



Universidad Veracruzana



Fusión de sensores electromiográficos y acelerómetro para la detección de movimientos de hombros utilizados en rehabilitación

TESIS DE MAESTRÍA

Josué Alexis Martínez García
josuealexis15@hotmail.com

Universidad Veracruzana

INSTITUTO DE INVESTIGACIONES EN INTELIGENCIA ARTIFICIAL
(IIIA)

MAESTRÍA EN INTELIGENCIA ARTIFICIAL
(MIA)

22 de febrero de 2023

Fusión de sensores electromiográficos y acelerómetro para la detección de movimientos de hombros utilizados en rehabilitación

Tesis para obtener el grado de:
Maestría en Inteligencia Artificial

Dirigida por:
Ericka Janet Rechy Ramírez

Universidad Veracruzana
INSTITUTO DE INVESTIGACIONES EN INTELIGENCIA ARTIFICIAL
(IIIA)
MAESTRÍA EN INTELIGENCIA ARTIFICIAL
(MIA)

22 de febrero de 2023

Agradecimientos

Un agradecimiento especial a mi familia, a mi padre y a mi madre. Ya que ellos me dieron el tiempo, comprensión y apoyo necesario para poder culminar mi maestría en los momentos difíciles que se vivieron en el 2021-2022.

De la misma forma, agradezco demasiado a mis instructores de clases; a los doctores y doctoras que cumplen un gran papel como investigadores del IIIA para la MIA, donde forjaron en mí los conocimientos suficientes para poder llegar hasta este punto. En especial a la Dra. Ericka Rechy, muchas gracias por ser tan comprensiva, amable, dedicada, educada e inspiradora en todo este tiempo que dirigió con cabalidad esta tesis. De igual manera, agradezco a mis compañeros de maestría, que a pesar de no conocer a muchos de manera presencial, logramos forjar un vínculo y apoyo para completar esta meta, muchas gracias por su apoyo, maestros y futuros investigadores.

También, agradecer a mi pareja, Andrea. Ya que gracias a ella y sus palabras, me mantuve inspirado para continuar después de esos días espantosos de estrés y bloqueo mental.

Muchas gracias a todos.

Resumen

El hombro es una de las articulaciones más móviles del cuerpo humano. Posee 3 grados de libertad (plano sagital, coronal y transversal). Debido a ello, es una de las articulaciones más susceptibles a lesionarse tanto en actividades de la vida cotidiana o en la práctica de deportes. Para una pronta y adecuada recuperación de esta articulación, es recomendable que se realice una rehabilitación del mismo; donde es importante la adecuada ejecución de los ejercicios de rehabilitación. Por tal motivo, en esta investigación se implementó un sistema en tiempo diferido, dotado con aprendizaje automático.

Este sistema clasifica cuatro tipos de movimientos de rehabilitación del hombro (abducción, flexión, aducción y péndulo de Codman), adquiriendo las señales de la fusión de cinco sensores de electromiografía de superficie y un sensor de aceleración (que adquiere los planos de movimiento X, Y y Z).

A cada una de las señales adquiridas por cada uno de los sensores se le extraen seis características (Mean Absolute Value, Root Mean Square, Variance, Median Frequency, Mean Frequency y Peak of Frequency) que describen las acciones realizadas en un valor numérico acorde a un tamaño de ventana de segmentación.

Con los valores antes mencionados, se realiza una combinación de modalidades de aplicación por cada característica extraída con cada uno de los tres clasificadores de aprendizaje automático (árbol de decisión, bosques aleatorios y máquinas de soporte vectorial). Donde estos valores son comparados por métricas para determinar el mejor clasificador, modalidad y extracción de característica para los cuatro movimientos de rehabilitación.

Además, se realiza la comparación de resultados con base a un análisis estadístico en las métricas de fusión de sensores contra los sensores por si solos; con el fin de determinar si existe diferencia significativa en las modalidades de aplicación.

Los resultados determinaron que en la modalidad de fusión de sensores de electromiografía y aceleración del clasificador de Bosques Aleatorios con la característica Peak of Frequency generó el mejor resultado en exactitud con 90.22%.

Sin embargo, las modalidades de fusión de sensores de electromiografía y aceleración del clasificador Bosques Aleatorios con las características Root Mean Square y Mean Frequency obtuvieron diferencia significativa en la prueba estadística, en comparación a las modalidades con la aplicación de solo electromiografía; obteniendo una exactitud de 90.2% en ambas.

Índice general

| | |
|--|-----------|
| 1. Introducción | 1 |
| 1.1. Motivación | 1 |
| 1.2. Justificación | 4 |
| 1.3. Planteamiento del problema | 4 |
| 1.4. Objetivos | 4 |
| 1.5. Hipótesis | 5 |
| 1.5.1. Contribución | 5 |
| 2. Estado del arte | 7 |
| 2.1. Obtención de la evidencia | 7 |
| 2.2. Resultados | 7 |
| 2.2.1. Síntesis de la evidencia | 9 |
| 2.2.2. Sensores de Visión | 10 |
| 2.2.3. Sensores de movimiento | 14 |
| 2.2.4. Sensores de bioseñales | 18 |
| 2.2.5. Sensores combinados | 20 |
| 2.3. Discusión | 22 |
| 3. Metodología | 27 |
| 3.1. Estrategia de trabajo | 27 |
| 3.1.1. Recolección de datos | 28 |
| 3.1.2. Preprocesamiento de datos | 28 |
| 3.1.3. Extracción de características | 29 |
| 3.1.4. Clasificación de los movimientos de hombros | 29 |
| 3.1.5. Análisis estadístico de los modos de identificación | 29 |
| 3.2. Movimientos de hombro | 30 |
| 3.3. Sensores | 31 |
| 3.3.1. Acelerómetro | 32 |
| 3.3.2. Electrodo de superficie para electromiografía | 32 |
| 3.3.3. Sensores a usar | 33 |
| 3.4. Segmentación | 34 |
| 3.5. Extracción de características | 35 |
| 3.6. Clasificadores | 37 |
| 3.6.1. Modos de clasificación | 39 |

| | |
|--|-----------|
| 4. Modos unimodales y multimodales | 41 |
| 4.1. Procesamiento general | 41 |
| 4.2. Aplicación a clasificadores | 41 |
| 4.3. Resultados | 43 |
| 4.3.1. Resultados en modos unimodales | 43 |
| 4.3.2. Resultados en modos multimodales | 44 |
| 4.3.3. Prueba estadística | 46 |
| 5. Discusión | 49 |
| 6. Conclusiones | 51 |
| A. Códigos en Python | 53 |
| A.1. Código de preprocesamiento de datos | 53 |
| A.2. Código de Decision Tree | 57 |
| A.3. Código de Random Forest | 59 |
| A.4. Código de Support Vector Machine | 60 |

Índice de figuras

| | |
|--|----|
| 1.1. Tres cabezas del deltoides (A) posterior, (B) media, (C) anterior | 2 |
| 2.1. PRISMA | 8 |
| 2.2. Sensores de visión aplicados en los 6 artículos correspondientes a la modalidad de adquisición de visión. | 11 |
| 2.3. Frecuencia de los sensores de movimiento aplicados de los 4 artículos correspondientes a la modalidad de adquisición de movimiento. | 15 |
| 2.4. Conteo de sensores aplicados en el estado del arte | 24 |
| 2.5. Clasificadores aplicados en el estado del arte | 24 |
| 2.6. Frecuencia de las modalidades de adquisición en los artículos encontrados por PRISMA 2.1. | 25 |
| 2.7. Movimientos de rehabilitación enfocados en los hombros de los artículos encontrados por PRISMA 2.1. <i>NOTA: MVD = Movimientos de la Vida Diaria (lavar trastes, empujar y jalar una puerta, beber, etc.). Ejercicios de RS = Ejercicios de rehabilitación secundaria (jalones de toalla, ejercicio de silla, etc.). Ejercicios de Codman = Cualquier ejercicio de péndulo que se mencione.</i> | 25 |
| 2.8. Puntos empleados para la adquisición de señales por cada modalidad en el plano coronal del cuerpo humano | 26 |
| 3.1. Metodología a seguir de la presente investigación | 27 |
| 3.2. Dataframe de la base de datos adquirida después de la extracción de características de las señales. | 29 |
| 3.3. Plano coronal del movimiento abducción de hombro a 180° | 30 |
| 3.4. Plano coronal del movimiento flexión de hombro a 180° | 30 |
| 3.5. Plano coronal del movimiento aducción de hombro a 90° | 31 |
| 3.6. Plano sagital del movimiento péndulo de Codman | 31 |
| 3.7. Diagrama de fusión de sensores aplicado en la investigación según la clasificación de Dasarathy | 32 |
| 3.8. Puntos adquiridos de los músculos mencionados por recomendaciones del SENIAM en la EMG de superficie (puntos rojos = ánodo de S-EMG, puntos negros = cátodo de S-EMG y punto azul = acelerómetro y S-EMG). | 33 |
| 3.9. Sensores implementados en el desarrollo de la investigación, de lazo izquierdo muscleband, del lado derecho Biosignalsplux EMG | 33 |
| 3.10. Ejemplo de segmentación adyacente con ventanas de 5 segundos en señal electromiografía | 35 |
| 3.11. Decision Tree | 37 |
| 3.12. Random Forest | 38 |

| | |
|---|----|
| 3.13. Support Vector Machine | 38 |
| 4.1. Métricas de la mejor modalidad unimodal RF-MDF | 43 |
| 4.2. Métricas de la peor modalidad unimodal DT-VAR | 43 |
| 4.3. Métricas de la mejor modalidad multimodal RF-PKF | 45 |
| 4.4. Métricas de la peor modalidad multimodal DT-VAR | 45 |

Índice de cuadros

| | |
|---|----|
| 2.1. Parámetros de información del artículo y obtención de datos de la modalidad de adquisición de visión | 12 |
| 2.2. Parámetros de procesamiento de datos de la modalidad adquisición de visión | 12 |
| 2.3. Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de visión | 13 |
| 2.4. Parámetros de información del artículo y obtención de datos de la modalidad de adquisición de movimiento | 16 |
| 2.5. Parámetro de procesamiento de datos de la modalidad adquisición de movimiento | 16 |
| 2.6. Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de movimiento | 17 |
| 2.7. Parámetros de información del artículo y obtención de datos de la modalidad de adquisición de bioseñales | 19 |
| 2.8. Parámetros de procesamiento de datos de la modalidad adquisición de bioseñales | 19 |
| 2.9. Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de bioseñales | 20 |
| 2.10. Parámetros de información del artículo y obtención de datos de la modalidad de adquisición de sensores combinados | 21 |
| 2.11. Parámetro de procesamiento de datos de la modalidad adquisición de sensores combinados | 21 |
| 2.12. Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de sensores combinados | 22 |
| 3.1. Modos de adquisición para la clasificación de movimientos de hombros | 39 |
| 4.1. Resultados obtenidos de la métrica de exactitud con los modos unimodales (empleando solo EMG) | 44 |
| 4.2. Resultados obtenidos de la métrica de especificidad con los modos unimodales (empleando solo EMG) | 44 |
| 4.3. Resultados obtenidos de la métrica de sensibilidad con los modos unimodales (empleando solo EMG) | 44 |
| 4.4. Resultados obtenidos de la métrica exactitud con los modos multimodales (empleando aceleración y EMG) | 45 |
| 4.5. Resultados obtenidos de la métrica especificidad con los modos multimodales (empleando aceleración y EMG) | 45 |
| 4.6. Resultados obtenidos de la métrica sensibilidad con los modos multimodales (empleando aceleración y EMG) | 46 |

| | | |
|------|---|----|
| 4.7. | Tabla Pruebas Shapiro-Wilk de las exactitudes de los modos unimodales utilizando Random Forest como clasificador con $\alpha = 0.05$ | 47 |
| 4.8. | Tabla Pruebas Shapiro-Wilk de las exactitudes de los modos multimodales utilizando Random Forest como clasificador $\alpha = 0.05$ | 47 |
| 4.9. | Tabla Pruebas t para determinar si existe diferencia significativa entre las exactitudes de los modos unimodales utilizando Random Forest y los modos multimodales utilizando Random Forest con $\alpha = 0.05$ | 47 |

Capítulo 1

Introducción

En el presente capítulo se comenta acerca de la motivación para el desarrollo de este trabajo de tesis, además se define su justificación y contribución. También se explica la hipótesis evaluada y los objetivos que se logran llevar a cabo durante la elaboración de esta investigación.

1.1. Motivación

Hoy en día el estilo de vida, actividades cotidianas y enfermedades, son razones por las cuales podemos adquirir ciertas condiciones médicas o sufrir accidentes; lo cual puede afectar, en cierta medida, la movilidad de algunas partes del cuerpo. Debido a ello, es recomendable que para las personas afectadas, se realicen ejercicios de rehabilitación; buscando recuperar la movilidad que tenían o mejorarla.

La rehabilitación tiene un fin en común, y bajo la definición de Durán:

“La rehabilitación es un proceso de ayuda, para las personas que presentan diferentes enfermedades que afecten su capacidad funcional, psicológica, social, laboral, educativa y vocacional. El fin es mejorar los problemas causados a razón de las afecciones presentadas [1]”.

En otras palabras, la rehabilitación busca evitar la aparición de futuras discapacidades, recuperar, mantener o mejorar las capacidades físicas y motoras que se necesitan para la vida diaria. Gresham y sus colaboradores [2] definen el proceso de rehabilitación en seis áreas principales de atención:

1. Prevenir y reconocer las enfermedades comórbidas, en conjunto con las complicaciones médicas.
2. Entrenar para conseguir la máxima independencia.
3. Facilitar el máximo afrontamiento psicosocial y la adaptación del paciente y su familia.
4. Prevenir la discapacidad secundaria, promoviendo la reintegración en la comunidad, incluyendo el reinicio de las actividades domésticas, familiares, recreativas y profesionales
5. Mejorar la calidad de vida evitando la discapacidad residual.

6. Prevenir el ictus recurrente y otras afecciones vasculares (por ejemplo, el infarto de miocardio).

La rehabilitación puede ser orientada a cualquier parte del cuerpo. Unas zonas son frecuentemente más tratadas que otras. Como ejemplo se encuentra el hombro; siendo este la tercera causa de dolor músculo esquelético, excedido solo por el dolor de espalda y cuello [3].

El hombro se encuentra conformado principalmente por el músculo deltoides, del cual este se divide en tres cabezas, anterior, media y posterior (ver imagen 1.1). Sin embargo, al ser la articulación más móvil del cuerpo humano, poseyendo tres grados de libertad en el plano sagital, plano coronal y plano transversal respectivamente, también se encuentra como la articulación más inestable [4] en comparación a otras articulaciones. Ya que cuenta con un apoyo óseo mínimo, el húmero está suspendido del omoplato solo por tejidos blandos, músculos, ligamentos y una cápsula articular [5]; dando lugar a múltiples lesiones y patologías inflamatorias, traumáticas, así como degenerativas.

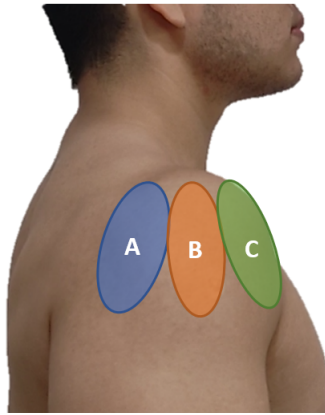


Figura 1.1: Tres cabezas del deltoides (A) posterior, (B) media, (C) anterior

Se estima que aproximadamente el 10% de la población general de adultos experimentará un episodio de dolor de hombro en su vida [6]. Reportándose en Estados Unidos una incidencia anual de 4.5 millones de casos por *Lesiones de Manguito Rotador* (un grupo de músculos y tendones del hombro) [7]; y al menos la consulta por hombro doloroso está dentro de las primeras diez causas de consulta en fisioterapia [8].

Algunos autores estiman que el porcentaje de personas que presentan dolencias del hombro en algún momento de su vida es del 40% [9]. Esta prevalencia aumenta con la edad, con algunas profesiones o tipo de vida laboral, actividad física o actividades deportivas (e.g., tenis, natación, deportes de contacto, béisbol, etc.). Siendo el hombro una de las articulaciones mayormente lesionadas en el área deportiva [10].

Desafortunadamente, en México no se reportan resultados de lesiones del hombro por si sola o combinada con otros procedimientos. Sin embargo, es una afección que puede presentarse a lo largo de nuestras actividades cotidianas.

Para las personas afectadas que necesitan rehabilitación existen diversos factores que pueden dificultar un correcto seguimiento del tratamiento. Tales como (I) ser una persona discapacitada, (II) ser una persona de la tercera edad, (III) estar lesionado en un alto grado que le impida una

movilidad adecuada o (IV) que no se encuentra cerca de la clínica de salud correspondiente.

Para el apoyo a estas personas se han implementado diversas investigaciones en el campo de prótesis [11–13], tele-manipulación [14–16], diagnósticos [17–19], reconocimiento de movimientos [20–22], rehabilitación [23–25], etc. Donde los estudios pueden comprender áreas como la inteligencia artificial (IA), biomédica, biónica y medicina en general, por mencionar algunas.

Actualmente, dentro del área de reconocimiento de movimientos se han empleado técnicas de *aprendizaje automático* (ML del inglés, Machine Learning); capaces de poder distinguir diferentes tipos de movimientos orientados a rehabilitación.

En el ML se construye un aprendizaje en un modelo matemático basado en datos de entrada, conocidos como “datos de entrenamiento”, con el fin de poder hacer predicciones o decisiones sin tener un algoritmo programado para realizar la tarea [26]. En cuanto al aprendizaje del modelo matemático, Mitchell [27] lo define como:

“Un programa de ordenador que aprende de la experiencia E con respecto a alguna clase de tareas T y una medida de rendimiento P , si su rendimiento en las tareas de T , es medido por P , mejora con la experiencia E .”

Donde su finalidad es proporcionar un apoyo auxiliar a los especialistas en rehabilitación. Paralelo a ello, la implementación de dos o más señales (como datos de entrada) en estas investigaciones ha sido un camino ampliamente desarrollado; con el fin de poder lograr obtener un mejor resultado de precisión para clasificar los movimientos.

Lo antes mencionado es llamado data-fusion o fusión de señales. Existen tres niveles de data-fusion: *Data-Level* (fusión de datos en bruto de múltiples fuentes y representación de la fusión de sensores en el nivel más bajo de abstracción), *Feature-Level* (fusión de datos con extracción de características de múltiples fuentes y representación de la fusión de sensores en el nivel medio de información) y *Decision-Level* (fusión de datos con extracción de características de múltiples fuentes y toma de decisiones con los resultados obtenidos en la técnica de fusión de sensores en el nivel más alto de información); donde en cada nivel, el procesamiento de datos es distinto.

Klein define desde una perspectiva general de data-fusion como:

“Un proceso de integración de múltiples fuentes de datos para producir una información mayormente robusta en comparación a la proporcionada por cualquier fuente de datos individual” [28].

El data-fusion pueden comprender diversos tipos de señales o bioseñales; tales como electromiografía (EMG), electroencefalografía (EEG), pulsioximetría (SpO_2), electrocardiografía (ECG), seguimiento de movimiento, entre otras.

La presente investigación describe el proceso llevado a cabo para generar un modelo de clasificación de movimientos de rehabilitación dirigidos al hombro, con la aplicación de fusión de señales de EMG de superficie y acelerómetro.

Además, se proporciona una comparación entre las diferentes técnicas de aprendizaje automático y modalidades que fueron implementadas para la clasificación de los movimientos realizados.

1.2. Justificación

Como se menciona con anterioridad, los problemas que abordan el hombro provocan un gran impacto a nivel social, debido a que se presenta en personas económicamente activas durante su labor cotidiana. En consecuencia, se generan incapacidades laborales, pérdidas económicas para la familia y baja productividad laboral, además de los costos generados para los sistemas de salud; esto dependiendo del grado de lesión que se presente.

Con base a lo anterior, es importante proveer una herramienta capaz de proporcionar información al especialista en rehabilitación sobre la ejecución de ejercicios; con un grado de precisión considerable para la identificación de movimientos.

1.3. Planteamiento del problema

Existen investigaciones con la finalidad de reconocer movimientos de hombros. Bajo modelos de ML se ha intentado mejorar la precisión de clasificación de los movimientos de hombro en estos trabajos (ver tablas del Capítulo 2, sección 2.2). Para el correcto desempeño de estos modelos, la problemática ha sido abordada en la obtención de datos; buscando un correcto entrenamiento. Por lo que se han obtenido señales de visión, bioseñales, señales de movimiento o combinaciones de las señales antes mencionadas (ver capítulo 2) para mejorar la precisión del modelo de ML aplicado. Sin embargo, existen pocas investigaciones con la aplicación de fusión de señales y comparación de diferentes tipos de modelos de ML.

La implementación de esta investigación tiene la finalidad de realizar una comparación de un total de 21 *modos de adquisición* con sensores de EMG de superficie y acelerómetro. Dividiendo las señales en segmentos determinados, en donde a cada segmento se le extraerán características acordes al dominio del tiempo y la frecuencia.

Además, se busca que esta investigación sea adjudicable para personas que necesiten rehabilitación del hombro en general. Ya sea el caso especial para personas de la tercera edad, discapacitadas o con dificultades de movilidad, en zonas inaccesibles o que se encuentren lejos de centro de rehabilitación.

A su vez, la investigación tiene la finalidad de proporcionar una ayuda extra a los expertos en rehabilitación encargados de proporcionar las herramientas y atención necesarias para el avance de las personas afectadas, logrando un avance en conjunto con el sistema que se plantea.

1.4. Objetivos

General:

- Analizar la clasificación de los movimientos del hombro mediante fusión de sensores electromiográficos y acelerómetro, aplicando rehabilitación y técnicas de aprendizaje automático (Random Forest, Support Vector Machine y Decision Tree).

Específicos:

- Aplicar las recomendaciones del SENIAM¹, para la adquisición de la señal EMG y su consecuente señal de aceleración.
- Analizar la correcta ejecución de los ejercicios de rehabilitación enfocados en lesiones del hombro a cada uno de los participantes.
- Implementar la extracción de características a las señales filtradas en el dominio de tiempo y el dominio de la frecuencia.
- Ejecutar los modelos de aprendizaje automático (Random Forest, Support Vector Machine y Decision Tree), reportando a los modelos con mejor grado de precisión, especificidad y sensibilidad.

1.5. Hipótesis

La variable independiente de esta investigación se establece como los diferentes modos de adquisición para los movimientos del hombro; esto es, la extracción de características a cada una de las señales adquiridas y la respectiva combinación de las características extraídas con cada uno de los clasificadores de ML propuestos (explicados detalladamente en el capítulo 3).

La variable dependiente se establece como las métricas a utilizar para medir el rendimiento de los modos de identificación (esto es, exactitud, especificidad, sensibilidad). La hipótesis de investigación de este estudio se define como...

“Los modos de identificación para los movimientos de hombro basados en fusión de sensores tendrá un porcentaje de exactitud mayor a los modos de identificación para los movimientos de hombro unimodales.”

1.5.1. Contribución

En el capítulo 2, sección 2.2 es observable en las tablas que existen trabajos previos de unión de diversos tipos de señales; como lo son bioseñales (EMG [29–32]), señales de movimiento (aceleración y giroscopio [33–36]), señales de visión (extracción o seguimiento de puntos [37–42]) y combinación de las señales antes mencionadas (por ejemplo: EMG y seguimiento de movimiento [43]). Sin embargo, no se presenta el caso de la aplicación de varios canales de EMG con la implementación de acelerómetro para identificar movimientos de hombro utilizados en rehabilitación.

En vista de los resultados, el valor teórico de esta investigación se encuentra en la contribución al estado del arte; ya que el presente trabajo agregaría información sobre la comparación de modos de adquisición. Reportando al modo de adquisición y al clasificador de ML con el mejor porcentaje de exactitud respecto a los demás modos de adquisición y clasificadores aplicados. Aunado a ello, se presenta la implementación de extracciones de características, valor medio absoluto, valor cuadrático medio, varianza, frecuencia mediana, frecuencia media y frecuencia máxima (MAV: Mean Absolute Value, RMS: Root Mean Square, Var: Variance, MDF: Median Frequency, MNF: Mean Frequency y PKF: Peak Frequency respectivamente, por sus siglas en inglés) en las señales,

¹SENIAM (del inglés Electromiografía de Superficie para la Evaluación No Invasiva de los Músculos) es una acción concertada europea dentro del Programa de Investigación y Salud Biomédica (BIOMED II) de la Unión Europea.

para proveer cuál desempeña un mejor rendimiento en el clasificador. Por otra parte, se proporciona la aplicación del acelerómetro en los movimientos de rehabilitación, añadiendo información a los datos adquiridos y generando mayor robustez al sistema.

De esta manera, la contribución de la presente investigación puede sugerir modos de identificación de movimientos de hombro para la implementación del sistema en la aplicación de juegos serios para la rehabilitación del hombro, aplicación en prótesis para la clasificación de movimientos, aplicación en movimientos para generar movilidad en personas de la tercera edad o personas en general que necesiten mejorar su rango de movilidad, aplicación de recuperación post-operación en fuerza, etc.

A la par, durante la ejecución de esta investigación se realizó una estancia académica en el INAOE, donde se publicó el siguiente artículo [On the Prediction of Chaotic Time Series using Neural Networks](#) [44].

Capítulo 2

Estado del arte

En este capítulo se presenta la revisión del estado del arte, en materia para la clasificación de movimientos de hombros empleando rehabilitación; donde la búsqueda del estado del arte fue dirigida por el protocolo Prisma. Aunado a ello, se extrajeron las características sobresalientes de cada uno de los artículos que fueron aceptados por el protocolo.

2.1. Obtención de la evidencia

La revisión del estado del arte se realizó siguiendo las directrices del protocolo PRISMA [45] (ver Figura 2.1). El cual permite comprender de una manera visual los procedimientos utilizados en una investigación de la selección de estudios a lo largo del proceso de revisión en el estado del arte.

Para la identificación de investigaciones acerca de sistemas identificadores de movimientos de hombros que empleen ML y rehabilitación, se realizaron búsquedas en las siguientes bases de datos electrónicas: *ACM Digital library* (2010 a 8 de octubre, 2021), *IEEE Xplore Digital Library* (2010 a 8 de octubre, 2021), *Taylor & Francis Online* (2010 a 10 de octubre, 2021) y *Springer link* (2010 a 16 de octubre, 2021). Utilizando las siguientes tres palabras clave “Shoulder”, “Motion” y “Machine learning”, conectadas por \wedge (“AND”).

La búsqueda en las dos primeras bases de datos fue *Shoulder \wedge Motion \wedge Machine learning*, utilizando como filtro principal el abstract o título de los documentos, que cumpla con la frase de búsqueda. Para las siguientes dos bases de datos la frase de búsqueda cambió a *Shoulder \wedge Motion \wedge “Machine learning”*, utilizando como filtro principal la selección de documentos que se encontraran como *Open Access* y solo para *Springer Link*, se agregaron los filtros de que sean artículos y se encuentren dentro del área de *computer science*. Realizada de esta manera debido a la forma en la que se encuentran implementados los buscadores en las bases de datos; ya que no se encontraban con los mismos filtros o dictámenes de búsqueda para una implementación equitativa.

2.2. Resultados

En la Figura 2.1 se puede observar que la búsqueda recuperó 99 artículos (17 para *ACM Digital library*, 11 para *IEEE Xplore Digital Library*, 36 para *Springer link* y 35 para *Taylor & Francis Online*).

En esta revisión, un estudio era rechazado si cumplía con los siguientes criterios: (I) los fines establecidos en el artículo no eran relacionados con la revisión [46–82] (por ejemplo: algunos buscadores arrojaron documentos relacionados con shoulder surfing¹, autenticación por gestos, análisis visual de animales, análisis no verbal, etc.); (II) la aplicación de IA no se realizaba [84–89]; (III) el enfoque de rehabilitación no se empleaba [90–118]; (IV) el hombro no se encontraba como objeto de estudio (por ejemplo: trayectoria del brazo [119], lenguaje de señas [120], imaginación motora de movimiento del hombro [121], detección de dolor del hombro [122], detección dactilar [123] y clasificación de la forma de la mano [124]); y (v) que fueran revisiones [125–128]. De los 99 artículos, 84 cumplieron estos criterios; siendo removidos.

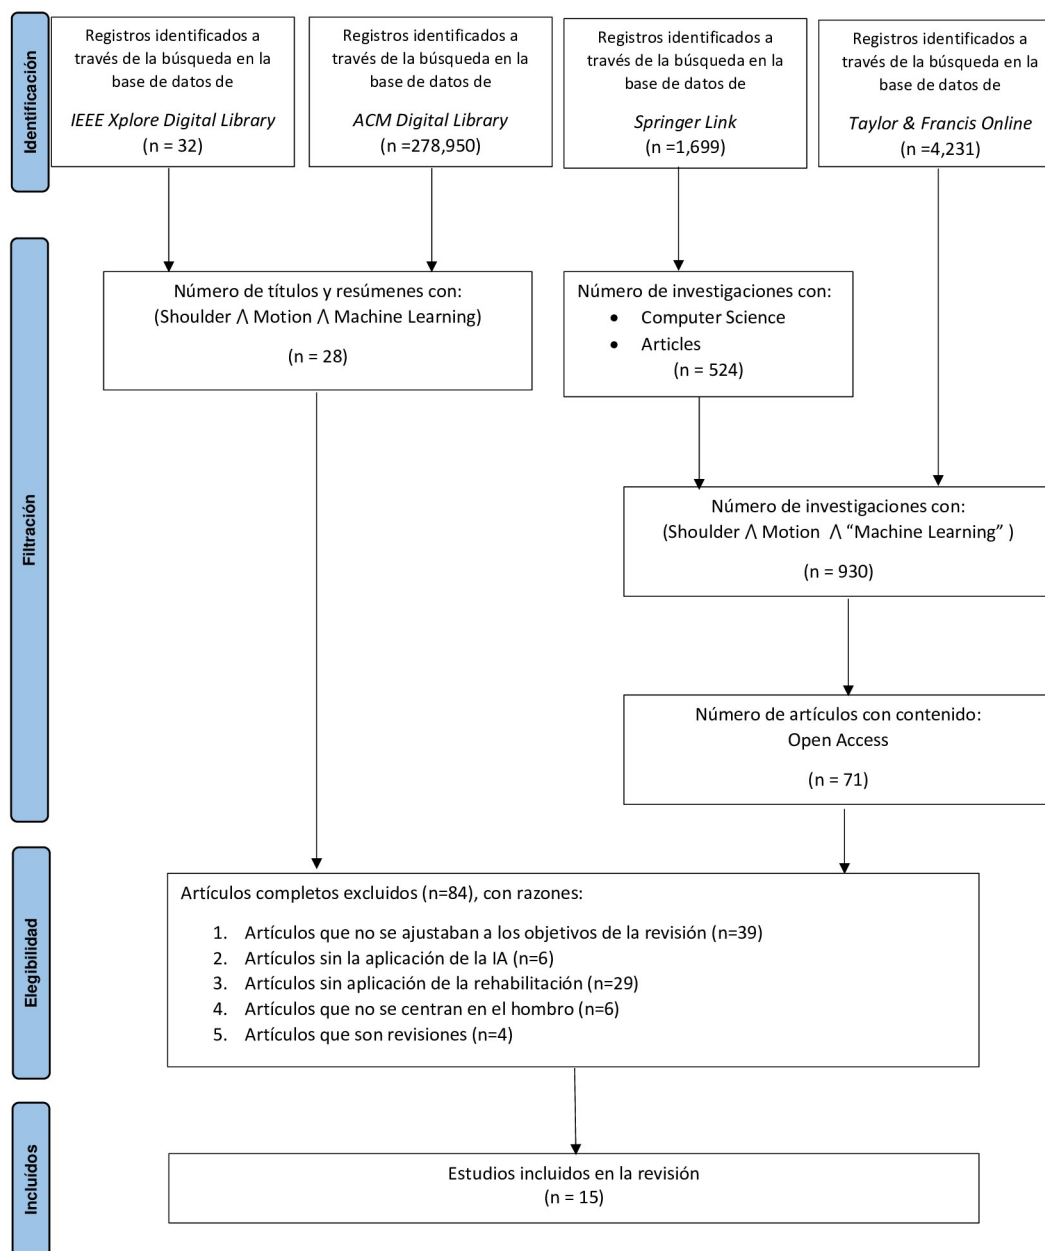


Figura 2.1: PRISMA

¹En seguridad informática, es una técnica usada para obtener información personal de un usuario concreto [83]

2.2.1. Síntesis de la evidencia

En esta revisión, se extrajeron los siguientes datos de los artículos incluidos. En las tablas: cuando el autor no implementa algunas de las técnicas se determina como “No” y cuando el autor es ambiguo en la técnica empleada o no se intuye adecuadamente el procedimiento se determina como “No específica”:

- **Información del artículo:**

Esta sección contiene información básica del artículo:

- Título: Del artículo.
- Autores: Del artículo.
- Fecha: De publicación del artículo.
- Meta: De la investigación.
- Aplicación: Ya sea para prótesis, robot, juego serio, casa inteligente o únicamente reconocimiento de movimientos

- **Obtención de datos:**

- Base de datos: Plantea si se buscó trabajar con una base de datos propia o se implementó alguna ya realizada.
- Sensor(es): Aplicados para la resolución del problema principal del estudio.
- Canales o ejes: Cantidad de ejes o canales aplicados para la adquisición de datos.
- Frecuencia de muestreo: Cantidad de Hertz a la que fue adquirida la señal(es).

- **Procesamiento de datos:**

- Segmentación: Tipo y longitud que se aplicó a la señal(es) adquirida para segmentarla.
- Preprocesamiento: Procesamiento aplicado a la señal(es) principal antes de obtener características de la misma o trabajar con la propuesta fundamental del estudio.
- Características: Adquiridas a la señal(es) principal(es) del estudio (Valor absoluto medio, Media cuadrática, Mediana de la frecuencia, Frecuencia máxima, etc.).
- Clasificadores: Técnica implementada para la clasificación de movimientos.
- Métricas: Aplicadas en el análisis de los resultados (por ejemplo: exactitud, precisión, errores, desviación estándar, etc.)
- Resultados: Presenta la exactitud del clasificador aplicado o sus resultados favorables.
- Software: Nombre de la plataforma ocupada para manipulación de sensores o señal(es).
- Datafusion: ¿Aplica la unión 2 o más señales adquiridas?, ¿Cuál tipo de datafusion se aplicó?

- **Información dirigida a hombros:**

Técnica rehabilitación aplicada en el artículo y software ocupado.

- Movimientos: Cantidad y tipo de movimientos empleados en el estudio.

- Patología: Problema médico que se aborda para las personas que serán beneficiadas con el sistema.
- **Participantes:**
Información general sobre la cantidad y edad de las personas que participaron en el artículo.
 - Total: Cantidad total de personas que participaron en el estudio.
 - Edad: Edad en rango o promedio de las personas que participaron en el estudio.

Los artículos analizados en esta revisión se agruparon en tres categorías de acuerdo al tipo de sensor utilizado para recolectar los datos de los movimientos de hombro, llamados sistemas de adquisición.

Un sistema de adquisición se define como el sensor o sensores utilizados para recoger datos, que se procesarán para proporcionar información al clasificador.

Se obtuvieron cuatro sistemas de adquisición:

- (a) **Sensores de movimiento:** Esta categoría se encuentra relacionada con sistemas que usan sensores basados en información del movimiento (por ejemplo: acelerómetro, magnetómetros, giroscopio).
- (b) **Sensores de visión:** Esta categoría se encuentra relacionada con sistemas que usan sensores basados en visión (por ejemplo: kinect, cámaras, cámaras infrarrojas).
- (c) **Sensores de bioseñales²:** Esta categoría se encuentra relacionada con sistemas que usan sensores basados en señales biológicas. (por ejemplo: Electromiografía)
- (d) **Sensores combinados:** Esta categoría se encuentra relacionada con sistemas de adquisición combinados que usan cualquiera de los sensores antes mencionados.

2.2.2. Sensores de Visión

Esta categoría representa 6/15 de artículos [129–134] del total en las investigaciones encontradas durante la búsqueda implementada por el protocolo de PRISMA (ver figura 2.1). 6/6 artículos se orientan únicamente al reconocimiento de movimientos. 5/6 de estas investigaciones obtuvo su propio dataset [129–133], mientras que en [134] emplearon el dataset *Recognition of Sign Language System for Indonesian Language Using Long Short-Term Memory Neural Networks*. El sensor mayormente empleado en esta modalidad de adquisición es Kinect [129–131, 134] (ver figura 2.2), utilizado para obtener puntos específicos del cuerpo (por ejemplo: hombros, codos, manos, rodillas, cabeza) u obtener planos frontales en 2D y de profundidad. El segundo sensor mayormente empleado fueron cámaras [131, 133], utilizadas para obtener planos frontales del cuerpo en 2D. Por último se encuentran las cámaras infrarrojas [132], utilizadas solo para recolectar puntos específicos como lo hacen con kinect (por ejemplo: hombros, codos, manos, rodillas, cabeza). 3/4 de los artículos que emplean Kinect, expresan explícitamente que no realizaron implementación de otro sensor [129, 130, 134], mientras que [131] realiza la implementación de kinect con cámara RGB. En adición, 6/6 de los artículos de este sistema de adquisición no aplica data-fusion [129–134].

²En esta sección se encontraron más sistemas como lo es electroencefalograma y electrocardiograma. Sin embargo, esas señales no se procesaban solo se adquirían, por lo cual fueron omitidas

Las frecuencias de muestreo que se especificaron fueron 60 Hz [130, 132] y 30 Hz [129, 133] en 4/6 de los artículos. 6/6 de los artículos no presenta segmentación en sus datos adquiridos. 4/6 de los artículos realizan algún tipo de preprocesamiento (por ejemplo: equidad de fps [131], interpolación [129] y normalización [134]). 4/6 de los artículos extrajeron características (por ejemplo: Haar-Like features [129], extracción de características con CNN (Convolutional Neural Network) o CaffeNet [131, 133], distancia euclidiana y diferencia entre puntos de articulaciones de hombros, codos y muñecas [132, 134]). En la sección de clasificadores, cada investigación propuso un algoritmo de clasificación diferente, tales como: red bayesiana, decision tree, random forest, neural networks, etc. 5/6 de los artículos empleó un análisis de métricas [129–133], siendo la exactitud la métrica mayor implementada [129, 132, 133]. 2/6 de los artículos reportan una exactitud mayor al 98 % [129, 132] en la clasificación de los movimientos propuestos; mientras que [130, 131] reportan mejoras en la identificación de puntos del cuerpo tales como mejoras de identificación de ángulos o posiciones finales de la persona. El estudio [133] reportó valores de exactitud entre 76,46 % y 99,63 % dependiendo del movimiento realizado (por ejemplo: con las manos tocar cabeza, tocar hombros, tocar rodillas o tocar dedos del pie). Por último [134] no presenta resultados significativos.

Cada una de las investigaciones propuso movimientos diferentes para la clasificación de los mismos (por ejemplo: movimientos de rehabilitación [129], inclinaciones del tronco [130], abducción y aducción del brazo [131], caminar de las personas [132], movimientos de cognición [133], movimientos de lenguaje de señas donde solo se involucran los brazos [134]). 3/6 de las investigaciones se encuentra orientada de manera general en la postura de las personas [130, 132, 134] (por ejemplo: abarcando disfunciones psicomotrices, forma de caminar, posturas de sentado). 2/6 de las investigaciones emplean Windows SDK para procesamiento de la señal [129, 130], mientras las demás investigaciones optan por softwares diferentes (por ejemplo: Python [131], C# [131], Electron [133] y Matlab [134]). 5/6 de los artículos presentan la cantidad de personas involucradas en su experimentación; donde el mayor número presentado de participantes fue de 15 personas [133], mientras que el menor fue de 2 personas [131, 134]. 2/6 de los artículos presenta el rango de edad de sus participantes, siendo de 18 a 30 años [133] y personas mayores a 60 años [132].

En las tablas 2.1, 2.2 y 2.3 se resumen los detalles.




Figura 2.2: Sensores de visión aplicados en los 6 artículos correspondientes a la modalidad de adquisición de visión.

| Información de artículo | | | Obtención de datos | | | | | |
|-------------------------|---|--------------------|--|---------------------------|---|---------------------|---|--|
| Cita | Autores | Fecha | Meta | Aplicación | Base de datos | Sensor(es) | Canales, ejes o datos | Frecuencia de muestreo |
| [129] | Ilkhan A. & Yusuf S. A. | Mayo 21, 2014 | Reconocimiento de ejercicios de fisioterapia (esto es, ejercicios de péndulo, ejercicios con toallas, ejercicios de posición, etc.) de todo el cuerpo empleando un Kinect | Únicamente reconocimiento | Propia y bajo petición al autor (Home-Based Physical Therapy Exercises) | Kinect | Videos en 2D y videos de profundidad del plano frontal sobre ejercicios de rehabilitación | 30 Hz cámara y Kinect profundidad a 256 niveles de gris |
| [130] | Oliver B., Alexander M., Verona N. & Christopher B. Muhammad Y., Jawad S., Kushairy K., Arif W., Sheraz K. & Haidawati N. | Julio 12, 2021 | Captura de movimiento (por ejemplo, anteverción del brazo, inclinación del tronco, etc.) sin marcadores y su mejora. | Únicamente reconocimiento | Propia | Kinect | 25 puntos (articulaciones) de una muñeca articulada (no específicas que articulaciones, solo posturas de la muñeca) | 60 Hz |
| [131] | Zoran B. & Matjaz G. | Mayo 23, 2019 | Estimación del ángulo de la articulación del hombro, entre cámara RGB basada en aprendizaje automático y MS Kinect | Únicamente reconocimiento | Propia | Cámara RGB y Kinect | Plano frontal 2D y de profundidad de movimientos (abducción y aducción de hombro) | No específica |
| [132] | Srijana G., Dylan E., Michalis P., Filipa M. & Vassilis A. | Noviembre 12, 2011 | Reconocimiento automático de problemas de salud que se manifiestan en el examen (en donde se involucran las posiciones del hombro). | Únicamente reconocimiento | Propia | Cámaras infrarrojas | 12 Puntos: Hombros, codos, muñecas, extremo derecho e izquierdo de la cadera, rodilla y tobillos. | 60 Hz |
| [133] | Surya A. D. & Erdel R. | Marzo 17, 2017 | Propone un sistema de evaluación de ejercicios físicos en el que se involucra el hombro, diseñados específicamente para el seguimiento del comportamiento cognitivo y como apoyo a las decisiones de los expertos para ayudar al desarrollo de la primera infancia. | Únicamente reconocimiento | Propia y compartida CogniLearn HSKT Dataset | Cámara RGB | 14 puntos y articulaciones del cuerpo: hombros, codos, manos, cintura izquierda, rodillas, tobillos, cabeza, cuello, cintura derecha. | 30 Hz |
| [134] | | Abril 19, 2019 | Proceso de generación de la secuencia de esqueleto para traducción de lenguaje de señas (mediante movimientos de hombros y brazos); en el que representan un gesto SIBI (Sistem Isyarat Bahasa Indonesia) de la parte superior del cuerpo, excluyendo las articulaciones de los dedos. | Únicamente reconocimiento | Dataset de Recognition of Sign Language System for Indonesian Language Using Long Short-Term Memory Neural Networks ⁶⁷ | Kinect | 6 Puntos: Articulaciones de hombros, codos y muñecas. | No específica |

Tabla 2.1: Parámetros de información del artículo y obtención de datos de la modalidad de adquisición de visión

| Información de artículo | | | Obtención de datos | | | | | |
|-------------------------|---|--------------------|--|---------------------------|---|---------------------|---|--|
| Cita | Autores | Fecha | Meta | Aplicación | Base de datos | Sensor(es) | Canales, ejes o datos | Frecuencia de muestreo |
| [129] | Ilkhan A. & Yusuf S. A. | Mayo 21, 2014 | Reconocimiento de ejercicios de fisioterapia (esto es, ejercicios de péndulo, ejercicios con toallas, ejercicios de posición, etc.) de todo el cuerpo empleando un Kinect | Únicamente reconocimiento | Propia y bajo petición al autor (Home-Based Physical Therapy Exercises) | Kinect | Videos en 2D y videos de profundidad del plano frontal sobre ejercicios de rehabilitación | 30 Hz cámara y Kinect profundidad a 256 niveles de gris |
| [130] | Oliver B., Alexander M., Verona N. & Christopher B. Muhammad Y., Jawad S., Kushairy K., Arif W., Sheraz K. & Haidawati N. | Julio 12, 2021 | Captura de movimiento (por ejemplo, anteverción del brazo, inclinación del tronco, etc.) sin marcadores y su mejora. | Únicamente reconocimiento | Propia | Kinect | 25 puntos (articulaciones) de una muñeca articulada (no específicas que articulaciones, solo posturas de la muñeca) | 60 Hz |
| [131] | Zoran B. & Matjaz G. | Mayo 23, 2019 | Estimación del ángulo de la articulación del hombro, entre cámara RGB basada en aprendizaje automático y MS Kinect | Únicamente reconocimiento | Propia | Cámara RGB y Kinect | Plano frontal 2D y de profundidad de movimientos (abducción y aducción de hombro) | No específica |
| [132] | Srijana G., Dylan E., Michalis P., Filipa M. & Vassilis A. | Noviembre 12, 2011 | Reconocimiento automático de problemas de salud que se manifiestan en el examen (en donde se involucran las posiciones del hombro). | Únicamente reconocimiento | Propia | Cámaras infrarrojas | 12 Puntos: Hombros, codos, muñecas, extremo derecho e izquierdo de la cadera, rodilla y tobillos. | 60 Hz |
| [133] | Surya A. D. & Erdel R. | Marzo 17, 2017 | Propone un sistema de evaluación de ejercicios físicos en el que se involucra el hombro, diseñados específicamente para el seguimiento del comportamiento cognitivo y como apoyo a las decisiones de los expertos para ayudar al desarrollo de la primera infancia. | Únicamente reconocimiento | Propia y compartida CogniLearn HSKT Dataset | Cámara RGB | 14 puntos y articulaciones del cuerpo: hombros, codos, manos, cintura izquierda, rodillas, tobillos, cabeza, cuello, cintura derecha. | 30 Hz |
| [134] | | Abril 19, 2019 | Proceso de generación de la secuencia de esqueleto para traducción de lenguaje de señas (mediante movimientos de hombros y brazos); en el que representan un gesto SIBI (Sistem Isyarat Bahasa Indonesia) de la parte superior del cuerpo, excluyendo las articulaciones de los dedos. | Únicamente reconocimiento | Dataset de Recognition of Sign Language System for Indonesian Language Using Long Short-Term Memory Neural Networks ⁶⁷ | Kinect | 6 Puntos: Articulaciones de hombros, codos y muñecas. | No específica |

Tabla 2.2: Parámetros de procesamiento de datos de la modalidad adquisición de visión

| Cita | Información dirigida a hombros | | Participantes | |
|-------|--|---|---------------|--------------------|
| | Movimientos | Patología | Total | Edad |
| [129] | 8 movimientos: Ejercicio de sentada, ejercicio de bastón diagonal, ejercicio de espalda tumbada, ejercicio de toalla, ejercicio de péndulo recto, ejercicio de péndulo circular, ejercicio de silla, ejercicio de talón. | Personas que necesitan fisioterapia, incluyendo el hombro | 5 | No |
| [130] | 4 movimientos: Inclinación del tronco, anteverción del brazo, rotación axial del tronco e inclinación lateral del tronco, con variación de ángulos (0°, 10°, 20° y 60°) | Personas con mala postura | No | No |
| [131] | 2 movimientos: Abducción y aducción del hombro | Daño cerebral por ictus | 2 | No |
| [132] | Caminar de las personas | Personas mayores con problemas de salud (hemiplejía, Parkinson, dolor en espalda y dolor en pierna) | 9 | Personas ≤ 60 años |
| [133] | 5 tipos de movimientos donde se toca cabeza, pies, hombros y rodillas | Personas con disfunciones psicométricas | 15 | 18 a 30 años |
| [134] | Lenguaje de señas, donde se emplean movimientos en la articulación del hombro | Personas sordomudas | 2 | No |

Tabla 2.3: Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de visión

2.2.3. Sensores de movimiento

Esta categoría representa 4/15 de artículos [135–138] del total en las investigaciones encontradas durante la búsqueda implementada por el protocolo de PRISMA (ver figura 2.1). 2/4 de los artículos se orientan únicamente al control de un cursor en pantalla dirigido con movimientos del hombro [135, 138], mientras que los demás se orientan únicamente al reconocimiento de movimiento [136, 137] y diagnóstico del ROM (Range Of Motion) del hombro [137]. 4/4 de los artículos obtuvo su propio dataset (en [136] se hicieron públicas sus bases de datos, ver tabla 2.4). 4/4 de los artículos empleó el sensor de aceleración para la adquisición de datos, siendo el sensor más empleado (ver figura 2.3). Sin embargo, en [135, 136] además del empleo del sensor de aceleración, ocuparon el sensor de giroscopio para determinar el cambio de rotación del hombro (en [136] se adquiere la ECG, pero el autor menciona que no se utilizó en la investigación). 3/4 de los artículos obtuvieron su señal en 3 planos de movimiento (X, Y y Z) respecto al hombro; mientras que en [138] se adquirieron solo 2 planos (por ejemplo: plano X y Y) de movimiento del hombro. 3/4 de los artículos empleó datafusion; donde [135, 136] lo realizan en feature level (esto es, fusión del acelerómetro, giroscopio y magnetómetro respectivamente, con extracción de características, tales como mean, median, filtro de kalman, etc.) y [138] en data level (por ejemplo: fusión de la señal del acelerómetro en bruto, sumando canales).

3/4 de los artículos emplearon como frecuencia de muestreo 50 Hz [135, 136, 138]; mientras que en [137] se emplea 30 Hz y [136] emplea 204.8 Hz (en su dataset 1). 3/4 de los artículos especifica el tipo de segmentación que empleó (esto es, 20 ms adyacente [135], 5 seg. sobrepuesta [136] y 100 ms adyacente [138]). 2/4 de los artículos realiza algún tipo de preprocesamiento (por ejemplo: eliminación de ruido [136] y filtrado como filtros Butterworth o interpolación lineal [136, 137]). 4/4 de los artículos extrajo características, tales como características del dominio del tiempo y frecuencia [136, 137] (esto es, mean, median, standard deviation, RMS, Kurtosis, etc.), características dadas por el filtro de Kalman [135] y características dadas por PCA y sus variantes (esto es, Candid Covariance free Incremental Principal Component Analysis) [138]. 2/4 de los artículos implementó como clasificación un modelo de ML como Decision tree, Random forest, Support vector machine, Logistic regression, entre otros [136, 137]. 4/4 de los artículos aplicó un análisis con base a métricas de los resultados obtenidos [135–138] (por ejemplo, tiempo de movimiento, error de amplitud, clasificación incorrecta, etc.). 3/4 de los artículos presentan resultados mayores al 83 % de exactitud para la clasificación de movimientos. Sin embargo, en [138] se reporta una mejora de la creación de un mapa de movimientos del hombro con una eficiencia computacional en tiempo y memoria respecto al algoritmo propuesto.

2/4 de los artículos emplea el movimiento de abducción del hombro [135, 137], además de integrar otros ejercicios como lo son la aducción, depresión, flexión y extensión del hombro. Mientras que en [136] se emplean ejercicios de la actividad diaria (por ejemplo: sentarse, acostarse, estar de pie, lavar los platos, pasar la aspiradora, barrer, caminar, subir escaleras, etc.). 2/4 de los artículos se orientan a enfrentar patologías con su propuesta de investigación (esto es, cuadriplejía y poca movilidad de hombros) [135, 137]. 2/4 de los artículos emplea Matlab como software para el análisis de las señales adquiridas [135, 136]. 3/4 de los artículos presentan la edad de las personas que participaron en el estudio [135, 137, 138], siendo 18 años la edad más baja [135, 138] y 43 años la edad más alta [135].

En las tablas 2.4, 2.5 y 2.6 se resumen los detalles.




Figura 2.3: Frecuencia de los sensores de movimiento aplicados de los 4 artículos correspondientes a la modalidad de adquisición de movimiento.

| Cita | Información de artículo | | | Obtención de datos | | | Frecuencia de muestreo |
|-------|---|--------------------|--|---|------------------------|---|---|
| | Autores | Fecha | Méica | Aplicación | Base de datos | Sensor(es) | |
| [135] | Ismael S. & Ferdinando A. M. | Junio 26, 2013 | Inferir la cinemática de un cursor a partir de las señales registradas por 4 unidades de medición inercial colocadas en los hombros de un sujeto | Control de cursor | Propia | Acelerómetro y giroscopio | 4 canales: 3 planos X, Y y Z de los hombros (2 sensores en cada hombro) 50 Hz |
| [136] | Henry F. N., Yang W. T., Ghilain M., Uzoma R. A. & Mohammed A. A. | Septiembre 9, 2019 | Fusión de sensores de movimiento (acelerómetro, giroscopio y/o magnetómetro) para la detección de actividad humana (esto es, sentar, caminar, subir escaleras, etc), con la aplicación multivista de algoritmos de ML. | Únicamente reconocimiento | Dataset 1 Dataset 2 | Dataset 1: Acelerómetro y giroscopio Dataset 2: Acelerómetro, magnetómetro, giroscopio y 2 derivaciones de electrocardiografía (la ECG solo se adquirió, pero no se procesó) | Dataset 1 - 3 canales: 3 planos X, Y y Z del tobillo, pecho y muñeca Dataset 2 - 2 canales: 3 planos X, Y y Z del tobillo y muñeca |
| [137] | Joseph J., Pomuraj K.P., Miralil P. & Ajay B.T. | Agosto 4, 2020 | Uso de un reloj inteligente para capturar la dirección del movimiento, velocidad y ROM (Range Of Movement) del hombro | Diagnóstico del hombro y reconocimiento | Propia | Acelerómetro | 1 Canal: 3 planos X, Y y Z 30 Hz |
| [138] | Dalia D. S., Parviga D. & Ferdinando A. M. | Agosto 29, 2018 | Algoritmo coadaptativo no supervisado que cambia el mapeo de una interfaz cuerpo-máquina para ajustarse a la distribución natural de los movimientos de los usuarios, con la finalidad de controlar un cursor de computadora mediante hombros y brazos | Control de cursor | Propia | Acelerómetro | Dataset 1 - 4 canales: 2 planos X y Y de cada hombro Dataset 2 - 4 canales: 2 planos X y Y del bíceps y antebrazo 50 Hz |

Tabla 2.4: Parámetros de información del artículo y obtención de datos de la modalidad de adquisición de movimiento

| Cita | Procesamiento de datos | | | Resultados | | | Software | Datafusion |
|-------|-------------------------------|---|---|---|---|---------------|----------------------|------------|
| | Preprocesamiento | Características extraídas | Clasificadores | Métricas | Grupos | Software | | |
| [135] | 20 ms adyacente | No específica | No | Exactitud | Grupo 1: Euler angles Grupo 2: Euler angles and angular velocities Grupo 3: Euler angles, angular velocities, and linear accelerations 83% de exactitud con el grupo 3 (% a better performance with less training than subjects in the other two groups ¹) | Matlab | Si, Feature level | |
| [136] | 5 seg con solapamiento al 50% | Filtro de interpolación lineal y eliminación de ruido | Decision Tree, Support Vector Machine, k-Nearest Neighbors y Logistic Regression | Accuracy | Dataset 1 (204.8 Hz): 97.89 % de exactitud Dataset 2 (50 Hz): 99.18 % de exactitud | Matlab y Weka | Si, Feature level | |
| [137] | No específica | Filtro Butterworth pasa bajas de corte 20 Hz | Decision Tree, Random Forest, Gradient Boosting, Ada Boost y Extra Tree. | Exactitud | Gradient boosting con exactitud de 94.17 % | No | No | |
| [138] | 100 ms adyacente | No | Principal Component Analysis (PCA) y Candid Covariance free Incremental Principal Component Analysis (CCIPCA) | time to target, path length, amplitude error, direction error cumulative map change, etc. | Mejora en la creación de un mapa de movimientos del hombro con eficiencia computacional en tiempo y memoria al adaptar el algoritmo propuesto. | No | Si, Data level | |

Tabla 2.5: Parámetro de procesamiento de datos de la modalidad adquisición de movimiento

| Cita | Información dirigida a hombros | | Participantes | |
|-------|---|---------------------------------------|--|--|
| | Movimientos | Patología | Total | Edad |
| [135] | 4 Movimientos: elevación, depresión, aducción y abducción del hombro Dataset 1: Sentarse, acostarse, estar de pie, lavar los platos, pasar la aspiradora, barrer, caminar, subir escaleras, bajar escaleras, correr en la cinta rodante, montar en bicicleta en el ergómetro (50 w), montar en bicicleta en el ergómetro (100 w) y saltar la cuerda. Dataset 2: Estar de pie, sentarse y relajarse, acostarse abajo, caminar, subir escaleras, cintura inclinada hacia adelante, la elevación frontal de los brazos, flexión de las rodillas (en cuclillas), ciclismo, trotar, correr y saltar. 3 Movimientos: abducción (45°, 90°, 135°, 180°), flexión (45°, 90°, 135°, 180°) y extensión del hombro (a su máxima amplitud) | Personas con cuadriplejía | 18 | 18 a 43 años |
| [136] | | No | 19 | No |
| [137] | | Personas con poca movilidad de hombro | Etapa 1: 25 Etapa 2: 50 | Fase 1: 28 ± 4 años Fase 2: 30 ± 3 años |
| [138] | No específica | No | Experimento 1: 16 Experimento 2: 10 | Experimento 1 (entrenamiento de un día): 19 a 34 años Experimento 2 (entrenamiento de 3 días): 18 a 28 años |

Tabla 2.6: Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de movimiento

2.2.4. Sensores de bioseñales

Esta categoría representa 4/15 de artículos [139–142] del total en las investigaciones encontradas durante la búsqueda implementada por el protocolo de PRISMA (ver figura 2.1). 4/4 de los artículos se orientan únicamente al reconocimiento de movimientos del hombro [139–142]. Además, 4/4 de los artículos de esta modalidad adquirió su propio dataset [139–142]. El único sensor empleado en estas investigaciones son los electrodos de superficie para electromiografía [139–142]. 2/4 de los artículos emplean la adquisición de sus sensores en los siete músculos para la clasificación de movimientos del brazo (esto es, bíceps braquial, tríceps braquial, deltoides anterior, deltoides posterior, pectoral mayor, infraespinoso y trapecio), donde se involucra el hombro [139, 141]; mientras que en [140, 142] emplean tres músculos (por ejemplo: bíceps, tríceps, deltoides). 4/4 de los artículos empleó datafusion en data level, esto es, la combinación de los sensores en bruto, sumando las señales.

3/4 de los artículos empleo 1 kHz como frecuencia de muestreo en su sistema [139–141], mientras que en [142] se empleó una frecuencia de muestreo de 1.1 kHz. 3/4 de los artículos empleó una segmentación adyacente a su señal adquirida, donde [139, 141] lo realizaron a 100 ms y [142] lo realizó a 150 ms. 4/4 de los artículos realizó un preprocesamiento a las señales adquiridas, donde en [139, 141] realizaron una rectificación y un filtrado con un filtro pasa bajas; mientras que en [140] realizan una normalización y linearización de la señal; y en [142] solo emplean un filtro pasa banda. 4/4 de los artículos extrajeron características, esto es, Mean Absolute Value (MAV), Varianza, Power Spectral Density (PSD), Root Mean Square (RMS) [139–142]. 3/4 de los artículos empleo un clasificador de aprendizaje automático (esto es, Extreme Machine Learning y Support Vector Machine) [139, 141, 142]. 3/4 de los artículos empleó la exactitud como métrica para análisis de sus resultados [140]. 3/4 de los artículos presentan resultados mayores al 82% de exactitud (dependiendo del tipo de movimiento para [139]) [141, 142], mientras que en [140] se presentan resultados preliminares.

3/4 de los artículos optó por incluir 5 movimientos para la clasificación con su sistema, donde se destacan como repetitivos los movimientos de flexión y protracción del hombro [139–141]; sin embargo, en [142] se emplearon 4 movimientos de la vida diaria. 2/4 de los artículos presentan alguna patología a enfrentar para la superación de las personas que adopten este sistema (por ejemplo: extremidades superiores amputadas) [139, 141]. 3/4 de los artículos emplean a Matlab como software de procesamiento de señales [139–141], mientras que en [142] se emplea LabVIEW. El número menor de participantes reportado es de 4 en [139, 141], mientras que el mayor es 8 en [140]. 2/4 de los artículos presentan un rango de edad de sus participantes, rondando en una edad de 20 años en [140] y de 25 a 30 años en [142].

En las tablas 2.7, 2.8 y 2.9 se resumen los detalles.

| Cita | Información de artículo | | Obtención de datos | | | | | |
|-------|---|---------------------|---|---------------------------|---------------|--|--|------------------------|
| | Autores | Fecha | Meta | Aplicación | Base de datos | Sensor(es) | Canales o ejes | Frecuencia de muestreo |
| [139] | Chris W.A., Federica B., Erik C. & Lorenzo M. | Octubre 1, 2015 | Interfaz de base mioeléctrica para controlar cinco movimientos discretos de las extremidades superiores que involucren la articulación del hombro y el codo | Únicamente reconocimiento | Propia | Electrodos de superficie para electromiografía | 7 Músculos: bíceps braquial, tríceps braquial, deltoides anterior, deltoides posterior, pectoral mayor, infraespinoso y trapecio | 1 kHz |
| [140] | Pritam C., Federica B., & Achintya D. | Octubre 4, 2020 | Interpretación de la señal de Electromiografía (D-EMG) del brazo humano para la caracterización de la interacción brazo-músculo durante varios movimientos del brazo (esto es, Extension of the forearm, flexion of elbow joint, pronation of forearm, shoulder abduction, and Wrist flexor stretch). | Únicamente reconocimiento | Propia | Electrodos de superficie para electromiografía | 4 Músculos: bíceps, tríceps, flexores y deltoídes | 1 kHz |
| [141] | Chris W. A., Federica B., Erik C. & Lorenzo M. | Agosto 29, 2015 | Este trabajo presenta una interfaz en tiempo real, basada en la mioelectricidad para identificar y clasificar los movimientos de la parte superior del brazo, con la participación del hombro y el codo. | Únicamente reconocimiento | Propia | Electrodos de superficie para electromiografía | 7 Músculos: bíceps braquial, tríceps braquial, deltoides anterior, deltoides posterior, pectoral mayor, infraespinoso y trapecio | 1 kHz |
| [142] | Chaoyang C., Mark C., Stetson F., Stephanie M. & Stephen L. | Octubre 30, 2020 | Reconocimiento de patrones de movimientos del hombro en tiempo real basado en la electromiografía de superficie (sEMG). | Únicamente reconocimiento | Propia | Electrodos de superficie para electromiografía | 6 Músculos: trapecio, infraespinoso, deltoides anterior, deltoides posterior, bíceps cabeza larga, y tríceps cabeza larga | 1.1 kHz |

Tabla 2.7: Parámetros de información del artículo y obtención de datos de la modalidad de adquisición de bioseñales

| Citas | Procesamiento de datos | | | | | | |
|-------|---|---|-----------------------------------|---------------|---|----------|-------------------|
| | Preprocesamiento | Características extraídas | Clasificadores | Métricas | Resultados | Software | Datafusión |
| [139] | Adyacente de 100 ms Rectificación y filtro pasa bajas a 10 Hz | Mean Absolute Value y Varianza | Extreme Learning Machine (ELM) | Exactitud | Depende del movimiento $\approx 62\%$ a 98% de exactitud | Matlab | Si, Data level |
| [140] | No específica Normalización y linearización | Magnitudes, ángulo de fase y Power Spectral Density de la señal. | No | No específica | Resultados preliminares | Matlab | Si, Data level |
| [141] | Adyacente de 100 ms Rectificación y filtro pasa bajas a 10 Hz | Mean Absolute Value, Variance y Synergies features | Extreme Learning Machine (ELM) | Exactitud | Exactitud de 99% para experimento 1 (time domain features) y 82% para experimento 2 (synergy features) | Matlab | Si, Data level |
| [142] | Adyacente de 150 ms Filtro pasa banda a 20-450Hz | Root Mean Square | Support Vector Machine | Exactitud | $87,6\%$ en el entrenamiento offline y $85,3\%$ en validación en tiempo real | LabVIEW | Si, Data level |

Tabla 2.8: Parámetros de procesamiento de datos de la modalidad adquisición de bioseñales

| Cita | Información dirigida a hombros | | Participantes | |
|-------|--|-----------------------------------|---------------|-------------------|
| | Movimientos | Patología | Total | Edad |
| [139] | 5 Movimientos: Flexión y extensión del codo, protracción, retracción y flexión del hombro | Extremidades superiores amputadas | 4 | No |
| [140] | 5 Movimientos: Abducción del hombro, extensión del antebrazo, pronación del antebrazo, estiramiento de los flexores de la muñeca y flexión de la articulación del codo | No | 8 | \bar{x} 20 años |
| [141] | 5 Movimientos: Flexión y extensión del codo, protracción, retracción y flexión del hombro | Extremidades superiores amputadas | 4 | No |
| [142] | 4 Movimientos: Abducción y aducción, beber, empujar hacia delante y hacia atrás, relajarse | No | 5 | 25 - 30 años |

Tabla 2.9: Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de bioseñales

2.2.5. Sensores combinados

Esta categoría representa 1/15 de artículos [143] del total en las investigaciones encontradas durante la búsqueda implementada por el protocolo de PRISMA (ver figura 2.1). El artículo [143] es el único artículo que presenta la combinación de sensores de diferentes modalidades (esto es, sensor de visión y bioseñales). La investigación se enfoca únicamente en el reconocimiento de los movimientos de la vida diaria (MVD), donde se emplea el hombro. Este artículo obtuvo su propio data set. Los sensores implementados en esta investigación consistieron en electrodos de superficie para electromiografía y marcadores de seguimiento de movimiento; además de adquirir electroencefalografía con electrodos de superficie, sin embargo, esta señal solo se adquirió y no se procesó. Se emplearon 24 músculos para la identificación de la actividad muscular de la EMG (por ejemplo: trapecio, deltoides, dorsal, pectoral mayor, bíceps, tríceps, pronador teres, flexor carpi radialis, etc.) y 5 Puntos para marcadores (esto es, hombro, pecho, codo, extremos de la muñeca y centro de la mano). Al emplear dos tipos de sensores con diferente sistema de adquisición, la datafusion aplicada fue realizada en feature level (por ejemplo: extracción de características en cada una de las señales adquiridas y su respectiva combinación).

La frecuencia de muestreo empleada en este artículo para la adquisición de la EMG fue de 2 kHz, mientras que para los marcadores de seguimiento de movimiento fue de 500 Hz. El preprocesamiento empleado para las señales de EMG fueron dos filtros, un filtro Butterworth pasa banda de corte 20 Hz-600 Hz de 4^o orden y un filtro pasa bajas de corte 2 Hz de 2^o orden; para la señal de video no se especificó preprocesamiento de la señal. Como extracción de características optaron por un filtro de Kalman. No se empleó un clasificador de ML. Sin embargo, si se realizó un análisis en exactitud de los resultados obtenidos por el clasificador, reportando al mejor. Se obtuvieron resultados con un 95 % de exactitud con la modalidad de solo 3 puntos de seguimiento en la señal de video.

Como se mencionó con anterioridad, se emplearon 30 tipos de MVD (esto es, saludando, gesto de OK, apuntando, leer un libro, etc.). En esta investigación no se abordó algún tipo de patología. Se empleó con 6 participantes en la investigación para la adquisición de señales, los cuales contaron con una edad de 30 ± 5.81 años.

En las tablas 2.10, 2.11 y 2.12 se resumen los detalles.

| Cita | Información de artículo | | Aplicación | Base de datos | Sensor(es) | Obtención de datos | Canales o ejes | Frecuencia de muestreo |
|-------|---------------------------------------|--------------------|------------------------------|---------------|---|--|-----------------------|--|
| | Autores | Fecha | | | | | | |
| [143] | Tughl H., Johannes K. & Sami H. | Agosto 29, 2018 | Únicamente reconocimiento | Propia | Electrodos de superficie para electromiografía y marcadores de seguimiento de movimiento (electrodos de electroencefalografía para trabajo futuro) | trapezio, deltoides, dorsal, pectoral mayor, bíceps, tríceps, pronador teres, flexor carpi radialis y palmaris longus, flexor carpi ulnaris, flexor digitorum superficialis, flexor, etc. 5 Puntos para marcadores: hombro, pecho, codo, extremos de la muñeca y centro de la mano. | 24 Muestras para EMG: | Seguimiento de movimiento 500 Hz y EMG 2 kHz |

Tabla 2.10: Parámetros de información del artículo y obtención de datos de la modalidad de sensores combinados

| Cita | Segmentación | Procesamiento de datos | | | Resultados | Software | Datafusión |
|-------|---------------|--|---------------------------|----------------|--|----------|----------------------|
| | | Preprocesamiento | Características extraídas | Clasificadores | | | |
| [143] | No específica | Para EMG filtro Butterworth pasa banda a 20Hz-600Hz de 4° orden y pasa bajas a 2 Hz de 2° orden | Filtro de Kalman | No | Exactitud catalogados con 3 puntos de control en señal de video | No | Sí, Feature level |

Tabla 2.11: Parámetro de procesamiento de datos de la modalidad adquisición de sensores combinados

| Cita | Información dirigida a hombros | | Participantes | |
|-------|--|-----------|---------------|----------------|
| | Movimientos | Patología | Total | Edad |
| [143] | 30 tipos de movimientos de la vida diaria (esto es, saludando, gesto de OK, apuntando, leer un libro, etc.) | No | 6 | 30 ± 5.81 años |

Tabla 2.12: Parámetros de la información dirigida a hombros y participantes de la modalidad de adquisición de sensores combinados

2.3. Discusión

Esta sección revisa las tecnologías desarrolladas en los últimos 11 años, centrándose en los tipos de modalidades que interactúan con movimientos del hombro, donde se identifican sistemas clasificadores de estos movimientos que empleen ML y rehabilitación. Se propuso la identificación de cuatro tipos de modalidades de adquisición, siendo estas modalidades de visión, movimiento, bioseñales y combinación; de las cuales se destaca lo siguiente.

6/15 de los artículos corresponden al empleo de modalidades de adquisición en sensores de visión; 4/15 de los artículos corresponden al empleo de modalidades de adquisición en sensores de movimiento; 4/15 de los artículos corresponde al empleo de modalidad de adquisición en sensores de bioseñales; 1/15 de los artículos corresponde al empleo de modalidad de adquisición de sensores combinados. Detalles en figura 2.6.

13/15 de los artículos se enfocan únicamente al reconocimiento de movimientos [129–134, 136, 137, 139–143], seguido de 2/15 de los artículos que se enfocan en el control de un cursor de pantalla [135, 138]. Y por último, 1/15 de los artículos se enfoca en el diagnóstico del hombro (Range Of Motion) con las señales que se adquieren [137], aparte de enfocarse en el reconocimiento del movimiento.

13/15 de los artículos obtuvieron su propio dataset [129–133, 135, 137–143], donde en [129, 133, 136] sus bases de datos se encuentran públicas o bajo petición al autor (ver tablas 2.1, 2.4).

Se aplicaron un total de 7 sensores diferentes (por ejemplo: Kinect, cámara, cámara infrarroja, acelerómetro, magnetómetro, giroscopio y electrodos de superficie para EMG), siendo Kinect, acelerómetro y los electrodos de S-EMG los sensores mayormente implementados correspondientemente en sus modos de adquisición (ver figura 2.4).

7/15 de los artículos no emplea data fusion [129–134, 137]. 5/15 sí emplea data fusion en data level, combinando las señales en bruto [138–142]. 3/15 de los artículos emplea data fusion en feature level, combinando las características extraídas por cada señal [135, 136, 143].

La frecuencia de muestreo se encuentra similar dependiendo el tipo de modalidad que se presente, ya sea el caso de visión a 50 o 60 Hz, de bioseñal a 1 kHz o 1.1kHz y movimiento de 30 Hz a 50 Hz.

El tipo de segmentación mayormente empleada es la adyacente, aplicada en 5/15 de los artículos [135, 138, 139, 141, 142], mientras que la segmentación por solapamiento es aplicada una vez en [136].

Los filtros mayormente aplicados en las modalidades de adquisición de bioseñal y movimiento fueron los filtros pasa banda y pasa bajas (correspondientes a la frecuencia de muestreo).

La extracción de características en cada modalidad fue distinta dependiendo el tipo de señal que se adquiriría.

Los clasificadores mayormente implementados en los 15 artículos fueron Decision Tree, Support Vector Machine y Random Forest (ver figura 2.5).

De un total de 21 ejercicios enfocados al hombro, los 5 ejercicios mayormente aplicados como técnica de rehabilitación fueron (ver figura 2.7): abducción, flexión, retracción, protracción y aducción; mencionadas de manera ascendente a descendente respectivamente (solo incluyendo para este conteo de frecuencias ejercicios de hombro; debido a la finalidad de la revisión. Los ejercicios como extensión y flexión del codo, inclinación, rotación axial e inclinación lateral del tronco, entre otros, fueron descartados en este conteo).

El software para procesamiento de las señales mayormente empleado fue Matlab, empleado en 6/15 de los artículos [134–136, 139–141].

El rango de edad de participantes en los artículos se establece en su mayoría de ≈ 20 a 40 años, siendo 8/15 investigaciones que definen específicamente el rango empleado en su estudio [132, 133, 135, 137, 138, 140, 142, 143].

El promedio general de participantes de personas en los artículos es de 12,37, siendo 50 el mayor y 2 el menor número presentado (el promedio fue calculado con base al total de participantes en cada etapa de experimentación presentadas); sin embargo, en [130] se empleó una muñeca articulada para la adquisición de su dataset, lo cual no reportaron participantes (este artículo no es contemplado en el cálculo del promedio descrito anteriormente).

En la figura 2.8 se pueden observar los diferentes puntos de adquisición para las 4 modalidades descritas. Donde la modalidad de visión es la que contempla mayor cantidad de puntos de medición respecto a las demás modalidades; mientras que la modalidad de movimiento se concentra en las extremidades del cuerpo humano (esto es, brazos y pies).

El año con el número de más publicaciones encontradas es 2020 (3 publicaciones) seguido en segundo lugar a 2018 y 2019 (2 publicaciones).

Con base a los resultados analizados, se identificó el trabajo futuro en las modalidades de adquisición. Donde se destaca en general para las modalidades el empleo de más sensores correspondientes al área de estudio, ya sea visión, movimiento y bioseñal; empleando sensores tales como marcapasos, láseres, diferentes tipos de cámaras, sensor de presencia, sensor de proximidad, sensor de cambios de velocidad, temperatura, etc. Así mismo como el empleo de identificación o clasificación de movimientos a una mayor distancia del usuario para la modalidad de visión. Una adquisición de más puntos o canales para la clasificación de movimientos del hombro con sensores de movimiento, ya sea aplicado o no a personas amputadas de sus extremidades superiores. Por último, se destaca también como trabajo futuro el empleo de datafusion con sensores de diferentes tipos de adquisición.




Figura 2.4: Conteo de sensores aplicados en el estado del arte

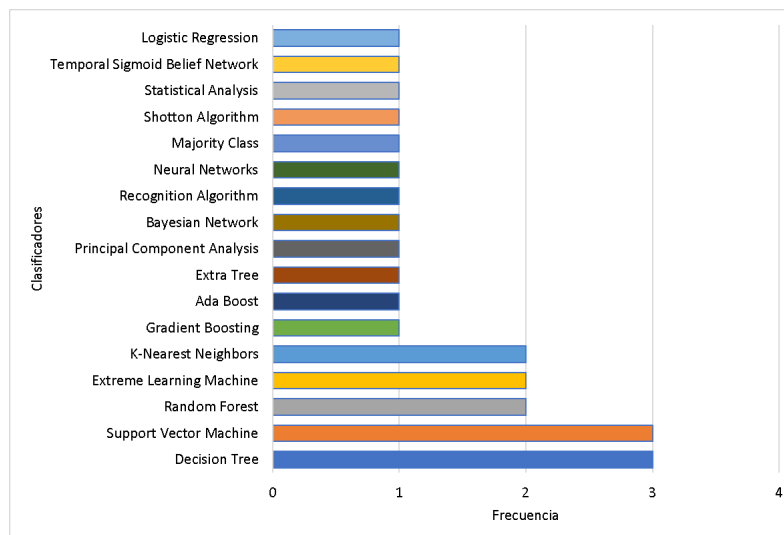


Figura 2.5: Clasificadores aplicados en el estado del arte

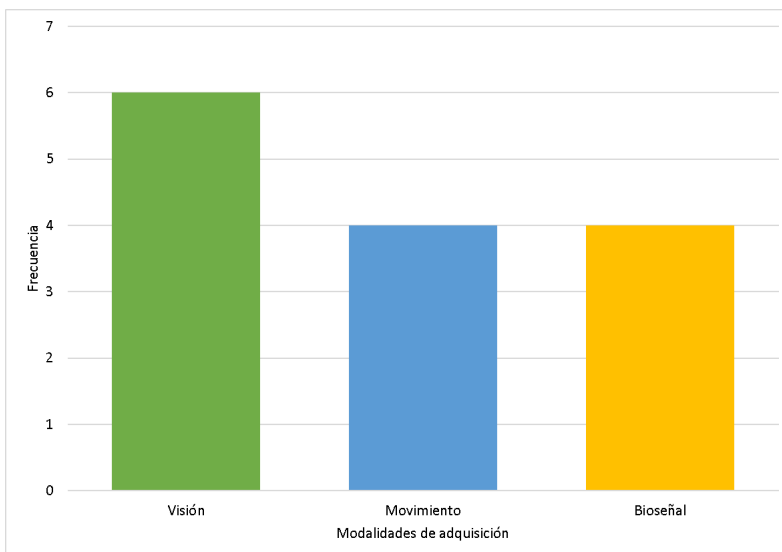


Figura 2.6: Frecuencia de las modalidades de adquisición en los artículos encontrados por PRISMA 2.1.

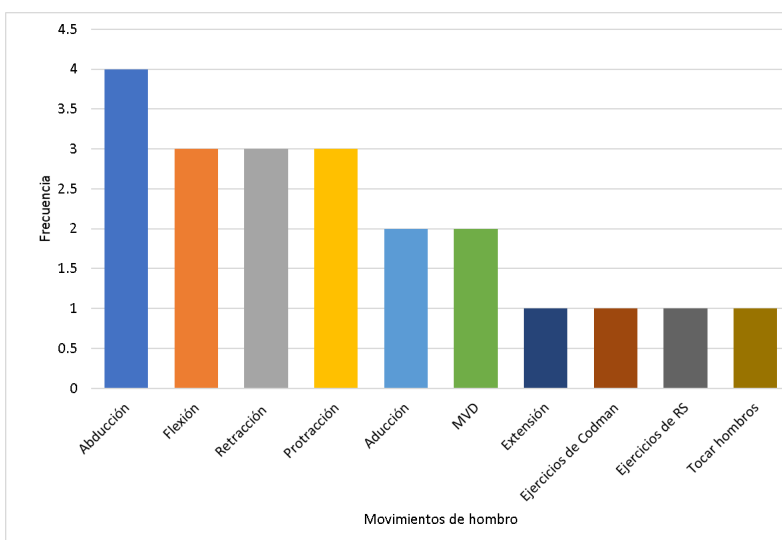


Figura 2.7: Movimientos de rehabilitación enfocados en los hombros de los artículos encontrados por PRISMA 2.1.

NOTA: MVD = Movimientos de la Vida Diaria (lavar trastes, empujar y jalar una puerta, beber, etc.).

Ejercicios de RS = Ejercicios de rehabilitación secundaria (jalones de toalla, ejercicio de silla, etc.).

Ejercicios de Codman = Cualquier ejercicio de péndulo que se mencione.

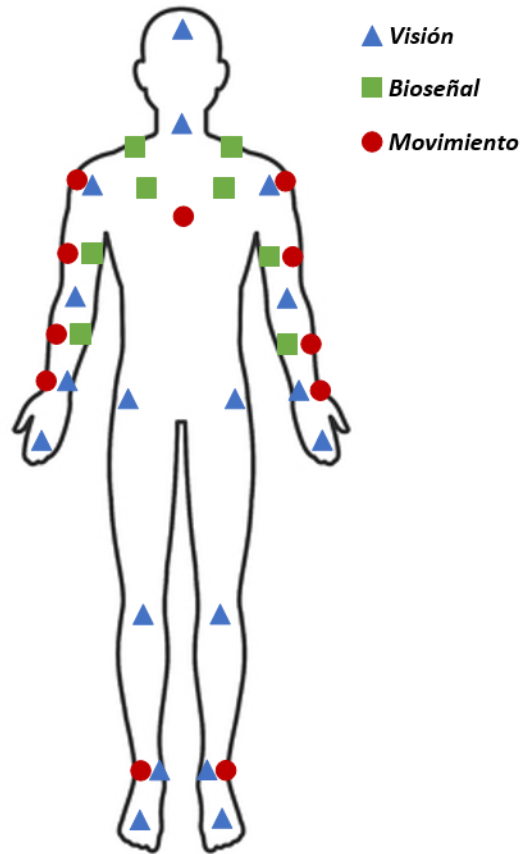


Figura 2.8: Puntos empleados para la adquisición de señales por cada modalidad en el plano coronal del cuerpo humano

Capítulo 3

Metodología

En este capítulo se describe la metodología llevada a cabo en el proyecto de investigación. Se describen los movimientos de hombro aplicado, los sensores implementados, su locación, cantidad de sensores, recomendaciones, los modos de adquisición de los movimientos propuestos, dominio de la extracción de características, entre otros.

3.1. Estrategia de trabajo

La estrategia de trabajo (metodología) que se siguió en esta investigación constó de cinco etapas: recolección de datos, segmentación de datos, extracción de características, clasificación de los movimientos de hombros y análisis estadístico de los modos de identificación.

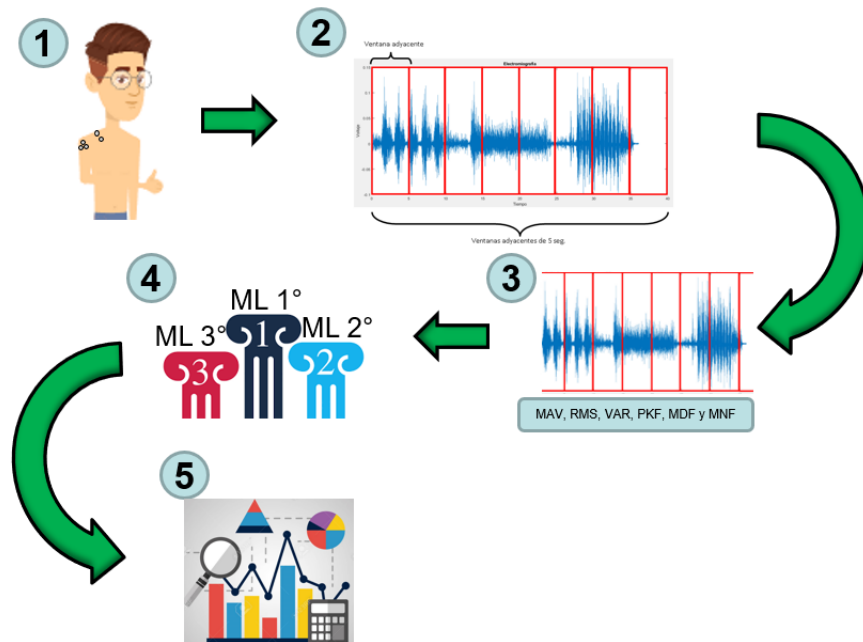


Figura 3.1: Metodología a seguir de la presente investigación

3.1.1. Recolección de datos

La correcta recolección de datos se estableció con base al teorema de muestreo de Nyquist [144, 145] y recomendaciones del SENIAM para la EMG, mientras que para la adquisición de la señal de aceleración se emplearon las recomendaciones del artículo de Srinivasan et al. [35].

Como primera etapa se estableció un protocolo de preparación para las personas participantes. Donde se plantea lo siguiente:

- Determinar el brazo dominante.
- Limpieza de la piel con alcohol en la zona de interés.
- Colocación de la postura inicial del paciente.
- Colocación y fijación de los electrodos.
- Colocación y fijación del acelerómetro.
- Evasión de la fatiga generada por los ejercicios.
- Ejecución correcta de las repeticiones, series y tempos de cada ejercicio propuesto.

La aplicación de los ejercicios serán ejecutados con el brazo dominante de la persona. Esto para generar una propiocepción¹ idónea y la búsqueda de una correcta ejecución.

La adquisición de las señales será en personas que se presenten sanas en el momento de la aplicación. Esto por motivos de *fase de prueba*, buscando cumplir con las etapas del ciclo de vida del software.

Una vez aplicado el protocolo anterior, se realizará una adquisición de prueba para observar y determinar si es correcta la adquisición final del sistema, como se plantea en esta investigación.

Como se mencionó con anterioridad, la electromiografía será aplicada con una frecuencia de muestreo de 1 kHz y para el acelerómetro la adquisición será a 1 KHz, pero con un downsampling a 30 Hz; a una resolución de 16 bits, CMRR² de 100 dB y una ganancia de 1000 para EMG y 1100 para el acelerómetro (valores por default en el sensor).

Después de la adquisición de las señales, estas serán filtradas, normalizadas y segmentadas.

3.1.2. Preprocesamiento de datos

Las señales electromiográficas y la señal de aceleración, antes de ser segmentadas, fueron filtradas y normalizadas. Los filtros consistieron en un filtro pasa banda de 10 Hz a 500 Hz de orden 6 para la EMG y un filtro pasa banda de 5 Hz a 20 Hz de orden 4, con esto garantizando que la señal se encuentra dentro de las frecuencias del ancho de banda que describe la literatura.

Después de ello, las señales se normalizaron con el fin de no tener diferencias en las magnitudes de los movimientos realizados con el hombro, ya que algunos movimientos requieren una mayor actividad muscular.

Por último, se segmentaron las señales adquiridas en ventanas adyacentes de 250 ms.

La implementación del código de preprocesamiento en Python se muestra en el apéndice A sección A.1

¹Hace referencia a la capacidad del cuerpo de detectar el movimiento y posición de las articulaciones [146]

²Rechazo al modo común: especificación de rendimiento de un amplificador operacional (opamp). Es una medida los voltajes que son comunes a ambas de sus entradas de corriente directa, por lo tanto, describe cuan limpiamente este amplifica las señales que aparecen como diferencias de tensión en sus entradas.

3.1.3. Extracción de características

A cada una de las ventanas obtenidas en la segmentación de las señales de EMG y aceleración, se le realizó una extracción de características, con la finalidad de obtener un valor numérico que describa la magnitud de valores numéricos abarcados en la ventana, según sea la característica aplicada.

Se aplicaron seis características de extracción: MAV, RMS, VAR, MDF, MNF y PKF.

3.1.4. Clasificación de los movimientos de hombros

Para la clasificación de movimientos del hombro, se ingresó un DataFrame con el valor numérico obtenido por cada una de las extracciones de características en cada una de las ventanas de segmentación para cada movimiento realizado en cada uno de los músculos muestreados. Esto dio como resultado un Dataframe de nueve columnas, donde cada columna corresponde a los canales obtenidos en la adquisición de señales (deltoides anterior, deltoides medio, deltoides posterior, trapecio descendente, pectoral mayor, planos de movimientos de aceleración X, Y y Z); en cada celda de este Dataframe se encuentra un array con siete valores numéricos correspondientes a cada una de las extracciones de características implementadas y el target asignado a cada ejercicio (ver figura 3.2). El acomodo de este Dataframe nos puede garantizar correr los algoritmos de manera unimodal y multimodal, solo delimitando las columnas del mismo data frame para el aprendizaje de los algoritmos.

La numeración de target fue asignada de la siguiente manera, 1 para abducción de hombro 3.3, 2 para flexión de hombro 3.4, 3 para aducción de hombro 3.5 y 4 para péndulo de Codman 3.6.

A cada uno de los clasificadores aplicados en esta investigación se implementó un 4K-Fold, con la finalidad de aprovechar al máximo la base de datos para el entrenamiento de los clasificadores y con los resultados de cada K-Fold poder ingresarlos en un análisis estadístico.

| Index | Descending_trapezoid | Posterior_deltoid | Anterior_deltoid | Pectoralis_mayor_(clavicular) | Middle_deltoid | AcelerometerX | AcelerometerY | AcelerometerZ |
|-------|---|--------------------|-------------------|-------------------------------|------------------|------------------|------------------|------------------|
| 0 | [0.0001944438329658533, 0.0002472360206352262, 2.918419018412214e-18, 80.0, 87.93168987252093, 75.0, 1.0] | 25... | [0.0001317117... | [7.1248313744... | [5.1085301703... | | | |
| 1 | [0.0002545987926700... | [2.171705780636... | [1.82222941836... | [1.8645947965843134e-05, ... | [2.8564390704... | [3.6368687952... | [5.8569003806... | [8.6940931583... |
| 2 | [0.0002020458034693... | [2.052824408717... | [1.61217447215... | [1.498510400311051e-05, 1... | [2.9289776975... | [3.2212287182... | [6.7098899142... | [9.3153552614... |
| 3 | [0.0002484559953053... | [2.416336110630... | [1.59720734668... | [1.45834051913026e-05, 1... | [3.1227164469... | [1.6217065718... | [2.1662690056... | [4.2817608663... |
| 4 | [0.0002432155182718... | [2.475108855589... | [1.56988947207... | [2.18760749837919e-05, 2... | [2.8102168591... | [2.3753526008... | [7.6732319137... | [9.3902115458... |
| 5 | [0.0002126944063822... | [2.236214251491... | [1.58266969781... | [1.5095998043488263e-05, ... | [3.2233643543... | [3.9102671760... | [6.5020388870... | [6.1460692572... |

Figura 3.2: Dataframe de la base de datos adquirida después de la extracción de características de las señales.

La implementación de los modos unimodales y multimodales en Python se muestra en el apéndice A sección A.2, A.3, A.4.

3.1.5. Análisis estadístico de los modos de identificación

El análisis estadístico se realizó en las métricas de exactitud. Donde el primer paso a corroborar es que estos valores siguieran una distribución normal, utilizando la prueba Shapiro-Wilk; todos los valores cumplieron con una distribución normal. Seguido de ello, con base al resultado anterior, se aplicaron pruebas t-test para determinar si existe diferencia significativa entre cada modo unimodal

con su respectivo modo multimodal. Esta etapa y valores de resultados son descritos en el capítulo 4, sección 4.3.3.

3.2. Movimientos de hombro

Los movimientos del hombro que serán realizados en esta investigación, son aplicados con un enfoque en rehabilitación. Utilizando el brazo dominante de la persona que realice el movimiento. Estos ejercicios son seleccionados como los 4 más implementados en la sección 2 (Antecedentes); además de apoyarse en los trabajos de rehabilitación descritos por Escamilla [147] y Burns [148]. Estos ejercicios también fueron supervisados bajo la supervisión de un apoyo médico para este estudio. En las figuras 3.3,3.4,3.5 y 3.6 se pueden observar los ejercicios propuestos.

1. De pie abducción de hombro a 180° .




Figura 3.3: Plano coronal del movimiento abducción de hombro a 180°

2. De pie flexión de hombro a 180° .




Figura 3.4: Plano coronal del movimiento flexión de hombro a 180°

3. De pie aducción horizontal de hombro a 90° .




Figura 3.5: Plano coronal del movimiento aducción de hombro a 90°

4. Péndulo de Codman con inclinación de cadera.



Figura 3.6: Plano sagital del movimiento péndulo de Codman

3.3. Sensores

Para la implementación de esta investigación, los sensores propuestos son cinco electrodos de superficie para electromiografía y un acelerómetro.

Además, se implementa el uso de la fusión de sensores de nivel medio, también llamada *Feature-Level*. El nivel de datafusion *feature level* que se aplicó es acorde a la clasificación de *Dasarathy*, donde “se emplean datos sin procesar de las fuentes, para extraer características que describen una entidad en el entorno [149]”.

En la figura 3.7, se describe el diagrama de flujo empleado para la fusión de datos en *feature-level* según la representación de la *clasificación de Dasarathy*.

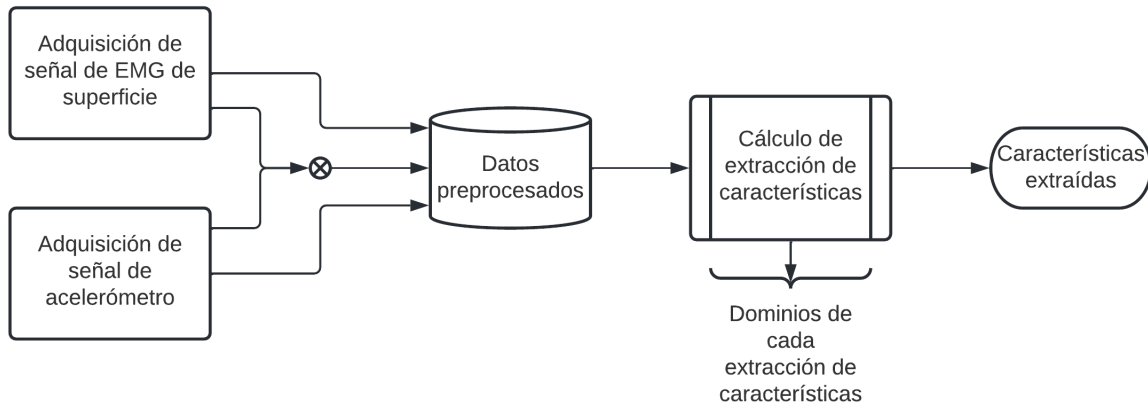


Figura 3.7: Diagrama de fusión de sensores aplicado en la investigación según la clasificación de Dasarathy

3.3.1. Acelerómetro

Para la aplicación del acelerómetro, según las investigaciones de Basel et al. [150] y las aplicaciones de Jayaraman et al. [35]; el mejor lugar para la adquisición de señales es la zona de la muñeca. Debido a que en ese punto se puede adquirir suficiente información de los movimientos angulares del brazo. Sin embargo, para fines futuros establecidos en el desarrollo de esta investigación, la adquisición de la señal de aceleración fue determinada en la parte media del hombro. Se estableció de esta manera, debido a futuras aplicaciones para personas que presenten extremidades superiores amputadas. Además, con base al artículo de Basel [150] y los resultados reportados por Amasay [151], en la zona media del húmero aún se contempla variación de movimientos angulares para la ejecución de movimientos del brazo.

Siendo esa zona la empleada para la extracción de los ejes de movimiento del hombro (eje transversal en el plano sagital, eje anteroposterior en el plano coronal y eje vertical en el plano transversal) con la variable de aceleración de cada uno de los movimientos en el cambio de dirección y de ángulo del brazo.

La frecuencia de muestreo fue a 1000 Hz, esto a razón de obtención datos del sensor. Sin embargo, se empleó un downsampling para utilizar esta señal a 30 Hz; siendo esta la frecuencia mayormente empleada en la aplicación de acelerómetros en el Capítulo 2.

3.3.2. Electrodo de superficie para electromiografía

Se colocaron cinco electrodos de superficie para EMG como se describe a continuación. Tres de ellos se dirigieron directamente al hombro. Adquiriendo las señales del deltoides anterior, medio y posterior (puntos 2, 5 y 3 respectivamente de la imagen 3.8). Los dos electrodos restantes se dirigieron a músculos que participan en los movimientos del hombro indirectamente. Como el trapecio descendente y pectoral mayor [152] en la zona del haz clavicular (puntos 1 y 4 respectivamente de la imagen 3.8).

Estos cinco electrodos se colocaron con base a las recomendaciones del SENIAM [153]. Por ejemplo,

la zona de colocación de electrodos, preparación de la piel, fijación de los electrodos, posición del paciente, etc.




Figura 3.8: Puntos adquiridos de los músculos mencionados por recomendaciones del SENIAM en la EMG de superficie (puntos rojos = ánodo de S-EMG, puntos negros = cátodo de S-EMG y punto azul = acelerómetro y S-EMG).

Para la determinación frecuencia de muestreo se sabe que el ancho de banda del músculo esquelético es de 10 Hz a 500 Hz [154]. Debido a ello, la señal debe tener una frecuencia de muestreo de mínimo 1 kHz para evitar el aliasing (es decir, la pérdida de información de la señal). Respetando de esta manera el teorema de muestreo de Nyquist. En este teorema se menciona que la frecuencia de muestreo debe ser al menos 2 veces mayor que la frecuencia más alta de la señal que se quiere reconstruir (muestrear) [144, 145].

A razón de esto y a recomendaciones vistas en [155], la frecuencia de muestreo se determinó a 1 kHz. Siendo esta frecuencia de adquisición idónea para la implementación de EMG de superficie, además de presentar resultados favorables para la extracción de características.

3.3.3. Sensores a usar

En la figura 3.9 se pueden observar los sensores implementados, los cuales fueron Biosignal plus para la EMG de superficie y acelerómetro.



Figura 3.9: Sensores implementados en el desarrollo de la investigación, de lazo izquierdo muscleband, del lado derecho Biosignalsplux EMG

Biosignalsplux EMG

Biosignalsplux Electromyography es una herramienta diseñada para monitorizar la actividad muscular incluso en las condiciones más extremas. Con una configuración bipolar (electrodos bipolares) para la adquisición de datos con bajo nivel de ruido. Proporciona la salida de datos en brutos a calidad médica, que permiten su uso de alta precisión para la investigación biomédica, biomecánica y deportiva avanzada.

Muscleband

Muscleband está diseñado para extraer información temporal y espectral de los datos de electromiografía adquiridos con el sensor de electromiografía de superficie (S-EMG) y el sensor de aceleración. Este puede ajustarse con precisión para la detección de activación muscular específica, definiendo los rangos de frecuencia de interés mediante los filtros de pasa bajas, pasa altas y pasa banda.

3.4. Segmentación

El proceso de segmentación, como su nombre lo indica, es el de segmentar (dividir) la señal. La segmentación puede ser definida como [156, 157]:

“ventanas adyacentes de igual longitud son definidas, ambas ventanas se deslizan sobre una secuencia de datos, donde en cada ventanas adquiridas se realizan operaciones matemáticas dependiendo el análisis futuro a ejecutar”.

Las señales de EMG y la señal de aceleración fueron segmentadas en ventanas adyacentes de 250 ms como lo describe Oskoei [158]. Debido a que este rango de segmentación presenta mejores resultados para la aplicación de características extraídas en las señales de la EMG. Y es el mismo tamaño de ventana presentado por el artículo [35] tomado como referencia de información para la adquisición de la señal de aceleración (ver figura 3.10).




Figura 3.10: Ejemplo de segmentación adyacente con ventanas de 5 segundos en señal electromiografía

3.5. Extracción de características

La extracción de características es entendida que parte de un conjunto inicial de datos adquiridos, con ellos se construyen valores que describen la interacción con el medio (es decir, valores numéricos que describen los cambios de posición, velocidad, giro, activación muscular, etc.). La idea del empleo de extracción de características es que sean informativos y no redundantes. Así facilitando el futuro aprendizaje, interpretación y generalización a nuestros modelos. Además “la extracción de características está relacionada con la reducción de la dimensionalidad” [159].

Las características que serán extraídas son:

• Dominio del tiempo:

- **Mean Absolute Value (MAV) [31]:**

Una estimación del valor absoluto medio de la señal.

$$MAV = \frac{1}{N} \sum_{k=1}^N |x_k| \quad (3.1)$$

Donde:

N es la longitud del segmento EMG,

x_k es la k -ésima muestra del segmento EMG.

- **Root Mean Square (RMS) [32]:**

Medida estadística de la magnitud de la señal.

$$RMS = \sqrt{\frac{1}{N} \sum_{k=1}^N x_k^2} \quad (3.2)$$

Donde:

N es la longitud del segmento EMG,
 x_k es la k -ésima muestra del segmento EMG.

- **Variance (VAR) [31]:**

Medida de dispersión que representa la variabilidad de la señal de respecto a su media.

$$VAR = \frac{1}{N} \sum_{k=1}^N (x_k - \bar{x})^2 \quad (3.3)$$

Donde:

N es la longitud del segmento EMG,
 x_k es la k -ésima muestra del segmento EMG,
 \bar{x} es la media del segmento de EMG.

- **Dominio de la frecuencia:**

- **Median Frequency (MDF) [160]:**

Punto en el espectro que divide la señal de frecuencias en dos regiones con igual amplitud.

$$MDF = \frac{1}{2} \sum_{j=1}^M P_j \quad (3.4)$$

Donde:

P_j es la potencia del EMG en la casilla de frecuencia j ,
 M es la longitud de la bandeja de frecuencias.

- **Mean Frequency (MNF) [160]:**

Es la suma del producto de la potencia de la EMG y la frecuencia dividida por la suma total de la intensidad del espectro.

$$MNF = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j} \quad (3.5)$$

Donde:

f_j es la frecuencia del espectro en la casilla de frecuencia j ,
 P_j es la potencia del EMG en la casilla de frecuencia j ,
 M es la longitud de la bandeja de frecuencias.

- **Peak Frequency (PKF) [160]:**

PKF es una frecuencia en la que se produce la máxima potencia en todo el espectro.

$$PKF = Max(P_j) \quad (3.6)$$

Donde:

P_j es el espectro de potencia del EMG en la casilla de frecuencia j .

La razón de implementación de las características en el dominio del tiempo es debido a que son las más aplicadas en el análisis de artículos presentados en la sección 2 (Antecedentes).

Por otro lado, se proponen la extracción de características en el dominio de la frecuencia. Como propuesta a los sistemas de ML con la información adquirida en este dominio.

3.6. Clasificadores

La clasificación en el ML es el proceso de predicción entre etiquetas (clases) y puntos de datos dados (datos de entrenamiento). Las clases se denominan como objetivos, por lo cual el modelado predictivo (el clasificador) busca aproximar, con una función (f) y las variables de entrada (X), a las variables de salida discretas (y) [161].

Para la clasificación de los movimientos se plantea la aplicación de los siguientes modelos. Implementando los tres modelos mayormente aplicados en la sección 2 (Antecedentes).

- **Decision Tree (DT) [162]:**

Es un modelo de predicción en donde se mapean los posibles resultados de una serie de decisiones relacionadas entre sí, según ciertas características o propiedades. Un árbol recibe un objeto o situación descrita por un conjunto de atributos y regresa una decisión, donde cada nodo interno corresponde a una prueba en el valor de uno de los atributos, las ramas están etiquetadas con los posibles valores de la prueba y cada hoja especifica el valor de la clase (ver figura 3.11).

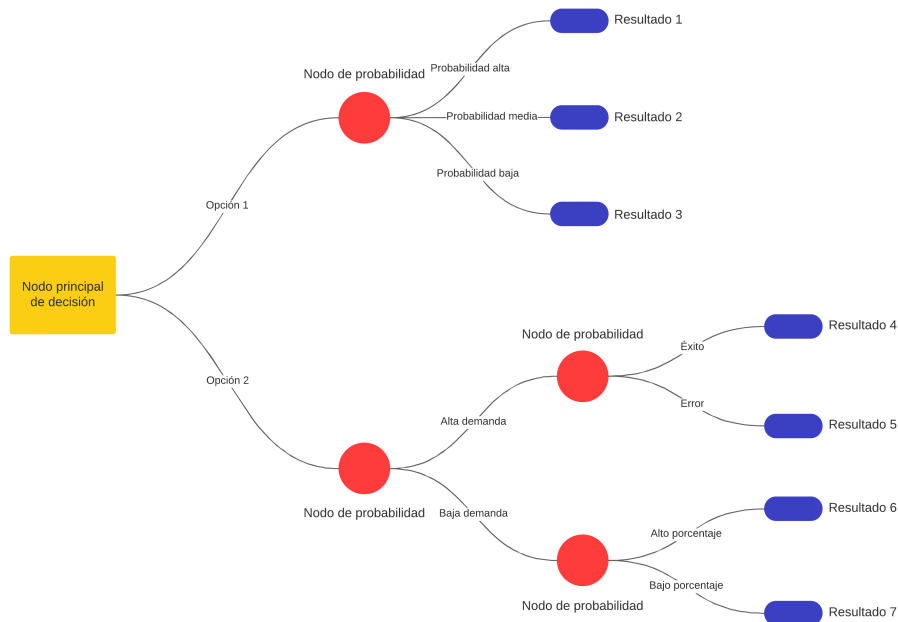


Figura 3.11: Decision Tree

- **Random Forest (RF) [163]:**

Es una combinación de *Decision tree* tal que cada árbol depende de los valores de un vector aleatorio probado independientemente y con la misma distribución para cada uno de estos. Construye una larga colección de árboles pequeños no correlacionados, que luego son promediados (ver figura 3.12).

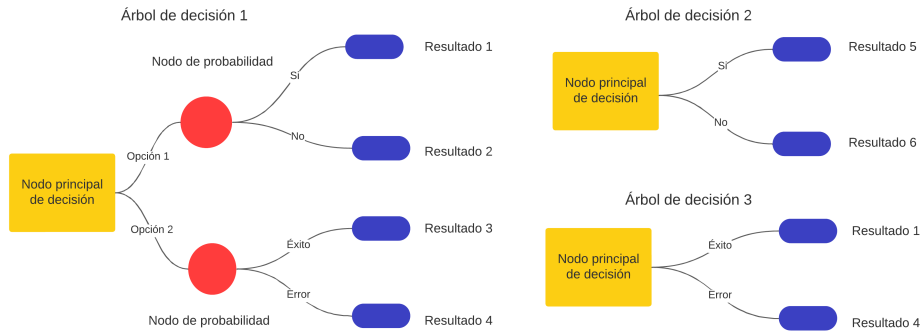


Figura 3.12: Random Forest

- **Support Vector Machine (SVM) [164]:**

Construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta que puede ser utilizado en problemas de clasificación o regresión. Una buena separación entre las clases con el hiperplano permitirá una clasificación correcta (ver figura 3.13). El *Kernel*, es la función matemática de transformación a elegir según la cantidad de clases que se presenten en nuestro dataset o la distribución que contengan; ésta puede ser lineal, polinómica, función de base radial (RBF) y sigmoide.

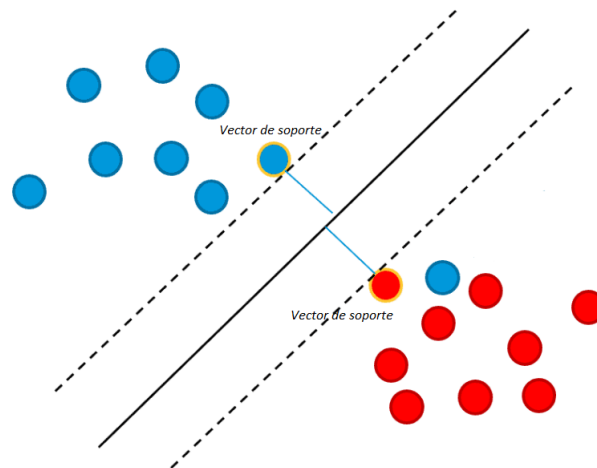


Figura 3.13: Support Vector Machine

3.6.1. Modos de clasificación

| Modo | Característica | Clasificador | | Modo | Característica | Clasificador | |
|---------------------------------------|----------------|--------------|-----------------------|---|----------------|--------------|-----------------------|
| <i>Modo 1</i> | MAV | DT | Dominio de tiempo | <i>Modo 1</i> | MAV | DT | Dominio de tiempo |
| <i>Modo 2</i> | MAV | RF | | <i>Modo 2</i> | MAV | RF | |
| <i>Modo 3</i> | MAV | SVM | | <i>Modo 3</i> | MAV | SVM | |
| <i>Modo 4</i> | RMS | DT | | <i>Modo 4</i> | RMS | DT | |
| <i>Modo 5</i> | RMS | RF | | <i>Modo 5</i> | RMS | RF | |
| <i>Modo 6</i> | RMS | SVM | | <i>Modo 6</i> | RMS | SVM | |
| <i>Modo 7</i> | VAR | DT | | <i>Modo 7</i> | VAR | DT | |
| <i>Modo 8</i> | VAR | RF | | <i>Modo 8</i> | VAR | RF | |
| <i>Modo 9</i> | VAR | SVM | | <i>Modo 9</i> | VAR | SVM | |
| <i>Modo 10</i> | MDF | DT | Dominio de frecuencia | <i>Modo 10</i> | MDF | DT | Dominio de frecuencia |
| <i>Modo 11</i> | MDF | RF | | <i>Modo 11</i> | MDF | RF | |
| <i>Modo 12</i> | MDF | SVM | | <i>Modo 12</i> | MDF | SVM | |
| <i>Modo 13</i> | MNF | DT | | <i>Modo 13</i> | MNF | DT | |
| <i>Modo 14</i> | MNF | RF | | <i>Modo 14</i> | MNF | RF | |
| <i>Modo 15</i> | MNF | SVM | | <i>Modo 15</i> | MNF | SVM | |
| <i>Modo 16</i> | PKF | DT | | <i>Modo 16</i> | PKF | DT | |
| <i>Modo 17</i> | PKF | RF | | <i>Modo 17</i> | PKF | RF | |
| <i>Modo 18</i> | PKF | SVM | | <i>Modo 18</i> | PKF | SVM | |
| Unimodales (Aceleración o EMG) | | | | Multimodales (Aceleración y EMG) | | | |

Tabla 3.1: Modos de adquisición para la clasificación de movimientos de hombros

En la tabla 3.1 se muestra la combinación de técnicas implementadas en esta investigación; las cuales se dividen en “Unimodales” y “Multimodales”. Las 18 modalidades *unimodales* son aquellas que representan un solo tipo de señal, ya sea aceleración o EMG; y estos 18 modos son el resultado de la combinación de cada uno de los clasificadores con cada una de las características extraídas a la señal. Las 18 modalidades *multimodales* es la unión de los dos tipos de señal adquiridos, aceleración y EMG. Estos 18 modos son el resultado de la combinación de cada uno de los clasificadores con cada una de las características extraídas a las señales fusionadas en feature level. A los canales se les extrajeron características en el dominio del tiempo y frecuencia. Esto se indica del *modo 1* al *modo 18* respectivamente (Ver tabla 3.1).

Capítulo 4

Modos unimodales y multimodales

En este capítulo, se describe el preprocesamiento a seguir para obtención de resultados en los modos unimodales y multimodales; así también, la elección de la señal con mejores resultados en su exactitud y muestra de resultados.

4.1. Procesamiento general

Adquiridas las señales de EMG y aceleración correspondientes a los movimientos del hombro descritos en la Sección 3.2. Las señales fueron preprocesadas para la eliminación de ruido que pudiera afectar el desempeño de los modelos de IA, asegurando así los rangos establecidos dentro del ancho de banda de cada señal y el valor eléctrico adecuado.

A las señales de EMG se les aplicó un filtro digital, pasa bandas de frecuencia de corte 10 Hz a 500 Hz de orden 6; esta frecuencia fue determinada con base a las recomendaciones del SENIAM y el ancho de banda del músculo esquelético.

Por otro lado, a las señales de aceleración se les aplicó un filtro digital, pasa bandas de frecuencia de corte 5 Hz a 30 Hz de orden 4.

Así mismo, ambas señales fueron normalizadas para evitar que valores elevados de contracción eléctrica para la EMG y variaciones de propiocepción en los movimientos de hombro afectaran el estudio.

Por último, las señales fueron segmentadas en ventanas de 250 ms, como se describe en la Sección 3.4. Ya que este rango de segmentación presenta mejores resultados para la aplicación de características extraídas de la EMG y movimiento; además, se presenta como un tamaño de ventana adecuado para futuras aplicaciones en clasificación de movimientos en tiempo real.

La implementación del código de preprocesamiento en Python se muestra en el apéndice A sección A.1

4.2. Aplicación a clasificadores

Después del procesamiento de las señales, el data set fue dividido en 4-KFold Cross Validation. Esto con motivos de mejorar la exactitud del sistema, y la aplicación en pruebas estadísticas con los resultados obtenidos; además de contar con una cantidad limitada de personas a las que se les adquirieron señales del hombro. Para el caso de esta investigación solo fue posible adquirir señales de una persona, ya que se presentaron dificultades en el sensor de adquisición de EMG y no fue posible adquirir más señales a tiempo. La participante realizó 1 serie de 10 repeticiones

por cada ejercicio a excepción del péndulo de Codman donde ahí solo se realizaron 4 repeticiones por cuestiones de dificultades en el desprendimiento de los sensores, donde cada ejercicio tiene un tempo de 1 segundo en la fase concéntrica y la excéntrica. A cada uno de los clasificadores se le obtuvieron las siguientes métricas:

- Matriz de confusión.

Nos permite visualizar el desempeño del modelo de ML, donde se adquieren valores Verdaderos Positivos (VP), Falsos Positivos (FP), Verdaderos Negativos (VN) y Falsos Negativos (FN). Positivo o Negativo se refiere a la predicción; si el modelo predice correctamente, entonces será positivo, y se predice incorrectamente será negativo. Verdadero o Falso, se refiere si la predicción es realmente correcta o no.

- Exactitud (en cada Kfold y su promedio).

Esta métrica es el número de predicciones correctas realizadas por el modelo de ML en el número total de registros.

$$Exactitud = \frac{VP + VN}{VP + FP + VN + FN} \quad (4.1)$$

- Sensibilidad (también llamado Recall).

Esta métrica nos indica un valor numérico en relación de los valores que fueron correctamente clasificados entre los que no fueron clasificados correctamente en su categoría.

$$Sensibilidad = \frac{VP}{VP + FN} \quad (4.2)$$

- Especificidad.

La especificidad es el valor de negativos verdaderos, se calcula como el número de predicciones negativas correctas dividido por el número total de negativos.

$$Especificidad = \frac{VN}{FP + VN} \quad (4.3)$$

- Precisión.

Con esta métrica podemos medir la calidad del modelo de ML. Es decir, la aproximación de los resultados entre sí.

$$Precision = \frac{VP}{VP + FP} \quad (4.4)$$

- F1-Score.

Esta métrica nos proporciona el promedio ponderado de la precisión y sensibilidad.

$$F1 - Score = 2 * \left(\frac{Precision * Sensibilidad}{Precision + Sensibilidad} \right) \quad (4.5)$$

- Tiempo de entrenamiento.

Esto con el fin de observar un resultado general de desempeño de los modelos de clasificación de ML y determinar una jerarquía de los tres algoritmos.

La implementación de los clasificadores en modos unimodales y multimodales en Python se muestra en el apéndice A sección A.2, A.3, A.4.

4.3. Resultados

Con base a los resultados obtenidos de manera unimodal y multimodal para las señales de EMG y aceleración. Se presenta la Tabla 4.1 con EMG, ya que esta señal fue la que presentó los resultados más sobresalientes en comparación con los observados con la señal de aceleración. Por otro lado, se presenta la Tabla 4.4, en la que se presentan la fusión de los sensores descritos con anterioridad.

4.3.1. Resultados en modos unimodales

Dentro de los resultados unimodales, la mejor modalidad que presentó la mayor exactitud fue Random Forest (RF) con la característica de Frecuencias Medias (MDF), obteniendo valores (ver imagen 4.1) con un valor de exactitud de 88.82 %, sensibilidad de 88.28 %, especificidad de 96.08 %, precisión de 88.88 % y F1-Score de 88.77 %. Por otro lado, la modalidad con peores resultados fue Decision Tree (DT) con la característica de Varianza (VAR), obteniendo valores (ver imagen 4.2) con un valor de exactitud de 33.93 %, sensibilidad de 25 %, especificidad de 75 %, precisión de 8.5 % y F1-Score de 17.19 %.

```
MÉTRICAS DE RANDOM FOREST
Exactitud: 88.82 %
Sensibilidad(recall): 88.28 %
Especificidad: 96.08 %
Precisión: 88.88 %
F1-Score: 88.77 %
Time: 0.28096
Confusion Matrix :
[[167  1  3  4]
 [  1 92 14  1]
 [ 14 11 133  0]
 [  3  4  0 53]]
```

Figura 4.1: Métricas de la mejor modalidad unimodal RF-MDF

```
MÉTRICAS DE DECISION TREE
Exactitud: 33.93 %
Sensibilidad(recall): 25.00 %
Especificidad: 75.00 %
Precisión: nan %
F1-Score: 17.19 %
Time: 0.00200
Confusion Matrix :
[[170  0  0  0]
 [105  0  0  0]
 [163  0  0  0]
 [ 63  0  0  0]]
```

Figura 4.2: Métricas de la peor modalidad unimodal DT-VAR

Por otro lado, en las tablas 4.1, 4.2 y 4.3 se puede observar el desempeño del mejor y peor resultado de los clasificadores implementados. Donde el mejor desempeño en métrica de exactitud se reporta con RF, ya que sus valores de exactitud se establecen en un rango del 86.23 % a 88.82 %; donde estos rangos de valores establecen un valor promedio de 87.98 %, con una σ (desviación estándar) de 0.8561 %. En contra parte, el peor desempeño en métrica de exactitud se reporta con DT, ya que sus valores de exactitud se establecen en un rango del 33.93 % a 83.03 %; donde estos rangos de valores establecen un valor promedio de 56.65 %, con una σ de 20.0183 %. La característica extraída que presentó menor σ fue MAV con 9.885 %; mientras que la característica que presentó mayor σ fue PKF con 22.1192 %.

| Característica\Clasificador | Decision Tree | Random Forest | Support Vector Machine |
|-----------------------------|---------------|---------------|------------------------|
| MAV | 83.03 % | 87.82 % | 64.87 % |
| RMS | 81.84 % | 88.62 % | 64.07 % |
| VAR | 33.93 % | 86.23 % | 66.27 % |
| MDF | 48.50 % | 88.82 % | 70.26 % |
| MNF | 58.08 % | 88.02 % | 66.07 % |
| PKF | 34.53 % | 88.42 % | 66.33 % |

Tabla 4.1: Resultados obtenidos de la métrica de **exactitud** con los modos unimodales (empleando solo EMG)

| Característica\Clasificador | Decision Tree | Random Forest | Support Vector Machine |
|-----------------------------|---------------|---------------|------------------------|
| MAV | 94.02 % | 95.75 % | 86.76 % |
| RMS | 93.64 % | 95.92 % | 86.64 % |
| VAR | 75 % | 95.23 % | 87.52 % |
| MDF | 82.04 % | 96.08 % | 88.56 % |
| MNF | 85.51 % | 95.87 % | 87.49 % |
| PKF | 77.37 % | 96.1 % | 88.86 % |

Tabla 4.2: Resultados obtenidos de la métrica de **especificidad** con los modos unimodales (empleando solo EMG)

| Característica\Clasificador | Decision Tree | Random Forest | Support Vector Machine |
|-----------------------------|---------------|---------------|------------------------|
| MAV | 83.37 % | 87.56 % | 61.41 % |
| RMS | 80.34 % | 88.23 % | 60.37 % |
| VAR | 25 % | 86.15 % | 62.92 % |
| MDF | 48.42 % | 88.28 % | 65.57 % |
| MNF | 57.11 % | 88.2 % | 62.28 % |
| PKF | 33.07 % | 88.69 % | 66.95 % |

Tabla 4.3: Resultados obtenidos de la métrica de **sensibilidad** con los modos unimodales (empleando solo EMG)

4.3.2. Resultados en modos multimodales

Para los resultados multimodales, la modalidad que presentó la mayor exactitud fue Random Forest (RF) con la característica de Picos de Frecuencia (PKF), obteniendo valores (ver imagen 4.3) de exactitud de 90.22 %, sensibilidad de 90.35 %, especificidad de 96.55 %, precisión de 89.95 % y F1-Score de 90.20 %. Por otro lado, la modalidad con peores resultados fue Decision Tree (DT) con la característica de Varianza (VAR), obteniendo valores (ver imagen 4.4) con un valor de exactitud de 36.93 %, sensibilidad de 25 %, especificidad de 75 %, precisión de 9.25 % y F1-Score de 19.92 %.

```

MÉTRICAS DE RANDOM FOREST
Exactitud: 90.22 %
Sensibilidad(recall): 90.35 %
Especificidad: 96.55 %
Precisión: 89.95 %
F1-Score: 90.20 %
Time: 0.28200
Confusion Matrix :
[[169  1  6  5]
 [  6 96  6  1]
 [ 12  7 135  1]
 [  1  2  1  52]]

```

Figura 4.3: Métricas de la mejor modalidad multimodal RF-PKF

```

MÉTRICAS DE DECISION TREE
Exactitud: 36.93 %
Sensibilidad(recall): 25.00 %
Especificidad: 75.00 %
Precisión: nan %
F1-Score: 19.92 %
Time: 0.00329
Confusion Matrix :
[[185  0  0  0]
 [106  0  0  0]
 [152  0  0  0]
 [ 58  0  0  0]]

```

Figura 4.4: Métricas de la peor modalidad multimodal DT-VAR

Por otro lado, en las tablas 4.4, 4.5 y 4.6 se puede observar el desempeño del mejor y peor resultado de los clasificadores implementados. Donde el mejor desempeño en métrica de exactitud se reporta como RF, ya que sus valores de exactitud se establecen en un rango del 87.82% a 90.22%; donde estos rangos de valores establecen un valor promedio de 89.32%, con una σ de 0.9%. En contra parte, el peor desempeño en métrica de exactitud se reporta como DT, ya que sus valores de exactitud se establecen en un rango del 36.93% a 77.64%; donde estos rangos de valores establecen un valor promedio de 55.92%, con una σ de 17.0881%.

La característica extraída que presentó menor σ fue MAV con 8.47%; mientras que la característica que presentó mayor σ fue PKF con 21.69%.

| Característica\Clasificador | Decision Tree | Random Forest | Support Vector Machine |
|-----------------------------|---------------|---------------|------------------------|
| MAV | 77.64 % | 87.82 % | 67.07 % |
| RMS | 78.44 % | 90.02 % | 67.27 % |
| VAR | 36.93 % | 89.42 % | 66.87 % |
| MDF | 48.30 % | 88.42 % | 65.67 % |
| MNF | 57.09 % | 90.02 % | 67.47 % |
| PKF | 37.13 % | 90.22 % | 65.87 % |

Tabla 4.4: Resultados obtenidos de la métrica **exactitud** con los modos multimodales (empleando aceleración y EMG)

| Característica\Clasificador | Decision Tree | Random Forest | Support Vector Machine |
|-----------------------------|---------------|---------------|------------------------|
| MAV | 92.24 % | 95.85 % | 87.32 % |
| RMS | 92.54 % | 96.55 % | 87.79 % |
| VAR | 75 % | 96.16 % | 87.56 % |
| MDF | 81.97 % | 95.93 % | 87.35 % |
| MNF | 85.13 % | 96.6 % | 87.64 % |
| PKF | 78.08 % | 96.55 % | 87.26 % |

Tabla 4.5: Resultados obtenidos de la métrica **especificidad** con los modos multimodales (empleando aceleración y EMG)

| Característica\Clasificador | Decision Tree | Random Forest | Support Vector Machine |
|-----------------------------|---------------|---------------|------------------------|
| MAV | 76.32 % | 88.93 % | 60.41 % |
| RMS | 77.21 % | 89.79 % | 62.1 % |
| VAR | 25 % | 88.4 % | 62.98 % |
| MDF | 47.08 % | 88.69 % | 63.47 % |
| MNF | 55.74 % | 90.33 % | 61.55 % |
| PKF | 33.86 % | 90.35 % | 62.92 % |

Tabla 4.6: Resultados obtenidos de la métrica **sensibilidad** con los modos multimodales (empleando aceleración y EMG)

4.3.3. Prueba estadística

Para la prueba estadística se implementó el software de R, con los resultados de exactitud en cada uno de los KFold obtenidos, buscando determinar si existe diferencia significativa en términos de exactitud entre los modos unimodales contra modos multimodales, donde se empleaba Random Forest como clasificador. Se analizaron estos modos debido a que fueron los modos que reportaron una mayor exactitud.

Primero, se verificó que cada valor de exactitud de la 4-tupla de KFold obtuviera una distribución normal con Shapiro-Wilk, utilizando un valor de $\alpha(\text{alpha}) = 0,05$, donde en las tablas 4.7 y 4.8 se pueden observar los resultados obtenidos por Random forest de manera unimodal y multimodal respectivamente. En esta prueba se identificó que tanto los modos unimodales y multimodales correspondían a una distribución normal ($p \geq 0,05$).

Después de ello se procedió a implementar Paired T-test, para determinar si un modo unimodal utilizando Random Forest tiene diferencia significativa en términos de exactitud con el modo multimodal correspondiente. Esta prueba estadística se realizó con un valor de $\alpha = 0,5$.

Como se puede apreciar de la tabla 4.9, existe diferencia significativa en términos de exactitud entre el modo unimodal RMS utilizando Random Forest y el modo multimodal RMS empleando Random Forest ($p = 0,0308$). Igualmente, las pruebas t revelaron diferencia significativa en términos de exactitud entre el modo unimodal con MNF empleando Random Forest y el modo multimodal con MNF utilizando Random Forest ($p = 0,0307$).

Con los resultados obtenidos se infiere que las modalidades con RMS y MNF presentan diferencia significativa en la aplicación unimodal o multimodal con Random Forest. Estas modalidades representan el segundo clasificador con mejor exactitud (90.02 %) de manera multimodal. Sin embargo, es de destacar que la modalidad multimodal de Random Forest con PKF obtuvo el mejor porcentaje de exactitud con un 90.22 %, pero sin generar una diferencia significativa entre las modalidades ($p = 0,2022$). En las tablas 4.1 y 4.4 se puede apreciar la diferencia de valores de exactitud, donde este porcentaje varía con la aplicación de fusión de sensores y extracción de características en los valores de estos sensores.

| Modos unimodales utilizando Random Forest como clasificador | Estadístico | Valor p |
|---|-------------|---------|
| Modo unimodal con MAV | 0.8478 | 0.3036 |
| Modo unimodal con RMS | 0.8319 | 0.2441 |
| Modo unimodal con VAR | 0.9814 | 0.9995 |
| Modo unimodal con MDF | 0.9477 | 0.9212 |
| Modo unimodal con MNF | 0.9941 | 0.9999 |
| Modo unimodal con PKF | 0.8230 | 0.2161 |

Tabla 4.7: Tabla Pruebas Shapiro-Wilk de las exactitudes de los modos unimodales utilizando Random Forest como clasificador con $\alpha = 0.05$

| Modos multimodales utilizando Random Forest como clasificador | Estadístico | Valor p |
|---|-------------|---------|
| Modo multimodal con MAV | 0.9434 | 0.8980 |
| Modo multimodal con RMS | 0.9765 | 0.9978 |
| Modo multimodal con VAR | 0.9267 | 0.7892 |
| Modo multimodal con MDF | 0.9945 | 0.9999 |
| Modo multimodal con MNF | 0.7232 | 0.05576 |
| Modo multimodal con PKF | 0.8914 | 0.5376 |

Tabla 4.8: Tabla Pruebas Shapiro-Wilk de las exactitudes de los modos multimodales utilizando Random Forest como clasificador $\alpha = 0.05$

| Comparación de exactitudes de los modos unimodales utilizando Random Forest y los modos multimodales utilizando Random Forest | Estadístico | Valor p |
|---|-------------|---------|
| Modo unimodal con MAV vs Modo multimodal con MAV | 0.9869 | 0.3965 |
| Modo unimodal con RMS vs Modo multimodal con RMS | 3.8272 | 0.0308 |
| Modo unimodal con RMS vs Modo multimodal con RMS | 2.1375 | 0.1221 |
| Modo unimodal con MDF vs Modo multimodal con MDF | 1.5303 | 0.2234 |
| Modo unimodal con MNF vs Modo multimodal con MNF | 3.8617 | 0.0307 |
| Modo unimodal con PKF vs Modo multimodal con PKF | 1.627 | 0.2022 |

Tabla 4.9: Tabla Pruebas t para determinar si existe diferencia significativa entre las exactitudes de los modos unimodales utilizando Random Forest y los modos multimodales utilizando Random Forest con $\alpha = 0.05$

Capítulo 5

Discusión

Con base a los resultados obtenidos por cada una de las modalidades de clasificación, se puede discutir lo siguiente.

La mejor exactitud, sensibilidad y especificidad fue establecida por Random forest, ya que presentó los mejores resultados con base a cada una de las características extraídas a cada movimiento aplicado. Determinando de esta manera que en cada evaluación, los valores *Verdaderos positivos* y *Verdaderos negativos* del algoritmo estaban siendo correctamente catalogados en un porcentaje elevado. La mejor combinación de clasificador y extracción de características fue obtenido por Random Forest con Median Frequency en la clasificación unimodal, y Random Forest con Peak of Frequency en la clasificación multimodal; obteniendo un 87,82 % y 90,22 % respectivamente (ver Tablas 4.1 y 4.4). Donde en las modalidades aplicadas en RF solo se obtuvo diferencia significativa en la aplicación con Root Mean Square y Mean Frequency.

Aunado a ello, los valores del clasificador en precisión, F1-Score y la matriz de confusión tuvieron un comportamiento relacionado con la exactitud, por lo cual si la exactitud desempeñaba un alto porcentaje, las demás métricas tendían a estar relacionadas con este desempeño, o viceversa.

Por otro lado, Decision Tree fue los algoritmos que se presenta con un tiempo menor de entrenamiento, con un promedio de 0.011 segundos, seguido de Support Vector machine con 0.486 segundos y Random forest con 0.158 segundos. La evaluación de tiempo se llevó a cabo en un procesador Intel i5-11400H y 8 Gb de Ram.

Con base a los resultados obtenidos y tomando en cuenta que el sistema de clasificación de movimientos es en tiempo diferido, se determina que Random Forest presenta una estabilidad mayor en comparación de las métricas de los otros modelos de ML, además de presentar los mejores resultados, ya sea de manera unimodal o multimodal.

Las limitaciones de esta investigación se encuentran en la cantidad de personas a las que se les aplicó el estudio, ya que por problemas del sensor de EMG, no se pudieron adquirir más señales. Esta limitante puede generar variabilidad en los resultados de exactitud cuando se aplique a nuevos usuarios. De la misma forma, se encuentra como limitación el tipo de clasificación en tiempo diferido, lo cual no proporciona una retroalimentación al usuario en cuanto a la ejecución adecuada de los ejercicios.

Por otro lado, la evaluación de la hipótesis en la identificación para los movimientos de hombro basados en fusión de sensores obtuvo un porcentaje de exactitud mayor y con diferencia significativa en comparación a los modos de identificación para los movimientos de hombro unimodales. Garantizando que con la fusión de sensores y la extracción de característica correspondiente se

presentan porcentajes de exactitud mayores.

Una de las mejoras a realizar a este sistema es la aplicación de más ejercicios para clasificación de movimientos de rehabilitación del hombro, así como la implementación de clasificación de los movimientos en modo online con una retroalimentación al usuario para la mejora del movimiento y su corrección.

Con respecto al análisis de resultados, es notable que, con base a los artículos presentados en el capítulo 2 en la tabla 2.7 y la tabla 4.4 el valor de exactitud tiende a estar dentro del rango de clasificación de bioseñales, estando por encima de [32], el experimento 2 de [141] y [29]; de la misma forma, se encuentra dentro de la cantidad de número de movimientos realizados por el hombro. Sin embargo, es notable la diferencia de cantidad de canales aplicados, siendo menor a [139], [141] y [142]. Además de contar con una aportación en la clasificación de movimientos de rehabilitación del hombro empleando fusión de sensores.

Capítulo 6

Conclusiones

Con base a lo anterior, se establece que la fusión de sensores electromiográficos y aceleración con la extracción de características de Peak of Frequency y el clasificador Random Forest, obtuvo una mayor exactitud en las pruebas realizadas en esta investigación, con un 90.22 % de exactitud, 96.55 % de especificidad y un 90.35 % de sensibilidad. Sin embargo, la fusión de sensores electromiográficos y aceleración con la extracción de características de Root Mean Square o Mean Frequency con el clasificador Random Forest tienen una diferencia significativa respecto a sus contrapartes unimodales para la clasificación de movimientos del hombro empleando rehabilitación. Tomando en cuenta esta investigación como trabajo futuro, una postura de mejora se encuentra en robustecer el sistema y buscar aumentar la exactitud con la adquisición de nuevos usuarios, la aplicación de más movimientos de rehabilitación del hombro, la aplicación de más canales de adquisición de señales y la combinación de extracción de características. Además, la aplicación de este sistema puede ser orientado a sistemas con clasificación de movimientos en tiempo online, juegos serios e interfaces humano-máquina.

Apéndice A

Códigos en Phytón

A.1. Código de preprocesamiento de datos

```
1 # -*- coding: utf-8 -*-
2 """
3 Created on Tue Jan 11 14:45:35 2022
4
5 @author: josue
6 """
7 import numpy as np
8 import scipy as sp
9 import math
10 import statistics
11 from scipy import signal
12 from numpy import where
13 from scipy.integrate import cumtrapz
14 import os
15 import pandas as pd
16 from sklearn import preprocessing
17
18 # Sentence that load the data
19 def load(Ruta):
20     Df = []
21     i = y = 1
22     os.chdir(Ruta)
23     for txt in contenido:
24         if y > 10:
25             i += 1
26             y = 1
27         emg = pd.DataFrame(np.loadtxt(txt))
28         emg = emg.drop([0,1,6], axis=1) # Remove de columns that no have
information
29         exercise = [i]*len(emg)
30         emg = pd.concat([emg,pd.DataFrame(exercise)],axis=1)
31         emg.columns = ['EMG1', 'EMG2', 'EMG3', 'EMG4', 'EMG5',
32                       'AcelerometerX', 'AcelerometerY',
33                       'AcelerometerZ', 'Exercise'] # Assign the names of the
columns
34         # Filtering of the signals
35         emgFiltered1 = Filter_bandpass(10, 499, 6, Norm(emg['EMG1']))
36         emg['EMG1'] = emgFiltered1
```

```

37     emgFiltered2 = Filter_bandpass(10, 499, 6, Norm(emg['EMG2']))
38     emg['EMG2'] = emgFiltered2
39     emgFiltered3 = Filter_bandpass(10, 499, 6, Norm(emg['EMG3']))
40     emg['EMG3'] = emgFiltered3
41     emgFiltered4 = Filter_bandpass(10, 499, 6, Norm(emg['EMG4']))
42     emg['EMG4'] = emgFiltered4
43     emgFiltered5 = Filter_bandpass(10, 499, 6, Norm(emg['EMG5']))
44     emg['EMG5'] = emgFiltered5
45     aceFilteredX = Filter_bandpass(5, 20, 4, Norm(emg['AcelerometerX']))
46     emg['AcelerometerX'] = aceFilteredX
47     aceFilteredY = Filter_bandpass(5, 20, 4, Norm(emg['AcelerometerY']))
48     emg['AcelerometerY'] = aceFilteredY
49     aceFilteredZ = Filter_bandpass(5, 20, 4, Norm(emg['AcelerometerZ']))
50     emg['AcelerometerZ'] = aceFilteredZ
51
52     Df.append(emg) # Save the information in a one dataframe
53     y += 1
54
55     Df = pd.concat(Df)
56     Df = Df.reset_index()
57     Df = Df.drop(['index'], axis=1) # Drop the duplicate of index
58     return Df
59
60 ##### Filtering #####
61 def Filter_bandpass(cut_low, cut_high, order, emg):
62     high = cut_high/((Fs)/2)
63     low = cut_low/((Fs)/2)
64     b, a = sp.signal.butter(order, [low, high], btype='bandpass')
65     emgFilt = sp.signal.filtfilt(b, a, emg)
66     return emgFilt
67
68 ### Normalize ###
69 def Norm(arr):
70     normalized = preprocessing.normalize([arr])
71     return normalized[0]
72
73 ##### Segmentation #####
74 def Split(arr, size):
75     arrs = []
76     while len(arr) > size:
77         pice = arr[:size]
78         arrs.append(pice)
79         arr = arr[size:]
80     arrs.append(arr)
81     return arrs
82
83 ### Features #####
84 # Time
85 def MAV(x):
86     N = len(x)
87     out = sum(abs(x))/N;
88     return out
89
90 def RMS(x):
91     N = len(x)
92     out = math.sqrt(sum(x*x)/N);

```

```

93     return out
94
95 def VAR(x):
96     N = len(x)
97     x_x = np.multiply(x,statistics.mean(x))
98     out = sum(x_x*x_x)/N
99     return out
100
101 # Frequency
102 def MDF(PSD_var,frequency_var):
103     area_freq = cumtrapz(PSD_var, frequency_var, initial = 0)
104     total_power = area_freq[-1]
105     median_freq = frequency_var[where(area_freq >= (total_power/2))[0][0]]
106     return median_freq
107
108 def MNF(PSD_var,frequency_var):
109     numerador = 0
110     index = 0
111     total_pj = 0
112     for pj in PSD_var:
113         fj = frequency_var[index]
114         index += 1
115         parcial = fj*pj
116         numerador = numerador + parcial
117         total_pj += pj
118     meanFreqPSD = numerador / total_pj
119     return meanFreqPSD
120
121 def PKF(PSD_var,frequency_var):
122     peak = max(PSD_var)
123     peak_freq = frequency_var[where(peak == PSD_var)[0][0]]
124     return peak_freq
125
126 def freq(emg):
127     win = 2/10*Fs
128     freqsWin, psd_WelchWin = signal.welch(emg, Fs, nperseg = win)
129     return [psd_WelchWin,freqsWin]
130
131 def Separate(X):
132     Abduction = Flexion = Aduction = Codman = pd.DataFrame()
133     Abduction= Df.where(Df['Exercise'] == 1)
134     Abduction = Abduction.dropna()
135     Flexion = Df.where(Df['Exercise'] == 2)
136     Flexion = Flexion.dropna()
137     Aduction = Df.where(Df['Exercise'] == 3)
138     Aduction = Aduction.dropna()
139     Codman = Df.where(Df['Exercise'] == 4)
140     Codman = Codman.dropna()
141     return [Abduction, Flexion, Aduction, Codman]
142
143 def Obtain_Features(arr):
144     Values = []
145
146     # Features
147     Mean_AV = MAV(arr)
148     Root_MS = RMS(arr)

```

```

149     Var = VAR(arr)
150
151     val_freq = freq(arr)
152
153     Median_F = MDF(val_freq[0],val_freq[1])
154     Mean_F = MNF(val_freq[0],val_freq[1])
155     Peak_F = PKF(val_freq[0],val_freq[1])
156     Values = [Mean_AV,Root_MS,Var,Median_F,Mean_F,Peak_F]
157     return Values
158
159 def Column_Segment(x):
160     Column_Seg = []
161     All_datas = pd.DataFrame()
162     for exer in range(len(x)):
163         Alldata = []
164         Signal = x[exer]
165         for column in Signal:
166             # Segmentation of the signals
167             if column == 'Exercise':
168                 break ##transformar segmentacion a tamaño de arr
169             Arr_Segmentation = Split(x[exer][column],int(Segmentation))
170             for window in Arr_Segmentation:
171                 F_segment = Obtain_Features(window)
172                 y = Signal.iloc[0][8] # Target
173                 F_segment.append(y)
174                 Column_Seg.append(F_segment)
175             Alldata.append(Column_Seg)
176             Column_Seg = []
177         Alldata2 = pd.DataFrame(Alldata)
178         All_datas = pd.concat([All_datas,Alldata2.T])
179     return All_datas
180
181
182 # Link of the dataset
183 Ruta = 'C://Users/josue/OneDrive/Documentos/M. en I.A/Materias/Protocolo/EMG/
184         Tesis/Dataset/Todos'
185 contenido = os.listdir(Ruta)
186
187 # Variables
188 Fs = 1000 #2000
189 Segmentation = 250
190
191 # Load all the data and we realize a preprocessing
192 Df = load(Ruta)
193
194 # Filtering of the signals for the future segmentation
195 Exercises = Separate(Df) # = [Abduction, Flexion, Aduction, Codman]
196
197 # Segmentation for column in each dataframe
198 Df_All = Column_Segment(Exercises)
199
200 Df_All.columns = ['Descending_trapezoid', 'Posterior_deltoid',
201                  'Anterior_deltoid', 'Pectoralis_major_(clavicular)',
202                  'Middle_deltoid',
203                  'AcelerometerX', 'AcelerometerY', 'AcelerometerZ']

```

```

204 Df_All = Df_All.reset_index()
205 Df_All = Df_All.drop(['index'], axis=1) # Drop the duplicate of index
206
207 # Save the dataset for jump the time of preprocessing for the next
208 New_Rute = 'C://Users/josue/OneDrive/Documentos/M. en I.A/Materias/Protocolo/
           EMG/Tesis'
209 os.chdir(New_Rute)
210 Df_All.to_pickle("Dataset.pkl")
211
212 #Final = pd.read_pickle("Dataset.pkl")
213 ##### Df_All.loc[0][0] para acceder a las variables

```

Listing A.1: Código en python del preprocesamiento

A.2. Código de Decision Tree

```

1 # -*- coding: utf-8 -*-
2 """
3 Created on Thu Jan 13 12:47:33 2022
4
5 @author: josue
6 """
7 from sklearn.tree import DecisionTreeClassifier # Import Decision Tree
   Classifier
8 from sklearn import metrics #Import scikit-learn metrics module for accuracy
   calculation
9 import sklearn.model_selection as model_selection
10 import pandas as pd
11 import time
12 import numpy as np
13 #from sklearn.metrics import sensitive_score, specificity_score,
   confusion_matrix
14
15 def Selection(Df,mode):
16     All = []
17     for Row in range(len(Df)):
18         Vec = Df.iloc[Row]
19         Feat = []
20         for Val in range(len(Vec)):
21             Res = Vec[Val][mode] # Modify depend by feature that you want
22             Feat.append(Res)
23             Feat.append(Vec[Val][-1]) # Target
24             All.append(Feat)
25     return pd.DataFrame(All)
26
27 ##### Load Database
28 Df = pd.read_pickle("Dataset.pkl")
29
30 # processing the data for the modes in the thesis
31 boundary = 8
32 mode = 0 # [MAV,RMS,VAR,MDF,MNF,PKF]
33 Df = Df.iloc[:,range(boundary)]# For unimodal select correctly
34 Df_N = Selection(Df,mode)
35 Df_shuffled = Df_N.sample(frac=1).reset_index(drop=True)
36

```

```

37 # Separate the dataset
38 X = Df_shuffled.iloc[:,range(boundary)] # modify depends of the modes
39 y = Df_shuffled.iloc[:,boundary]
40
41 # Initialazing of Desicion tree
42 start = time.time()
43 X_train, X_test, y_train, y_test = model_selection.train_test_split(X, y,
44                                                                     train_size
45                                                                     =0.75,
46                                                                     test_size
47                                                                     =0.25)
48
49 # Create Decision Tree classifier object
50 clf = DecisionTreeClassifier(criterion='entropy', splitter='best',
51                             max_depth=None, min_samples_split=2,
52                             min_samples_leaf=1, min_weight_fraction_leaf=0.0,
53                             max_features=3, random_state=1,
54                             max_leaf_nodes=None, min_impurity_decrease=0.0,
55                             class_weight=None, ccp_alpha=0.0)
56
57 # Train Decision Tree Classifier
58 clf = clf.fit(X_train,y_train)
59
60 # Predict the response for test dataset
61 y_pred = clf.predict(X_test)
62 end = time.time()
63
64 ##### Precision del modelo #####
65 cnf_matrix = metrics.confusion_matrix(y_test,y_pred)
66 FP = cnf_matrix.sum(axis=0) - np.diag(cnf_matrix)
67 FN = cnf_matrix.sum(axis=1) - np.diag(cnf_matrix)
68 TP = np.diag(cnf_matrix)
69 TN = cnf_matrix.sum() - (FP + FN + TP)
70
71 FP = FP.astype(float)
72 FN = FN.astype(float)
73 TP = TP.astype(float)
74 TN = TN.astype(float)
75
76 print('METRICAS DE DECISION TREE')
77 print("Exactitud: ", "%.2f" % (metrics.accuracy_score(y_test, y_pred)*100), "%")
78 print('Sensibilidad(recall): ', "%.2f" % ((sum(TP/(TP+FN))/4)*100), "%")
79 print('Especificidad: ', "%.2f" % ((sum(TN/(TN+FP))/4)*100), "%")
80 print('Precision: ', "%.2f" % ((sum(TP/(TP+FP))/4)*100), "%")
81 print ("F1-Score: ", "%.2f" % (metrics.f1_score(y_test, y_pred, average='
82 weighted')*100), "%")
83
84 print('Time: ', "%.5f" % (end - start))
85 print('Confusion Matrix : \n', cnf_matrix)
86
87 target_names=['Ejercicio-1', 'Ejercicio-2', 'Ejercicio-3', 'Ejercicio-4']
88 report = metrics.classification_report(y_test, y_pred, target_names=target_names)
89 print('Report: \n', report)

```

Listing A.2: Código en python de Decision Tree

A.3. Código de Random Forest

```

1 # -*- coding: utf-8 -*-
2 """
3 Created on Thu Jan 13 12:48:07 2022
4
5 @author: josue
6 """
7
8 import numpy as np
9 import pandas as pd
10 from sklearn.ensemble import RandomForestClassifier
11 from sklearn import metrics
12 import sklearn.model_selection as model_selection
13 import time
14
15 def Selection(Df):
16     All = []
17     for Row in range(len(Df)):
18         Vec = Df.iloc[Row]
19         Feat = []
20         for Val in range(len(Vec)):
21             Res = Vec[Val][0] # Modify depend by feature that you want
22             Feat.append(Res)
23         Feat.append(Vec[Val][-1]) # Target
24         All.append(Feat)
25     return pd.DataFrame(All)
26
27 # Load Database
28 Df = pd.read_pickle("Dataset.pkl")
29
30 # processing the data for the modes in the thesis
31 boundary = 8
32 mode = 0 # [MAV,RMS,VAR,MDF,MNF,PKF]
33 Df = Df.iloc[:,range(boundary)]# For unimodal select correctly
34 Df_N = Selection(Df)
35 Df_shuffled = Df_N.sample(frac=1).reset_index(drop=True)
36
37 # Separate the dataset
38 X = Df_shuffled.iloc[:,range(boundary)]
39 y = Df_shuffled.iloc[:,boundary]
40
41 # Initialazing of Random Forest
42 start = time.time()
43 X_train, X_test, y_train, y_test = model_selection.train_test_split(X, y,
44                                                                     train_size
45                                                                     =0.75,
46                                                                     test_size
47                                                                     =0.25)
48
49 # Creacion del modelo
50 #
51 =====

```

```

51 clf = RandomForestClassifier(
52     n_estimators = 150,
53     criterion     = 'entropy',
54     max_depth     = None,
55     max_features  = 'log2',
56     oob_score     = False,
57     n_jobs        = -1,
58     random_state  = None
59 )
60
61 # Entrenamiento del modelo
62 #
63     =====
64
63 clf = clf.fit(X_train, y_train)
64 #Predict the response for test dataset
65 y_pred = clf.predict(X_test)
66 end = time.time()
67
68
69 ##### Precision del modelo #####
70 cnf_matrix = metrics.confusion_matrix(y_test, y_pred)
71 FP = cnf_matrix.sum(axis=0) - np.diag(cnf_matrix)
72 FN = cnf_matrix.sum(axis=1) - np.diag(cnf_matrix)
73 TP = np.diag(cnf_matrix)
74 TN = cnf_matrix.sum() - (FP + FN + TP)
75
76 FP = FP.astype(float)
77 FN = FN.astype(float)
78 TP = TP.astype(float)
79 TN = TN.astype(float)
80
81 print('METRICAS DE RANDOM FOREST')
82 print("Exactitud: ", "%.2f" % (metrics.accuracy_score(y_test, y_pred)*100), "%")
83 print('Sensibilidad(recall): ', "%.2f" % ((sum(TP/(TP+FN))/4)*100), "%")
84 print('Especificidad: ', "%.2f" % ((sum(TN/(TN+FP))/4)*100), "%")
85 print('Precision: ', "%.2f" % ((sum(TP/(TP+FP))/4)*100), "%")
86 print ("F1-Score: ", "%.2f" % (metrics.f1_score(y_test, y_pred, average='
      weighted')*100), "%")
87
88 print('Time: ', "%.5f" % (end - start))
89 print('Confusion Matrix : \n', cnf_matrix)
90
91 target_names=['Ejercicio-1', 'Ejercicio-2', 'Ejercicio-3', 'Ejercicio-4']
92 report = metrics.classification_report(y_test, y_pred, target_names=target_names)
93 print('Report: \n', report)

```

Listing A.3: Código en python de Random Forest

A.4. Código de Support Vector Machine

```

1 # -*- coding: utf-8 -*-
2 """
3 Created on Thu Jan 13 12:24:52 2022

```

```

4
5 @author: josue
6 """
7
8 ##### Importamos paqueterias #####
9
10 from sklearn import svm
11 import sklearn.model_selection as model_selection
12 from sklearn import metrics
13 import pandas as pd
14 import time
15 import numpy as np
16
17 def Selection(Df):
18     All = []
19     for Row in range(len(Df)):
20         Vec = Df.iloc[Row]
21         Feat = []
22         for Val in range(len(Vec)):
23             Res = Vec[Val][0] # Modify depend by feature that you want
24             Feat.append(Res)
25             Feat.append(Vec[Val][-1]) # Target
26         All.append(Feat)
27     return pd.DataFrame(All)
28
29
30 #iris = datasets.load_iris()
31 Df = pd.read_pickle("Dataset.pkl")
32 # processing the data for the modes in the thesis
33 boundary = 8
34 mode = 0 # [MAV,RMS,VAR,MDF,MNF,PKF]
35 Df = Df.iloc[:,range(boundary)]# For unimodal select correctly
36 Df_N = Selection(Df)
37 Df_shuffled = Df_N.sample(frac=1).reset_index(drop=True)
38
39 # Separate the dataset
40 X = Df_shuffled.iloc[:,range(boundary)]
41 y = Df_shuffled.iloc[:,boundary]
42
43 # Initialazing of SVM
44 start = time.time()
45 X_train, X_test, y_train, y_test = model_selection.train_test_split(X, y,
46                             train_size
47                             =0.75,
48                             test_size
49                             =0.25)
50
51                             #
52                             random_state=None) # semilla
53
54 clf = svm.SVC(decision_function_shape='ovo').fit(X_train, y_train)
55
56 ##### Eficiencia de los dos modelos #####
57
58 y_pred = clf.predict(X_test)
59 end = time.time()
60
61

```

```

57 ##### Precision del modelo #####
58 cnf_matrix = metrics.confusion_matrix(y_test,y_pred)
59 FP = cnf_matrix.sum(axis=0) - np.diag(cnf_matrix)
60 FN = cnf_matrix.sum(axis=1) - np.diag(cnf_matrix)
61 TP = np.diag(cnf_matrix)
62 TN = cnf_matrix.sum() - (FP + FN + TP)
63
64 FP = FP.astype(float)
65 FN = FN.astype(float)
66 TP = TP.astype(float)
67 TN = TN.astype(float)
68
69 print('METRICAS DE SUPPORT VECTOR MACHINE')
70 print("Exactitud: ", "%.2f" % (metrics.accuracy_score(y_test, y_pred)*100),"%")
71 print('Sensibilidad(recall): ', "%.2f" % ((sum(TP/(TP+FN))/4)*100),"%")
72 print('Especificidad: ', "%.2f" % ((sum(TN/(TN+FP))/4)*100),"%")
73 print('Precision: ', "%.2f" % ((sum(TP/(TP+FP))/4)*100),"%")
74 print ("F1-Score: ", "%.2f" % (metrics.f1_score(y_test, y_pred, average='
    weighted')*100),"%")
75
76 print('Time: ', "%.5f" % (end - start))
77 print('Confusion Matrix : \n', cnf_matrix)
78
79 target_names=['Ejercicio-1', 'Ejercicio-2', 'Ejercicio-3', 'Ejercicio-4']
80 report = metrics.classification_report(y_test, y_pred, target_names=target_names)
81 print('Report: \n', report)

```

Listing A.4: Código en python de Support Vector Machine

Bibliografía

- [1] F. Durán and L. Agudelo, *Rehabilitación en salud, 2.a edición*. Salud (Medellín, Colombia): Medicina, Editorial Universidad de Antioquia, 2008.
- [2] G. E. Gresham, D. Alexander, D. S. Bishop, C. Giuliani, G. Goldberg, A. Holland, M. Kelly-Hayes, R. T. Linn, E. J. Roth, W. B. Stason, *et al.*, “Rehabilitation,” *Stroke*, vol. 28, no. 7, pp. 1522–1526, 1997.
- [3] R. Cailliet, *Shoulder Pain*. Cailliet, Rene. Pain series, F. A. Davis Company, 1981.
- [4] N. S. Sanabria and A. M. O. Patiño, “Biomecánica del hombro y bases fisiológicas de los ejercicios de codman,” *Revista CES Medicina*, vol. 27, no. 2, pp. 205–217, 2013.
- [5] D. Champin Michelena, “Hombro doloroso en la consulta del internista,” *Revista de la Sociedad Peruana de Medicina Interna*, vol. 19, pp. 27–31, dic. 2019.
- [6] G. J. van der Heijden, “Shoulder disorders: a state-of-the-art review,” *Best Practice & Research Clinical Rheumatology*, vol. 13, no. 2, pp. 287–309, 1999.
- [7] L. S. Oh, B. R. Wolf, M. P. Hall, B. A. Levy, and R. G. Marx, “Indications for rotator cuff repair: A systematic review,” *Clinical Orthopaedics and Related Research®*, vol. 455, 2007.
- [8] G. C. Fonseca-Portilla, S. Vargas-Naranjo, C. E. Alpízar-Chacón, and A. Y. Moreno-Cordero, “Síndrome de hombro doloroso,” *Acta Médica Costarricense*, vol. 52, pp. 227 – 231, 12 2010.
- [9] F. A. Freddie, “Clinical guideline on shoulder pain american academy of orthopaedic surgeons,” *Support document. Rosemont (IL): American Academy of Orthopaedic Surgeons*, 2001.
- [10] F. Cruz, A. Almazán, F. Pérez, L. Sierra, E. Villalobos, H. G. Ugalde, and C. Ibarra, “Lesiones en el hombro ocurridas durante la práctica de deportes,” *Orthotips AMOT*, vol. 5, no. 1, pp. 65–78, 2009.
- [11] K. Kiguchi and Y. Hayashi, “An emg-based control for an upper-limb power-assist exoskeleton robot,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 42, pp. 1064–1071, 2012.
- [12] S. Bitzer and P. van der Smagt, “Learning emg control of a robotic hand: towards active prostheses,” in *Proceedings 2006 IEEE International Conference on Robotics and Automation, 2006. ICRA 2006.*, pp. 2819–2823, 2006.

- [13] C. Castellini, A. E. Fiorilla, and G. Sandini, “Multi-subject/daily-life activity emg-based control of mechanical hands,” *Journal of NeuroEngineering and Rehabilitation*, vol. 6, p. 41, Nov 2009.
- [14] T. S. Saponas, D. S. Tan, D. Morris, and R. Balakrishnan, “Demonstrating the feasibility of using forearm electromyography for muscle-computer interfaces,” *Association for Computing Machinery*, p. 515–524, 2008.
- [15] P. K. Artemiadis and K. J. Kyriakopoulos, “A switching regime model for the emg-based control of a robot arm,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, vol. 41, no. 1, pp. 53–63, 2011.
- [16] M. S. Erkilinc and F. Sahin, “Camera control with emg signals using principal component analysis and support vector machines,” in *2011 IEEE International Systems Conference*, pp. 417–421, 2011.
- [17] G. Rom, G. Jochtl, and G. Pfurtscheller, “A transputer-based emg-system with integrated knowledge-base for diagnostic-support,” in *Proceedings Fifth Annual IEEE Symposium on Computer-Based Medical Systems*, pp. 353–359, 1992.
- [18] O. A. Alim, M. Moselhy, and F. Mroueh, “Emg signal processing and diagnostic of muscle diseases,” in *2012 2nd International Conference on Advances in Computational Tools for Engineering Applications (ACTEA)*, pp. 1–6, 2012.
- [19] A. Singh, M. K. Dutta, and C. M. Travieso, “Analysis of emg signals for automated diagnosis of myopathy,” in *2017 4th IEEE Uttar Pradesh Section International Conference on Electrical, Computer and Electronics (UPCON)*, pp. 628–631, 2017.
- [20] K. Rhee and H.-C. Shin, “Finger motion recognition robust to diverse arm postures using emg and accelerometer,” in *2018 International Conference on Information Networking (ICOIN)*, pp. 834–836, 2018.
- [21] R. Shioji, S.-I. Ito, M. Ito, and M. Fukumi, “Personal authentication and hand motion recognition based on wrist emg analysis by a convolutional neural network,” in *2018 Joint 10th International Conference on Soft Computing and Intelligent Systems (SCIS) and 19th International Symposium on Advanced Intelligent Systems (ISIS)*, pp. 1172–1176, 2018.
- [22] K. Nagata, K. Ando, K. Magatani, and M. Yamada, “Development of the hand motion recognition system based on surface emg using suitable measurement channels for pattern recognition,” in *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 5214–5217, 2007.
- [23] X. Shusong and Z. Xia, “Emg-driven computer game for post-stroke rehabilitation,” in *2010 IEEE Conference on Robotics, Automation and Mechatronics*, pp. 32–36, 2010.
- [24] R. U. Khan, M. W. Tahir, and M. I. Tiwana, “Rehabilitation process of upper limbs muscles through emg based video game,” in *2019 International Conference on Robotics and Automation in Industry (ICRAI)*, pp. 1–5, 2019.
- [25] J.-Y. Seo, Y.-H. Noh, and D.-U. Jeong, “Implementation of emg data-based rehabilitation assistance system,” in *2018 International Conference on Electronics, Information, and Communication (ICEIC)*, pp. 1–2, 2018.

- [26] X.-D. Zhang, *Machine Learning*, pp. 223–440. Singapore: Springer Singapore, 2020.
- [27] T. Mitchell, “Machine learning,” 1997.
- [28] L. A. Klein, *Sensor and data fusion: a tool for information assessment and decision making*, vol. 138. SPIE press, 2004.
- [29] C. W. Antuvan, F. Bisio, E. Cambria, and L. Masia, “Discrete classification of upper limb motions using myoelectric interface,” in *2015 IEEE International Conference on Rehabilitation Robotics (ICORR)*, pp. 451–456, 2015.
- [30] P. Chakraborty, B. Neogi, and A. Das, “Knowledge based database of arm-muscle and activity characterization during load pull exercise using diagnostic electromyography (d-emg) signal,” *Cogent Engineering*, vol. 7, no. 1, p. 1849942, 2020.
- [31] C. W. Antuvan, F. Bisio, E. Cambria, and L. Masia, “Muscle synergies for reliable classification of arm motions using myoelectric interface,” in *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 1136–1139, 2015.
- [32] Y. Zhou, C. Chen, M. Cheng, S. Franovic, S. Muh, and S. Lemos, “Real-time surface emg pattern recognition for shoulder motions based on support vector machine,” in *Proceedings of the 2020 9th International Conference on Computing and Pattern Recognition, ICCPR 2020*, (New York, NY, USA), p. 63–66, Association for Computing Machinery, 2020.
- [33] I. Seáñez and F. A. Mussa-Ivaldi, “A body-machine interface for the control of a 2d cursor,” in *2013 IEEE 13th International Conference on Rehabilitation Robotics (ICORR)*, pp. 1–6, 2013.
- [34] H. F. Nweke, Y. W. Teh, G. Mujtaba, U. R. Alo, and M. A. Al-garadi, “Multi-sensor fusion based on multiple classifier systems for human activity identification,” *Human-centric Computing and Information Sciences*, vol. 9, p. 34, Sep 2019.
- [35] S. Jayaraman, J. Joshy, P. K. Priya, M. Poduval, and A. B. Thangavel, “Smartwatch as a kinesthetic system for shoulder function assessment,” in *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 1–6, 2020.
- [36] D. De Santis, P. Dzialecka, and F. A. Mussa-Ivaldi, “Unsupervised coadaptation of an assistive interface to facilitate sensorimotor learning of redundant control,” in *2018 7th IEEE International Conference on Biomedical Robotics and Biomechanics (Biorob)*, pp. 801–806, 2018.
- [37] I. Ar and Y. S. Akgul, “A computerized recognition system for the home-based physiotherapy exercises using an rgbd camera,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 22, no. 6, pp. 1160–1171, 2014.
- [38] O. Brunner, A. Mertens, V. Nitsch, and C. Brandl, “Accuracy of a markerless motion capture system for postural ergonomic risk assessment in occupational practice,” *International Journal of Occupational Safety and Ergonomics*, vol. 0, no. 0, pp. 1–9, 2021. PMID: 34252007.

- [39] M. Yahya, J. Shah, K. Kadir, A. Warsi, S. Khan, and H. Nasir, “Accurate shoulder joint angle estimation using single rgb camera for rehabilitation,” in *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, pp. 1–6, 2019.
- [40] B. Pogorelc, Z. Bosnić, and M. Gams, “Automatic recognition of gait-related health problems in the elderly using machine learning,” *Multimedia Tools and Applications*, vol. 58, pp. 333–354, May 2012.
- [41] S. Gattupalli, D. Ebert, M. Papakostas, F. Makedon, and V. Athitsos, “Cognilearn: A deep learning-based interface for cognitive behavior assessment,” in *Proceedings of the 22nd International Conference on Intelligent User Interfaces, IUI '17*, (New York, NY, USA), p. 577–587, Association for Computing Machinery, 2017.
- [42] I. S. A. Darmana and E. Rakun, “Generating of sign system for bahasa indonesia (sibi) root word gestures using deep temporal sigmoid belief network,” in *Proceedings of the 2019 5th International Conference on Computing and Artificial Intelligence, ICCAI '19*, (New York, NY, USA), p. 221–225, Association for Computing Machinery, 2019.
- [43] T. Hu, J. Kuehn, and S. Haddadin, “Identification of human shoulder-arm kinematic and muscular synergies during daily-life manipulation tasks,” in *2018 7th IEEE International Conference on Biomedical Robotics and Biomechatronics (Biorob)*, pp. 1011–1018, 2018.
- [44] J. A. Martinez-garcia, A. M. Gonzalez-zapata, E. J. Rechy-ramirez, and E. Tlelo-cuautle, “On the prediction of chaotic time series using neural networks,” vol. 4, (Sakarya University of Applied Sciences, Faculty of Technology Department of Electrical and Electronics Engineering Serdivan, 54050, Sakarya, TURKEY.), pp. 94 – 103, Akif AKGÜL, 2022.
- [45] D. Moher, A. Liberati, J. Tetzlaff, D. G. Altman, and T. P. Group, “Preferred reporting items for systematic reviews and meta-analyses: The prisma statement,” *PLOS Medicine*, vol. 6, pp. 1–6, 07 2009.
- [46] B. Sayis, R. Ramirez, and N. Pares, “Mixed reality or lego game play? fostering social interaction in children with autism,” *Virtual Reality*, Sep 2021.
- [47] T. Fujinami and S. Hidaka, “A representation of rhythmic motions,” *New Generation Computing*, vol. 37, pp. 185–201, Apr 2019.
- [48] J. P. Hanna, S. Desai, H. Karnan, G. Warnell, and P. Stone, “Grounded action transformation for sim-to-real reinforcement learning,” *Machine Learning*, vol. 110, pp. 2469–2499, Sep 2021.
- [49] C. Georgakis, Y. Panagakis, and M. Pantic, “Dynamic behavior analysis via structured rank minimization,” *International Journal of Computer Vision*, vol. 126, pp. 333–357, Apr 2018.
- [50] O. Alonso, J. Kamps, and J. Karlgren, “Report on the seventh workshop on exploiting semantic annotations in information retrieval (esair'14),” *SIGIR Forum*, vol. 49, p. 27–34, June 2015.
- [51] F. Hong, M. Wei, S. You, Y. Feng, and Z. Guo, “Waving authentication: Your smartphone authenticate you on motion gesture,” in *Proceedings of the 33rd Annual ACM Conference Extended Abstracts on Human Factors in Computing Systems, CHI EA '15*, (New York, NY, USA), p. 263–266, Association for Computing Machinery, 2015.

- [52] Y. Ding, K. Prepin, J. Huang, C. Pelachaud, and T. Artières, “Laughter animation synthesis,” in *Proceedings of the 2014 International Conference on Autonomous Agents and Multi-Agent Systems*, AAMAS ’14, (Richland, SC), p. 773–780, International Foundation for Autonomous Agents and Multiagent Systems, 2014.
- [53] T. Nohara and R. Uda, “Personal identification by flick input using self-organizing maps with acceleration sensor and gyroscope,” in *Proceedings of the 10th International Conference on Ubiquitous Information Management and Communication*, IMCOM ’16, (New York, NY, USA), Association for Computing Machinery, 2016.
- [54] J. D. Hincapié-Ramos, K. Ozacar, P. P. Irani, and Y. Kitamura, “Gyrowand: Imu-based raycasting for augmented reality head-mounted displays,” in *Proceedings of the 3rd ACM Symposium on Spatial User Interaction*, SUI ’15, (New York, NY, USA), p. 89–98, Association for Computing Machinery, 2015.
- [55] J. A. DeFalco, J. P. Rowe, L. Paquette, V. Georgoulas-Sherry, K. Brawner, B. W. Mott, R. S. Baker, and J. C. Lester, “Detecting and addressing frustration in a serious game for military training,” *International Journal of Artificial Intelligence in Education*, vol. 28, pp. 152–193, Jun 2018.
- [56] G. Boddington, “The internet of bodies—alive, connected and collective: the virtual physical future of our bodies and our senses,” *AI & SOCIETY*, Feb 2021.
- [57] C. Yolgormez and J. Thibodeau, “Socially robotic: making useless machines,” *AI & SOCIETY*, Aug 2021.
- [58] E. M. G. Younis, E. Kanjo, and A. Chamberlain, “Designing and evaluating mobile self-reporting techniques: crowdsourcing for citizen science,” *Personal and Ubiquitous Computing*, vol. 23, pp. 329–338, Apr 2019.
- [59] H. Song, J. Huang, Y.-P. Cao, and T.-J. Mu, “Hdr-net-fusion: Real-time 3d dynamic scene reconstruction with a hierarchical deep reinforcement network,” *Computational Visual Media*, vol. 7, pp. 419–435, Dec 2021.
- [60] R. de Bem, A. Ghosh, T. Ajanthan, O. Miksik, A. Boukhayma, N. Siddharth, and P. Torr, “Dgpose: Deep generative models for human body analysis,” *International Journal of Computer Vision*, vol. 128, pp. 1537–1563, May 2020.
- [61] T. Jiang, X. Yang, J. Zhang, F. Tian, S. Liu, N. Xiang, and K. Qian, “Huber- l_1 -based non-isometric surface registration,” *The Visual Computer*, vol. 35, pp. 935–948, Jun 2019.
- [62] K. Takahashi, T. Ogata, J. Nakanishi, G. Cheng, and S. Sugano, “Dynamic motion learning for multi-dof flexible-joint robots using active–passive motor babbling through deep learning,” *Advanced Robotics*, vol. 31, no. 18, pp. 1002–1015, 2017.
- [63] R. D. Brown, “Property ownership and the legal personhood of artificial intelligence,” *Information & Communications Technology Law*, vol. 30, no. 2, pp. 208–234, 2021.
- [64] B. Prainsack, “Oil crisis: the political economy of digital data. conclusion of the special issue,” *Policy Studies*, vol. 41, no. 5, pp. 563–566, 2020.

- [65] A. L. N. Zhang, B. P. Wu, C. X. H. Jiang, D. C. Z. Xuan, E. Y. H. Ma, and F. Y. A. Zhang, “Development and validation of a visual image analysis for monitoring the body size of sheep,” *Journal of Applied Animal Research*, vol. 46, no. 1, pp. 1004–1015, 2018.
- [66] M. Anandarajan and C. Hill, “Data quilting: Art and science of analyzing disparate data,” *Cogent Business & Management*, vol. 6, no. 1, p. 1629095, 2019.
- [67] A. Rossman and J. J. Cochran, “Interview with james j. cochran,” *Journal of Statistics Education*, vol. 26, no. 2, pp. 149–159, 2018.
- [68] E. Keymolen and S. V. der Hof, “Can i still trust you, my dear doll? a philosophical and legal exploration of smart toys and trust,” *Journal of Cyber Policy*, vol. 4, no. 2, pp. 143–159, 2019.
- [69] J. Østbø, “Hybrid surveillance capitalism: Sber’s model for russia’s modernization,” *Post-Soviet Affairs*, vol. 37, no. 5, pp. 435–452, 2021.
- [70] G. Zdolsek, Y. Chen, H.-P. Bögl, C. Wang, M. Woisetschläger, and J. Schilcher, “Deep neural networks with promising diagnostic accuracy for the classification of atypical femoral fractures,” *Acta Orthopaedica*, vol. 92, no. 4, pp. 394–400, 2021. PMID: 33627045.
- [71] C. Göbel, “The political logic of protest repression in china,” *Journal of Contemporary China*, vol. 30, no. 128, pp. 169–185, 2021.
- [72] B. Yuan, “Toward holistic medicine and holistic biology: life sciences after precision medicine and systems biology,” *Frontiers in Life Science*, vol. 12, no. 1, pp. 14–26, 2019.
- [73] S. Shibata, “Digitalization or flexibilization? the changing role of technology in the political economy of japan,” *Review of International Political Economy*, vol. 0, no. 0, pp. 1–45, 2021.
- [74] K. Wu, C. Liu, and R. A. Calvo, “Automatic nonverbal mimicry detection and analysis in medical video consultations,” *International Journal of Human–Computer Interaction*, vol. 36, no. 14, pp. 1379–1392, 2020.
- [75] D. Welch and D. Southerton, “After paris: transitions for sustainable consumption,” *Sustainability: Science, Practice and Policy*, vol. 15, no. 1, pp. 31–44, 2019.
- [76] S. N. Sadeek and S. M. Rifaat, “Development of district-wise crash prediction model in bangladesh,” *Cogent Engineering*, vol. 7, no. 1, p. 1762525, 2020.
- [77] M. Ghasemi, M. Varshosaz, S. Pirasteh, and G. Shamsipour, “Optimizing sector ring histogram of oriented gradients for human injured detection from drone images,” *Geomatics, Natural Hazards and Risk*, vol. 12, no. 1, pp. 581–604, 2021.
- [78] V. Mäkinen, J. Oksanen, and T. Sarjakoski, “Automatic determination of stream networks from dems by using road network data to locate culverts,” *International Journal of Geographical Information Science*, vol. 33, no. 2, pp. 291–313, 2019.
- [79] R. Mantovani and A. Cecchinato, “Aspa 24th congress book of abstract,” *Italian Journal of Animal Science*, vol. 20, no. sup1, pp. 1–236, 2021.

- [80] L. D. Urquhart and P. J. Craigon, “The moral-it deck: a tool for ethics by design,” *Journal of Responsible Innovation*, vol. 8, no. 1, pp. 94–126, 2021.
- [81] A. Önder *et al.*, “Poster presentations,” *Psychiatry and Clinical Psychopharmacology*, vol. 28, no. sup1, pp. 74–113, 2018.
- [82] F. Bovera, “Aspa 23rd congress book of abstracts,” *Italian Journal of Animal Science*, vol. 18, no. sup1, pp. 1–239, 2019.
- [83] S. Wiedenbeck, J. Waters, L. Sobrado, and J.-C. Birget, “Design and evaluation of a shoulder-surfing resistant graphical password scheme,” in *Proceedings of the working conference on Advanced visual interfaces*, pp. 177–184, 2006.
- [84] A. Amini, K. Banitsas, and W. R. Young, “Kinect4fog: monitoring and improving mobility in people with parkinson’s using a novel system incorporating the microsoft kinect v2,” *Disability and Rehabilitation: Assistive Technology*, vol. 14, no. 6, pp. 566–573, 2019. PMID: 29790385.
- [85] S. Shen, M. Gowda, and R. Roy Choudhury, “Closing the gaps in inertial motion tracking,” in *Proceedings of the 24th Annual International Conference on Mobile Computing and Networking*, MobiCom ’18, (New York, NY, USA), p. 429–444, Association for Computing Machinery, 2018.
- [86] S. Shen, H. Wang, and R. Roy Choudhury, “I am a smartwatch and i can track my user’s arm,” in *Proceedings of the 14th Annual International Conference on Mobile Systems, Applications, and Services*, MobiSys ’16, (New York, NY, USA), p. 85–96, Association for Computing Machinery, 2016.
- [87] P.-H. Han, K.-W. Chen, C.-H. Hsieh, Y.-J. Huang, and Y.-P. Hung, “Ar-arm: Augmented visualization for guiding arm movement in the first-person perspective,” in *Proceedings of the 7th Augmented Human International Conference 2016*, AH ’16, (New York, NY, USA), Association for Computing Machinery, 2016.
- [88] S.-Y. J. Lau and H. Agius, “A framework and immersive serious game for mild cognitive impairment,” *Multimedia Tools and Applications*, vol. 80, pp. 31183–31237, Aug 2021.
- [89] L. H. V. van der Woude, H. J. P. Houdijk, T. W. J. Janssen, B. Seves, R. Schelhaas, C. Plaggenmarsch, N. L. J. Mouton, R. Dekker, H. van Keeken, S. de Groot, and R. J. K. Vegter, “Rehabilitation: mobility, exercise & sports; a critical position stand on current and future research perspectives,” *Disability and Rehabilitation*, vol. 0, no. 0, pp. 1–16, 2020. PMID: 32805152.
- [90] A. Albers, M. Frietsch, C. Sander, and J. Ottnad, “Development of a highly integrated torque sensor concept for drive units of a humanoid robot,” in *ISR 2010 (41st International Symposium on Robotics) and ROBOTIK 2010 (6th German Conference on Robotics)*, pp. 1–6, 2010.
- [91] K. Hoshino and C. Cheng, “Development of a swordsmanship machine enabling the inner and outer muscles to be safely trained while having fun,” in *Proceedings of the 3rd International Conference on Biomedical and Bioinformatics Engineering*, ICBBE ’16, (New York, NY, USA), p. 59–62, Association for Computing Machinery, 2016.

- [92] I. Aslan, F. Primessnig, M. Murer, C. Moser, and M. Tscheligi, “Inspirations from honey bees: Exploring movement measures for dynamic whole body gestures,” in *Proceedings of the 2013 ACM International Conference on Interactive Tabletops and Surfaces, ITS '13*, (New York, NY, USA), p. 421–424, Association for Computing Machinery, 2013.
- [93] P. Trung, M. Giuliani, M. Miksch, G. Stollnberger, S. Stadler, N. Mirnig, and M. Tscheligi, “Head and shoulders: Automatic error detection in human-robot interaction,” in *Proceedings of the 19th ACM International Conference on Multimodal Interaction, ICMI '17*, (New York, NY, USA), p. 181–188, Association for Computing Machinery, 2017.
- [94] E. Z. Borba, M. Cabral, A. Montes, O. Belloc, and M. Zuffo, “Immersive and interactive procedure training simulator for high risk power line maintenance,” in *ACM SIGGRAPH 2016 VR Village, SIGGRAPH '16*, (New York, NY, USA), Association for Computing Machinery, 2016.
- [95] V. D’Amato, E. Volta, L. Oneto, G. Volpe, A. Camurri, and D. Anguita, “Understanding violin players’ skill level based on motion capture: a data-driven perspective,” *Cognitive Computation*, vol. 12, pp. 1356–1369, Nov 2020.
- [96] A. Behera, P. Matthew, A. Keidel, P. Vangorp, H. Fang, and S. Canning, “Associating facial expressions and upper-body gestures with learning tasks for enhancing intelligent tutoring systems,” *International Journal of Artificial Intelligence in Education*, vol. 30, pp. 236–270, Jun 2020.
- [97] B. Chang, Y. Li, Q. Wang, W.-T. Zhu, and R. H. Deng, “Making a good thing better: enhancing password/pin-based user authentication with smartwatch,” *Cybersecurity*, vol. 1, p. 7, Aug 2018.
- [98] M. Evans, S. Colyer, A. Salo, and D. Cosker, “Automatic high fidelity foot contact location and timing for elite sprinting,” *Machine Vision and Applications*, vol. 32, p. 112, Aug 2021.
- [99] V. Holzwarth, J. Schneider, J. Handali, J. Gisler, C. Hirt, A. Kunz, and J. vom Brocke, “Towards estimating affective states in virtual reality based on behavioral data,” *Virtual Reality*, vol. 25, pp. 1139–1152, Dec 2021.
- [100] B. Münzer, K. Schoeffmann, and L. Böszörményi, “Content-based processing and analysis of endoscopic images and videos: A survey,” *Multimedia Tools and Applications*, vol. 77, pp. 1323–1362, Jan 2018.
- [101] M. Hofmann and D. M. Gavrilu, “Multi-view 3d human pose estimation in complex environment,” *International Journal of Computer Vision*, vol. 96, pp. 103–124, Jan 2012.
- [102] B. Kwolek, A. Michalczyk, T. Krzeszowski, A. Switonski, H. Josinski, and K. Wojciechowski, “Calibrated and synchronized multi-view video and motion capture dataset for evaluation of gait recognition,” *Multimedia Tools and Applications*, vol. 78, pp. 32437–32465, Nov 2019.
- [103] M. Al-Sada, K. Jiang, S. Ranade, M. Kalkattawi, and T. Nakajima, “Hapticsnakes: multi-haptic feedback wearable robots for immersive virtual reality,” *Virtual Reality*, vol. 24, pp. 191–209, Jun 2020.

- [104] M. Paolanti, R. Pietrini, A. Mancini, E. Frontoni, and P. Zingaretti, “Deep understanding of shopper behaviours and interactions using rgb-d vision,” *Machine Vision and Applications*, vol. 31, p. 66, Sep 2020.
- [105] M. Z. Uddin, T. T. Ngo, Y. Makihara, N. Takemura, X. Li, D. Muramatsu, and Y. Yagi, “The ou-isir large population gait database with real-life carried object and its performance evaluation,” *IPSS Transactions on Computer Vision and Applications*, vol. 10, p. 5, May 2018.
- [106] M. Doyran, A. Schimmel, P. Baki, K. Ergin, B. Türkmen, A. A. Salah, S. C. J. Bakkes, H. Kaya, R. Poppe, and A. A. Salah, “Mumbai: multi-person, multimodal board game affect and interaction analysis dataset,” *Journal on Multimodal User Interfaces*, vol. 15, pp. 373–391, Dec 2021.
- [107] T. Hachaj and M. R. Ogiela, “Human actions recognition on multimedia hardware using angle-based and coordinate-based features and multivariate continuous hidden markov model classifier,” *Multimedia Tools and Applications*, vol. 75, pp. 16265–16285, Dec 2016.
- [108] R. Brito, R. Biuk-Aghai, and S. Fong, “Gpu-based parallel shadow features generation at neural system for improving gait human activity recognition,” *Multimedia Tools and Applications*, vol. 80, 03 2021.
- [109] P. O. Stalph and M. V. Butz, “Learning local linear jacobians for flexible and adaptive robot arm control,” *Genetic Programming and Evolvable Machines*, vol. 13, pp. 137–157, Jun 2012.
- [110] O. Ozturk, T. Matsunami, Y. Suzuki, T. Yamasaki, and K. Aizawa, “Real-time tracking of humans and visualization of their future footsteps in public indoor environments,” *Multimedia Tools and Applications*, vol. 59, pp. 65–88, Jul 2012.
- [111] S. Asteriadis and P. Daras, “Landmark-based multimodal human action recognition,” *Multimedia Tools and Applications*, vol. 76, pp. 4505–4521, Feb 2017.
- [112] C.-J. Wu, A. Quigley, and D. Harris-Birtill, “Out of sight: a toolkit for tracking occluded human joint positions,” *Personal and Ubiquitous Computing*, vol. 21, pp. 125–135, Feb 2017.
- [113] D. Groos, H. Ramampiaro, and E. A. Ihlen, “Efficientpose: Scalable single-person pose estimation,” *Applied Intelligence*, vol. 51, pp. 2518–2533, Apr 2021.
- [114] A.-W. de Leeuw, S. van der Zwaard, R. van Baar, and A. Knobbe, “Personalized machine learning approach to injury monitoring in elite volleyball players,” *European Journal of Sport Science*, vol. 0, no. 0, pp. 1–10, 2021. PMID: 33568023.
- [115] T. Kucherenko, D. Hasegawa, N. Kaneko, G. E. Henter, and H. Kjellström, “Moving fast and slow: Analysis of representations and post-processing in speech-driven automatic gesture generation,” *International Journal of Human-Computer Interaction*, vol. 37, no. 14, pp. 1300–1316, 2021.
- [116] B. Reimer, B. Mehler, M. Muñoz, J. Dobres, D. Kidd, and I. J. Reagan, “Patterns in transitions of visual attention during baseline driving and during interaction with visual-manual and voice-based interfaces,” *Ergonomics*, vol. 0, no. 0, pp. 1–23, 2021. PMID: 34018916.

- [117] D. Nasu and M. Kashino, “Impact of each release parameter on pitch location in baseball pitching,” *Journal of Sports Sciences*, vol. 39, no. 10, pp. 1186–1191, 2021. PMID: 33377819.
- [118] S. C. Calvert, D. D. Heikoop, G. Mecacci, and B. van Arem, “A human centric framework for the analysis of automated driving systems based on meaningful human control,” *Theoretical Issues in Ergonomics Science*, vol. 21, no. 4, pp. 478–506, 2020.
- [119] T. Tanaka, I. Nambu, and Y. Wada, “Developing a method to control an arm-assist-suit by predicting arm-trajectory using electromyography,” in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine Biology Society (EMBC)*, pp. 4882–4885, 2020.
- [120] T. Fukui, M. Ito, S.-i. Ito, and M. Fukumi, “Motion identification of fingerspelling by wrist emg analysis,” in *2020 IEEE Symposium Series on Computational Intelligence (SSCI)*, pp. 1739–1744, 2020.
- [121] S. Guan, J. Wang, and F. Wang, “Research on recognition of shoulder joint movement imagination based on bci technology,” in *Proceedings of the 2nd International Conference on Artificial Intelligence and Advanced Manufacture, AIAM2020*, (New York, NY, USA), p. 163–167, Association for Computing Machinery, 2020.
- [122] Z. Hammal and J. F. Cohn, “Automatic detection of pain intensity,” in *Proceedings of the 14th ACM International Conference on Multimodal Interaction, ICMI '12*, (New York, NY, USA), p. 47–52, Association for Computing Machinery, 2012.
- [123] D.-S. Tran, N.-H. Ho, H.-J. Yang, S.-H. Kim, and G. S. Lee, “Real-time virtual mouse system using rgb-d images and fingertip detection,” *Multimedia Tools and Applications*, vol. 80, pp. 10473–10490, Mar 2021.
- [124] R. Fukui, M. Watanabe, M. Shimosaka, and T. Sato, “Hand shape classification in various pronation angles using a wearable wrist contour sensor,” *Advanced Robotics*, vol. 29, no. 1, pp. 3–11, 2015.
- [125] B. Debnath, M. O’Brien, M. Yamaguchi, and A. Behera, “A review of computer vision-based approaches for physical rehabilitation and assessment,” *Multimedia Systems*, Jun 2021.
- [126] A. P. Ruiz, M. Flynn, J. Large, M. Middlehurst, and A. Bagnall, “The great multivariate time series classification bake off: a review and experimental evaluation of recent algorithmic advances,” *Data Mining and Knowledge Discovery*, vol. 35, pp. 401–449, Mar 2021.
- [127] S.-H. Zhou, J. Fong, V. Crocher, Y. Tan, D. Oetomo, and I. Mareels, “Learning control in robot-assisted rehabilitation of motor skills – a review,” *Journal of Control and Decision*, vol. 3, no. 1, pp. 19–43, 2016.
- [128] P. H. S. Kalmet, S. Sanduleanu, S. Primakov, G. Wu, A. Jochems, T. Refaee, A. Ibrahim, L. v. Hulst, P. Lambin, and M. Poeze, “Deep learning in fracture detection: a narrative review,” *Acta Orthopaedica*, vol. 91, no. 2, pp. 215–220, 2020. PMID: 31928116.
- [129] I. Ar and Y. S. Akgul, “A computerized recognition system for the home-based physiotherapy exercises using an rgbd camera,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 22, no. 6, pp. 1160–1171, 2014.

- [130] O. Brunner, A. Mertens, V. Nitsch, and C. Brandl, “Accuracy of a markerless motion capture system for postural ergonomic risk assessment in occupational practice,” *International Journal of Occupational Safety and Ergonomics*, vol. 0, no. 0, pp. 1–9, 2021. PMID: 34252007.
- [131] M. Yahya, J. Shah, K. Kadir, A. Warsi, S. Khan, and H. Nasir, “Accurate shoulder joint angle estimation using single rgb camera for rehabilitation,” in *2019 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, pp. 1–6, 2019.
- [132] B. Pogorelc, Z. Bosnić, and M. Gams, “Automatic recognition of gait-related health problems in the elderly using machine learning,” *Multimedia Tools and Applications*, vol. 58, pp. 333–354, May 2012.
- [133] S. Gattupalli, D. Ebert, M. Papakostas, F. Makedon, and V. Athitsos, “Cognilearn: A deep learning-based interface for cognitive behavior assessment,” in *Proceedings of the 22nd International Conference on Intelligent User Interfaces, IUI '17*, (New York, NY, USA), p. 577–587, Association for Computing Machinery, 2017.
- [134] I. S. A. Darmana and E. Rakun, “Generating of sign system for bahasa indonesia (sibi) root word gestures using deep temporal sigmoid belief network,” in *Proceedings of the 2019 5th International Conference on Computing and Artificial Intelligence, ICCAI '19*, (New York, NY, USA), p. 221–225, Association for Computing Machinery, 2019.
- [135] I. Seáñez and F. A. Mussa-Ivaldi, “A body-machine interface for the control of a 2d cursor,” in *2013 IEEE 13th International Conference on Rehabilitation Robotics (ICORR)*, pp. 1–6, 2013.
- [136] H. F. Nweke, Y. W. Teh, G. Mujtaba, U. R. Alo, and M. A. Al-garadi, “Multi-sensor fusion based on multiple classifier systems for human activity identification,” *Human-centric Computing and Information Sciences*, vol. 9, p. 34, Sep 2019.
- [137] S. Jayaraman, J. Joshy, P. K. Priya, M. Poduval, and A. B. Thangavel, “Smartwatch as a kinesthetic system for shoulder function assessment,” in *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pp. 1–6, 2020.
- [138] D. De Santis, P. Dzialecka, and F. A. Mussa-Ivaldi, “Unsupervised coadaptation of an assistive interface to facilitate sensorimotor learning of redundant control,” in *2018 7th IEEE International Conference on Biomedical Robotics and Biomechatronics (Biorob)*, pp. 801–806, 2018.
- [139] C. W. Antuvan, F. Bisio, E. Cambria, and L. Masia, “Discrete classification of upper limb motions using myoelectric interface,” in *2015 IEEE International Conference on Rehabilitation Robotics (ICORR)*, pp. 451–456, 2015.
- [140] P. Chakraborty, B. Neogi, and A. Das, “Knowledge based database of arm-muscle and activity characterization during load pull exercise using diagnostic electromyography (d-emg) signal,” *Cogent Engineering*, vol. 7, no. 1, p. 1849942, 2020.
- [141] C. W. Antuvan, F. Bisio, E. Cambria, and L. Masia, “Muscle synergies for reliable classification of arm motions using myoelectric interface,” in *2015 37th Annual International*

- Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 1136–1139, 2015.
- [142] Y. Zhou, C. Chen, M. Cheng, S. Franovic, S. Muh, and S. Lemos, “Real-time surface emg pattern recognition for shoulder motions based on support vector machine,” in *Proceedings of the 2020 9th International Conference on Computing and Pattern Recognition, ICCPR 2020*, (New York, NY, USA), p. 63–66, Association for Computing Machinery, 2020.
- [143] T. Hu, J. Kuehn, and S. Haddadin, “Identification of human shoulder-arm kinematic and muscular synergies during daily-life manipulation tasks,” in *2018 7th IEEE International Conference on Biomedical Robotics and Biomechatronics (Biorob)*, pp. 1011–1018, 2018.
- [144] J. Alvarado Reyes and C. Stern Forgach, “Un complemento al teorema de Nyquist,” *Revista mexicana de Física E*, vol. 56, pp. 165 – 171, 12 2010.
- [145] M. Semeria, “Los tres teoremas: Fourier - nyquist - shannon,” *Universidad del Centro de Estudios Macroeconómicos de Argentina (UCEMA)*, no. 582, 2015.
- [146] J. Taylor, “Proprioception,” in *Encyclopedia of Neuroscience* (L. R. Squire, ed.), pp. 1143–1149, Oxford: Academic Press, 2009.
- [147] R. F. Escamilla, K. Yamashiro, L. Paulos, and J. R. Andrews, “Shoulder muscle activity and function in common shoulder rehabilitation exercises,” *Sports Medicine*, vol. 39, pp. 663–685, Aug 2009.
- [148] D. M. Burns, N. Leung, M. Hardisty, C. M. Whyne, P. Henry, and S. McLachlin, “Shoulder physiotherapy exercise recognition: machine learning the inertial signals from a smartwatch,” *Physiological Measurement*, vol. 39, p. 075007, jul 2018.
- [149] F. Castanedo, “A review of data fusion techniques,” *The Scientific World Journal*, vol. 2013, p. 704504, Oct 2013.
- [150] B. Kikhia, M. Gomez, L. L. Jiménez, J. Hallberg, N. Karvonen, and K. Synnes, “Analyzing body movements within the laban effort framework using a single accelerometer,” *Sensors*, vol. 14, no. 3, pp. 5725–5741, 2014.
- [151] T. Amasay, M. Latteri, and A. Karduna, “In vivo measurement of humeral elevation angles and exposure using a triaxial accelerometer,” *Human factors*, vol. 52, pp. 616–26, 12 2010.
- [152] V. Pereira, I. E. de Elguezabal, I. Reyes, and C. Restrepo, “Asociación de síndrome de pinzamiento subacromial y lesiones parciales intrarticulares de hombro,” *Vitae: Academia Biomédica Digital*, no. 28, p. 2, 2006.
- [153] H. J. Hermens, B. Freriks, R. Merletti, D. Stegeman, J. Blok, G. Rau, C. Disselhorst-Klug, and G. Hägg, “European recommendations for surface electromyography,” *Roessingh research and development*, vol. 8, no. 2, pp. 13–54, 1999.
- [154] N. Nazmi, M. A. Abdul Rahman, S.-I. Yamamoto, S. A. Ahmad, H. Zamzuri, and S. A. Mazlan, “A review of classification techniques of emg signals during isotonic and isometric contractions,” *Sensors*, vol. 16, no. 8, p. 1304, 2016.

- [155] C. J. Payton and A. Burden, *Biomechanical evaluation of movement in sport and exercise: the British Association of Sport and Exercise Sciences guide*. Routledge, 2017.
- [156] M. Asghari Oskoei and H. Hu, “Myoelectric control systems—a survey,” *Biomedical Signal Processing and Control*, vol. 2, no. 4, pp. 275–294, 2007.
- [157] D. Marple-Horvat and S. Gilbey, “A method for automatic identification of periods of muscular activity from emg recordings,” *Journal of Neuroscience Methods*, vol. 42, no. 3, pp. 163–167, 1992.
- [158] M. A. Oskoei and H. Hu, “Ga-based feature subset selection for myoelectric classification,” in *2006 IEEE International Conference on Robotics and Biomimetics*, pp. 1465–1470, 2006.
- [159] S. Sarangi, M. Sahidullah, and G. Saha, “Optimization of data-driven filterbank for automatic speaker verification,” *Digital Signal Processing*, vol. 104, p. 102795, 2020.
- [160] Orhan and C. Altın, “Comparison of different time and frequency domain feature extraction methods on elbow gesture’s emg,” *European Journal of Interdisciplinary Studies*, vol. 2, p. 35–44, Aug. 2016.
- [161] A. Upadhyay, “Classification in machine learning,” Jul 2020.
- [162] J. R. Quinlan, “Induction of decision trees,” *Machine Learning*, vol. 1, pp. 81–106, Mar 1986.
- [163] L. Breiman, “Bagging predictors,” *Machine learning*, vol. 24, no. 2, pp. 123–140, 1996.
- [164] B. E. Boser, I. M. Guyon, and V. N. Vapnik, “A training algorithm for optimal margin classifiers,” in *Proceedings of the fifth annual workshop on Computational learning theory*, pp. 144–152, 1992.