE AND HUMANIZED COMPUTING* (). DOI: {10.1007/s12652-021-03237-2}.
- [16] Lin Ma, Shu-Ying Liu, Shan-Shan Cen, Yuan Li, Hui Zhang, Chao Han, Zhu-Qin Gu, Wei Mao, Jing-Hong Ma, Yong-Tao Zhou, Er-He Xu y Piu Chan. “Detection of Motor Dysfunction With Wearable Sensors in Patients With Idiopathic Rapid Eye Movement Disorder”. English. En: *FRONTIERS IN BIOENGINEERING AND BIOTECHNOLOGY* 9 (2021). ISSN: 2296-4185. DOI: {10.3389/fbioe.2021.627481}.
- [17] Xinru Zhou, Chengye Hu, Xuechun Lin, Xiao Han, Xiaoman Zhao y Jianhan Hong. “Polyaniline-coated cotton knitted fabric for body motion monitoring”. English. En: *SENSORS AND ACTUATORS A-PHYSICAL* 321 (2021). ISSN: 0924-4247. DOI: {10.1016/j.sna.2021.112591}.
- [18] Slah Drira, Sai G. S. Pai y Ian F. C. Smith. “Uncertainties in Structural Behavior for Model-Based Occupant Localization Using Floor Vibrations”. English. En: *FRONTIERS IN BUILT ENVIRONMENT* 7 (2021). DOI: {10.3389/fbuil.2021.602118}.
- [19] Anlong Huang y Juan Wang. “Wearable device in college track and field training application and motion image sensor recognition”. English. En: *JOURNAL OF AMBIENT INTELLIGENCE AND HUMANIZED COMPUTING* (). DOI: {10.1007/s12652-021-03107-x}.

- [20] Hailong Ren y Xiao Wang. “Application of wearable inertial sensor in optimization of basketball player’s human motion tracking method”. English. En: *JOURNAL OF AMBIENT INTELLIGENCE AND HUMANIZED COMPUTING* (). DOI: {10.1007/s12652-021-03110-2}.
- [21] Hazita Azman, Warid Mihat y Or Kan Soh. “Analyzing Stimuli Presentations and Exit-Interview Protocols to Improve Wearable Eye-Tracking Data Collection Guidelines for Reading Research”. English. En: *INTERNATIONAL JOURNAL OF COMPUTER-ASSISTED LANGUAGE LEARNING AND TEACHING* 11.2, SI (2021), 51-65. ISSN: 2155-7098. DOI: {10.4018/IJCALLT.2021040104}.
- [22] Chariklia Chatzaki, Vasileios Skaramagkas, Nikolaos Tachos, Georgios Christodoulakis, Evangelia Maniadi, Zinovia Kefalopoulou, Dimitrios I. Fotiadis y Manolis Tsiknakis. “The Smart-Insole Dataset: Gait Analysis Using Wearable Sensors with a Focus on Elderly and Parkinson’s Patients”. English. En: *SENSORS* 21.8 (2021). DOI: {10.3390/s21082821}.
- [23] Mohammad Hasan Rahmani, Rafael Berkvens y Maarten Weyn. “Chest-Worn Inertial Sensors: A Survey of Applications and Methods”. English. En: *SENSORS* 21.8 (2021). DOI: {10.3390/s21082875}.
- [24] Ruonan Li, Xuelian Wei, Jiahui Xu, Junhuan Chen, Bin Li, Zhiyi Wu y Zhong Lin Wang. “Smart Wearable Sensors Based on Triboelectric Nanogenerator for Personal Healthcare Monitoring”. English. En: *MICROMACHINES* 12.4 (2021). DOI: {10.3390/mi12040352}.
- [25] Brenda Elizabeth Olivas-Padilla, Sotiris Manitsaris, Dimitrios Menychtas y Alina Glushkova. “Stochastic-Biomechanic Modeling and Recognition of Human Movement Primitives, in Industry, Using Wearables”. English. En: *SENSORS* 21.7 (2021). DOI: {10.3390/s21072497}.
- [26] Luca Menghini, Dilara Yuksel, Aimee Goldstone, Fiona C. Baker y Massimiliano de Zambotti. “Performance of Fitbit Charge 3 against polysomnography in measuring sleep in adolescent boys and girls”. English. En: *CHRONOBIOLOGY INTERNATIONAL* (). DOI: {10.1080/07420528.2021.1903481}.
- [27] Shweta Pant, Sharath Umesh y Sundarrajan Asokan. “Assessment of Spatio-Temporal Parameters of Human Gait Using Fiber Bragg Grating Sensor-Based Devices”. English. En: *IEEE SENSORS JOURNAL* 21.7 (2021), 9186-9193. ISSN: 1530-437X. DOI: {10.1109/JSEN.2021.3055246}.
- [28] Senay Mihcin, Samet Ciklacandir, Mertcan Kocak y Aliye Tosun. “Wearable Motion Capture System Evaluation for Biomechanical Studies for Hip Joints”. English. En: *JOURNAL OF BIOMECHANICAL ENGINEERING-TRANSACTIONS OF THE ASME* 143.4 (2021). ISSN: 0148-0731. DOI: {10.1115/1.4049199}.
- [29] Yue Zhou, Anas Ibrahim, Mary E. Jenkins, Michael D. Naish y Ana Luisa Trejos. “Analysis of the Effect of Common Disturbances on the Safety of a Wearable Tremor Suppression Device”. English. En: *IEEE ROBOTICS AND AUTOMATION LETTERS* 6.2 (2021), 2846-2853. ISSN: 2377-3766. DOI: {10.1109/LRA.2021.3062592}.

- [30] Hanjun Song y H. Harry Asada. “Integrated Voluntary-Reactive Control of a Human-SuperLimb Hybrid System for Hemiplegic Patient Support”. English. En: *IEEE ROBOTICS AND AUTOMATION LETTERS* 6.2 (2021), 1646-1653. ISSN: 2377-3766. DOI: {10.1109/LRA.2021.3058926}.
- [31] Seioh Ezaki, Hideki Kadone, Shigeki Kubota, Tetsuya Abe, Yukiyo Shimizu, Chun Kwang Tan, Kousei Miura, Yasushi Hada, Yoshiyuki Sankai, Masao Koda, Kenji Suzuki y Masashi Yamazaki. “Analysis of Gait Motion Changes by Intervention Using Robot Suit Hybrid Assistive Limb (HAL) in Myelopathy Patients After Decompression Surgery for Ossification of Posterior Longitudinal Ligament”. English. En: *FRONTIERS IN NEUROBOTICS* 15 (2021). ISSN: 1662-5218. DOI: {10.3389/fnbot.2021.650118}.
- [32] Hyo-Ryoung Lim, Yongkuk Lee, Kathryn A. Jones, Young-Tae Kwon, Shinjae Kwon, Musa Mahmood, Soon Min Lee y Woon-Hong Yeo. “All-in-one, wireless, fully flexible sodium sensor system with integrated Au/CNT/Au nanocomposites”. English. En: *SENSORS AND ACTUATORS B-CHEMICAL* 331 (2021). DOI: {10.1016/j.snb.2020.129416}.
- [33] Zhiqi Zhao, Qiujin Li, Linna Chen, Yu Zhao, Jixian Gong, Zheng Li y Jianfei Zhang. “A thread/fabric-based band as a flexible and wearable microfluidic device for sweat sensing and monitoring”. English. En: *LAB ON A CHIP* 21.5 (2021), 916-932. ISSN: 1473-0197. DOI: {10.1039/d01c01075h}.
- [34] Ben T. van Oeveren, Cornelis J. de Ruyter, Peter J. Beek y Jaap H. van Dieen. “The biomechanics of running and running styles: a synthesis”. English. En: *SPORTS BIOMECHANICS* (). DOI: {10.1080/14763141.2021.1873411}.
- [35] Emily J. Hill, C. Grant Mangleburg, Isabel Alfradique-Dunham, Brittany Ripperger, Amanda Stillwell, Hiba Saade, Sindhu Rao, Oluwafunmiso Fagbongbe, Rainer von Coelln, Arjun Tarakad, Christine Hunter, Robert J. Dawe, Joseph Jankovic, Lisa M. Shulman, Aron S. Buchman y Joshua M. Shulman. “Quantitative mobility measures complement the MDS-UPDRS for characterization of Parkinson’s disease heterogeneity”. English. En: *PARKINSONISM & RELATED DISORDERS* 84 (2021), 105-111. ISSN: 1353-8020. DOI: {10.1016/j.parkreldis.2021.02.006}.
- [36] Francesca Ferrari, Courtney E. Shell, Zachary C. Thumser, Francesco Clemente, Ela B. Plow, Christian Cipriani y Paul D. Marasco. “Proprioceptive Augmentation With Illusory Kinaesthetic Sensation in Stroke Patients Improves Movement Quality in an Active Upper Limb Reach-and-Point Task”. English. En: *FRONTIERS IN NEUROBOTICS* 15 (2021). ISSN: 1662-5218. DOI: {10.3389/fnbot.2021.610673}.
- [37] Adnan Albaba, Neide Simo, Yuyang Wang, Richard C. Hendriks, Walter De Raedt y Chris Van Hoof. “Assessing the signal quality of electrocardiograms from varied acquisition sources: A generic machine learning pipeline for model generation”. English. En: *COMPUTERS IN BIOLOGY AND MEDICINE* 130 (2021). ISSN: 0010-4825. DOI: {10.1016/j.combiomed.2020.104164}.

- [38] Hitomi Oigawa, Yoshiro Musha, Youhei Ishimine, Sumito Kinjo, Yuya Takesue, Hideyuki Negoro y Tomohiro Umeda. “Visualizing and Evaluating Finger Movement Using Combined Acceleration and Contact-Force Sensors: A Proof-of-Concept Study”. English. En: *SENSORS* 21.5 (2021). DOI: {10.3390/s21051918}.
- [39] Shin-Ting Wu, Jose Angel Ivan Rubianes Silva, Sergio Luiz Novi, Nicolas Gabriel S. R. de Souza, Edwin Johan Forero y Rickson C. Mesquita. “Accurate Image-guided (Re)Placement of NIRS Probes”. English. En: *COMPUTER METHODS AND PROGRAMS IN BIOMEDICINE* 200 (2021). ISSN: 0169-2607. DOI: {10.1016/j.cmpb.2020.105844}.
- [40] Deren Y. Barsakcioglu, Mario Bracklein, Ales Holobar y Dario Farina. “Control of Spinal Motoneurons by Feedback From a Non-Invasive Real-Time Interface”. English. En: *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING* 68.3 (2021), 926-935. ISSN: 0018-9294. DOI: {10.1109/TBME.2020.3001942}.
- [41] Ze Yang, Yiyong Yang, Fan Liu, Zhaozheng Wang, Yinbo Li, Jiahao Qiu, Xuan Xiao, Zhiwei Li, Yijia Lu, Linhong Ji, Zhong Lin Wang y Jia Cheng. “Power Backpack for Energy Harvesting and Reduced Load Impact”. English. En: *ACS NANO* 15.2 (2021), 2611-2623. ISSN: 1936-0851. DOI: {10.1021/acsnano.0c07498}.
- [42] Allison Shapiro, Benjamin Bradshaw, Sabine Landes, Petra Kammann, Beatrice Bois De Fer, Wei-Nchih Lee y Robert Lange. “A novel digital approach to describe real world outcomes among patients with constipation”. English. En: *NPJ DIGITAL MEDICINE* 4.1 (2021). ISSN: 2398-6352. DOI: {10.1038/s41746-021-00391-x}.
- [43] Aboajeila Milad Ashleibta, Qammer H. Abbasi, Syed Aziz Shah, Muhammad Arslan Khalid, Najah Abed AbuAli y Muhammad Ali Imran. “Non-Invasive RF Sensing for Detecting Breathing Abnormalities Using Software Defined Radios”. English. En: *IEEE SENSORS JOURNAL* 21.4 (2021), 5111-5118. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3035960}.
- [44] Rahil N. Khasgiwale, Beth A. Smith y Julia Looper. “Leg Movement Rate Pre- and Post-Kicking Intervention in Infants with Down Syndrome”. English. En: *PHYSICAL & OCCUPATIONAL THERAPY IN PEDIATRICS* (). DOI: {10.1080/01942638.2021.1889735}.
- [45] Jing Wang, Yuxing Liu, Shuo Wang, Xinle Liu, Yipeng Chen, Peiyao Qi y Xiaofei Liu. “Molybdenum disulfide enhanced polyacrylamide-acrylic acid-Fe³⁺ ionic conductive hydrogel with high mechanical properties and anti-fatigue abilities as strain sensors”. English. En: *COLLOIDS AND SURFACES A-PHYSICOCHEMICAL AND ENGINEERING ASPECTS* 610 (2021). ISSN: 0927-7757. DOI: {10.1016/j.colsurfa.2020.125692}.
- [46] Xin Zhou, Geng Liu, Bing Han y Xiaoli Liu. “Different kinds of energy harvesters from human activities”. English. En: *INTERNATIONAL JOURNAL OF ENERGY RESEARCH* 45.4 (2021), 4841-4870. DOI: {10.1002/er.6045}.
- [47] Liisa Kuula y Anu-Katriina Pesonen. “Heart Rate Variability and Firstbeat Method for Detecting Sleep Stages in Healthy Young Adults: Feasibility Study”. English. En: *JMIR MHEALTH AND UHEALTH* 9.2 (2021). ISSN: 2291-5222. DOI: {10.2196/24704}.

- [48] Yanran Jiang, Vincent Hernandez, Gentiane Venture, Dana Kulic y Bernard K. Chen. “A Data-Driven Approach to Predict Fatigue in Exercise Based on Motion Data from Wearable Sensors or Force Plate”. English. En: *SENSORS* 21.4 (2021). DOI: {10.3390/s21041499}.
- [49] Yue Zhang, Shengli Sun, Linjian Lei, Huikai Liu y Hui Xie. “STAC: Spatial-Temporal Attention on Compensation Information for Activity Recognition in FPV”. English. En: *SENSORS* 21.4 (2021). DOI: {10.3390/s21041106}.
- [50] Liu Feng, Han Jing-Long, Qi Ji, Zhang Yu, Yu Jia-Luo, Li Wen-Peng, Lin Dong, Chen Ling-Xin y Li Bo-Wei. “Research and Application Progress of Intelligent Wearable Devices”. Chinese. En: *CHINESE JOURNAL OF ANALYTICAL CHEMISTRY* 49.2 (2021), 159-171. ISSN: 0253-3820. DOI: {10.19756/j.issn.0253-3820.201410}.
- [51] Cemil Keskinoglu y Ahmet Aydin. “Wearable wireless low-cost electrogoniometer design with Kalman filter for joint range of motion measurement and 3D modeling of joint movements”. English. En: *PROCEEDINGS OF THE INSTITUTION OF MECHANICAL ENGINEERS PART H-JOURNAL OF ENGINEERING IN MEDICINE* 235.2 (2021), 222-231. ISSN: 0954-4119. DOI: {10.1177/0954411920971398}.
- [52] Roberto Casas, Arturo Hermosa, Alvaro Marco, Teresa Blanco y Francisco Javier Zarazaga-Soria. “Real-Time Extensive Livestock Monitoring Using LPWAN Smart Wearable and Infrastructure”. English. En: *APPLIED SCIENCES-BASEL* 11.3 (2021). DOI: {10.3390/app11031240}.
- [53] Arnaldo G. Leal-Junior, Diana Ribeiro, Leticia M. Avellar, Mariana Silveira, Camilo A. Rodriguez Diaz, Anselmo Frizera-Neto, Wilfried Blanc, Eduardo Rocon y Carlos Marques. “Wearable and Fully-Portable Smart Garment for Mechanical Perturbation Detection With Nanoparticles Optical Fibers”. English. En: *IEEE SENSORS JOURNAL* 21.3 (2021), 2995-3003. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3024242}.
- [54] Aleksandr Talitckii, Ekaterina Kovalenko, Anna Anikina, Olga Zimniakova, Maksim Semenov, Ekaterina Bril, Aleksei Shcherbak, Dmitry V. Dylov y Andrey Somov. “Avoiding Misdiagnosis of Parkinson’s Disease With the Use of Wearable Sensors and Artificial Intelligence”. English. En: *IEEE SENSORS JOURNAL* 21.3 (2021), 3738-3747. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3027564}.
- [55] Sevgi Z. Gurbuz, Ali Cafer Gurbuz, Evie A. Malaia, Darrin J. Griffin, Chris S. Crawford, Mohammad Mahbubur Rahman, Emre Kurtoglu, Ridvan Aksu, Trevor Macks y Robiulhos-sain Mdraf. “American Sign Language Recognition Using RF Sensing”. English. En: *IEEE SENSORS JOURNAL* 21.3 (2021), 3763-3775. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3022376}.
- [56] Zehao Zhang y Linling Xie. “Adaptive body movement system for wearable IoT instruments based on matrix vector parameter estimation”. English. En: *MEASUREMENT* 169 (2021). ISSN: 0263-2241. DOI: {10.1016/j.measurement.2020.108350}.
- [57] David G. Vossler. “Forecasting Seizure Storms Using Epilepsy Wristband Sensors”. English. En: *EPILEPSY CURRENTS* 21.2 (2021), 99-101. DOI: {10.1177/1535759721990062}.

- [58] Anne Schwarz, Janne M. Veerbeek, Jeremia P. O. Held, Jaap H. Buurke y Andreas R. Luft. “Measures of Interjoint Coordination Post-stroke Across Different Upper Limb Movement Tasks”. English. En: *FRONTIERS IN BIOENGINEERING AND BIOTECHNOLOGY* 8 (2021). ISSN: 2296-4185. DOI: {10.3389/fbioe.2020.620805}.
- [59] Dong Jun Park, Jun Woo Lee, Myung Jun Lee, Se Jin Ahn, Jiyoung Kim, Gyu Lee Kim, Young Jin Ra, Yu Na Cho y Weui Bong Jeong. “Evaluation for Parkinsonian Bradykinesia by deep learning modeling of kinematic parameters”. English. En: *JOURNAL OF NEURAL TRANSMISSION* 128.2 (2021), 181-189. DOI: {10.1007/s00702-021-02301-7}.
- [60] Luca Franco, Raj Sengupta, Logan Wade y Dario Cazzola. “A novel IMU-based clinical assessment protocol for Axial Spondyloarthritis: a protocol validation study”. English. En: *PEERJ* 9 (2021). ISSN: 2167-8359. DOI: {10.7717/peerj.10623}.
- [61] Mariana H. G. Monje, Alvaro Sanchez-Ferro, Jose A. Pineda-Pardo, Lydia Vela-Desojo, Fernando Alonso-Frech y Jose A. Obeso. “Motor Onset Topography and Progression in Parkinson’s Disease: the Upper Limb Is First”. English. En: *MOVEMENT DISORDERS* 36.4 (2021), 905-915. DOI: {10.1002/mds.28462}.
- [62] Giovanni Saggio, Francesca Tombolini y Antonio Ruggiero. “Technology-Based Complex Motor Tasks Assessment: A 6-DOF Inertial-Based System Versus a Gold-Standard Optoelectronic-Based One”. English. En: *IEEE SENSORS JOURNAL* 21.2 (2021), 1616-1624. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3016642}.
- [63] Vitor Sencadas, Charbel Tawk, Thomas Searle y Gursel Alici. “Low-Hysteresis and Ultra-sensitive Microcellular Structures for Wearable Electronic Applications”. English. En: *ACS APPLIED MATERIALS & INTERFACES* 13.1 (2021), 1632-1643. ISSN: 1944-8244. DOI: {10.1021/acsmi.0c20173}.
- [64] Maxine E. Whelan, Francesca Denton, Claire L. A. Bourne, Andrew P. Kingsnorth, Lauren B. Sherar, Mark W. Orme y Dale W. Esliger. “A digital lifestyle behaviour change intervention for the prevention of type 2 diabetes: a qualitative study exploring intuitive engagement with real-time glucose and physical activity feedback”. English. En: *BMC PUBLIC HEALTH* 21.1 (2021). DOI: {10.1186/s12889-020-09740-z}.
- [65] Mohammed A. Alqarni. “Error-less data fusion for posture detection using smart healthcare systems and wearable sensors for patient monitoring”. English. En: *PERSONAL AND UBIQUITOUS COMPUTING* (). DOI: {10.1007/s00779-020-01518-9}.
- [66] Niilo V. Valtakari, Ignace T. C. Hooge, Charlotte Viktorsson, Par Nystrom, Terje Falck-Ytter y Roy S. Hessels. “Eye tracking in human interaction: Possibilities and limitations”. English. En: *BEHAVIOR RESEARCH METHODS* (). DOI: {10.3758/s13428-020-01517-x}.
- [67] Davide Bacciu, Gioele Bertoncini y Davide Morelli. “Topographic mapping for quality inspection and intelligent filtering of smart-bracelet data”. English. En: *NEURAL COMPUTING & APPLICATIONS* (). DOI: {10.1007/s00521-020-05600-4}.

- [68] Genko Oyama y Nobutaka Hattori. “New modalities and directions for dystonia care”. English. En: *JOURNAL OF NEURAL TRANSMISSION* 128.4, SI (2021), 559-565. DOI: {10.1007/s00702-020-02278-9}.
- [69] Shafaq Zia, Ali Nawaz Khan, Khurram Shabih Zaidi y Shan E. Ali. “Detection of Generalized Tonic Clonic Seizures and Falls in Unconstraint Environment Using Smartphone Accelerometer”. English. En: *IEEE ACCESS* 9 (2021), 39432-39443. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2021.3063765}.
- [70] Daniel Fuller, Javad Rahimipour Anaraki, Bongai Simango, Machel Rayner, Faramarz Dorani, Arastoo Bozorgi, Hui Luan y Fabien A. Basset. “Predicting lying, sitting, walking and running using Apple Watch and Fitbit data”. English. En: *BMJ OPEN SPORT & EXERCISE MEDICINE* 7.1 (2021). ISSN: 2398-9459. DOI: {10.1136/bmjsem-2020-001004}.
- [71] Donggeon Lee, Soungkyun Hong, Kyeongbong Lee y Gyuchang Lee. “Analysis of the lower extremity muscle activity depending on the use of a knee aid in elderly people with osteoarthritis”. English. En: *JOURNAL OF HUMAN SPORT AND EXERCISE* 16.2 (2021), 463-469. ISSN: 1988-5202. DOI: {10.14198/jhse.2021.162.20}.
- [72] Amirashkan Darvish y Ahmed A. Kishk. “Near-Field Shielding Analysis of Single-Sided Flexible Metasurface Stopband TE: Comparative Approach”. English. En: *IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION* 69.1 (2021), 239-253. ISSN: 0018-926X. DOI: {10.1109/TAP.2020.3000530}.
- [73] Pritika Dasgupta, Jessie VanSwearingen, Alan Godfrey, Mark Redfern, Manuel Montero-Odasso y Ervin Sejdic. “Acceleration Gait Measures as Proxies for Motor Skill of Walking: A Narrative Review”. English. En: *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING* 29 (2021), 249-261. ISSN: 1534-4320. DOI: {10.1109/TNSRE.2020.3044260}.
- [74] J. Soulard, J. Vaillant, C-T Agier y N. Vuillerme. “Gait characteristics in patients with ankylosing spondylitis: a systematic review”. English. En: *CLINICAL AND EXPERIMENTAL RHEUMATOLOGY* 39.1 (2021), 173-186. ISSN: 0392-856X.
- [75] Ling Zhang y Faze Liang. “Monitoring and analysis of athletes’ local body movement status based on BP neural network”. English. En: *JOURNAL OF INTELLIGENT & FUZZY SYSTEMS* 40.2 (2021), 2325-2335. ISSN: 1064-1246. DOI: {10.3233/JIFS-189229}.
- [76] Y. Celik, S. Stuart, W. L. Woo y A. Godfrey. “Gait analysis in neurological populations: Progression in the use of wearables”. English. En: *MEDICAL ENGINEERING & PHYSICS* 87 (2021), 9-29. ISSN: 1350-4533. DOI: {10.1016/j.medengphy.2020.11.005}.
- [77] Tomasz Gutowski y Mariusz Chmielewski. “An Algorithmic Approach for Quantitative Evaluation of Parkinson’s Disease Symptoms and Medical Treatment Utilizing Wearables and Multi-Criteria Symptoms Assessment”. English. En: *IEEE ACCESS* 9 (2021), 24133-24144. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2021.3056629}.
- [78] Sumit A. Raurale, John McAllister y Jesus Martinez Del Rincon. “EMG Biometric Systems Based on Different Wrist-Hand Movements”. English. En: *IEEE ACCESS* 9 (2021), 12256-12266. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2021.3050704}.

- [79] Vincent Hernandez, Davood Dadkhah, Vahid Babakeshizadeh y Dana Kulic. “Lower body kinematics estimation from wearable sensors for walking and running: A deep learning approach”. English. En: *GAIT & POSTURE* 83 (2021), 185-193. ISSN: 0966-6362. DOI: {10.1016/j.gaitpost.2020.10.026}.
- [80] Luigi Truppa, Michelangelo Guaitolini, Pietro Garofalo, Carlo Castagna y Andrea Manini. “Assessment of Biomechanical Response to Fatigue through Wearable Sensors in Semi-Professional Football Referees”. English. En: *SENSORS* 21.1 (2021). DOI: {10.3390/s21010066}.
- [81] Paul Farago, Lacrimioara Grama, Monica-Adriana Farago y Sorin Hintea. “A Novel Wearable Foot and Ankle Monitoring System for the Assessment of Gait Biomechanics”. English. En: *APPLIED SCIENCES-BASEL* 11.1 (2021). DOI: {10.3390/app11010268}.
- [82] Karl M. Trounson, Aglaja Busch, Neil French Collier y Sam Robertson. “Effects of acute wearable resistance loading on overground running lower body kinematics”. English. En: *PLOS ONE* 15.12 (2020). ISSN: 1932-6203. DOI: {10.1371/journal.pone.0244361}.
- [83] Ja Young Choi, Sook-Hee Yi, Lijuan Ao, Xin Tang, Xuan Xu, Dain Shim, Beomki Yoo, Eun Sook Park y Dong-wook Rha. “Virtual reality rehabilitation in children with brain injury: a randomized controlled trial”. English. En: *DEVELOPMENTAL MEDICINE AND CHILD NEUROLOGY* 63.4 (2021), 480-487. DOI: {10.1111/dmcn.14762}.
- [84] Kiki Adhinugraha, Wenny Rahayu, Takahiro Hara y David Taniar. “Dealing with noise in crowdsourced GPS human trajectory logging data”. English. En: *CONCURRENCY AND COMPUTATION-PRACTICE & EXPERIENCE* (). DOI: {10.1002/cpe.6139}.
- [85] Eduardo Casilari, Jose A. Santoyo-Ramon y Jose M. Cano-Garcia. “On the Heterogeneity of Existing Repositories of Movements Intended for the Evaluation of Fall Detection Systems”. English. En: *JOURNAL OF HEALTHCARE ENGINEERING* 2020 (2020). ISSN: 2040-2295. DOI: {10.1155/2020/6622285}.
- [86] Mark Parent, Isabela Albuquerque, Abhishek Tiwari, Raymundo Cassani, Jean-Francois Gagnon, Daniel Lafond, Sebastien Tremblay y Tiago H. Falk. “PASS: A Multimodal Database of Physical Activity and Stress for Mobile Passive Body/ Brain-Computer Interface Research”. English. En: *FRONTIERS IN NEUROSCIENCE* 14 (2020). DOI: {10.3389/fnins.2020.542934}.
- [87] Giovanni Marco Scalera, Maurizio Ferrarin y Marco Rabuffetti. “Gait regularity assessed by wearable sensors: Comparison between accelerometer and gyroscope data for different sensor locations and walking speeds in healthy subjects”. English. En: *JOURNAL OF BIOMECHANICS* 113 (2020). ISSN: 0021-9290. DOI: {10.1016/j.jbiomech.2020.110115}.
- [88] Manuel Gil-Martin, Ruben San-Segundo, Fernando Fernandez-Martinez y Ricardo de Cordoba. “Human activity recognition adapted to the type of movement”. English. En: *COMPUTERS & ELECTRICAL ENGINEERING* 88 (2020). ISSN: 0045-7906. DOI: {10.1016/j.compeleceng.2020.106822}.

- [89] Gun Hyun Park, Su Jin Kim y Young Sam Cho. “Development of a voiding diary using urination recognition technology in mobile environment”. English. En: *JOURNAL OF EXERCISE REHABILITATION* 16.6 (2020), 529-533. ISSN: 2288-176X. DOI: {10.12965/jer.2040790.395}.
- [90] Christopher L. Dembia, Nicholas A. Bianco, Antoine Falisse, Jennifer L. Hicks y Scott L. Delp. “OpenSim Moco: Musculoskeletal optimal control”. English. En: *PLOS COMPUTATIONAL BIOLOGY* 16.12 (2020). ISSN: 1553-734X. DOI: {10.1371/journal.pcbi.1008493}.
- [91] Michele Paoletti, Alberto Belli, Lorenzo Palma y Paola Pierleoni. “Electromyography Pattern Likelihood Analysis for Flexion-Relaxation Phenomenon Evaluation”. English. En: *ELECTRONICS* 9.12 (2020). DOI: {10.3390/electronics9122046}.
- [92] G. M. Nazmul Islam, Stewart Collie, Muhammad Qasim y M. Azam Ali. “Highly Stretchable and Flexible Melt Spun Thermoplastic Conductive Yarns for Smart Textiles”. English. En: *NANOMATERIALS* 10.12 (2020). DOI: {10.3390/nano10122324}.
- [93] Pringgo Widyo Laksono, Kojiro Matsushita, Muhammad Syaiful Amri bin Suhaimi, Takahide Kitamura, Waweru Njeri, Joseph Muguro y Minoru Sasaki. “Mapping Three Electromyography Signals Generated by Human Elbow and Shoulder Movements to Two Degree of Freedom Upper-Limb Robot Control”. English. En: *ROBOTICS* 9.4 (2020). DOI: {10.3390/robotics9040083}.
- [94] Andrea Bizzego, Giulio Gabrieli, Cesare Furlanello y Gianluca Esposito. “Comparison of Wearable and Clinical Devices for Acquisition of Peripheral Nervous System Signals”. English. En: *SENSORS* 20.23 (2020). DOI: {10.3390/s20236778}.
- [95] Bhavesh Pandya, Amir Pourabdollah y Ahmad Lotfi. “Comparative Analysis of Real-Time Fall Detection Using Fuzzy Logic Web Services and Machine Learning”. English. En: *TECHNOLOGIES* 8.4 (2020). DOI: {10.3390/technologies8040074}.
- [96] Ho Seon Choi, Chang Hee Lee y Yoon Su Baek. “Design and Validation of a Two-Degree-of-Freedom Powered Ankle-Foot Orthosis with Two Pneumatic Artificial Muscles”. English. En: *MECHATRONICS* 72 (2020). ISSN: 0957-4158. DOI: {10.1016/j.mechatronics.2020.102469}.
- [97] Luke Wicent F. Sy, Nigel H. Lovell y Stephen J. Redmond. “Estimating Lower Limb Kinematics Using a Lie Group Constrained Extended Kalman Filter with a Reduced Wearable IMU Count and Distance Measurements”. English. En: *SENSORS* 20.23 (2020). DOI: {10.3390/s20236829}.
- [98] Peter B. Shull y Haisheng Xia. “Modeling and Prediction of Wearable Energy Harvesting Sliding Shoes for Metabolic Cost and Energy Rate Outside of the Lab”. English. En: *SENSORS* 20.23 (2020). DOI: {10.3390/s20236915}.
- [99] Mengxia Yu, Xuanyu Shang, Miao Wang, Yulong Liu y Terry Tao Ye. “Exploiting Embroidered UHF RFID Antennas as Deformation Sensors”. English. En: *IEEE JOURNAL OF RADIO FREQUENCY IDENTIFICATION* 4.4 (2020), 406-413. DOI: {10.1109/JRFID.2020.3030790}.

- [100] Nikiforos Okkalidis, Kenneth P. Camilleri, Alfred Gatt, Marvin K. Bugeja y Owen Falzon. “A review of foot pose and trajectory estimation methods using inertial and auxiliary sensors for kinematic gait analysis”. English. En: *BIOMEDICAL ENGINEERING-BIOMEDIZINISCHE TECHNIK* 65.6 (2020), 653-671. ISSN: 0013-5585. DOI: {10.1515/bmt-2019-0163}.
- [101] Xiaoli Wu, Wenhui Zhang, Zhibo Fu, Roy T. H. Cheung y Rosa H. M. Chan. “An investigation of in-ear sensing for motor task classification”. English. En: *JOURNAL OF NEURAL ENGINEERING* 17.6 (2020). ISSN: 1741-2560. DOI: {10.1088/1741-2552/abc1b6}.
- [102] Xinyu Ji, Dashuai Wang, Pengfei Li, Liangsheng Zheng, Jianquan Sun y Xinyu Wu. “SIAT-WEXv2: A Wearable Exoskeleton for Reducing Lumbar Load during Lifting Tasks”. English. En: *COMPLEXITY* 2020 (2020). ISSN: 1076-2787. DOI: {10.1155/2020/8849427}.
- [103] Ghayth AlMahadin, Ahmad Lotfi, Eva Zysk, Francesco Luke Siena, Marie Mc Carthy y Philip Breedon. “Parkinson’s disease: current assessment methods and wearable devices for evaluation of movement disorder motor symptoms-a patient and healthcare professional perspective”. English. En: *BMC NEUROLOGY* 20.1 (2020). DOI: {10.1186/s12883-020-01996-7}.
- [104] Renee Marie Shelby. “Techno-physical feminism: anti-rape technology, gender, and corporeal surveillance”. English. En: *FEMINIST MEDIA STUDIES* 20.8 (2020), 1088-1109. ISSN: 1468-0777. DOI: {10.1080/14680777.2019.1662823}.
- [105] Suraj Baloda, Zeeshan Alam Ansari, Sumitra Singh y Navneet Gupta. “Development and Analysis of Graphene Nanoplatelets (GNPs)-Based Flexible Strain Sensor for Health Monitoring Applications”. English. En: *IEEE SENSORS JOURNAL* 20.22 (2020), 13302-13309. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3004574}.
- [106] Ozlem Feyzioglu, Selvi Dincer, Arzu Akan y Zeliha Candan Algun. “Is Xbox 360 Kinect-based virtual reality training as effective as standard physiotherapy in patients undergoing breast cancer surgery?” English. En: *SUPPORTIVE CARE IN CANCER* 28.9 (2020), 4295-4303. ISSN: 0941-4355. DOI: {10.1007/s00520-019-05287-x}.
- [107] Mohammad R. Saeedpour-Parizi, Shirin E. Hassan, Tayebah Baniyadi, Kelly J. Baute y John B. Shea. “Hierarchical goal effects on center of mass velocity and eye fixations during gait”. English. En: *EXPERIMENTAL BRAIN RESEARCH* 238.11 (2020), 2433-2443. DOI: {10.1007/s00221-020-05900-0}.
- [108] Daniel H. K. Chow, Wilson H. W. Cheng y Simone S. M. Tam. “A Video-Based Classification System for Assessing Locomotor Skills in Children”. English. En: *JOURNAL OF SPORTS SCIENCE AND MEDICINE* 19.3 (2020), 585-595. ISSN: 1303-2968.
- [109] Polona Caserman, Augusto Garcia-Agundez y Stefan Gobel. “A Survey of Full-Body Motion Reconstruction in Immersive Virtual Reality Applications”. English. En: *IEEE TRANSACTIONS ON VISUALIZATION AND COMPUTER GRAPHICS* 26.10 (2020), 3089-3108. ISSN: 1077-2626. DOI: {10.1109/TVCG.2019.2912607}.

- [110] Mireia Sempere-Tortosa, Francisco Fernandez-Carrasco, Francisco Mora-Lizan y Carlos Rizo-Maestre. “Objective Analysis of Movement in Subjects with ADHD. Multidisciplinary Control Tool for Students in the Classroom”. English. En: *INTERNATIONAL JOURNAL OF ENVIRONMENTAL RESEARCH AND PUBLIC HEALTH* 17.15 (2020). DOI: {10.3390/ijerph17155620}.
- [111] Yi Zhang y Mengni Zhang. “Machine learning model-based two-dimensional matrix computation model for human motion and dance recovery”. English. En: *COMPLEX & INTELLIGENT SYSTEMS* (). DOI: {10.1007/s40747-020-00186-9}.
- [112] Mohammad R. Saeedpour-Parizi, Shirin E. Hassan y John B. Shea. “Pupil diameter as a biomarker of effort in goal-directed gait”. English. En: *EXPERIMENTAL BRAIN RESEARCH* 238.11 (2020), 2615-2623. DOI: {10.1007/s00221-020-05915-7}.
- [113] Marwa Bouri, Ali Khalfallah y Med Salim Bouhleb. “Improvement of Body Movements and Stability of Blind or Visually Impaired Adults by Physical Activity using Kinect V2”. English. En: *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 11.8 (2020), 457-463. ISSN: 2158-107X.
- [114] Jing Li, Kan Jin, Dalin Zhou, Naoyuki Kubota y Zhaojie Ju. “Attention mechanism-based CNN for facial expression recognition”. English. En: *NEUROCOMPUTING* 411 (2020), 340-350. ISSN: 0925-2312. DOI: {10.1016/j.neucom.2020.06.014}.
- [115] Andrea Vitali, Federico Maffioletti, Daniele Regazzoni y Caterina Rizzi. “Quantitative Assessment of Shoulder Rehabilitation Using Digital Motion Acquisition and Convolutional Neural Network”. English. En: *JOURNAL OF COMPUTING AND INFORMATION SCIENCE IN ENGINEERING* 20.5, SI (2020). American-Society-of-Mechanical-Engineers(ASME) International Design Engineering Technical Conferences / 39th American-Society-of-Mechanical-Engineers(ASME) Computers and Information in Engineering Conference (IDETC-CIE), Anaheim, CA, AUG 18-21, 2019. ISSN: 1530-9827. DOI: {10.1115/1.4047772}.
- [116] Eric J. Evans, Keith E. Naugle, Tyler Owen y Kelly M. Naugle. “Active Gaming: It Is Not Just for Young People”. English. En: *JOURNAL OF AGING AND PHYSICAL ACTIVITY* 28.5 (2020), 731-739. ISSN: 1063-8652. DOI: {10.1123/japa.2019-0303}.
- [117] Andre Maharaj V, Anibal Gutierrez, Carlos Cueto y Steven Cadavid. “Automated measurement of repetitive behavior using the Microsoft Kinect: a proof of concept”. English. En: *BEHAVIORAL INTERVENTIONS* 35.4 (2020), 488-497. DOI: {10.1002/bin.1746}.
- [118] Erica Dove, Rosalie Wang, Karl Zabjek y Arlene Astell. “Impacts of Motion-Based Technology on Balance, Movement Confidence, and Cognitive Function Among People With Dementia or Mild Cognitive Impairment: Protocol for a Quasi-Experimental Pre- and Post-test Study”. English. En: *JMIR RESEARCH PROTOCOLS* 9.9 (2020). ISSN: 1929-0748. DOI: {10.2196/18209}.

- [119] Md Assad-Uz-Zaman, Rasedul Islam, Mohammad Habibur Rahman, Ying-Chih Wang y Erin McGonigle. “Kinect Controlled NAO Robot for Telerehabilitation”. English. En: *JOURNAL OF INTELLIGENT SYSTEMS* 30.1 (2021), 224-239. ISSN: 0334-1860. DOI: {10.1515/jisys-2019-0126}.
- [120] Marilena Enus, Ebba Dellwik, Jakob Mann, Horia Hangan y Adrian Costache. “Three-dimensional measurements of tree crown movement using an infrared time-of-flight camera”. English. En: *EXPERIMENTS IN FLUIDS* 61.11 (2020). ISSN: 0723-4864. DOI: {10.1007/s00348-020-03053-y}.
- [121] Kaijun Zhu, Ruxin Wang, Qingsong Zhao, Jun Cheng y Dapeng Tao. “A Cuboid CNN Model With an Attention Mechanism for Skeleton-Based Action Recognition”. English. En: *IEEE TRANSACTIONS ON MULTIMEDIA* 22.11 (2020), 2977-2989. ISSN: 1520-9210. DOI: {10.1109/TMM.2019.2962304}.
- [122] Vibha Bhatia, Jagjit Singh Randhawa, Ashish Jain y Vishakha Grover. “Comparative analysis of imaging and novel markerless approach for measurement of postural parameters in dental seating tasks”. English. En: *MEASUREMENT & CONTROL* 53.7-8 (2020), 1059-1069. ISSN: 0020-2940. DOI: {10.1177/0020294020932340}.
- [123] Karen Otte, Tobias Ellermeyer, Tim-Sebastian Vater, Marlen Voigt, Daniel Kroneberg, Ludwig Rasche, Theresa Krueger, Hanna Maria Roehling, Bastian Kayser, Sebastian Mansow-Model, Fabian Klostermann, Alexander Ulrich Brandt, Friedemann Paul, Axel Lipp y Tanja Schmitz-Huebsch. “Instrumental Assessment of Stepping in Place Captures Clinically Relevant Motor Symptoms of Parkinson’s Disease”. English. En: *SENSORS* 20.19 (2020). DOI: {10.3390/s20195465}.
- [124] Peter Fermin Dajime, Heather Smith y Yanxin Zhang. “Automated classification of movement quality using the Microsoft Kinect V2 sensor”. English. En: *COMPUTERS IN BIOLOGY AND MEDICINE* 125 (2020). ISSN: 0010-4825. DOI: {10.1016/j.combiomed.2020.104021}.
- [125] Robert P. Matthew, Sarah Seko, Gregorij Kurillo, Ruzena Bajcsy, Louis Cheng, Jay J. Han y Jeffrey Lotz. “Reachable Workspace and Proximal Function Measures for Quantifying Upper Limb Motion”. English. En: *IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS* 24.11 (2020), 3285-3294. ISSN: 2168-2194. DOI: {10.1109/JBHI.2020.2989722}.
- [126] Filippo Colombo Zefinetti, Andrea Vitali, Daniele Regazzoni, Caterina Rizzi y Guido Molinero. “Tracking and Characterization of Spinal Cord-Injured Patients by Means of RGB-D Sensors”. English. En: *SENSORS* 20.21 (2020). DOI: {10.3390/s20216273}.
- [127] Wojciech Kaczmarek, Jaroslaw Panasiuk, Szymon Borys y Patryk Banach. “Industrial Robot Control by Means of Gestures and Voice Commands in Off-Line and On-Line Mode”. English. En: *SENSORS* 20.21 (2020). DOI: {10.3390/s20216358}.
- [128] Ting Feng. “Research on Image-Based Movement Accuracy Monitoring of Aerobics”. English. En: *MATHEMATICAL PROBLEMS IN ENGINEERING* 2020 (2020). ISSN: 1024-123X. DOI: {10.1155/2020/7152197}.

- [129] Xin Zhang, Jiehao Li, Wen Qi, Xuanyi Zhou, Yingbai Hu, Hao Quan y Zhen Wang. “A Novel Human-Like Control Framework for Mobile Medical Service Robot”. English. En: *COMPLEXITY* 2020 (2020). ISSN: 1076-2787. DOI: {10.1155/2020/2905841}.
- [130] Kayode P. Ayodele, Eniola A. Akinboboye y Morenikeji A. Komolafe. “The performance of a low-cost bio-amplifier on 3D human arm movement reconstruction”. English. En: *BIO-MEDICAL ENGINEERING-BIOMEDIZINISCHE TECHNIK* 65.5 (2020), 577-585. ISSN: 0013-5585. DOI: {10.1515/bmt-2019-0085}.
- [131] Ha Tran, Khoa D. Nguyen, Pubudu N. Pathirana, Malcolm K. Horne, Laura Power y David J. Szmulewicz. “A comprehensive scheme for the objective upper body assessments of subjects with cerebellar ataxia”. English. En: *JOURNAL OF NEUROENGINEERING AND REHABILITATION* 17.1 (2020). DOI: {10.1186/s12984-020-00790-3}.
- [132] Prakarn Jaroonsorn, Paramin Neranon, Pruttikorn Smithmaitrie y Charoenyutr Dechwayukul. “Robot-assisted transcranial magnetic stimulation using hybrid position/force control”. English. En: *ADVANCED ROBOTICS* 34.24, SI (2020). 29th IEEE International Conference on Robot and Human Interactive Communication (IEEE RO-MAN), ELECTR NETWORK, AUG 31-SEP 04, 2020, 1559-1570. DOI: {10.1080/01691864.2020.1855243}.
- [133] Elise Klæbo Vonstad, Xiaomeng Su, Beatrix Vereijken, Kerstin Bach y Jan Harald Nilsen. “Comparison of a Deep Learning-Based Pose Estimation System to Marker-Based and Kinect Systems in Exergaming for Balance Training”. English. En: *SENSORS* 20.23 (2020). DOI: {10.3390/s20236940}.
- [134] Elio Romano, Carlo Bisaglia, Aldo Calcante, Roberto Oberti, Alberto Zani, Denis Vinnikov, Andrea Marconi, Ermanno Vitale, Massimo Bracci y Venerando Rapisarda. “Assessment of Comfort Variation among Different Types of Driving Agricultural Tractors: Traditional, Satellite-Assisted and Semi-Automatic”. English. En: *INTERNATIONAL JOURNAL OF ENVIRONMENTAL RESEARCH AND PUBLIC HEALTH* 17.23 (2020). DOI: {10.3390/ijerph17238836}.
- [135] Karolis Ryselis, Tautvydas Petkus, Tomas Blazauskas, Rytis Maskeliunas y Robertas Damasevicius. “Multiple Kinect based system to monitor and analyze key performance indicators of physical training”. English. En: *HUMAN-CENTRIC COMPUTING AND INFORMATION SCIENCES* 10.1 (2020). DOI: {10.1186/s13673-020-00256-4}.
- [136] Javad Abbasi, Hassan Salarieh y Aria Alasty. “A motion capture algorithm based on inertia-Kinect sensors for lower body elements and step length estimation”. English. En: *BIO-MEDICAL SIGNAL PROCESSING AND CONTROL* 64 (2021). ISSN: 1746-8094. DOI: {10.1016/j.bspc.2020.102290}.
- [137] Xiaoyang Wang, Yilin Wang, Mingjie Zhou, Baobin Li, Xiaoqian Liu y Tingshao Zhu. “Identifying Psychological Symptoms Based on Facial Movements”. English. En: *FRONTIERS IN PSYCHIATRY* 11 (2020). ISSN: 1664-0640. DOI: {10.3389/fpsy.2020.607890}.

- [138] Matthew H. Foreman y Jack R. Engsberg. “The Validity and Reliability of the Microsoft Kinect for Measuring Trunk Compensation during Reaching”. English. En: *SENSORS* 20.24 (2020). DOI: {10.3390/s20247073}.
- [139] Peter Beshara, Judy F. Chen, Andrew C. Read, Pierre Lagadec, Tian Wang y William Robert Walsh. “The Reliability and Validity of Wearable Inertial Sensors Coupled with the Microsoft Kinect to Measure Shoulder Range-of-Motion”. English. En: *SENSORS* 20.24 (2020). DOI: {10.3390/s20247238}.
- [140] Homa Rafiei Milajerdi, Mahmoud Sheikh, Mahboubeh Ghayour Najafabadi, Behnaz Saghaei, Naser Naghdi y Deborah Dewey. “The Effects of Physical Activity and Exergaming on Motor Skills and Executive Functions in Children with Autism Spectrum Disorder”. English. En: *GAMES FOR HEALTH JOURNAL* 10.1 (2021), 33-42. DOI: {10.1089/g4h.2019.0180}.
- [141] K. Ashwini y R. Amutha. “Compressive sensing based recognition of human upper limb motions with kinect skeletal data”. English. En: *MULTIMEDIA TOOLS AND APPLICATIONS* 80.7 (2021), 10839-10857. DOI: {10.1007/s11042-020-10327-4}.
- [142] Hamid Roozbahani, Marjan Alizadeh, Stanislav Ustinov y Heikki Handroos. “Development of a novel real-time simulation of human skeleton/muscles”. English. En: *JOURNAL OF BIOMECHANICS* 114 (2021). ISSN: 0021-9290. DOI: {10.1016/j.jbiomech.2020.110157}.
- [143] Huosheng Xie, Hongwen Luo, Jie Lin y Ning Yang. “A novel algorithm of fast CPR quality evaluation based on kinect”. English. En: *JOURNAL OF ALGORITHMS & COMPUTATIONAL TECHNOLOGY* 14 (2020). ISSN: 1748-3018. DOI: {10.1177/1748302620983661}.
- [144] David Gonzalez-Ortega, Francisco Javier Diaz-Pernas, Mario Martinez-Zarzuola y Miriam Anton-Rodriguez. “Comparative Analysis of Kinect-Based and Oculus-Based Gaze Region Estimation Methods in a Driving Simulator”. English. En: *SENSORS* 21.1 (2021). DOI: {10.3390/s21010026}.
- [145] Ricardo Brito, Robert P. Biuk-Aghai y Simon Fong. “GPU-based parallel Shadow Features generation at neural system for improving gait human activity recognition”. English. En: *MULTIMEDIA TOOLS AND APPLICATIONS* 80.8 (2021), 12293-12308. DOI: {10.1007/s11042-020-10274-0}.
- [146] Yujia Zhang, Qianzhong Li, Xiaoguang Zhao y Min Tan. “Robot learning through observation via coarse-to-fine grained video summarization”. English. En: *APPLIED SOFT COMPUTING* 99 (2021). ISSN: 1568-4946. DOI: {10.1016/j.asoc.2020.106913}.
- [147] Ditte Ruda, Gudmundur Einarsson, Anne Sofie Schott Andersen, Jannik Boll Matthiassen, Christoph U. Correll, Kristian Winge, Line K. H. Clemmensen, Rasmus R. Paulsen, Anne Katrine Pagsberg y Anders Fink-Jensen. “Exploring Movement Impairments in Patients With Parkinson’s Disease Using the Microsoft Kinect Sensor: A Feasibility Study”. English. En: *FRONTIERS IN NEUROLOGY* 11 (2021). ISSN: 1664-2295. DOI: {10.3389/fneur.2020.610614}.

- [148] Peter Lisman, Joshua N. Wilder, Joshua Berenbach, James J. Foster y Bethany L. Hansberger. “Sex differences in lower extremity kinematics during overhead and single leg squat tests”. English. En: *SPORTS BIOMECHANICS* (). DOI: {10.1080/14763141.2020.1839124}.
- [149] Dorothea Sze Min Ong, Melvyn Zhang Weibin y Ranganath Vallabhajosyula. “Serious games as rehabilitation tools in neurological conditions: A comprehensive review”. English. En: *TECHNOLOGY AND HEALTH CARE* 29.1 (2021), 15-31. ISSN: 0928-7329. DOI: {10.3233/THC-202333}.
- [150] Min Li, Fan Wei, Yu Li, Sicong Zhang y Guanghua Xu. “Three-Dimensional Pose Estimation of Infants Lying Supine Using Data From a Kinect Sensor With Low Training Cost”. English. En: *IEEE SENSORS JOURNAL* 21.5 (2021), 6904-6913. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.3037121}.
- [151] Xiaoyang Wang, Xiaoqian Liu, Yuqian Wang y Tingshao Zhu. “How Can People Express Their Trait Self-Esteem Through Their Faces in 3D Space?” English. En: *FRONTIERS IN PSYCHOLOGY* 12 (2021). ISSN: 1664-1078. DOI: {10.3389/fpsyg.2021.591682}.
- [152] Christoph Heidt, Matia Vrankovic, Alejandro Mendoza, Karsten Hollander, Thomas Dreher y Matthias Rueger. “Simplified digital balance assessment in typically developing school children”. English. En: *GAIT & POSTURE* 84 (2021), 389-394. ISSN: 0966-6362. DOI: {10.1016/j.gaitpost.204.01.005}.
- [153] Caio Victor Sousa, Jungyun Hwang, Herbert Gustavo Simoes, Kyung Jin Sun y Amy Shirong Lu. “Rapid component of excess post-exercise oxygen consumption of children of different weight status after playing active video games”. English. En: *BMC PEDIATRICS* 21.1 (2021). DOI: {10.1186/s12887-021-02528-z}.
- [154] Timothy C. Mauntel, Kenneth L. Cameron, Brian Pietrosimone, Stephen W. Marshall, Anthony C. Hackney y Darin A. Padua. “Validation of a Commercially Available Markerless Motion-Capture System for Trunk and Lower Extremity Kinematics During a Jump-Landing Assessment”. English. En: *JOURNAL OF ATHLETIC TRAINING* 56.2 (2021), 177-190. ISSN: 1062-6050. DOI: {10.4085/1062-6050-0023.20}.
- [155] Raquel Gutierrez Zuniga, Maria Alonso de Lecinana, Alejandro Diez, Gabriel Torres Iglesias, Alejandro Pascual, Ariaki Higashi, Jorge Rodriguez Pardo, David Hernandez Herrero, Blanca Fuentes y Exuperio Diez Tejedor. “A New Software for Quantifying Motor Deficit After Stroke: A Case-Control Feasibility Pilot Study”. English. En: *FRONTIERS IN NEUROLOGY* 12 (2021). ISSN: 1664-2295. DOI: {10.3389/fneur.2021.603619}.
- [156] Tan-Nhu Nguyen, Stephanie Dakpe, Marie-Christine Ho Ba Tho y Tien-Tuan Dao. “Kinect-driven Patient-specific Head, Skull, and Muscle Network Modelling for Facial Palsy Patients”. English. En: *COMPUTER METHODS AND PROGRAMS IN BIOMEDICINE* 200 (2021). ISSN: 0169-2607. DOI: {10.1016/j.cmpb.2020.105846}.
- [157] Yongjoo Cho y Kyoung Shin Park. “The Chongchong Step Master Game for Gait and Balance Training”. English. En: *MULTIMODAL TECHNOLOGIES AND INTERACTION* 4.3 (2020). DOI: {10.3390/mti4030056}.

- [158] Ying Sun, Yaoqing Weng, Bowen Luo, Gongfa Li, Bo Tao, Du Jiang y Disi Chen. “Gesture recognition algorithm based on multi-scale feature fusion in RGB-D images”. English. En: *IET IMAGE PROCESSING* 14.15 (2020), 3662-3668. ISSN: 1751-9659. DOI: {10.1049/iet-ipr.2020.0148}.
- [159] Masahiro Nishihori, Takashi Izumi, Yoshitaka Nagano, Masaki Sato, Tetsuya Tsukada, Asuka Elisabeth Kropp y Toshihiko Wakabayashi. “Development and clinical evaluation of a contactless operating interface for three-dimensional image-guided navigation for endovascular neurosurgery”. English. En: *INTERNATIONAL JOURNAL OF COMPUTER ASSISTED RADIOLOGY AND SURGERY* 16.4 (2021), 663-671. DOI: {10.1007/s11548-021-02330-3}.
- [160] Guillermo Diaz-San Martin, Luis Reyes-Gonzalez, Sergio Sainz-Ruiz, Luis Rodriguez-Cobo y Jose M. Lopez-Higuera. “Automatic Ankle Angle Detection by Integrated RGB and Depth Camera System”. English. En: *SENSORS* 21.5 (2021). DOI: {10.3390/s21051909}.
- [161] Bahar Tuncgenc, Carolina Pacheco, Rebecca Rochowiak, Rosemary Nicholas, Sundararaman Rengarajan, Erin Zou, Brice Messenger, Rene Vidal y Stewart H. Mostofsky. “Computerized Assessment of Motor Imitation as a Scalable Method for Distinguishing Children With Autism”. English. En: *BIOLOGICAL PSYCHIATRY-COGNITIVE NEUROSCIENCE AND NEUROIMAGING* 6.3 (2021), 321-328. ISSN: 2451-9022. DOI: {10.1016/j.bpsc.2020.09.001}.
- [162] Yanxia Li y Ke Zhao. “Sports motional characteristics modeling by leveraging multi-modal image technique”. English. En: *FUTURE GENERATION COMPUTER SYSTEMS-THE INTERNATIONAL JOURNAL OF ESCIENCE* 119 (2021), 37-42. ISSN: 0167-739X. DOI: {10.1016/j.future.2021.01.031}.
- [163] Wei Yang, Jian Wang y Jinlong Shi. “Video quality evaluation toward complicated sport activities for clustering analysis”. English. En: *FUTURE GENERATION COMPUTER SYSTEMS-THE INTERNATIONAL JOURNAL OF ESCIENCE* 119 (2021), 43-49. ISSN: 0167-739X. DOI: {10.1016/j.future.2021.01.018}.
- [164] Leonardo Sabatino Scimmi, Matteo Melchiorre, Mario Troise, Stefano Mauro y Stefano Pastorelli. “A Practical and Effective Layout for a Safe Human-Robot Collaborative Assembly Task”. English. En: *APPLIED SCIENCES-BASEL* 11.4 (2021). DOI: {10.3390/app11041763}.
- [165] Qurat Ul Ain, Sara Khan, Saad Ilyas, Amna Yaseen, Iqbal Tariq, Tian Liu y Jue Wang. “Additional Effects of Xbox Kinect Training on Upper Limb Function in Chronic Stroke Patients: A Randomized Control Trial”. English. En: *HEALTHCARE* 9.3 (2021). DOI: {10.3390/healthcare9030242}.
- [166] Guo-Shing Huang, Shao-Chian Chang, Chung-Liang Lai y Chi-Chun Chen. “Development of a Lower Extremity Exoskeleton as an Individualized Auxiliary Tool for Sit-to-Stand-to-Sit Movements”. English. En: *IEEE ACCESS* 9 (2021), 48276-48285. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2021.3063253}.

- [167] Ricardo Andres Diaz Suarez, Leidy Tatiana Moreno Moreno, Marlon Andres Sanjuan Vargas, Carlos Alberto Prada Garcia y Luis Dalmiro Torres. “Development of an exoskeleton for the rehabilitation of the flexo-extensor movement of the elbow”. Spanish. En: *REVISTA ITECKNE* 18.1 (2021). ISSN: 1692-1798. DOI: {10.15332/iteckne.v18i1.2539}.
- [168] Kamel Aouaidjia, Bin Sheng, Ping Li, Jinman Kim y David Dagan Feng. “Efficient Body Motion Quantification and Similarity Evaluation Using 3-D Joints Skeleton Coordinates”. English. En: *IEEE TRANSACTIONS ON SYSTEMS MAN CYBERNETICS-SYSTEMS* 51.5 (2021), 2774-2788. ISSN: 2168-2216. DOI: {10.1109/TSMC.2019.2916896}.
- [169] Maria Carrillo-Diaz, Laura Lacomba-Trejo, Antonio del Valle-Gonzalez, Martin Romero-Maroto y Maria Jose Gonzalez-Olmo. “Anxiety and facial self-contacts: possible impact on COVID-19 transmission in dental practice”. English. En: *BMC ORAL HEALTH* 21.1 (2021). ISSN: 1472-6831. DOI: {10.1186/s12903-021-01564-6}.
- [170] Jan Stenum, Cristina Rossi y Ryan T. Roemmich. “Two-dimensional video-based analysis of human gait using pose estimation”. English. En: *PLOS COMPUTATIONAL BIOLOGY* 17.4 (2021). ISSN: 1553-734X. DOI: {10.1371/journal.pcbi.1008935}.
- [171] Mireia Sempere-Tortosa, Francisco Fernandez-Carrasco, Ignasi Navarro-Soria y Carlos Rizo-Maestre. “Movement Patterns in Students Diagnosed with ADHD, Objective Measurement in a Natural Learning Environment”. English. En: *INTERNATIONAL JOURNAL OF ENVIRONMENTAL RESEARCH AND PUBLIC HEALTH* 18.8 (2021). DOI: {10.3390/ijerph18083870}.
- [172] Giulia Colombini, Mirko Duradoni, Federico Carpi, Laura Vagnoli y Andrea Guazzini. “LEAP Motion Technology and Psychology: A Mini-Review on Hand Movements Sensing for Neurodevelopmental and Neurocognitive Disorders”. English. En: *INTERNATIONAL JOURNAL OF ENVIRONMENTAL RESEARCH AND PUBLIC HEALTH* 18.8 (2021). DOI: {10.3390/ijerph18084006}.
- [173] Farman Shah, Muhammad Saqlain Shah, Waseem Akram, Awais Manzoor, Rasha Orban Mahmoud y Diaan Salama Abdelminaam. “Sign Language Recognition Using Multiple Kernel Learning: A Case Study of Pakistan Sign Language”. English. En: *IEEE ACCESS* 9 (2021), 67548-67558. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2021.3077386}.
- [174] Paulo Ricardo da Silva y Clariton Rodrigues Bernadelli. “Dynamic Time Warping in Iris Biometric Recognition Process”. English. En: *IEEE LATIN AMERICA TRANSACTIONS* 19.01 (2021), 42-49. ISSN: 1548-0992. DOI: {10.1109/TLA.2021.9423825}.
- [175] Hang Su, Andrea Mariani, Salih Ertug Ovrur, Arianna Menciassi, Giancarlo Ferrigno y Elena De Momi. “Toward Teaching by Demonstration for Robot-Assisted Minimally Invasive Surgery”. English. En: *IEEE TRANSACTIONS ON AUTOMATION SCIENCE AND ENGINEERING* 18.2 (2021), 484-494. ISSN: 1545-5955. DOI: {10.1109/TASE.2020.3045655}.
- [176] Zhiyong Chen, Xiaowei Chen, Yong Ma, Shihui Guo, Yipeng Qin y Minghong Liao. “Human posture tracking with flexible sensors for motion recognition”. English. En: *COMPUTER ANIMATION AND VIRTUAL WORLDS* (). DOI: {10.1002/cav.1993}.

- [177] Bahar Tuncgenc, Carolina Pacheco, Rebecca Rochowiak, Rosemary Nicholas, Sundararaman Rengarajan, Erin Zou, Brice Messenger, Rene Vidal y Stewart H. Mostofsky. “Computerized Assessment of Motor Imitation as a Scalable Method for Distinguishing Children With Autism”. English. En: *BIOLOGICAL PSYCHIATRY-COGNITIVE NEUROSCIENCE AND NEUROIMAGING* 6.3 (2021), 321-328. ISSN: 2451-9022. DOI: {10.1016/j.bpsc.2020.09.001}.
- [178] Jing Li y Hao Wu. “Localisation algorithm for security access control in railway communications”. English. En: *IET INTELLIGENT TRANSPORT SYSTEMS* 14.14 (2020), 2151-2159. ISSN: 1751-956X. DOI: {10.1049/iet-its.2020.0065}.
- [179] Ricardo Santos, Ricardo Leonardo, Marilia Barandas, Dinis Moreira, Tiago Rocha, Pedro Alves, Joao P. Oliveira y Hugo Gamboa. “Crowdsourcing-Based Fingerprinting for Indoor Location in Multi-Storey Buildings”. English. En: *IEEE ACCESS* 9 (2021), 31143-31160. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2021.3060123}.
- [180] Ismail Sadiq, Erick A. Perez-Alday, Amit J. Shah y Gari D. Clifford. “Breathing rate and heart rate as confounding factors in measuring T wave alternans and morphological variability in ECG”. English. En: *PHYSIOLOGICAL MEASUREMENT* 42.1 (2021). ISSN: 0967-3334. DOI: {10.1088/1361-6579/abd237}.
- [181] Natalia Bogach, Elena Boitsova, Sergey Chernonog, Anton Lamtev, Maria Lesnichaya, Iurii Lezhenin, Audrey Novopashenny, Roman Svechnikov, Daria Tsikach, Konstantin Vasiliev, Evgeny Pyshkin y John Blake. “Speech Processing for Language Learning: A Practical Approach to Computer-Assisted Pronunciation Teaching”. English. En: *ELECTRONICS* 10.3 (2021). DOI: {10.3390/electronics10030235}.
- [182] Yuri Gloumakov, Adam J. Spiers y Aaron M. Dollar. “Dimensionality Reduction and Motion Clustering During Activities of Daily Living: Three-, Four-, and Seven-Degree-of-Freedom Arm Movements”. English. En: *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING* 28.12 (2020). IEEE International Conference on Robotics and Automation (ICRA), Montreal, CANADA, MAY 20-24, 2019, 2826-2836. ISSN: 1534-4320. DOI: {10.1109/TNSRE.2020.3040522}.
- [183] Hasan Mahmud, Robiul Islam y Md. Kamrul Hasan. “On-air English Capital Alphabet (ECA) recognition using depth information”. English. En: *VISUAL COMPUTER* (). DOI: {10.1007/s00371-021-02065-x}.
- [184] Sophie Van der Zee, Paul Taylor, Ruth Wong, John Dixon y Tarek Menacere. “A liar and a copycat: nonverbal coordination increases with lie difficulty”. English. En: *ROYAL SOCIETY OPEN SCIENCE* 8.1 (2021). ISSN: 2054-5703. DOI: {10.1098/rsos.200839}.
- [185] Lushuang Chen, Menghan Hu, Ning Liu, Guangtao Zhai y Simon X. Yang. “Collaborative use of RGB and thermal imaging for remote breathing rate measurement under realistic conditions”. English. En: *INFRARED PHYSICS & TECHNOLOGY* 111 (2020). ISSN: 1350-4495. DOI: {10.1016/j.infrared.2020.103504}.

- [186] Renuka Mannem y Prasanta Kumar Ghosh. “A deep neural network based correction scheme for improved air-tissue boundary prediction in real-time magnetic resonance imaging video”. English. En: *COMPUTER SPEECH AND LANGUAGE* 66 (2021). ISSN: 0885-2308. DOI: {10.1016/j.csl.2020.101160}.
- [187] Tobias Steinmetzer, Ingrid Bonninger, Markus Reckhardt, Fritjof Reinhardt, Dorela Erk y Carlos M. Travieso. “Comparison of algorithms and classifiers for stride detection using wearables”. English. En: *NEURAL COMPUTING & APPLICATIONS* 32.24, SI (2020), 17857-17868. ISSN: 0941-0643. DOI: {10.1007/s00521-019-04384-6}.
- [188] Sagar Dutta, Banani Basu y Fazal Ahmed Talukdar. “Classification of Lower Limb Activities Based on Discrete Wavelet Transform Using On-Body Creeping Wave Propagation”. English. En: *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT* 70 (2021). ISSN: 0018-9456. DOI: {10.1109/TIM.2020.3031210}.
- [189] Hsin-Hsiao Scott Wang, Dylan Cahill, John Panagides, Caleb P. Nelson, Hau-Tieng Wu y Carlos Estrada. “Pattern recognition algorithm to identify detrusor overactivity on urodynamics”. English. En: *NEUROUROLOGY AND URODYNAMICS* 40.1 (2021), 428-434. DOI: {10.1002/nau.24578}.
- [190] Suvodip Chakraborty, Anirban Dasgupta y Aurobinda Routray. “Localization of eye Saccadic signatures in Electrooculograms using sparse representations with data driven dictionaries”. English. En: *PATTERN RECOGNITION LETTERS* 139 (2020), 104-111. ISSN: 0167-8655. DOI: {10.1016/j.patrec.2017.11.001}.
- [191] Wenguo Li, Zhizeng Luo y Xugang Xi. “Movement Trajectory Recognition of Sign Language Based on Optimized Dynamic Time Warping”. English. En: *ELECTRONICS* 9.9 (2020). DOI: {10.3390/electronics9091400}.
- [192] Andre Maharaj V, Anibal Gutierrez, Carlos Cueto y Steven Cadavid. “Automated measurement of repetitive behavior using the Microsoft Kinect: a proof of concept”. English. En: *BEHAVIORAL INTERVENTIONS* 35.4 (2020), 488-497. DOI: {10.1002/bin.1746}.
- [193] Igi Ardiyanto, Sunu Wibirama y Fajri Nurwanto. “Sliding variance and data range for lightweight sports activity recognition with fusion of modalities”. English. En: *JOURNAL OF KING SAUD UNIVERSITY-COMPUTER AND INFORMATION SCIENCES* 32.7 (2020), 775-783. ISSN: 1319-1578. DOI: {10.1016/j.jksuci.2018.08.012}.
- [194] Tomer Stern, Stanislav Y. Shvartsman y Eric F. Wieschaus. “Template-based mapping of dynamic motifs in tissue morphogenesis”. English. En: *PLOS COMPUTATIONAL BIOLOGY* 16.8 (2020). ISSN: 1553-734X. DOI: {10.1371/journal.pcbi.1008049}.
- [195] Giovanni Saggio, Pietro Cavallo, Mariachiara Ricci, Vito Errico, Jonathan Zea y Marco E. Benalcazar. “Sign Language Recognition Using Wearable Electronics: Implementing k-Nearest Neighbors with Dynamic Time Warping and Convolutional Neural Network Algorithms”. English. En: *SENSORS* 20.14 (2020). DOI: {10.3390/s20143879}.

- [196] Chunxu Li, Ashraf Fahmy, Shaoxiang Li y Johann Sienz. “An Enhanced Robot Massage System in Smart Homes Using Force Sensing and a Dynamic Movement Primitive”. English. En: *FRONTIERS IN NEUROBOTICS* 14 (2020). ISSN: 1662-5218. DOI: {10.3389/fnbot.2020.00030}.
- [197] Xu Haiyang, Kong Jun y Jiang Min. “Human Action Recognition Based on Quaternion 3D Skeleton Representation”. Chinese. En: *LASER & OPTOELECTRONICS PROGRESS* 55.2 (2018). ISSN: 1006-4125. DOI: {10.3788/L0P55.021002}.
- [198] Huanhuan Li, Jingxian Liu, Zaili Yang, Ryan Wen Liu, Kefeng Wu y Yuan Wan. “Adaptively constrained dynamic time warping for time series classification and clustering”. English. En: *INFORMATION SCIENCES* 534 (2020), 97-116. ISSN: 0020-0255. DOI: {10.1016/j.ins.2020.04.009}.
- [199] Ryan K. Orosco, Benjamin Lurie, Tokio Matsusaki, Emily K. Funk, Vasu Divi, F. Christopher Holsinger, Steven Hong, Florian Richter, Nikhil Dass y Michael Yip. “Compensatory motion scaling for time-delayed robotic surgery”. English. En: *SURGICAL ENDOSCOPY AND OTHER INTERVENTIONAL TECHNIQUES* 35.6 (2021), 2613-2618. DOI: {10.1007/s00464-020-07681-7}.
- [200] Yangyang Zhang, Ying Huang, Xuehu Sun, Yunong Zhao, Xiaohui Guo, Ping Liu, Caixia Liu y Yugang Zhang. “Static and Dynamic Human Arm/Hand Gesture Capturing and Recognition via Multiinformation Fusion of Flexible Strain Sensors”. English. En: *IEEE SENSORS JOURNAL* 20.12 (2020), 6450-6459. ISSN: 1530-437X. DOI: {10.1109/JSEN.2020.2965580}.
- [201] Yangyang Zhang, Ying Huang, Baisheng Lu, Yuanming Ma, Jihong Qiu, Yunong Zhao, Xiaohui Guo, Caixia Liu, Ping Liu y Yugang Zhang. “Real-time sitting behavior tracking and analysis for rectification of sitting habits by strain sensor-based flexible data bands”. English. En: *MEASUREMENT SCIENCE AND TECHNOLOGY* 31.5 (2020). ISSN: 0957-0233. DOI: {10.1088/1361-6501/ab63ea}.
- [202] Haitao Guo y Yunsick Sung. “Movement Estimation Using Soft Sensors Based on Bi-LSTM and Two-Layer LSTM for Human Motion Capture”. English. En: *SENSORS* 20.6 (2020). DOI: {10.3390/s20061801}.
- [203] Sheila Clemens, Kyoung Jae Kim, Robert Gailey, Neva Kirk-Sanchez, Anat Kristal e Ignacio Gaunaurd. “Inertial sensor-based measures of gait symmetry and repeatability in people with unilateral lower limb amputation”. English. En: *CLINICAL BIOMECHANICS* 72 (2020), 102-107. ISSN: 0268-0033. DOI: {10.1016/j.clinbiomech.2019.12.007}.
- [204] Ting Zhang, Bradley S. Duerstock y Juan P. Wachs. “Classification of Blind Users’ Image Exploratory Behaviors Using Spiking Neural Networks”. English. En: *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING* 28.4 (2020), 1032-1041. ISSN: 1534-4320. DOI: {10.1109/TNSRE.2019.2959555}.

- [205] Khoa D. Nguyen, Louise A. Corben, Pubudu N. Pathirana, Malcolm K. Horne, Martin B. Delatycki y David J. Szmulewicz. “The Assessment of Upper Limb Functionality in Friedreich Ataxia via Self-Feeding Activity”. English. En: *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING* 28.4 (2020), 924-933. ISSN: 1534-4320. DOI: {10.1109/TNSRE.2020.2977354}.
- [206] Xinyao Hu, Shaorong Mo y Xingda Qu. “Basketball Activity Classification Based on Upper Body Kinematics and Dynamic Time Warping”. English. En: *INTERNATIONAL JOURNAL OF SPORTS MEDICINE* 41.4 (2020), 255-263. ISSN: 0172-4622. DOI: {10.1055/a-1065-2044}.
- [207] Olayinka O. Ogundile y Daniel J. J. Versfeld. “Analysis of Template-Based Detection Algorithms for Inshore Bryde’s Whale Short Pulse Calls”. English. En: *IEEE ACCESS* 8 (2020), 14377-14385. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2020.2966254}.
- [208] Kim Sarah Sczuka, Lars Schwickert, Clemens Becker y Jochen Klenk. “Re-Enactment as a Method to Reproduce Real-World Fall Events Using Inertial Sensor Data: Development and Usability Study”. English. En: *JOURNAL OF MEDICAL INTERNET RESEARCH* 22.4 (2020). ISSN: 1438-8871. DOI: {10.2196/13961}.
- [209] Jesus Franco-Robles, Alejandro De Lucio-Rangel, Karla A. Camarillo-Gomez, Gerardo Perez-Soto I y Miguel A. Martinez-Prado. “Liquid State Machine to Generate the Movement Profiles for the Gait Cycle of a Six Degrees-of-Freedom Bipedal Robot in a Sagittal Plane”. English. En: *JOURNAL OF DYNAMIC SYSTEMS MEASUREMENT AND CONTROL-TRANSACTIONS OF THE ASME* 142.1 (2020). ISSN: 0022-0434. DOI: {10.1115/1.4044621}.
- [210] Somayeh Aghanavasi, Hasan Fleyeh y Mark Dougherty. “Feasibility of Using Dynamic Time Warping to Measure Motor States in Parkinson’s Disease”. English. En: *JOURNAL OF SENSORS* 2020 (2020). ISSN: 1687-725X. DOI: {10.1155/2020/3265795}.
- [211] Renaud Hage, Christine Detrembleur, Frederic Dierick, Laurent Pitance, Laurent Joczzyk, Wesley Estievenart y Fabien Buisseret. “DYSKIMOT: An Ultra-Low-Cost Inertial Sensor to Assess Head’s Rotational Kinematics in Adults during the Didren-Laser Test”. English. En: *SENSORS* 20.3 (2020). DOI: {10.3390/s20030833}.
- [212] Jesus D. Ceron, Christine F. Martindale, Diego M. Lopez, Felix Kluge y Bjoern M. Eskofier. “Indoor Trajectory Reconstruction of Walking, Jogging, and Running Activities Based on a Foot-Mounted Inertial Pedestrian Dead-Reckoning System”. English. En: *SENSORS* 20.3 (2020). DOI: {10.3390/s20030651}.
- [213] Yiqun Kuang, Hong Cheng, Yali Zheng, Fang Cui y Rui Huang. “One-shot gesture recognition with attention-based DTW for human-robot collaboration”. English. En: *ASSEMBLY AUTOMATION* 40.1, SI (2019), 40-47. ISSN: 0144-5154. DOI: {10.1108/AA-11-2018-0228}.
- [214] XiaoJuan Ding y Zhao Lv. “Design and development of an EOG-based simplified Chinese eye-writing system”. English. En: *BIOMEDICAL SIGNAL PROCESSING AND CONTROL* 57.SI (2020). ISSN: 1746-8094. DOI: {10.1016/j.bspc.2019.101767}.

- [215] Amani Elaoud, Walid Barhoumi, Ezzeddine Zagrouba y Brahim Agrebi. “Skeleton-based comparison of throwing motion for handball players”. English. En: *JOURNAL OF AMBIENT INTELLIGENCE AND HUMANIZED COMPUTING* 11.1, SI (2020), 419-431. ISSN: 1868-5137. DOI: {10.1007/s12652-019-01301-6}.
- [216] Joana N. Rocha, Claire M. Barnes, Paul Rees, Cain T. Clark, Gareth Stratton y Huw D. Summers. “Activity Mapping of Children in Play Using Multivariate Analysis of Movement Events”. English. En: *MEDICINE AND SCIENCE IN SPORTS AND EXERCISE* 52.1 (2020), 259-266. ISSN: 0195-9131. DOI: {10.1249/MSS.0000000000002119}.
- [217] Omkar S. Powar y Krishnan Chemmangat. “Reducing the effect of wrist variation on pattern recognition of Myoelectric Hand Prostheses Control through Dynamic Time Warping”. English. En: *BIOMEDICAL SIGNAL PROCESSING AND CONTROL* 55 (2020). ISSN: 1746-8094. DOI: {10.1016/j.bspc.2019.101626}.
- [218] Ian R. Cleasby, Ewan D. Wakefield, Barbara J. Morrissey, Thomas W. Bodey, Steven C. Votier, Stuart Bearhop y Keith C. Hamer. “Using time-series similarity measures to compare animal movement trajectories in ecology”. English. En: *BEHAVIORAL ECOLOGY AND SOCIOBIOLOGY* 73.11 (2019). ISSN: 0340-5443. DOI: {10.1007/s00265-019-2761-1}.
- [219] Cameron J. R. McClelland, Nicholas C. Coops, Ethan E. Berman, Sean P. Kearney, Scott E. Nielsen, A. Cole Burton y Gordon B. Stenhouse. “Detecting changes in understorey and canopy vegetation cycles in West Central Alberta using a fusion of Landsat and MODIS”. English. En: *APPLIED VEGETATION SCIENCE* 23.2 (2020), 223-238. DOI: {10.1111/avsc.12466}.
- [220] A. Moayedi, R. Ali Abbaspour y A. Chehreghan. “An evaluation of the efficiency of similarity functions in density-based clustering of spatial trajectories”. English. En: *ANNALS OF GIS* 25.4 (2019), 313-327. ISSN: 1947-5683. DOI: {10.1080/19475683.2019.1679254}.
- [221] Minwoo Kim, Jaechan Cho, Seongjoo Lee y Yunho Jung. “IMU Sensor-Based Hand Gesture Recognition for Human-Machine Interfaces”. English. En: *SENSORS* 19.18 (2019). DOI: {10.3390/s19183827}.
- [222] Ioannis Rallis, Eftychios Protopapadakis, Athanasios Voulodimos, Nikolaos Doulamis, Anastasios Doulamis y Georgios Bardis. “Choreographic Pattern Analysis from Heterogeneous Motion Capture Systems Using Dynamic Time Warping”. English. En: *TECHNOLOGIES* 7.3 (2019). DOI: {10.3390/technologies7030056}.
- [223] Tao Hu, Xinyan Zhu, Wei Guo, Shaohua Wang y Jianfeng Zhu. “Human action recognition based on scene semantics”. English. En: *MULTIMEDIA TOOLS AND APPLICATIONS* 78.20 (2019), 28515-28536. ISSN: 1380-7501. DOI: {10.1007/s11042-017-5496-x}.
- [224] Ammar Yasser, Doha Tariq, Radwa Samy, Mennat Allah Hassan y Ayman Atia. “Smart Coaching: Enhancing Weightlifting and Preventing Injuries”. English. En: *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 10.7 (2019), 686-691. ISSN: 2158-107X.

- [225] Omkar S. Powar y Krishnan Chemmangat. “Dynamic time warping for reducing the effect of force variation on myoelectric control of hand prostheses”. English. En: *JOURNAL OF ELECTROMYOGRAPHY AND KINESIOLOGY* 48 (2019), 152-160. ISSN: 1050-6411. DOI: {10.1016/j.jelekin.2019.07.006}.
- [226] Thibaut Le Naour, Chiara Re y Jean-Pierre Bresciani. “3D feedback and observation for motor learning: Application to the roundoff movement in gymnastics”. English. En: *HUMAN MOVEMENT SCIENCE* 66 (2019), 564-577. ISSN: 0167-9457. DOI: {10.1016/j.humov.2019.06.008}.
- [227] Kang Cheng, Ning Ye, Reza Malekian y Ruchuan Wang. “In-Air Gesture Interaction: Real Time Hand Posture Recognition Using Passive RFID Tags”. English. En: *IEEE ACCESS* 7 (2019), 94460-94472. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2019.2928318}.
- [228] Rizwan Qureshi, Mehmood Nawaz, Avirup Ghosh y Hong Yan. “Parametric Models for Understanding Atomic Trajectories in Different Domains of Lung Cancer Causing Protein”. English. En: *IEEE ACCESS* 7 (2019), 67551-67563. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2019.2918294}.
- [229] Li Rui, Yu Jun, Li Xian, Fang Peng y Wang Zengfu. “An Evaluation Framework for Virtual Articulatory Movements Based on Medical Video”. English. En: *CHINESE JOURNAL OF ELECTRONICS* 28.3 (2019), 585-592. ISSN: 1022-4653. DOI: {10.1049/cje.2018.09.019}.
- [230] Ha Tran, Pubudu N. Pathirana, Malcolm Horne, Laura Power y David J. Szmulewicz. “Quantitative Evaluation of Cerebellar Ataxia Through Automated Assessment of Upper Limb Movements”. English. En: *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING* 27.5 (2019), 1081-1091. ISSN: 1534-4320. DOI: {10.1109/TNSRE.2019.2911657}.
- [231] Joe Sarsfield, David Brown, Nasser Sherkat, Caroline Langensiepen, James Lewis, Mohammad Taheri, Louise Selwood, Penny Standen y Pip Logan. “Segmentation of Exercise Repetitions Enabling Real-Time Patient Analysis and Feedback Using a Single Exemplar”. English. En: *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING* 27.5 (2019), 1004-1019. ISSN: 1534-4320. DOI: {10.1109/TNSRE.2019.2907483}.
- [232] Miao Yu. “Motion standard level system based on Internet of things”. English. En: *INTERNATIONAL JOURNAL OF DISTRIBUTED SENSOR NETWORKS* 15.4 (2019). ISSN: 1550-1477. DOI: {10.1177/1550147719844158}.
- [233] Yosuke Kurihara, Takashi Kaburagi, Satoshi Kumagai y Toshiyuki Matsumoto. “Development of Swallowing-Movement-Sensing Device and Swallowing-State-Estimation System”. English. En: *IEEE SENSORS JOURNAL* 19.9 (2019), 3532-3542. ISSN: 1530-437X. DOI: {10.1109/JSEN.2019.2894744}.

- [234] Baichuan Yuan, Yen Joe Tan, Maruti K. Mudunuru, Omar E. Marcillo, Andrew A. Delorey, Peter M. Roberts, Jeremy D. Webster, Christine N. L. Gammans, Satish Karra, George D. Guthrie y Paul A. Johnson. “Using Machine Learning to Discern Eruption in Noisy Environments: A Case Study Using CO₂-Driven Cold-Water Geyser in Chimayo, New Mexico”. English. En: *SEISMOLOGICAL RESEARCH LETTERS* 90.2, A (2019), 591-603. ISSN: 0895-0695. DOI: {10.1785/0220180306}.
- [235] Antonio Parziale, Moises Diaz, Miguel A. Ferrer y Angelo Marcelli. “SM-DTW: Stability Modulated Dynamic Time Warping for signature verification”. English. En: *PATTERN RECOGNITION LETTERS* 121.SI (2019). 18th Conference of the International-Graphonomics-Society (IGS), Gaeta, ITALY, JUN 18-21, 2017, 113-122. ISSN: 0167-8655. DOI: {10.1016/j.patrec.2018.07.029}.
- [236] Chunxu Li, Chenguang Yang, Andy Annamalai, Qingsong Xu y Shaoxiang Li. “Development of writing task recombination technology based on DMP segmentation via verbal command for Baxter robot”. English. En: *SYSTEMS SCIENCE & CONTROL ENGINEERING* 6.1 (2018), 350-359. ISSN: 2164-2583. DOI: {10.1080/21642583.2018.1509397}.
- [237] Jing Bai y Aiguo Song. “Development of a Novel Home Based Multi-Scene Upper Limb Rehabilitation Training and Evaluation System for Post-Stroke Patients”. English. En: *IEEE ACCESS* 7 (2019), 9667-9677. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2019.2891606}.
- [238] R. Varatharajan, Gunasekaran Manogaran, M. K. Priyan y Revathi Sundarasekar. “Wearable sensor devices for early detection of Alzheimer disease using dynamic time warping algorithm”. English. En: *CLUSTER COMPUTING-THE JOURNAL OF NETWORKS SOFTWARE TOOLS AND APPLICATIONS* 21.1, SI (2018), 681-690. ISSN: 1386-7857. DOI: {10.1007/s10586-017-0977-2}.
- [239] Yves Rybarczyk, Jorge Luis Perez Medina, Louis Leconte, Karina Jimenes, Mario Gonzalez y Danilo Esparza. “Implementation and Assessment of an Intelligent Motor Tele-Rehabilitation Platform”. English. En: *ELECTRONICS* 8.1 (2019). ISSN: 2079-9292. DOI: {10.3390/electronics8010058}.
- [240] Sang Hyuk Kim, Hee Soo Lee, Han Jun Ko, Seung Hwan Jeong, Hyun Woo Byun y Kyong Joo Oh. “Pattern Matching Trading System Based on the Dynamic Time Warping Algorithm”. English. En: *SUSTAINABILITY* 10.12 (2018). DOI: {10.3390/su10124641}.
- [241] Patrick N. Lawlor, Matthew G. Perich, Lee E. Miller y Konrad P. Kording. “Linear-nonlinear-time-warp-poisson models of neural activity”. English. En: *JOURNAL OF COMPUTATIONAL NEUROSCIENCE* 45.3 (2018), 173-191. ISSN: 0929-5313. DOI: {10.1007/s10827-018-0696-6}.
- [242] Gladys Calle Condori, Eveling Castro-Gutierrez y Luis Alfaro Casas. “Virtual Rehabilitation Using Sequential Learning Algorithms”. English. En: *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS* 9.11 (2018), 639-645. ISSN: 2158-107X.

- [243] Weimin Zheng, Rui Zhou, Zhemin Zhang, Yihui Zhong, Surui Wang, Zhao Wei y Haipeng Ji. “Understanding the tourist mobility using GPS: How similar are the tourists?” English. En: *TOURISM MANAGEMENT* 71 (2019), 54-66. ISSN: 0261-5177. DOI: {10.1016/j.tourman.2018.09.019}.
- [244] An-Ti Chiang, Qi Chen, Yao Wang y Mei R. Fu. “Kinect-Based In-Home Exercise System for Lymphatic Health and Lymphedema Intervention”. English. En: *IEEE JOURNAL OF TRANSLATIONAL ENGINEERING IN HEALTH AND MEDICINE-JTEHM* 6 (2018). ISSN: 2168-2372. DOI: {10.1109/JTEHM.2018.2859992}.
- [245] Felix Huelsmann, Jan Philip Goepfert, Barbara Hammer, Stefan Kopp y Mario Botsch. “Classification of motor errors to provide real-time feedback for sports coaching in virtual reality - A case study in squats and Tai Chi pushes”. English. En: *COMPUTERS & GRAPHICS-UK* 76 (2018), 47-59. ISSN: 0097-8493. DOI: {10.1016/j.cag.2018.08.003}.
- [246] Tomasz Hachaj, Katarzyna Koptyra y Marek R. Ogiela. “Averaging of motion capture recordings for movements’ templates generation”. English. En: *MULTIMEDIA TOOLS AND APPLICATIONS* 77.23 (2018), 30353-30380. ISSN: 1380-7501. DOI: {10.1007/s11042-018-6137-8}.
- [247] Hyo-Rim Choi y TaeYong Kim. “Modified Dynamic Time Warping Based on Direction Similarity for Fast Gesture Recognition”. English. En: *MATHEMATICAL PROBLEMS IN ENGINEERING* 2018 (2018). ISSN: 1024-123X. DOI: {10.1155/2018/2404089}.
- [248] Sarah Moudy, Chris Richter y Siobhan Strike. “Landmark registering waveform data improves the ability to predict performance measures”. English. En: *JOURNAL OF BIOMECHANICS* 78 (2018), 109-117. ISSN: 0021-9290. DOI: {10.1016/j.jbiomech.2018.07.027}.
- [249] C. Rufener, J. Berezowski, F. Maximiano Sousa, Y. Abreu, L. Asher y M. J. Toscano. “Finding hens in a haystack: Consistency of movement patterns within and across individual laying hens maintained in large groups”. English. En: *SCIENTIFIC REPORTS* 8 (2018). ISSN: 2045-2322. DOI: {10.1038/s41598-018-29962-x}.
- [250] Yen-Lin Chen, Chin-Hsuan Liu, Chao-Wei Yu, Posen Lee y Yao-Wen Kuo. “An Upper Extremity Rehabilitation System Using Efficient Vision-Based Action Identification Techniques”. English. En: *APPLIED SCIENCES-BASEL* 8.7 (2018). ISSN: 2076-3417. DOI: {10.3390/app8071161}.
- [251] Chunxu Li, Chenguang Yang, Zhaojie Ju y Andy S. K. Annamalai. “An enhanced teaching interface for a robot using DMP and GMR”. English. En: *INTERNATIONAL JOURNAL OF INTELLIGENT ROBOTICS AND APPLICATIONS* 2.1 (2018), 110-121. ISSN: 2366-5971. DOI: {10.1007/s41315-018-0046-x}.
- [252] Albert Clapes, Alex Pardo, Oriol Pujol Vila y Sergio Escalera. “Action detection fusing multiple Kinects and a WIMU: an application to in-home assistive technology for the elderly”. English. En: *MACHINE VISION AND APPLICATIONS* 29.5 (2018), 765-788. ISSN: 0932-8092. DOI: {10.1007/s00138-018-0931-1}.

- [253] Christian Kahindo, Mounim A. El-Yacoubi, Sonia Garcia-Salicetti, Anne-Sophie Rigaud y Victoria Cristancho-Lacroix. “Characterizing Early-Stage Alzheimer Through Spatiotemporal Dynamics of Handwriting”. English. En: *IEEE SIGNAL PROCESSING LETTERS* 25.8 (2018), 1136-1140. ISSN: 1070-9908. DOI: {10.1109/LSP.2018.2794500}.
- [254] Duarte Folgado, Marilia Barandas, Ricardo Matias, Rodrigo Martins, Miguel Carvalho y Hugo Gamboa. “Time Alignment Measurement for Time Series”. English. En: *PATTERN RECOGNITION* 81 (2018), 268-279. ISSN: 0031-3203. DOI: {10.1016/j.patcog.2018.04.003}.
- [255] R. Elakkiya y K. Selvamani. “Enhanced dynamic programming approach for subunit modelling to handle segmentation and recognition ambiguities in sign language”. English. En: *JOURNAL OF PARALLEL AND DISTRIBUTED COMPUTING* 117 (2018), 246-255. ISSN: 0743-7315. DOI: {10.1016/j.jpdc.2017.07.001}.
- [256] Benxiao Tang, Zhibo Wang, Run Wang, Lei Zhao y Lina Wang. “Niffer: A Context-Aware and User-Independent Side-Channel Attack System for Password Inference”. English. En: *WIRELESS COMMUNICATIONS & MOBILE COMPUTING* (2018). ISSN: 1530-8669. DOI: {10.1155/2018/4627108}.
- [257] Markus P. Nemitz, Ryan J. Marcotte, Mohammed E. Sayed, Gonzalo Ferrer, Alfred O. Hero, Edwin Olson y Adam A. Stokes. “Multi-Functional Sensing for Swarm Robots Using Time Sequence Classification: HoverBot, an Example”. English. En: *FRONTIERS IN ROBOTICS AND AI* 5 (2018). ISSN: 2296-9144. DOI: {10.3389/frobt.2018.00055}.
- [258] Jingren Tang, Hong Cheng, Yang Zhao y Hongliang Guo. “Structured dynamic time warping for continuous hand trajectory gesture recognition”. English. En: *PATTERN RECOGNITION* 80 (2018), 21-31. ISSN: 0031-3203. DOI: {10.1016/j.patcog.2018.02.011}.
- [259] Kaustubha Mendhurwar, Qing Gu, Sudhir Mudur y Tiberiu Popa. “The Discriminative Power of Shape an Empirical Study in Time Series Matching”. English. En: *IEEE TRANSACTIONS ON VISUALIZATION AND COMPUTER GRAPHICS* 24.5 (2018), 1799-1813. ISSN: 1077-2626. DOI: {10.1109/TVCG.2017.2691322}.
- [260] Claire M. Barnes, Cain C. T. Clark, Paul Rees, Gareth Stratton y Huw D. Summers. “Objective profiling of varied human motion based on normative assessment of magnetometer time series data”. English. En: *PHYSIOLOGICAL MEASUREMENT* 39.4 (2018). ISSN: 0967-3334. DOI: {10.1088/1361-6579/aab9de}.
- [261] Nhan D. Nguyen, Trieu H. Pham, Pubudu N. Pathirana, Sina Babazadeh, Richard Page y Aruna Seneviratne. “Sensing and Characterization of the Wrist Using Dart Thrower’s Movement”. English. En: *IEEE SENSORS JOURNAL* 18.10 (2018), 4145-4153. ISSN: 1530-437X. DOI: {10.1109/JSEN.2018.2821243}.
- [262] Marianna Capecci, Maria Gabriella Ceravolo, Francesco Ferracuti, Sabrina Iarlori, Ville Kyrki, Andrea Monteriu, Luca Romeo y Federica Verdini. “A Hidden Semi-Markov Model based approach for rehabilitation exercise assessment”. English. En: *JOURNAL OF BIOMEDICAL INFORMATICS* 78 (2018), 1-11. ISSN: 1532-0464. DOI: {10.1016/j.jbi.2017.12.012}.

- [263] Alireza Haji Fathaliyan, Xiaoyu Wang y Veronica J. Santos. “Exploiting Three-Dimensional Gaze Tracking for Action Recognition During Bimanual Manipulation to Enhance Human-Robot Collaboration”. English. En: *FRONTIERS IN ROBOTICS AND AI* 5 (2018). ISSN: 2296-9144. DOI: {10.3389/frobt.2018.00025}.
- [264] V. Manoj Kumar y D. Srii Hari Thipesh. “Robot Arm Performing Writing through Speech Recognition Using Dynamic Time Warping Algorithm”. English. En: *INTERNATIONAL JOURNAL OF ENGINEERING* 30.8 (2017), 1238-1245. ISSN: 1025-2495. DOI: {10.5829/ije.2017.30.08b.17}.
- [265] Pawel Kasprowski y Katarzyna Harezlak. “Fusion of eye movement and mouse dynamics for reliable behavioral biometrics”. English. En: *PATTERN ANALYSIS AND APPLICATIONS* 21.1 (2018), 91-103. ISSN: 1433-7541. DOI: {10.1007/s10044-016-0568-5}.
- [266] Nooshin Haji Ghassemi, Julius Hannink, Christine F. Martindale, Heiko Gassner, Meinard Mueller, Jochen Klucken y Bjoern M. Eskofier. “Segmentation of Gait Sequences in Sensor-Based Movement Analysis: A Comparison of Methods in Parkinson’s Disease”. English. En: *SENSORS* 18.1 (2018). ISSN: 1424-8220. DOI: {10.3390/s18010145}.
- [267] Cheng-Hao Quan, Zia Mohy-Ud-Din y Sangmin Lee. “Analysis of Shooting Consistency in Archers: A Dynamic Time Warping Algorithm-Based Approach”. English. En: *JOURNAL OF SENSORS* 2017 (2017). ISSN: 1687-725X. DOI: {10.1155/2017/7471217}.
- [268] Guilherme Maeda, Marco Ewerton, Gerhard Neumann, Rudolf Lioutikov y Jan Peters. “Phase estimation for fast action recognition and trajectory generation in human-robot collaboration”. English. En: *INTERNATIONAL JOURNAL OF ROBOTICS RESEARCH* 36.13-14, SI (2017), 1579-1594. ISSN: 0278-3649. DOI: {10.1177/0278364917693927}.
- [269] Yan Zhang, Yanhua Long, Xiangrong Shen, Haoran Wei, Min Yang, Hong Ye y Hongwei Mao. “Articulatory movement features for short-duration text-dependent speaker verification”. English. En: *INTERNATIONAL JOURNAL OF SPEECH TECHNOLOGY* 20.4 (2017), 753-759. ISSN: 1381-2416. DOI: {10.1007/s10772-017-9447-8}.
- [270] Bin Xu, Yang Li y Youngwook Kim. “Classification of Finger Movements Based on Reflection Coefficient Variations of a Body-Worn Electrically Small Antenna”. English. En: *IEEE ANTENNAS AND WIRELESS PROPAGATION LETTERS* 16 (2017), 1812-1815. ISSN: 1536-1225. DOI: {10.1109/LAWP.2017.2681099}.
- [271] Mahtab J. Fard, Abhilash K. Pandya, Ratna B. Chinnam, Michael D. Klein y R. Darin Ellis. “Distance-based time series classification approach for task recognition with application in surgical robot autonomy”. English. En: *INTERNATIONAL JOURNAL OF MEDICAL ROBOTICS AND COMPUTER ASSISTED SURGERY* 13.3 (2017). ISSN: 1478-5951. DOI: {10.1002/rcs.1766}.
- [272] Laxmi Shaw, Aurobinda Routray y Sirin Sanchay. “A robust motifs based artifacts removal technique from EEG”. English. En: *BIOMEDICAL PHYSICS & ENGINEERING EXPRESS* 3.3 (2017). ISSN: 2057-1976. DOI: {10.1088/2057-1976/aa6db8}.

- [273] Hideaki Ohashi, Toshiyuki Shimizu y Masatoshi Yoshikawa. “Flexible and Fast Similarity Search for Enriched Trajectories”. English. En: *IEICE TRANSACTIONS ON INFORMATION AND SYSTEMS* E100D.9 (2017), 2081-2091. ISSN: 1745-1361. DOI: {10.1587/transinf.2016EDP7482}.
- [274] Farnood Gholami, Daria A. Trojan, Jozsef Kovacs, Wassim M. Haddad y Behnood Gholami. “A Microsoft Kinect-Based Point-of-Care Gait Assessment Framework for Multiple Sclerosis Patients”. English. En: *IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS* 21.5 (2017), 1376-1385. ISSN: 2168-2194. DOI: {10.1109/JBHI.2016.2593692}.
- [275] Sibylle B. Thies, Laurence P. J. Kenney, Mohammad Sobuh, Adam Galpin, Peter Kyberd, Rebecca Stine y Matthew J. Major. “Skill assessment in upper limb myoelectric prosthesis users: Validation of a clinically feasible method for characterising upper limb temporal and amplitude variability during the performance of functional tasks”. English. En: *MEDICAL ENGINEERING & PHYSICS* 47.SI (2017), 137-143. ISSN: 1350-4533. DOI: {10.1016/j.medengphy.2017.03.010}.
- [276] Qingsong Ai, Yanan Zhang, Weili Qi, Quan Liu y Kun Chen. “Research on Lower Limb Motion Recognition Based on Fusion of sEMG and Accelerometer Signals”. English. En: *SYMMETRY-BASEL* 9.8 (2017). DOI: {10.3390/sym9080147}.
- [277] Hyo-Rim Choi y TaeYong Kim. “Combined Dynamic Time Warping with Multiple Sensors for 3D Gesture Recognition”. English. En: *SENSORS* 17.8 (2017). ISSN: 1424-8220. DOI: {10.3390/s17081893}.
- [278] Radu-Daniel Vatavu. “Beyond Features for Recognition: Human-Readable Measures to Understand Users’ Whole-Body Gesture Performance”. English. En: *INTERNATIONAL JOURNAL OF HUMAN-COMPUTER INTERACTION* 33.9 (2017), 713-730. ISSN: 1044-7318. DOI: {10.1080/10447318.2017.1278897}.
- [279] Eun-Soo Jung, Dong-Gun Lee, Kyeongho Lee y Soo-Young Lee. “Temporally Robust Eye Movements through Task Priming and Self-referential Stimuli”. English. En: *SCIENTIFIC REPORTS* 7 (2017). ISSN: 2045-2322. DOI: {10.1038/s41598-017-07641-7}.
- [280] Qingxue Zhang, Xuan Zeng, Wenchuang Hu y Dian Zhou. “A Machine Learning-Empowered System for Long-Term Motion-Tolerant Wearable Monitoring of Blood Pressure and Heart Rate With Ear-ECG/PPG”. English. En: *IEEE ACCESS* 5 (2017), 10547-10561. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2017.2707472}.
- [281] Peiguo Fu, Haozhou Wang, Kuiren Liu, Xiaohui Hu y Hui Zhang. “Finding Abnormal Vessel Trajectories Using Feature Learning”. English. En: *IEEE ACCESS* 5 (2017), 7898-7909. ISSN: 2169-3536. DOI: {10.1109/ACCESS.2017.2698208}.
- [282] Mohammad Sharif y Ali Asghar Alesheikh. “Context-awareness in similarity measures and pattern discoveries of trajectories: a context-based dynamic time warping method”. English. En: *GISCIENCE & REMOTE SENSING* 54.3 (2017), 426-452. ISSN: 1548-1603. DOI: {10.1080/15481603.2017.1278644}.

- [283] Andreas Fischer y Rejean Plamondon. “Signature Verification Based on the Kinematic Theory of Rapid Human Movements”. English. En: *IEEE TRANSACTIONS ON HUMAN-MACHINE SYSTEMS* 47.2 (2017), 169-180. ISSN: 2168-2291. DOI: {10.1109/THMS.2016.2634922}.
- [284] Igor Bisio, Alessandro Delfino, Fabio Lavagetto y Andrea Sciarrone. “Enabling IoT for In-Home Rehabilitation: Accelerometer Signals Classification Methods for Activity and Movement Recognition”. English. En: *IEEE INTERNET OF THINGS JOURNAL* 4.1 (2017), 135-146. ISSN: 2327-4662. DOI: {10.1109/JIOT.2016.2628938}.
- [285] Maximilian Konzack, Thomas McKetterick, Tim Ophelders, Maike Buchin, Luca Giuggioli, Jed Long, Trisalyn Nelson, Michel A. Westenberg y Kevin Buchin. “Visual analytics of delays and interaction in movement data”. English. En: *INTERNATIONAL JOURNAL OF GEOGRAPHICAL INFORMATION SCIENCE* 31.2 (2017), 320-345. ISSN: 1365-8816. DOI: {10.1080/13658816.2016.1199806}.
- [286] Ana Muñoz-Mazón, Laura Fuentes-Moraleda, Angela Chantre-Astaiza y Marlon-Felipe Burbano-Fernandez. “The study of tourist movements in tourist historic cities: A comparative analysis of the applicability of four different tools”. En: *Sustainability* 11.19 (2019), pág. 5265.
- [287] Díaz-Perez Patricia Orea-Giner Alicia Muñoz-Mazón Ana Burbano-Fernández Marlon Villace-Molinero María Teresa FuentesMoraleda Laura. “Does the acceptance of service robots in hotels depend on the type of customer and type of robot?” En: *AIRSI2020 CONFERENCE* (2020).
- [288] Marlon Felipe Burbano-Fernandez y Gustavo Ramirez-Gonzalez. “Wearable technology and health: A bibliometric analysis using SciMAT”. En: *F1000Research* 7.1893 (2018), pág. 1893.
- [289] RDocumentation. *TermDocumentMatrix function - RDocumentation*. 2021. URL: <https://www.rdocumentation.org/packages/tm/versions/0.7-8/topics/TermDocumentMatrix> (visitado 27-05-2021).
- [290] K Ashwini y R Amutha. “Compressive sensing based recognition of human upper limb motions with kinect skeletal data”. En: *Multimedia Tools and Applications* 80.7 (2021), págs. 10839-10857.
- [291] Sumit Hazra, Acharya Aditya Pratap, Dattatreya Tripathy y Anup Nandy. “Novel data fusion strategy for human gait analysis using multiple kinect sensors”. En: *Biomedical Signal Processing and Control* 67 (2021), pág. 102512.
- [292] Won Joo Lee. “A Design and Implementation of Fitness Application Based on Kinect Sensor”. En: *Journal of the Korea Society of Computer and Information* 26.3 (2021), págs. 43-50.
- [293] Davide Alinovi, Gianluigi Ferrari, Francesco Pisani y Riccardo Raheli. “Markov chain modeling and simulation of breathing patterns”. En: *Biomedical Signal Processing and Control* 33 (2017), págs. 245-254.

- [294] Simon Fong, Wei Song, Kyungeun Cho, Raymond Wong y Kelvin KL Wong. “Training classifiers with shadow features for sensor-based human activity recognition”. En: *Sensors* 17.3 (2017), pág. 476.
- [295] MW McCarthy, DA James, James Bruce Lee y DD Rowlands. “Decision-tree-based human activity classification algorithm using single-channel foot-mounted gyroscope”. En: *Electronics Letters* 51.9 (2015), págs. 675-676.
- [296] William Possos, Robinson Cruz, Jesús D Cerón, Diego M López y Carlos H Sierra-Torres. “Open Dataset for the Automatic Recognition of Sedentary Behaviors.” En: *pHealth*. 2017, págs. 107-114.
- [297] Ferhat Attal, Samer Mohammed, Mariam Dedabrishvili, Faicel Chamroukhi, Latifa Oukhellou y Yacine Amirat. “Physical human activity recognition using wearable sensors”. En: *Sensors* 15.12 (2015), págs. 31314-31338.
- [298] Z Lv, J Guan, B Zhou y X Wu. “A novel saccade signals detection algorithm for eog-based human activity recognition”. En: *Bioinformatics and Biomedical Engineering: New Advances: Proceedings of the 9th International Conference on Bioinformatics and Biomedical Engineering (iCBBE 2015)*. 2015, pág. 67.
- [299] Alan Godfrey, AK Bourke, GM O’laighin, P Van De Ven y J Nelson. “Activity classification using a single chest mounted tri-axial accelerometer”. En: *Medical engineering & physics* 33.9 (2011), págs. 1127-1135.
- [300] Nimsiri Abhayasinghe y Iain Murray. “Human activity recognition using thigh angle derived from single thigh mounted imu data”. En: *2014 International Conference on Indoor Positioning and Indoor Navigation (IPIN)*. IEEE. 2014, págs. 111-115.
- [301] Fajri Nurwanto, Igi Ardiyanto y Sunu Wibirama. “Light sport exercise detection based on smartwatch and smartphone using k-Nearest Neighbor and Dynamic Time Warping algorithm”. En: *2016 8th International Conference on Information Technology and Electrical Engineering (ICITEE)*. IEEE. 2016, págs. 1-5.
- [302] Nantakrit Yodpijit, Nicha Tavichaiyuth, Manutchanok Jongprasithporn, Chalida Songwongamarit y Teppakorn Sittiwanchai. “The use of smartphone for gait analysis”. En: *2017 3rd International Conference on Control, Automation and Robotics (ICCAR)*. IEEE. 2017, págs. 543-546.
- [303] Lin Zhang, Lei Yang, Zhili Wang y Dangyan Yan. “Sports wearable device design and health data monitoring based on wireless internet of things”. En: *Microprocessors and Microsystems* (2020), pág. 103423.
- [304] Ningning Xiao, Wei Yu y Xu Han. “Wearable heart rate monitoring intelligent sports bracelet based on Internet of things”. En: *Measurement* 164 (2020), pág. 108102.
- [305] Wang Huifeng, Seifedine Nimer Kadry y Ebin Deni Raj. “Continuous health monitoring of sportsperson using IoT devices based wearable technology”. En: *Computer Communications* 160 (2020), págs. 588-595.

- [306] Liang Gao, Gaofei Zhang, Bo Yu, Ziwei Qiao y Junchao Wang. “Wearable human motion posture capture and medical health monitoring based on wireless sensor networks”. En: *Measurement* 166 (2020), pág. 108252.
- [307] Shuisheng Li, Baoxin Zhang, Panfeng Fei, P Mohamed Shakeel y R Dinesh Jackson Samuel. “Computational efficient wearable sensor network health monitoring system for sports athletics using IoT”. En: *Aggression and Violent Behavior* (2020), pág. 101541.
- [308] David R Mullineaux, Stacy M Underwood, Robert Shapiro y John W Hall. “Real-time biomechanical biofeedback effects on top-level rifle shooters”. En: *Applied Ergonomics* 43.1 (2012), págs. 109-114.
- [309] Claire M Wood y Kristof Kipp. “Use of audio biofeedback to reduce tibial impact accelerations during running”. En: *Journal of biomechanics* 47.7 (2014), págs. 1739-1741.
- [310] Rui Li, Zibo Cai, WeeSit Lee y Daniel TH Lai. “A wearable biofeedback control system based body area network for freestyle swimming”. En: *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE. 2016, págs. 1866-1869.
- [311] Antonio Bevilacqua, Bingquan Huang, Rob Argent, Brian Caulfield y Tahar Kechadi. “Automatic classification of knee rehabilitation exercises using a single inertial sensor: A case study”. En: *2018 IEEE 15th International conference on wearable and implantable Body Sensor Networks (BSN)*. IEEE. 2018, págs. 21-24.
- [312] Mark Versteyhe, Henri De Vroey, Frederik Debrouwere, Hans Hallez y Kurt Claeys. “A Novel Method to Estimate the Full Knee Joint Kinematics Using Low Cost IMU Sensors for Easy to Implement Low Cost Diagnostics”. En: *Sensors* 20.6 (2020), pág. 1683.
- [313] Cuong Pham, Thomas Plötz y Patrick Olivier. “A dynamic time warping approach to real-time activity recognition for food preparation”. En: *International Joint Conference on Ambient Intelligence*. Springer. 2010, págs. 21-30.
- [314] Majid Janidarmian, Atena Roshan Fekr, Katarzyna Radecka y Zeljko Zilic. “Affordable rehabilitation monitoring platform”. En: *2014 IEEE Canada International Humanitarian Technology Conference-(IHTC)*. IEEE. 2014, págs. 1-6.
- [315] Atsuki Ikeda, Dong-Hyun Hwang, Hideki Koike, Gerd Bruder, Shunsuke Yoshimoto y Sue Cobb. “AR based Self-sports Learning System using Decayed Dynamic TimeWarping Algorithm.” En: *ICAT-EGVE*. 2018, págs. 171-174.
- [316] Maria S Ashapkina, Alexey V Alpatov, Victoria A Sablina y Alexander A Chekushin. “Quantitative parameters developing for estimation of rehabilitation exercising on the basis of IMU sensor device”. En: *2018 7th Mediterranean Conference on Embedded Computing (MECO)*. IEEE. 2018, págs. 1-4.
- [317] Joe Sarsfield, David Brown, Nasser Sherkat, Caroline Langensiepen, James Lewis, Mohammad Taheri, Louise Selwood, Penny Standen y Pip Logan. “Segmentation of exercise repetitions enabling real-time patient analysis and feedback using a single exemplar”. En: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 27.5 (2019), págs. 1004-1019.

- [318] Marlon Felipe Burbano-Fernandez, Gustavo Ramirez-Gonzalez y Mario Muñoz-Organero. “Memorias del SINNEM18 - Architecture proposal for MOOC and wearable integration”. es. En: (oct. de 2018). Universidad Del Cauca 2018, pág. 204. URL: <https://www.unicauca.edu.co/moocmaker/sinnem/memorias.html>.
- [319] Philippe Kruchten. “Reference: Title: Architectural Blueprints—The “4+ 1” View Model of Software Architecture”. En: *IEEE software* 12 (1995), pág. 6.
- [320] Yesid Felipe Tombe-Castillo, Juan Esteban Bedoya-Ramírez, Marlon Felipe Burbano-Fernández y Ramirez-Gonzalez Gustavo. “Aproximación metodológica con propósito académico para el desarrollo de dispositivos wearable para extremidades inferiores del cuerpo humano”. es. 2018. URL: <http://repositorio.unicauca.edu.co:8080/xmlui/bitstream/handle/123456789/1599/APROXIMACI%C3%93N%20METODOL%C3%93GICA%20CON%20PROP%C3%93SITO%20ACAD%C3%89MICO%20PARA%20EL%20DESARROLLO%20DE%20DISPOSITIVOS%20WEARABLE.pdf?sequence=1&isAllowed=y>.
- [321] keuwl. *Accelerometer*, <https://www.keuwl.com/Accelerometer/>. 2018. URL: <https://www.keuwl.com/Accelerometer/> (visitado 08-04-2020).
- [322] Nordic-Semiconductor. *Nordic Semiconductor Infocenter*. 2018. URL: https://infocenter.nordicsemi.com/index.jsp?topic=%2Fstruct_nrf51%2Fstruct%2Fnrf51822.html (visitado 16-04-2020).
- [323] ACRMDOG Godfrey, Richard Conway, David Meagher y Gearoid ÓLaighin. “Direct measurement of human movement by accelerometry”. En: *Medical engineering & physics* 30.10 (2008), págs. 1364-1386.
- [324] Alicia Vila, Máximo Sedano, Ana López y Angel Juan. “Correlación lineal y análisis de regresión”. En: *Barcelona: Universidad Oberta de Catalunya* (2004).
- [325] John H McDonald. *Handbook of biological statistics*. Vol. 2. sparky house publishing Baltimore, MD, 2009.
- [326] Munshi Yadav y Afshar Alam. “Dynamic time warping (DTW) algorithm in speech: a review”. En: *Int. J. Res. Electron. Comput. Eng* 6 (2018).
- [327] Hiroaki Sakoe y Seibi Chiba. “Dynamic programming algorithm optimization for spoken word recognition”. En: *IEEE transactions on acoustics, speech, and signal processing* 26.1 (1978), págs. 43-49.
- [328] Clara Laguna. “Correlación y regresión lineal”. En: *Instituto Aragonés de Ciencias de la Salud* (2014), págs. 1-18.
- [329] Ezequiel Uriel. “El modelo de regresión simple: estimación y propiedades”. En: *Introducción a La Econometría* (2013), págs. 1-49.
- [330] Riascos Yilton Munoz-Organero Mario Thilagaraj M-Venkataraman V Arunkumar N Ramirez-Gonzalez Gustavo Burbano-Fernandez Marlon Sandoval-Serna Jhoana. “Algorithm for the comparison of Human periodic movements Using Wearable Devices”. En: *Journal of Healthcare Engineering, Special Issue Developments in Optimization Algorithms for Smart Healthcare* 6 (2021).

- [331] Ahmed Faeq Hussein, Marlon Burbano-Fernandez, Gustavo Ramírez-González, Enas Abdulhay, Victor Hugo C De Albuquerque y col. “An automated remote cloud-based heart rate variability monitoring system”. En: *IEEE Access* 6 (2018), págs. 77055-77064.
- [332] G Rajkumar, R Jayabharathy, Kumaravelu Narasimhan, N Raju, M Easwaran, V Elamarran, Gustavo Ramírez-González y Marlon Burbano-Fernandez. “Spectral and SNR improvement analysis of normal and abnormal heart sound signals using different windows”. En: *Future Generation Computer Systems* 92 (2019), págs. 438-443.
- [333] Munoz-Organero Mario Burbano-Fernandez Marlon Ramirez-Gonzalez Gustavo. “Architecture proposal for MOOC and wearable integration”. En: *Revista Ingenierías Universidad de Medellín* 20.38 (2021).

APÉNDICES

Algoritmo para la comparación de movimientos periódicos humanos en el contexto de la enseñanza y el aprendizaje de habilidades motrices

Tesis Doctoral en Ingeniería Telemática



Universidad
del Cauca

Autor:

Marlon Felipe Burbano Fernández

Director:

Dr. Gustavo Ramirez Gonzalez

Universidad del Cauca

FACULTAD DE INGENIERÍA ELECTRÓNICA Y

TELECOMUNICACIONES

PROGRAMA DE DOCTORADO EN INGENIERÍA TELEMÁTICA
3 de febrero de 2022

Apéndice A

Código en lenguaje R para análisis de corpus

A.1. Código en lenguaje R aplicativo para análisis de corpus

```
#  
#Este programa crea el corpus, genera una nube de palabras,  
#entrega el listado de palabras, hace análisis de proximidad con palabras ingresadas  
#Entrega un análisis de herarchy-clust y lo muestra en una gráfica
```

```
#  
library(readxl)  
library(corrplot)  
library(scales)  
library(dummies)  
library(kableExtra)  
library(cluster)  
library(tm)  
library(stringi)  
library(proxy)  
library(wordcloud)  
library(readxl)  
library(tokenizers)  
library(SnowballC)  
library(readr)  
library(tm)  
library(SnowballC)  
library(wordcloud)  
library(ggplot2)  
library(dplyr)  
library(readr)  
library(cluster)
```

Apéndice B

Arquitectura Propuesta

A partir del proyecto de investigación, se realiza una arquitectura según el modelo de $4 + 1$ vistas [319]. este pretende mostrar un bosquejo general de un sistema que permite la captura de datos de los movimientos periódicos realizados por una persona, para su comparación de los movimientos que una persona experta. El sistema entrega como resultado una recomendación a partir de una comparación de los movimientos capturados [318].

De forma tradicional, cuando se pretende enseñar habilidades motrices de forma virtual, una persona que intenta aprender este tipo habilidades, mira un vídeo que está sujeto a una plataforma virtual, e intenta imitar los movimientos que en este vídeo se realizan.

Describiendo la forma clásica en que se realizan las la enseñanza y aprendizaje de habilidades motrices, se realiza un modelo de negocio a partir de un diagrama de casos de uso (figura 2.2). En este diagrama se representan dos actores del sistema. Estos son, el estudiante y el Profesor. En este caso encontramos que el profesor realizar la acción de subir un vídeo, con el fin de mostrar algo que pretende enseñar, en este caso particular, habilidad motriz. Por otro lado, el estudiante realizar dos acciones, la primera es el vídeo que se subió previamente por el Profesor. La segunda acción, es imitar este movimiento. Como resultado se observa que no existe ningún tipo de realimentación del Profesor hacia el estudiante.

Pensando en el desarrollo de un sistema que permita la captura de datos de los actores que conforman el sistema y la realimentación, se propone un sistema que se resume en la figura B.1 que representa una arquitectura de alto nivel. Aquí se representa un sistema donde una persona a partir de un componente wearable, en este caso puesto en un pie puede enviar datos que genera con movimientos del cuerpo según la imitación que realiza al ver un vídeo. Los datos son transportados a través de una interfaz Bluetooth y capturados por un componente de integración. A su vez, el componente de integración envía los datos ajustados a una plataforma a través de Internet. El componente de plataforma devuelve como resultado el análisis a partir de algún algoritmo. Finalmente con estas acciones se puede realizar una recomendación.




Figura B.1: Arquitectura de Alto Nivel

B.1. Propuesta Arquitectónica con base al modelo 4+1 vistas

Según lo descrito previamente, se donde en marcha el desarrollo de una arquitectura según el modelo 4+1 vistas, donde se obtiene una vista lógica, una vista desarrollo, una de procesos, una vista física y una vista de escenarios. Dentro de la vista lógica, se desarrolla un diagrama de clases. En la vista de desarrollo, se realiza un diagrama de paquetes. En la vista de procesos se estructura un diagrama de actividades. En la vista física, un diagrama despliegue. Y finalmente en la vista de escenarios se realiza un diagrama de casos de uso.

B.1.1. Vista lógica

En este caso, a partir de un diagrama de clases, se muestra la funcionalidad del sistema. En este diagrama encuentran las clases que componen el sistema, los atributos, los métodos y relaciones que existen entre las diferentes clases (figura B.2).

En este diagrama se encuentran las clases que componen el sistema, los atributos, los métodos, y relaciones que existen entre las diferentes clases.

Los actores representan a partir de la clase user, la cual tributos a las clases Teacher, Student y Admin. Las tres clases, tienen como atributo principal, el nombres de usuario (+UserName). La clase Admin, está por encima de las otras tres clases y permite otorgar los diferentes roles al usuario (Como estudiante “Student”, profesor “Teacher” o Administrador “Admin”). Por su parte la clase teacher, contiene dos métodos, que son subir video y subir movimientos (+UploadVideo(), +UploadMovements()). Por otro lado, la clase Student, solamente se permite como método, subir movimientos (+UploadMovements()).

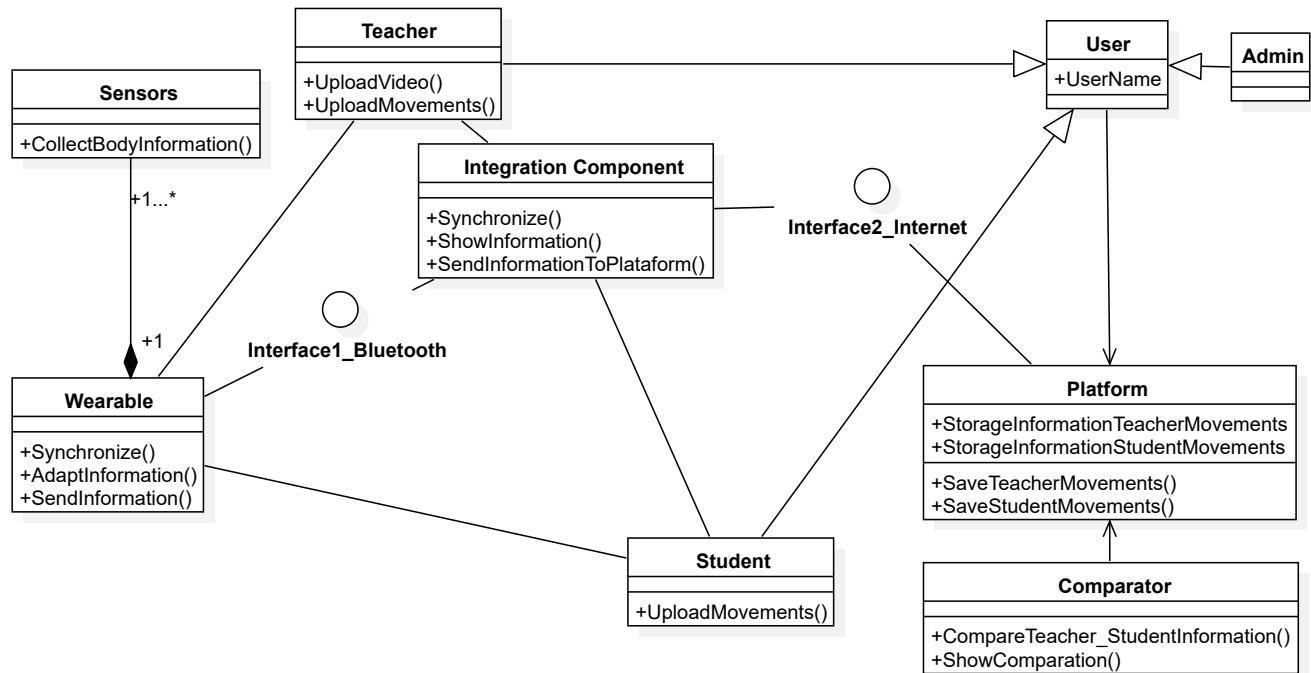


Figura B.2: Diagrama de clases

La clase sensors, tiene como método recolectar información de movimientos del cuerpo humano (+CollectBodyInformation()). Es a su vez se comunica con la clase y clase Wearable, cual se encarga de sincronizar la información, adaptarla y enviarla (+Synchronize(), +AdaptInformation() y +SendInformation()).

Clase Integration Component, es la encargada de sincronizar, mostrar y enviar información (+Synchronize(), +ShowInformation() y +SendInformationToPlatform()) a la plataforma proveniente de los sensores que contienen los dispositivos wearable.

Clase plataforma, Tiene como atributos almacenamiento de la información de los movimientos del Profesor y de los movimientos del estudiante, provenientes de los dispositivos wearable (+StorageInformationTeacherMovements y +StorageInformationStudentMovement). y cómo métodos, guarda los datos generados por el profesor y el estudiante (+SaveTeacherMovement() y SaveStudentMovement()).

Finalmente la clase Comparator, es la encargada de realizar la comparación entre los datos obtenidos de los movimientos capturados de la clase Teacher y de la clase Student.

Por otra parte encontramos que en la comunicación entre la clase Wearable e Integration Component, existe una interfaz de tipo Bluetooth, más específicamente, esta corresponde a una comunicación BLE (Bluetooth Low Energy).

Y se propone una segunda interfaz entre las clases de Integration Component y Platform que se realiza a través de Internet.

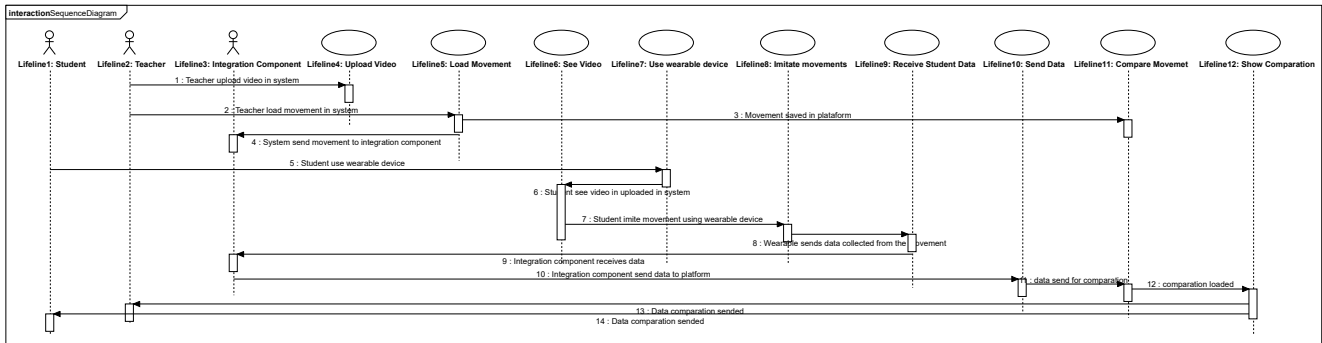


Figura B.3: Diagrama de secuencia

Igualmente en este caso, para un mejor entendimiento del sistema, a partir de las clases propuestas, se realiza un diagrama de secuencia, figura B.3

El diagrama de secuencias se muestran varios actores y casos de uso del sistema propuesto. Aquí se muestra tres actores, Un Profesor, un estudiante y un componente de integración. Y los casos de uso que corresponden a las acciones de Subir vídeo, Cargar Movimiento, Ver vídeo, usar dispositivo wearable, imitar movimientos, recibir datos, enviar datos, comparar movimientos y mostrar comparación.

Las secuencias se describen así:

1. El profesor sube un vídeo al sistema.
2. El profesor carga un movimiento en el sistema usando un dispositivo wearable.
3. El movimiento del profesor es guardado en la plataforma.
4. El movimiento es enviado al componente de integración.
5. El estudiante usa el dispositivo wearable.
6. El estudiante mira el vídeo cargado previamente en el sistema.
7. El estudiante imita los movimientos vistos en el vídeo usando el dispositivo wearable.
8. El dispositivo wearable recolecta los datos de los movimientos.
9. Los datos de los movimientos son enviados al componente de integración.
10. Los datos son enviados del componente de integración a la plataforma.
11. Los datos son enviados al módulo de comparación.
12. Se realiza la comparación.
13. La comparación es enviada al profesor.
14. La comparación es enviada al estudiante.

A partir de estos dos diagramas se puede entender el comportamiento lógico del sistema mostrándolo desde su parte estructural y funcional.

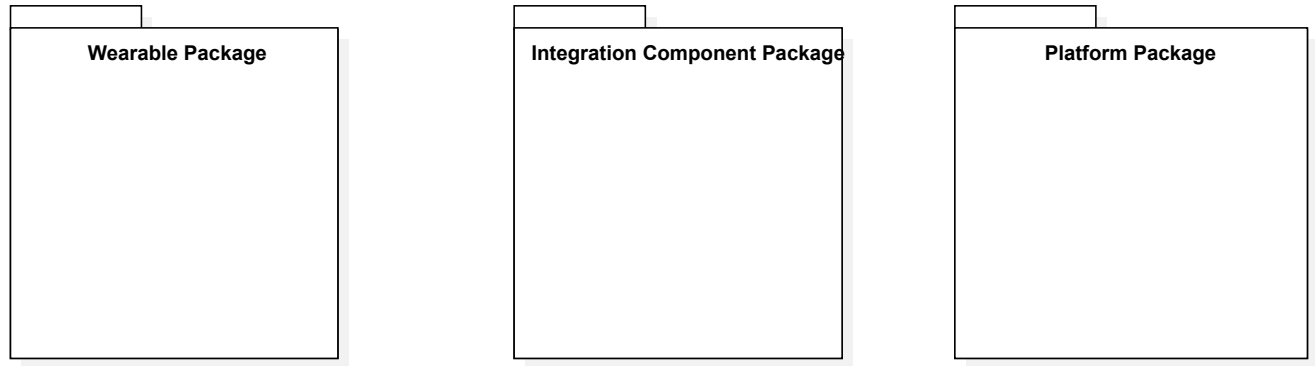


Figura B.4: Diagrama de Paquetes

B.1.2. Vista de Desarrollo

En la figura B.4, se muestra un diagrama de paquetes del sistema, donde se definieron tres paquetes de desarrollo, Wearable Package, Integration Component Package y Plataforma Package.

El Wearable Package lo compone el desarrollo que corresponde a la captura de datos a partir de sensores y la realización dentro de este de un preprocesamiento de la información capturada.

El Integration Component Package, se comunica con una interfaz de Bluetooth con el Wearable Package, y está encargado de servir de interfaz entre el usuario y los resultados que sean entregados en el sistema. a su vez, este se comunica a través de internet con el Plataforma Package.

Finalmente el Platform Package, es el encargado de realizar todas las operaciones computacionales requeridas a partir de la captura de datos y el análisis comparativo a realizar.

Por otra parte, el diagrama de componentes que se muestra en la figura B.5 representa la relación de clases que se encuentra en cada paquete y como se realiza el respectivo despliegue (las clases son explicadas en la vista lógica).

B.1.3. Vista de Procesos

En esta vista, se consideran los aspectos dinámicos del sistema y sus diferentes etapas de comunicación a partir de el análisis temporal en el tiempo de ejecución. Para este caso, observamos la figura B.6, que representa el diagrama de actividades del sistema.

El diagrama B.6 representa el flujo de actividades ejecutadas por el sistema. En este caso encontramos cinco bloques de actividades realizadas por algún actor del sistema, estos son profesor (Teacher), Estudiante (Student), Dispositivo Wearable (WearableDevice), Componente de Integración (Integration-Component) y Plataforma (Platform). En este caso el profesor realiza la actividad de subir un vídeo a la plataforma. Por otra parte el profesor usa un dispositivo wearable y con él carga un movimiento. Por su parte el estudiante imita los movimientos haciendo uso de un dispositivo wearable. En el bloque del dispositivo wearable tanto el profesor como el estudiante cargan los movimientos, envían los movimientos a través del componente de integración. El componente de integración envía los datos de los movimientos capturados al componente Plataforma. Cuando el componente plataforma recibe los datos generados a partir de los movimientos, guarda los movimientos. Posteriormente el componente plataforma carga los datos generados por el profesor y el estudiante y realiza una comparación, cuyo resultado es enviado al componente de integración, y en este se muestran los resultados tanto al profesor como al estudiante en

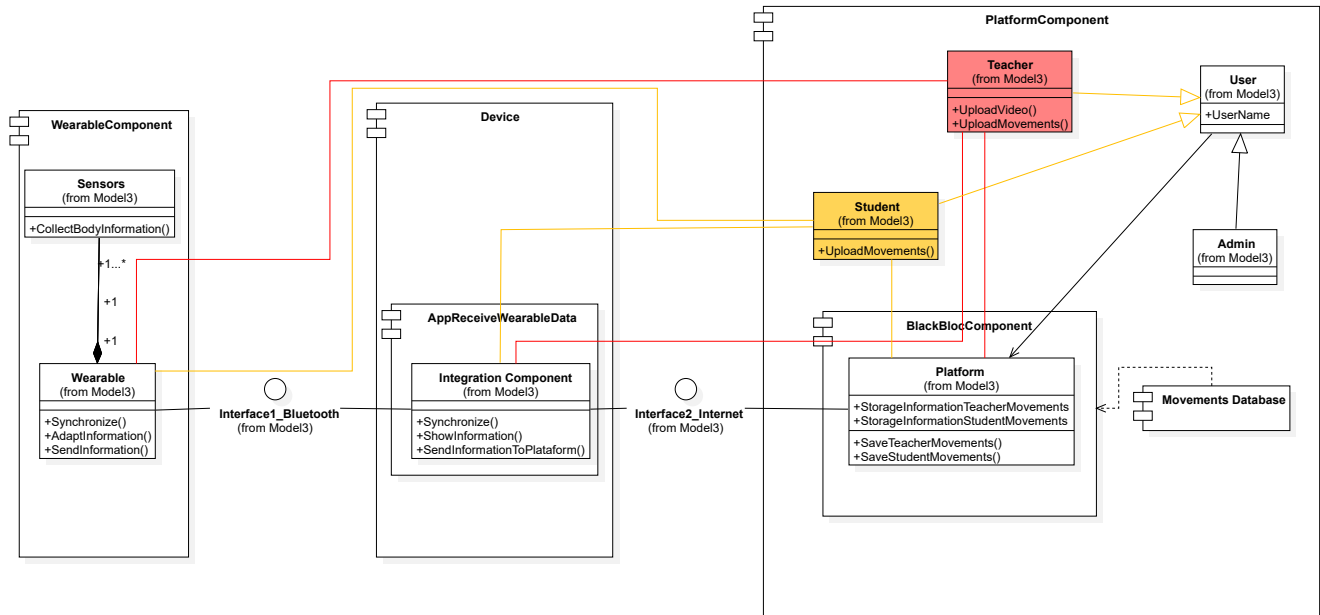


Figura B.5: Diagrama de componentes

forma de recomendación.

B.1.4. Vista Física

En la Figura B.7, se representa los componentes de software desde el punto de vista físico, y la conexión de sus componentes. En este caso se encuentran tres bloques de carácter físico, Bloque Wearable, Componente de integración (Integration Component) y una plataforma (Platform). El componte wearable consta de un dispositivo que cuenta con los sensores necesarios para la captura de datos a partir de los movimiento y su almacenamiento temporal para su posterior envío. A través de una interfaz inalámbrica, en este caso, Bluetooth, se envían los datos generados por el dispositivo wearable. Los datos son recolectados por el componente de integración, que consta de un dispositivo móvil, en este caso el componente de integración recolecta los datos emitidos por el dispositivo wearable para que sean sincronizados, enviados a la plataforma a demás de mostrar la información. cabe resaltar que este componente de integración es el encargado de mostrar toda la información a los usuarios. El componte de integración finalmente se conecta a la plataforma a partir de una conexión por Internet. En este caso, la plataforma se encarga de recibir los datos, guardarlos y procesarlos para nuevamente enviar la información que surga de este procesamiento nuevamente al componente de integración para que pueda ser observada por los usuarios.

B.1.5. Vista de escenarios

En la figura de Casos de uso del sistema, figura B.8, se observa el comportamiento del sistema. en este caso tenemos 3 actores, Un estudiante (Student), un profesor (Teacher) y el componente de integración (Integration Component). Y se crean los casos de uso ver vídeo (See Video), usar dispositivo wearable (Use wearable device), imitar movimientos (Imitate movements), comparar movimientos (Compare Movement),




Figura B.6: Diagrama de actividades

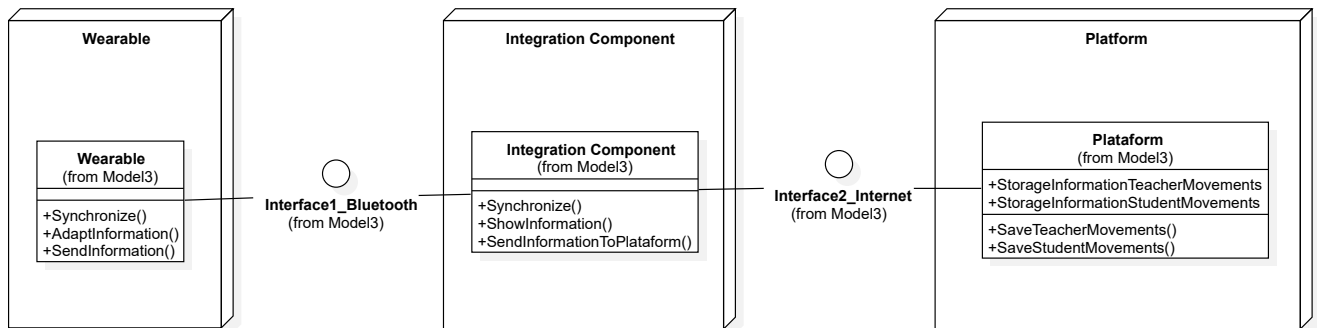


Figura B.7: Diagrama de despliegue

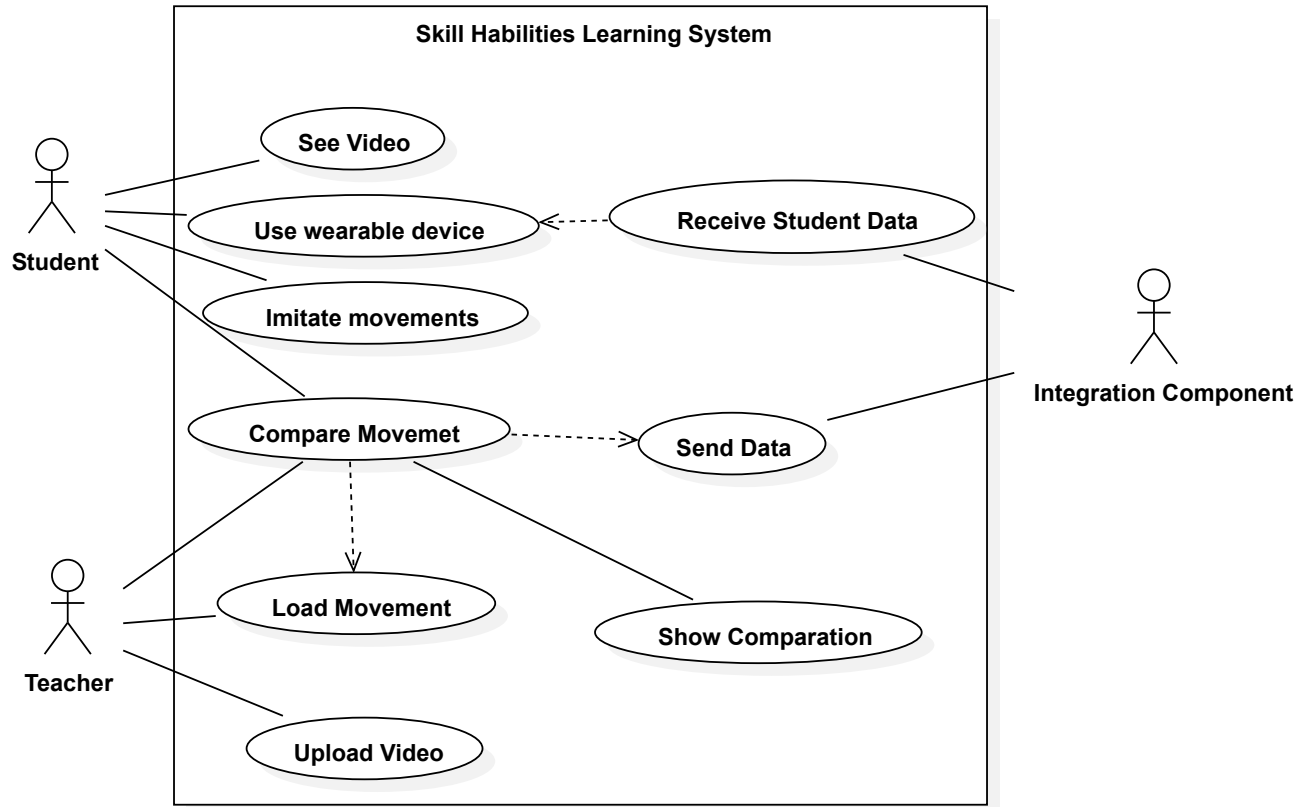


Figura B.8: Casos de Uso del Sistema

cargar movimiento (Load Movement), Subir vídeo (Upload Video), Recibir Datos (Recive Data), Enviar Datos (Send Data) y Mostrar comparación (Show Comparation).

El profesor inicia los casos de uso de cargar movimiento y subir vídeo. Los movimientos se cargan después de ser capturados con un dispositivo wearable. E inicia el caso de uso subir vídeo, donde sube un vídeo a la plataforma.

El Estudiante por su parte inicia el caso de uso ver vídeo, donde ve el vídeo que fue subido previamente por el profesor. Inicia el caso de uso usar dispositivo wearable para la captura de datos a partir de los movimientos generados. El caso de uso imitar movimiento, es iniciado también por el estudiante, donde el estudiante al ver el vídeo subido por el profesor imita los movimientos que logra observar.

Por otra parte, el actor de componente de integración inicia los el caso de uso enviar datos y recibir datos. En este caso de uso enviar datos, recibe del caso de uso de usar dispositivo wearable los datos generados por el estudiante y por el profesor. Por su parte el caso de uso enviar datos, recibe los datos generados por el profesor y por el estudiante y activa el caso de estudio comparar movimientos. Finalmente el caso de estudio comparar movimientos, inicia el caso de uso mostrar comparación, que se encarga de desplegar el análisis que se pueda obtener a partir de los datos generados.

Apéndice C

Código en lenguaje R del algoritmo para comparación de movimientos

C.1. Código fuente main

```
# ImportData

#Data options
#
# User1BackBackSample1
# User1BackBackSample2
# User1BackBackSample3
#
# User1ForwardBackwardSample1
# User1ForwardBackwardSample2
# User1ForwardBackwardSample3
#
# User1SideSideSample1
# User1SideSideSample2
# User1SideSideSample3
#
# User2BackBackSample1
# User2BackBackSample2
# User2BackBackSample3
#
# User2ForwardBackwardSample1
# User2ForwardBackwardSample2
# User2ForwardBackwardSample3
#
# User2SideSideSample1
# User2SideSideSample2
# User2SideSideSample3
```

Apéndice D

Publicaciones

- Algorithm for the comparison of Human periodic movements Using Wearable Devices [330] (a la fecha en proceso de publicación)

El artículo resume los resultados del algoritmo creado en el core de la tesis. En el a groso modo se muestra como se obtuvieron los datos con la creación de un data set, que se encuentra habilitado en línea en <https://github.com/mfburbano/SalsaDanceDataSet>. El artículo se centra en la construcción de forma modular del Algoritmo tanto en un lenguaje ingenieril, como en su soporte matemático de forma tal que permita a los investigadores y personas interesadas replicarlo sin importar mucho su lenguaje de programación, aunque el producto en sí se encuentra desarrollado en lenguaje R. Finalmente el artículo muestra de forma experimental los resultados del algoritmo de comparación. Este artículo parte de la estancia de investigación realizada en 2019 en el grupo GAST de la Universidad Carlos III de Madrid.

- Architecture proposal for MOOC and wearable integration [333]

<https://revistas.udem.edu.co/index.php/ingenierias/article/view/2983>

Este artículo muestra el desarrollo de una arquitectura basada en el modelo 5+1 vistas. Indaga en el modelo del negocio actual en lo que respecta a la enseñanza y aprendizaje de habilidades motrices en un contexto virtual. Hace la propuesta del empleo de dispositivos wearable para la obtención de datos a partir de los movimientos realizados por una persona. Los datos que se obtienen permiten alimentar un sistema que brinda realimentación, evalúa y recomienda a un usuario que desea aprender alguna habilidad motriz a través de medios electrónicos. Centra el contexto entre otras cosas, en las acciones se desarrollen fuera de un laboratorio especializado de captura de movimientos, con un costo para el usuario reducido y que permita cierto grado de privacidad al no usar vídeo como vía bidireccional. El artículo es base para justificar la investigación desarrollada en la tesis. Este artículo es un producto de una estancia de investigación realizada en 2017 en la Universidad Carlos III de Madrid en el grupo GAST.

- Spectral and SNR improvement analysis of normal and abnormal heart sound signals using different Windows [332]

<https://doi.org/10.1016/j.future.2018.09.047>

En este artículo se usan señales provenientes del corazón y las analiza en tiempo y frecuencia haciendo uso de una transformación digital. A partir de estas señales, el algoritmo propuesto en

esta investigación compara y permite reconocer una anomalía cardíaca. Este algoritmo sienta una de las bases para el desarrollo del algoritmo propuesto en la tesis. En ambos casos se decide emplear las series de tiempo para identificar diferencias en las señales. En el caso de la tesis, a partir de dos señales con características de serie de tiempo se consigue realizar una comparación.

- The study of tourist movements in tourist historic cities: A comparative analysis of the applicability of four different tools [286]

<https://doi.org/10.3390/su11195265>

En este artículo realizado en colaboración con el departamento de ciencias del turismo de la Universidad Rey Juan Carlos, se indagó en la analítica de datos y junto con la participación en la conferencia AIRSI 2020, con el artículo "Does the acceptance of service robots in hotels depend on the type of customer and type of robot?." [287] y el artículo "Understanding guests 'sentiments from the interaction with hotel service robots: text mining of tripadvisor reviews" (que se encuentra en proceso de revisión para publicación), se logra consolidar una herramienta software con base en lenguaje R, que a través de la minería de texto permite complementar varias aplicaciones científicas como ScientoPy, CiteSpace o SciMat con el análisis de grandes volúmenes de textos. Pese a que la herramienta propiamente no se ha publicado, esta se emplea en el desarrollo de la tesis para hacer un análisis bibliométrico que contextualiza y muestra la pertinencia de esta investigación haciendo agrupaciones de tópicos de investigaciones a partir del uso de un conjunto de datos que se obtiene de una revisión en Scopus y WOS.

- Wearable technology and health: A bibliometric analysis using SciMAT [288]

<https://doi.org/10.12688/f1000research.15622.1>

El artículo de revisión literaria, con el uso de la herramienta SciMat indaga los tópicos y brechas de investigación que se hay en el uso de tecnologías wearable mostrando que la investigación propuesta en la tesis es relevante y aplicable en un ambiente real.

- An automated remote cloud-based heart rate variability monitoring system [331]

<https://doi.org/10.1109/ACCESS.2018.2831209>

Con este artículo se hizo un análisis de series temporales tanto en dominio del tiempo como en el dominio de la frecuencia para mostrar opciones en el monitoreo efectivo en un contexto médico. A partir de este análisis, en la tesis se logra la selección del manejo de datos, que en este caso se hace en el dominio del tiempo, con el fin de lograr que el algoritmo propuesto en la tesis sea eficaz para hacer las comparaciones propuestas.