



**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL  
INSTITUTO POLITÉCNICO NACIONAL**

UNIDAD ZACATENCO  
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA  
SECCIÓN DE BIOELECTRÓNICA

Desarrollo de un brazo robótico para el estudio de los  
movimientos de la extremidad superior humana.

**Tesis que presenta**

Lauro Armando Contreras Rodríguez

**Para obtener el Grado de**

**Doctor en Ciencias**

**En la especialidad de**

Ingeniería Eléctrica

**Codirectores de tesis:** Dr. Pablo Rogelio Hernández Rodríguez  
Dr. José Antonio Barraza Madrigal

Ciudad de México

Noviembre, 2022

## **Dedicatoria**

A mis sobrinos Sebastián Vega Contreras y Esteban Vega Contreras, por llegar a mi vida en un momento tan difícil y ayudarme a superar esos momentos tan complicados. Significan mucho para mí chiquitos y son mi mayor motivación en estos momentos.

A mí abuela Alicia Montoya Montoya (1940-2021), que ya no se encuentra más con nosotros, pero sé que me cuida desde el cielo. Te amo Abuelita.

Al Dr. Roberto Muñoz Guerrero (1960-2019), muchas gracias por su apoyo en la maestría y por motivarme a seguir en el doctorado, no olvidaré los consejos y las charlas que teníamos sobre lo que sea que pasara en el momento.

## **Agradecimientos**

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo económico brindado durante mi estancia de doctorado. Al Centro de Investigación y de Estudios Avanzados de Instituto Politécnico Nacional (CINVESTAV-IPN) por permitirme realizar mi posgrado en esta institución y complementar mi formación académica.

Agradecer a mis asesores el Dr. Pablo Rogelio Hernández Rodríguez y el Dr. José Antonio Barraza Madrigal por su atención, consejos y disposición para guiarme y trabajar conmigo en esta etapa y hacerme crecer no solo en lo profesional, sino también en lo personal. A los ingenieros Eladio Cardiel Pérez y Ángel Eduardo Llanas Soto por su aportación a mi trabajo con sus observaciones, consejos, revisiones y recomendaciones para mejorar mi trabajo. Al personal del taller de la sección de bioelectrónica, por su ayuda en la modificación y construcción de elementos necesarios para mi trabajo. Al personal académico Mariana, Paty y Mónica, por apoyarme con los trámites cuando fue requerido.

Agradezco enormemente a mis padres Rosa Elvia Rodríguez Montoya y José Alfredo Contreras Gutiérrez por siempre estar para apoyarme, ver por mí en todo momento y por todo el amor que me profesan. A mis hermanos Evelin Alitzi Contreras Rodríguez y Víctor Alfredo Contreras Rodríguez, por su apoyo incondicional, las ideas y la motivación que me dan. A mis abuelos que, aunque ya no están conmigo sé que me cuidan desde el cielo. A mis tíos y primos que me apoyan desde casa. A mis sobrinos, mi motivación para continuar con mi desarrollo profesional. A Óscar y Hugo, por ser parte de mi familia política y con quienes siempre encuentro alguna platica interesante.

Agradecer a mis amigos de la infancia Pepe, Eliezer, Alejandrina, Brianda, Martha, Vero, Yeni y Luis por estar, no estar y volver a estar en mi vida. A mis amigos de la carrera que me motivaron a continuar mi desarrollo profesional Pau, Fer, Edwin, Angélica, Vero, David, Ville, Marthoz, Sinuhé y Manny. A mis amigos de SERTES Topo, Diana y Jesving por seguir en contacto luego de este tiempo. A Adriana Bastidas, por aconsejarme en estos últimos años con sus experiencias vividas en su doctorado.

A mis compañeros y amigos con quienes tuve la oportunidad de convivir en esta etapa: Ana, Luis y Janette del laboratorio 4; Jenny, David, Lore, Mimí, Luis y Chabelita del laboratorio 11; A mis amigos de la sección: Frank, Limón, Jonathan, Jorge, Michelle y Linda. A mis amigos del Cinves: Daniel, Isaac, Luis, Diana, Zacarías y Alberto. A los que ya no están, pero nos seguimos frecuentando: Héctor, Carlos, Miguel y Saraí.

Y a mis roomies Abril Karina Robles Sánchez y Daniel Alberto Hernández Chávez. Que más que mis roomies son mis hermanos de la vida con quienes tuve la oportunidad de vivir los últimos 6 años y a quienes voy a extrañar mucho después de esta etapa. Han sido una constante muy positiva en mi vida. Me llevo todas las pláticas, las preocupaciones, los enojos, las risas... tantas experiencias juntos en estos años que han dejado una marca en mi vida, muchas gracias por permitirme estar con ustedes todo este tiempo.

## Resumen

En este trabajo se presenta el desarrollo de un brazo robótico para el análisis de movimientos de la extremidad superior humana. El brazo robótico se diseñó a partir de estudios relacionados con la antropometría mexicana y de la extremidad superior, los cuales sirvieron para calcular el torque que requieren los motores para las articulaciones y las dimensiones de los segmentos corporales.

Se desarrolló un algoritmo para estimar la orientación para los módulos de monitoreo para la extremidad superior (MMES) con los cuales se realizaron pruebas para adquirir registros del movimiento de la extremidad superior en personas. Estos registros se utilizaron para el diseño de una red neuronal artificial que permita clasificar e identificar los movimientos a partir de los patrones de la actividad. Los registros también se utilizaron como señales que indican la actividad a realizar por el brazo robótico.

El algoritmo propuesto en combinación con los MMES permitió publicar un artículo en la revista *Medical Engineering and Physics* en donde los resultados indican su utilidad para el análisis de movimiento humano. Por su parte, el modelo de red neuronal artificial permitió desarrollar un artículo para el congreso internacional de ingeniería eléctrica, ciencias de la computación y control automático (CCE 2022) en cual se mencionan las oportunidades que crean estas herramientas para el estudio de movimiento humano y su aplicación en sistemas de control para brazos robóticos.

La actividad del brazo robótico se analizó para evaluar la repetibilidad de sus movimientos, los resultados obtenidos indican que el brazo robótico es capaz de repetir un mismo movimiento bajo el mismo patrón de actividad con diferencias menores a  $1^\circ$ , una desviación estándar menor a  $2.1^\circ$  y con coeficientes de correlación mayores a 0.97. Otro análisis realizado a la actividad del brazo robótico fue su comparación mediante análisis Bland-Altman con respecto a los registros originales sobre los que se determinan los patrones de movimiento del brazo. Los resultados indican que los registros del brazo tienen una diferencia menor a  $3^\circ$ , desviación estándar menor a  $4.5^\circ$  y coeficientes de correlación mayores a 0.91 con respecto a los registros de la persona para los movimientos evaluados.

## **Abstract**

In this work, the development of a robotic arm for the analysis of the human upper limb movement is presented. The robotic arm was design based on anthropometric studies based on Mexican population and the upper limb, which were used to calculate the torque required by the motors for the joints and the dimensions of the body segments.

An algorithm for orientation estimation was developed for the upper limb measuring modules (MMES) with which tests were carried out to acquire records of the upper limb movement in persons. These records were used to design an artificial neural network to classify and identify movements based on activity patterns. The records were also used as signals indicating the activity to be carried out by the robotic arm.

The proposed algorithm in combination with the MMES allowed to publish in the Medical Engineering and Physics journal where results indicate its usefulness for the human motion analysis. The artificial neural network also allowed to develop an article for the international conference on electrical engineering, computing science and automatic control (CCE 2022) in which it is mentioned that the implementation of ANN creates opportunities for the human motion studies and applications for robotic arms' control system.

The robotic arm activity was analyzed to evaluate the repeatability of its movements, the results obtained indicate that the robotic arm can repeat the same movement under the same activity pattern with differences of less than  $1^\circ$ , a standard deviation less than  $2.1^\circ$  and correlation coefficients greater than 0.97. Another analysis was carried out comparing the activity of the robotic arm with respect to the original records on which the movement patterns of the robotic arm were determined. The results using a Bland-Altman analysis indicated that the records of the arm have a difference less than  $3^\circ$ , a standard deviation less than  $4.5^\circ$  and correlation coefficients greater than 0.91 with respect to the records of the person for the evaluated movements.

# Contenido

Capítulo 1. Introducción.....	1
1.1 Objetivo general .....	2
1.2 Objetivos particulares.....	2
1.3 Solución propuesta .....	2
1.4 Organización de la tesis.....	3
Capítulo 2. Antecedentes.....	5
2.1 Estudio del movimiento humano.....	5
2.1.1 Conceptos generales .....	5
2.1.2 La extremidad superior humana .....	6
2.2 Robots para el estudio de movimiento humano .....	12
2.2.1 Conceptos básicos de robótica.....	12
2.2.2 Movimiento de la extremidad superior desde la perspectiva de la robótica.....	14
2.3 Posición y orientación de los segmentos corporales en el espacio 3D.....	14
2.3.1 Representación de la posición .....	14
2.3.2 Representación de la orientación.....	15
2.4 Sensores inerciales y magnéticos .....	16
2.4.1 Unidad de medición inercial (IMU) .....	16
2.4.2 MARG .....	17
2.4.3 Sensores IMU/MARG comerciales .....	17
2.5 Análisis de movimiento humano con <i>machine learning</i> .....	17
2.5.1 Conceptos generales .....	17
2.5.2 Principios básicos de las redes neuronales artificiales .....	19
2.5.3 Métodos de aprendizaje .....	25
2.5.4 Validación de los modelos de redes neuronales artificiales .....	29

Capítulo 3. Estado del arte .....	32
Capítulo 4. Metodología.....	36
4.1 Consideraciones para el Diseño del Brazo Robótico.....	36
4.1.1 Antropometría de la Extremidad Superior en México.....	36
4.1.2 Selección de los actuadores .....	38
4.1.3 Diseño de las piezas del brazo robótico.....	40
4.2 Desarrollo del brazo robótico .....	42
4.3 Sistema para el registro del movimiento humano .....	45
4.3.1 Diseño de los módulos para la medición del movimiento de la extremidad superior (MMES).....	45
4.4 Pruebas de movimiento de la extremidad superior humana con los MMES.....	53
4.4.1 Validación de los MMES .....	53
4.4.2 Pruebas de movimiento con personas.....	54
4.5 Desarrollo de una RNA para la identificación de los movimientos de la extremidad superior humana. ....	58
4.5.1 Arquitectura de la red neuronal artificial.....	58
4.5.2 Validación de la arquitectura de la red neuronal artificial.....	59
4.5.3 Aprendizaje del modelo de red neuronal.....	60
4.5.4 Métodos estadísticos para la validación del modelo .....	61
4.6 Pruebas de movimiento del brazo robótico .....	62
4.6.1 Movimientos del brazo robótico y validación con Xsens .....	63
Capítulo 5. Resultados.....	65
5.1 Brazo robótico .....	65
5.2 Sensores .....	65
5.3 Red neuronal artificial .....	71

5.4 Validación de los movimientos con el brazo robótico .....	74
Capítulo 6. Discusión .....	86
Capítulo 7. Conclusión y trabajo a futuro .....	89
Referencias .....	91
Anexos.....	101

## Capítulo 1. Introducción

En este trabajo se presenta el desarrollo de un brazo robótico para el análisis de movimientos de la extremidad superior humana. Este proyecto es la continuación del trabajo realizado en maestría [1] y el trabajo de doctorado del Dr. José Antonio Barraza Madrigal [2]. Estos trabajos aportan el conocimiento previo para el estudio del movimiento de la extremidad superior mediante sensores inerciales. En este trabajo se pretende utilizar la información adquirida en estas etapas para su aplicación en un sistema mecatrónico que simule el movimiento de la extremidad superior humana.

El estudio del movimiento humano permite conocer la condición en la que se encuentra la función motora de una persona, así como las patologías a las que puede estar sujeto [3-5]. El entendimiento del movimiento del humano permite realizar una correcta evaluación de la condición del paciente proporcionando un tratamiento adecuado para su caso. De la misma manera, en el ámbito del deporte el estudio del movimiento ha permitido desarrollar las capacidades de los deportistas para mejorar su rendimiento y disminuir el riesgo de lesiones [6-8]. El estudio del movimiento humano se enfoca en el desarrollo de técnicas y dispositivos que permitan obtener información objetiva y confiable de la función motora del cuerpo humano. La evaluación del movimiento humano suele realizarse en función de la experiencia clínica, en el caso de la medicina, o la experiencia visual/motora, en el caso de deportistas y maestros de danza. Sin embargo, dos médicos con distintas experiencias pueden llegar a diagnósticos diferentes si la afección que se atiende es poco común o presenta síntomas indefinidos. En la actualidad, la búsqueda de técnicas y dispositivos que permitan obtener información objetiva y confiable para analizar el movimiento humano se ha vuelto una herramienta valiosa para un correcto diagnóstico del movimiento [9]. El auge tecnológico de las últimas décadas ha llevado a la investigación de técnicas en *machine learning* y robótica para el análisis del movimiento en humanos. La combinación de ambas tecnologías ha dado al estudio del movimiento humano un nuevo impulso en el que se han desarrollado múltiples técnicas o dispositivos para obtener información relativa al movimiento [10, 11].

El enfoque moderno del estudio de movimiento humano se caracteriza por el uso de diferentes soluciones tecnológicas que permiten lograr una comprensión cuantitativa de los fenómenos que ocurren durante el movimiento [9]. Desde el punto de vista de la robótica, el

estudio de movimiento humano ha permitido el desarrollo de sistemas mecánicos capaces de simular las actividades humanas, los cuales, auxiliados con actuadores han permitido reemplazar la función de un miembro corporal en caso de amputación o ayudar en el proceso de terapia y rehabilitación para la recuperación de las funciones motrices [12, 13]. El estudio de movimiento humano aplicado con brazos robóticos se ha realizado desde la perspectiva de la predicción del movimiento mediante técnicas de *machine learning* [14-17] Esto ha permitido mejorar el entendimiento del movimiento humano para una colaboración humano-máquina más eficiente en entornos médicos, industriales y sociales [18-20].

## **1.1 Objetivo general**

Diseñar y construir un brazo robótico para el estudio de movimiento de la extremidad superior derecha de humanos basado en el uso de sensores MARG y redes neuronales artificiales.

## **1.2 Objetivos particulares**

- Diseñar un sistema de medición conjunta de actividades de los movimientos de los segmentos corporales con cuatro módulos de medición, considerando los segmentos mano, antebrazo, brazo y tórax.
- Desarrollar un algoritmo para obtener la información relativa a la orientación de los segmentos corporales utilizando sensores MARG.
- Desarrollar una red neuronal artificial que permita clasificar los diferentes movimientos que realizan las articulaciones del hombro, codo y muñeca.
- Diseñar y construir un sistema robótico que permita reproducir movimientos de la extremidad superior derecha humana, considerando el hombro, codo y muñeca.
- Validar el desempeño del robot mediante la prueba Reach-to-Grasp y sensores Xsens.

## **1.3 Solución propuesta**

El presente trabajo de tesis presenta el desarrollo de un brazo robótico para el estudio del movimiento de la extremidad superior derecha. El brazo robótico desarrollado cuenta con siete grados de libertad para las articulaciones hombro (3), codo (1) y muñeca (2), y un grado

de libertad adicional para el movimiento de pronosupinación en el antebrazo. De manera paralela, se desarrolló un sistema de medición basado en sensores MARG para el registro de movimientos en la extremidad, las cuales servirán para indicar la actividad a realizar en el brazo robótico y para el entrenamiento y pruebas de un modelo de red neuronal artificial para la clasificación de los movimientos. El brazo robótico se elaboró mediante deposición de material fundido (FDM) con impresión 3D en material ABS. La validación del movimiento del brazo robótico se hizo comparando la actividad realizada por el brazo registrada con sensores Xsens y la actividad del movimiento humano registrada con el sistema desarrollado.

## **1.4 Organización de la tesis**

La tesis se dividió en 8 capítulos:

- Capítulo 1: introducción sobre el tema de tesis abarcando la necesidad del estudio, los temas relacionados, la hipótesis presentada, los objetivos y breve descripción de la metodología empleada para la hipótesis.
- Capítulo 2: antecedentes necesarios para comprender el tema enfocando la información a los temas que se buscan atender con la metodología a emplear.
- Capítulo 3: estado del arte; para la búsqueda del contenido de este capítulo se utilizaron palabras claves tales como “análisis de movimiento humano/marcha/extremidad superior”, “estudio del movimiento humano/marcha/extremidad superior”, “evaluación del movimiento humano/marcha/extremidad superior”, “colaboración robot-humano”, “predicción del movimiento humano”, “robots antropomorfos”, “rehabilitación robótica”, “Redes neuronales artificiales”.
- Capítulo 4: metodología empleada para resolver el problema planteado.
- Capítulo 5: resultados obtenidos a partir de la metodología.
- Capítulo 6: discusión de los resultados obtenidos a partir de la hipótesis planteada y comparación con trabajos que reportan resultados en una temática similar.
- Capítulo 7: conclusión de la tesis a partir de la discusión presentada. En este capítulo se hace una propuesta al trabajo a futuro que dé continuidad a la tesis.

Una sección de anexos se agregó al final del contenido de la tesis en la que se presenta información adicional a cerca de los documentos necesarios para la experimentación y los productos obtenidos del trabajo de tesis.

## Capítulo 2. Antecedentes

### 2.1 Estudio del movimiento humano

#### 2.1.1 Conceptos generales

El estudio del movimiento humano tiene como propósito analizar, describir y evaluar la mecánica de la actividad de movimiento en el cuerpo humano con el fin de explicar el cómo y porqué se mueve de la forma en que lo hace [21]. Algunos conceptos asociados al estudio del movimiento humano son el análisis del movimiento humano (AMH) y la biomecánica. El AMH se encarga de la detección, seguimiento y reconocimiento de la actividad humana durante la realización de una tarea específica [22-24]. Por otro lado, la biomecánica es una rama de la física que se encarga de la descripción del movimiento y las fuerzas que lo ocasionan, proveyendo herramientas conceptuales y matemáticas para el entendimiento de su actividad [25]. La información que proporcionan estos estudios incluye datos como la antropometría, actividad muscular, cinética o cinemática de los segmentos anatómicos y las articulaciones involucradas para realizar una tarea específica. En la actualidad, el estudio del movimiento humano se ha enfocado en el desarrollo de técnicas y dispositivos que otorguen información precisa y confiable de los segmentos corporales bajo estudio [9]. Bajo este enfoque el estudio de movimiento humano se ha convertido en campo de investigación desde la perspectiva de nuevas disciplinas en ingeniería tales como sistemas de visión por computadora [26, 27], aprendizaje automático (*machine learning*) [28, 29] y robótica [30, 31] con especialización en ciertas actividades como el análisis de marcha [32, 33], el movimiento de la extremidad superior [34, 35] o el movimiento de ciertos segmentos corporales para actividades deportivas [36, 37].

El estudio del cuerpo humano se realiza a partir del sistema musculoesquelético, un sistema complejo de huesos, músculos y tejido suave que producen el movimiento del cuerpo humano [38]. Estos movimientos se centran en las articulaciones y se representan tridimensionalmente en planos anatómicos, Figura 1.

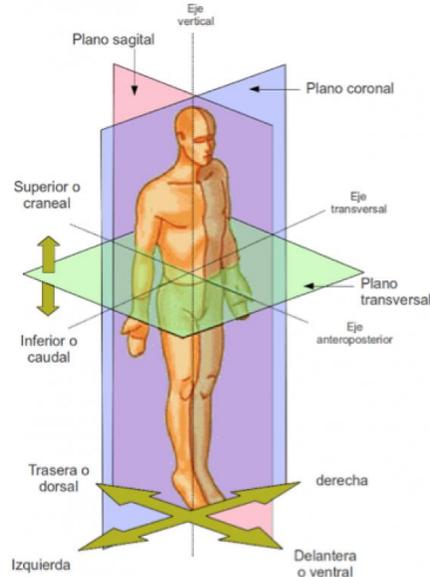


Figura 1. Posición anatómica estándar, planos anatómicos y sus ejes principales [39].

Plano frontal: Observar el cuerpo de frente (cara a cara).

Plano sagital: Observar el cuerpo de costado.

Plano transversal: Observar el cuerpo directamente desde arriba de la cabeza.

Eje transversal: Se encuentra sobre el plano frontal, permite los movimientos de flexión y extensión los cuales se realizan sobre el plano sagital.

Eje anteroposterior: Se encuentra sobre el plano sagital, permite los movimientos de abducción y aducción los cuales se realizan sobre el plano frontal.

Eje vertical: Se encuentra sobre el plano transversal, permite los movimientos de rotación lateral, rotación medial.

### 2.1.2 La extremidad superior humana

La extremidad superior humana se caracteriza por su rango de movimiento y su capacidad para posicionar y orientar la mano para la manipulación de objetos. Comprende desde la cintura escapular hasta los dedos de la mano y está formado por cuatro segmentos principales: hombro, brazo, antebrazo y mano, Figura 2 [40].

- Hombro: Es el segmento proximal de la extremidad superior en el cual se superponen partes del tronco (tórax y dorso) y de la porción lateral e inferior del cuello. Comprende la región pectoral, escapular y deltoidea de la extremidad superior y la

parte lateral (fosa supraclavicular mayor) de la región cervical lateral. Recubre la mitad de la cintura escapular.

- **Brazo:** Primer segmento libre de la extremidad superior y la porción más larga de la extremidad superior. Es la parte de mayor movilidad de la extremidad superior, independiente del tronco. Se extiende entre el hombro y el codo conectando ambas articulaciones, y comprende las regiones anterior y posterior del brazo, centradas en torno al húmero.
- **Antebrazo:** Segundo segmento más largo de la extremidad superior. Se extiende entre el codo y el carpo conectando ambas articulaciones y comprende las regiones anterior y posterior del antebrazo, que recubren el radio y la ulna (cúbito).
- **Mano:** Es el segmento distal de la extremidad superior. Comprende el carpo (muñeca), la palma y el dorso de la mano, y los dedos (entre los que se encuentra un pulgar oponible), y está ricamente inervada con numerosas terminaciones sensibles al tacto, el dolor y la temperatura.



Figura 2. Segmentos y huesos de la extremidad superior[40].

Las articulaciones de la extremidad superior interactúan de forma sincronizada para coordinar los segmentos participantes en la realización de movimientos suaves y eficientes a

la distancia o en las posiciones más operativas necesarias para una tarea en concreto. La eficiencia de la función de la mano se debe, en gran medida, a la capacidad para situarla en la posición adecuada mediante movimientos de las articulaciones de la cintura escapular, del hombro, del codo, radioulnar (pronosupinación) y del carpo.

#### *2.1.2.1 Biomecánica de la extremidad superior humana*

El hombro es la articulación más móvil de la extremidad superior, posee cinco grados de libertad que le permiten orientar al brazo en relación con los tres planos anatómicos sobre sus tres ejes principales [41]. Los movimientos de la cintura escapular se realizan sobre el plano frontal o el plano sagital. Sobre el plano frontal se realizan los movimientos de elevación y depresión del hombro, mientras que sobre el plano sagital se realizan los movimientos de protracción y retracción del hombro. Los movimientos de la articulación glenohumeral se realizan sobre los tres planos. Sobre el plano sagital, se tienen los movimientos de flexión (levantamiento del brazo hacia enfrente) y extensión (empuje de brazo hacia atrás de la línea media); en el frontal, se tienen los movimientos de abducción (levantamiento del brazo hacia un costado) y aducción (bajando el brazo hacia el cuerpo) y en el transversal, se realizan los movimientos de rotación lateral (también llamada rotación externa, rotación del brazo sobre su eje hacia afuera del cuerpo) y rotación medial (también llamada rotación interna, rotación del brazo sobre su eje hacia adentro del cuerpo).

Anatómicamente el codo contiene una articulación, la cual se desplaza sobre el plano sagital con los movimientos de flexión y extensión. Debido a las restricciones mecánicas del codo, el movimiento de extensión solo se puede lograr posterior a un movimiento de flexión del codo.

El movimiento del antebrazo puede ser considerado como una acción conjunta, ya que los dos huesos del antebrazo, radio y ulna (cúbito), rotan a lo largo de su eje. A estos movimientos se les conocen como pronación (la palma de la mano se orienta hacia abajo) y supinación (la palma de la mano se orienta hacia arriba).

Los movimientos sobre la articulación de la muñeca se realizan sobre los planos sagital y frontal. Sobre el plano frontal se realizan los movimientos de flexión y extensión, mientras que en el plano sagital se realizan los movimientos de abducción y aducción.

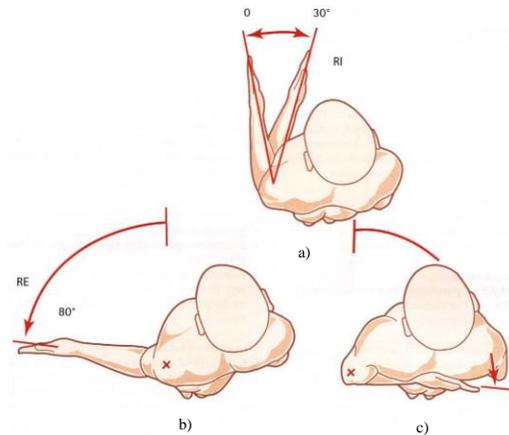
### *2.1.2.2 Amplitud de movimiento de segmentos corporales*

La amplitud de movimiento de un segmento corporal se define como el rango de acción que tiene para moverse, asociado con la flexibilidad que tienen para moverse a su máxima amplitud posible. Este factor ha sido ampliamente estudiado y se tiene reportes acerca de la amplitud para las articulaciones y los movimientos que éstas pueden realizar [40, 41].

La articulación del hombro es la que tiene más libertad en todo el cuerpo humano. Como se mencionó en el apartado 2.1.2.1, el hombro cuenta con movimientos sobre los tres planos anatómicos. El movimiento de flexión con una amplitud de movimiento de hasta 180° con respecto a la línea media (sobre la vertical en posición anatómica estándar) y una extensión entre 45-50° sobre la línea media, dando un rango de movimiento total de 225-230° rotando sobre el plano sagital [41].

Para el movimiento de abducción, se logra una amplitud de movimiento de 180° de los cuales el movimiento de 0-60° requiere únicamente de la actividad de la articulación glenohumeral; de 60-120° se requiere de la participación de la articulación escapulotorácica; y de 120-180° se requiere de la inclinación del lado opuesto del tronco para lograr ese rango de movimiento [41]. En sentido estricto, la abducción a partir de los 90° se convierte en una aducción. Debido a la presencia del tronco, el movimiento de aducción no es mecánicamente posible, se requiere de un movimiento de flexión o extensión para lograrse. El movimiento de flexión permite realizar un movimiento de aducción de entre 30-45°, mientras que el movimiento de extensión permite solo una aducción leve. Con estos parámetros, se obtiene un rango de movimiento para el movimiento del hombro sobre el plano frontal de 210-225° considerando un movimiento de flexión [41].

Para medir el rango de movimiento de la rotación lateral y medial se considera la posición anatómica con el codo flexionado 90° de forma que el antebrazo se encuentre sobre el plano sagital. La rotación lateral (externa) tiene una amplitud de 80° (con el brazo en vertical esta posición no se alcanza), Figura 3b, y la rotación medial (interna) una amplitud de 30°, Figura 3a, aunque puede alcanzar los 100-110° si el antebrazo se pasa por detrás del tronco, lo que lo asocia a un cierto grado de extensión del hombro, Figura 3c. Se puede lograr un rango de movimiento de 110° y hasta 190° si se pasa el codo por detrás del cuerpo (esto último considera que el rango de movimiento incluye la porción del tronco [41]).



*Figura 3. Rotación latero-medial del hombro. a) Rotación interna (30°). B) Rotación externa (80°). C) Rotación interna por detrás del tronco (110°) [41].*

La articulación del codo cuenta con un grado de libertad dispuesto en los movimientos de flexión y extensión. Las limitantes de la amplitud del movimiento de flexión en el codo se deben a tres factores: el impacto del pico olecraniano en el fondo de la fosita olecraniana; la puesta en tensión de la parte anterior de la cápsula articular; y la resistencia que oponen los músculos flexores (músculo bíceps braquial, músculo braquial y músculo braquiorradial). La limitación de la flexión es distinta según sea una flexión activa o pasiva. Si la flexión es activa, el primer factor limitante es el contacto de las masas musculares del brazo y antebrazo, endurecidos por la contracción. Esto ocasiona que la flexión del codo no pueda sobrepasar los 145° (esta amplitud es menor entre mayor sea la masa muscular del sujeto). Si la flexión es pasiva, se pueden alcanzar hasta los 160°, ya que las masas musculares sin contraer pueden aplastarse una contra la otra. Como se mencionó en el apartado 2.1.2.1, el movimiento de extensión del codo no es común, salvo en caso de una gran laxitud ligamentosa en los que se puede alcanzar una hiperextensión de codo de 5-10°. El rango de movimiento convencional del codo va entre los 145-160° dependiendo del tipo de flexión [41].

El movimiento de pronosupinación se mide con el codo flexionado a 90° y pegado al cuerpo. De no realizarse de esta manera el antebrazo se encontraría en prolongación con el brazo y la rotación longitudinal del antebrazo se añade a la rotación del brazo entorno a su eje longitudinal gracias a los movimientos de rotación latero-medial del hombro. La posición intermedia se considera con el codo flexionado a 90° con el pulgar apuntando hacia arriba. Desde esta posición el movimiento de supinación se realiza cuando la palma de la mano se dirige hacia arriba, con el pulgar hacia a fuera con una amplitud de movimiento de 90°. El

movimiento de pronación se realiza cuando la palma de la mano se dirige hacia abajo, con el pulgar en dirección al cuerpo con una amplitud de 85°. El movimiento de pronosupinación tiene entonces un rango de movimiento de 175° [41].

Los movimientos de la muñeca se efectúan en dos ejes. En el primer eje, perteneciente al plano frontal, se realizan los movimientos de flexo-extensión. La flexión de la mano se realiza cuando la palma de la mano se acerca a la cara anterior del antebrazo con una amplitud de 85° cuando es activa. Por su parte el movimiento de extensión de la mano se realiza cuando el dorso de la mano se aproxima a la cara posterior del antebrazo la cual alcanza una amplitud de 85° cuando es activa. El rango de movimiento de la flexo-extensión de la muñeca es de 170°, pudiendo alcanzar los 195° cuando se realiza una flexión y extensión pasivas las cuales se realizan al combinarlas con el movimiento de pronosupinación. En el segundo eje, perteneciente al plano sagital, se realizan los movimientos de abducción y aducción. La aducción se realiza cuando la mano se aproxima al eje del cuerpo la cual alcanza aproximadamente los 15° de amplitud. La abducción se realiza cuando la mano se aleja del cuerpo y alcanza una amplitud aproximada de 45°. El rango de movimiento total para la abducción-aducción de la muñeca es de 60° aproximadamente [41].

La Tabla 1 muestra un resumen de la amplitud y rango de movimiento de las tres articulaciones de mayor movilidad de la extremidad superior.

Tabla 1. Amplitud y rango de movimiento de las articulaciones de la extremidad superior

Movimiento	Plano	Amplitud	Rango de movimiento
Flexo-extensión del hombro	Sagital	Flexión: 180°	225-230°
		Extensión: 45-50°	
Abducción-aducción del hombro	Frontal	Abducción: 180°	210-225°
		Aducción: 30-45°	
Rotación latero-medial del hombro	Transversal	Rot. Lateral: 80°	110°
		Rot. Medial: 30° 100-110° (Codo atrás)	180-190° (codo atrás)
Flexo-extensión del codo	Sagital	Flexión: 145°	145-160°
		Extensión: 0°	
Pronosupinación del antebrazo	Transversal	Pronación: 85°	175°
		Supinación: 90°	
Flexo-extensión de la muñeca	Frontal	Flexión: 85°	170° (activas)
		Extensión: 85°	195° (pasivas)
Abducción-aducción de la muñeca	Sagital	Abducción: 45°	60°
		Aducción: 15°	

## 2.2 Robots para el estudio de movimiento humano

### 2.2.1 Conceptos básicos de robótica

La robótica es una rama de la ingeniería en la que se involucran disciplinas como la física, ingeniería mecánica, ingeniería eléctrica, ingeniería electrónica, ingeniería de control, ingeniería informática e inteligencia artificial. Su principal enfoque se encuentra en el diseño y construcción de aparatos/máquinas para realizar trabajos u operaciones, generalmente en ambientes industriales en sustitución de la mano de obra humana, a los que se les denomina robots. Actualmente, se hace una distinción sobre el tipo de robot de acuerdo con las siguientes categorías [42, 43]:

- Robots móviles autónomos (AMR): Son los robots que se mueven y toman decisiones sobre la marcha en tiempo casi real.
- Vehículo de guiado automático (AGV): Se apoyan en pistas o recorridos predefinidos y a menudo requieren de la supervisión de un operario.

- Robots articulados: También denominados brazos robóticos, tienden a emular las funciones de un brazo humano. Las prótesis y ortesis se encuentran en esta categoría.
- Humanoides: Son los robots que realizan funciones centradas en las personas y que a menudo adoptan la forma de un humano.
- Cobots: Son robots diseñados para funcionar junto a los humanos o directamente con ellos.
- Híbridos: Son los robots que combinan características que los tipos mencionados anteriormente para crear soluciones en tareas más complejas.

Otra forma de categorizar a los robots es de acuerdo con su movilidad. Los que son de carácter móvil, los que pueden moverse en su entorno (AMR, AGV, Humanoides, Híbridos), los de carácter fijo, y los que no se mueven por su entorno (Robots articulados, Cobots).

Un robot está formado por los siguientes elementos: estructura mecánica, actuadores, sistema de accionamiento, sistema sensorial, sistema de control y elementos terminales [44]. La estructura mecánica es una serie de elementos o eslabones que se unen mediante articulaciones que permiten un movimiento relativo entre dos eslabones consecutivos. Los actuadores son los elementos encargados de transmitir el movimiento a las articulaciones. El sistema de accionamiento hace referencia al procesador que se utiliza para determinar la activación de los actuadores. El sistema sensorial son los dispositivos que se utilizan para determinar la posición angular de una estructura mecánica. El sistema de control se encarga de determinar la velocidad, posición, accionamiento y paro de los actuadores de acuerdo con la información del sistema sensorial. Por último, los elementos terminales, también llamados efectores finales, son estructuras que interactúan con el entorno del robot para la manipulación de objetos o su uso como herramientas [44].

Dentro de los actuadores, podemos encontrar principalmente tres tipos: Actuadores neumáticos, actuadores hidráulicos y actuadores eléctricos. Los actuadores neumáticos funcionan con presión de aire (5-10 bar), se encuentran en tres tipos diferentes (cilindros, motor de paletas y motor de pistón), dentro de sus ventajas se encuentran que son económicos, son de acción rápida, son sencillos de utilizar y son robustos; sin embargo, tienen como desventajas su dificultad de control continuo, requieren de instalaciones especiales (compresor, filtros, válvulas) y generan ruido al operar. Los actuadores hidráulicos

funcionan con aceite a presiones entre los 50-100 bar, al igual que los neumáticos, también se encuentran en tres tipos diferentes (cilindros, motor de paletas y motor de pistón axial), presentan ventajas como rápida acción, alta relación potencia-peso, son auto lubricantes, tiene alta capacidad de carga y son estables frente a cargas estáticas; dentro de sus desventajas se encuentran un difícil mantenimiento, requieren de instalación especial (filtros, válvulas, depósito de aceite, sistema de eliminación de aire), pueden presentar fugas y son costosos. Por su parte, los actuadores eléctricos funcionan mediante corriente eléctrica, normalmente los encontramos en tres tipos (motor de corriente directa, motor de corriente alterna y motor paso a paso). Dentro de sus ventajas presentan una alta precisión, son de fácil control, instalación sencilla y son silenciosos comparados con los actuadores neumáticos e hidráulicos; su principal desventaja se encuentra en la potencia limitada que presentan sujeta a las capacidades de corriente máxima del bobinado [44].

### **2.2.2 Movimiento de la extremidad superior desde la perspectiva de la robótica**

Para que un robot sea capaz de determinar sus movimientos de la misma manera que la extremidad superior humana se recurre a la cinemática del movimiento. La cinemática en robótica es el estudio del movimiento del robot respecto a un sistema de referencia describiendo el movimiento en función de la relación entre la posición y orientación del efector final con los valores que toman sus coordenadas articulares [44]. Dado que un robot se considera como una cadena cinemática formada por eslabones unidos entre sí por articulaciones, se puede establecer un sistema de referencia fijo situado en la base del robot y describir la localización de cada uno de los eslabones con respecto a dicho sistema de referencia. De la misma manera, la extremidad superior humana puede ser considerada una cadena corporal articulada con una referencia fija en el hombro y se puede determinar la posición de la mano describiendo la localización del brazo y antebrazo con respecto al sistema de referencia fijo en el hombro.

## **2.3 Posición y orientación de los segmentos corporales en el espacio 3D**

### **2.3.1 Representación de la posición**

Para localizar un cuerpo rígido en el espacio, es necesario contar con una herramienta que permita la localización espacial de sus puntos; en robótica, se suelen emplear el sistema de

referencia cartesiano para lograrlo. En el caso particular de los robots que emulan el movimiento de la extremidad humana, hacen uso del sistema cartesiano OXYZ, el cual se compone de una terna de ejes ortonormales entre sí de vectores coordenados OX, OY, OZ. Para representar la posición de un objeto se utilizan coordenadas las cuales pueden presentarse como cartesianas, polares y cilíndricas, o esféricas [44].

- Coordenadas cartesianas:  $p(x,y,z)$  el vector que corresponde a la posición de un punto  $p$  en el espacio viene definido con respecto al sistema OXYZ, donde los componentes cartesianos  $(x, y, z)$  representan la distancia del punto  $p$  con respecto al origen en cada uno de los ejes.
- Coordenadas polares y cilíndricas:  $p(r,\theta,z)$  es el vector que corresponde a la posición de un punto  $p$  en el espacio se define a partir de las componentes  $r, \theta$  y  $z$ . Donde  $r$  indica la distancia del punto desde el origen;  $\theta$  es el ángulo que forma el vector del punto  $p$  con respecto al eje OX, sobre el plano OY; y  $z$  es el ángulo que forma el vector del punto  $p$  con respecto al eje OZ, sobre el plano OY.
- Coordenadas esféricas: Al igual que las coordenadas polares y cilíndricas, las coordenadas esféricas  $p(r,\theta,\phi)$  representan la posición de un punto  $p$  en el espacio mediante componentes de distancia y ángulos sobre un plano. El componente  $r$  es la distancia entre el punto y el origen; el componente  $\theta$  es el ángulo formado por la proyección del vector de  $p$  sobre el plano OXY con el eje OX; y el componente  $\phi$  es el ángulo formado por el vector  $p$  con el eje OZ.

### 2.3.2 Representación de la orientación

Un punto queda totalmente definido en el espacio a través de los datos de su posición. Sin embargo, en el caso de un objeto, es necesario definir cuál es su orientación con respecto al sistema de referencia. La orientación en el espacio viene definida por tres grados de libertad o tres componentes linealmente independientes. Para poder describir la orientación de un objeto con respecto a otro es habitual asignar al objeto un nuevo sistema para estudiar la relación espacial entre las coordenadas del nuevo sistema OUVW y las del anterior OXYZ. En robótica usualmente se utilizan los siguientes métodos para representar la orientación de un objeto en el espacio, [44]:

- **Matrices de rotación:** Es el método más extendido, consiste en determinar el vector de rotación entre el sistema OUVW con respecto al sistema OXYZ a partir de las rotaciones individuales en cada eje.
- **Ángulos de Euler:** Este método consiste en girar sucesivamente el sistema OXYZ sobre unos ejes determinados de un triedro ortonormal los valores  $\phi, \theta, \Psi$  para obtener el sistema OUVW.
- **Cuaterniones:** Un cuaternión está conformado por cuatro componentes ( $q_0, q_1, q_2, q_3$ ) que representan las coordenadas de un cuaternio en una base  $[e,i,j,k]$  que se generan a partir de un giro  $\theta$  sobre un eje  $k$ , Ecuación (1).

$$Q = Rot(k, \theta) = \left( \cos \frac{\theta}{2}, k \cdot \text{sen} \frac{\theta}{2} \right) \quad (1)$$

## 2.4 Sensores inerciales y magnéticos

### 2.4.1 Unidad de medición inercial (IMU)

Las unidades de medición inercial (IMU, *inertial measurement unit*) son dispositivos electrónicos capaces de detectar magnitudes físicas mediante fenómenos inerciales. Convencionalmente, estos dispositivos cuentan con tres acelerómetros lineales y tres giroscopios, dispuestos de manera ortogonal entre sí, para medir la información sobre los tres ejes definidos en el espacio 3D. Su principal aplicación se encuentra en los sistemas de navegación, sin embargo, en los últimos años han sido ampliamente utilizados en el estudio de movimiento humano y robótica [34, 45, 46].

Una gran desventaja que tienen estos dispositivos es que son susceptibles a los errores acumulativos. Esto se debe al proceso de integración para el cálculo de la orientación del giroscopio, el cual al cambiar de dirección puede ocasionar un error en la medición que se acumula y aumenta con cada integración. El uso del acelerómetro permite corregir estos errores durante la estimación de la orientación y solo es capaz de corregir de manera eficaz los ejes que se encuentran sobre el plano de tierra [47]. Para corregir estos errores durante la estimación de la orientación sobre el eje perpendicular al plano de tierra, los magnetómetros han sido una opción que ha demostrado aumentar en gran medida la precisión.

### **2.4.2 MARG**

Los sensores MARG (*Magnetic, Angular Rate, Gravity*) son dispositivos que integran las capacidades de los IMU añadiendo sensores magnéticos para corregir los errores de estimación de la orientación sobre el eje vertical al plano de tierra [47]. Al igual que los IMU, en los MARG también se cuenta con tres acelerómetros lineales, tres giroscopios y tres magnetómetros dispuestos de manera ortogonal entre sí para la medición sobre los tres ejes en el espacio. La inclusión de los magnetómetros permite utilizar el campo magnético local para generar un sistema de referencia para la corrección de las derivas y en combinación con el acelerómetro se genera un sistema de referencia geodésico para los tres ejes [48-50].

### **2.4.3 Sensores IMU/MARG comerciales**

En el mercado podemos encontrar sensores IMU/MARG los cuales contienen algoritmos propios para calcular la posición y orientación de objetos en el espacio tridimensional. Algunos ejemplos de estos sensores son los desarrollados por compañías como Xsens, Shimmer sensing, InterSense, Technaid, IMeasureU o Noraxon [51]. Empresas como Xsens o Shimmer desarrollan sus dispositivos con algoritmos de fusión de datos propios diseñados para su aplicación con propósitos médicos y de entretenimiento [52, 53].

## **2.5 Análisis de movimiento humano con *machine learning***

### **2.5.1 Conceptos generales**

El aprendizaje automático, *machine learning*, es una disciplina de la inteligencia artificial que, a través de algoritmos, permite identificar patrones en datos masivos y elaborar predicciones. Esta disciplina se divide en dos áreas principalmente denominadas aprendizaje supervisado y aprendizaje no supervisado. La primera requiere la intervención humana para el entrenamiento de patrones y características asociadas a categorías en la base de datos de su predicción. La segunda no requiere de la intervención humana, ya que el sistema se encarga de buscar y organizar las características o patrones mediante la exploración de la base de datos. El aprendizaje automático es normalmente utilizado para realizar tareas de clasificación o regresión. La primera tarea sirve para predecir categorías que comparten las mismas características, mientras que la segunda sirve para predecir números basándose en las características del conjunto de entrenamiento.

Algunos conceptos claves para *machine learning* son [54]:

- **Entrenamiento:** También llamado aprendizaje, es el proceso en el que se detectan los patrones de un conjunto de entrenamiento. Una vez identificados los patrones, es posible utilizar datos nuevos para predecir los objetivos entrenados.
- **Conjunto de datos:** Es el histórico de datos utilizado para el entrenamiento del sistema. Esta información es utilizada durante la etapa de entrenamiento para el reconocimiento de los objetivos a los cuales se enfocará el aprendizaje. El conjunto de datos se compone de instancias.
- **Instancia:** Se refiere a cada uno de los datos disponibles para hacer un análisis. Estos datos se componen de características o patrones los cuales identifican a la instancia a una categoría a predecir.
- **Características:** Son los atributos que describen el comportamiento de la instancia a la que corresponden.
- **Objetivo:** Es el atributo que se quiere predecir. Esta información es utilizada durante el entrenamiento para asociar las características de una instancia a una categoría particular.
- **Modelo:** Es el resultado del sistema entrenado. El modelo sirve como filtro en el que entran datos nuevos y la salida muestra la clasificación los datos según los patrones que se han detectado en el entrenamiento.
- **Minería de datos:** Es un concepto asociado al aprendizaje automático en el que se descubren patrones anteriormente desconocidos. La minería de datos se puede realizar como una etapa previa al entrenamiento del sistema dentro del aprendizaje no supervisado.
- **Redes neuronales artificiales:** Son modelos computacionales que simulan la actividad de las redes neuronales biológicas. Consisten en un conjunto de unidades conectadas entre sí para transmitir señales produciendo valores de salida correspondientes a una categoría.
- **Deep Learning:** Es un tipo de *machine learning* inspirado en como las redes neuronales biológicas procesan la información. En estos sistemas, cada capa de la red neuronal transforma los datos que recibe en una representación más compleja

alcanzando una comprensión muy detallada de los datos que equivale a una forma de razonamiento inteligente.

- **Hiper-Parámetros:** son los factores de entrenamiento que componen una red neuronal artificial. Estos varían su valor durante la fase de entrenamiento permitiendo que el modelo ajuste los parámetros de entrada para aproximarlos a los parámetros de salida.
- **Robots:** Son máquinas programables capaces de realizar determinadas operaciones de manera autónoma. Pueden sustituir a los seres humanos en algunas tareas que requieren de precisión y repetición además de poder ser utilizados en ambientes peligrosos para un humano.
- **Sistemas expertos:** Son aplicaciones tecnológicas capaces de resolver problemas en un dominio muy específico el cual puede alcanzar y superar el rendimiento humano dentro de este dominio.
- **Agentes inteligentes:** Son entidades capaces de percibir su entorno, procesar la información que perciben y responden o actúan en su entorno de manera racional de manera correcta.

### 2.5.2 Principios básicos de las redes neuronales artificiales

Las redes neuronales artificiales, como su nombre indica, son redes computacionales que simulan, *grosso modo*, el proceso de decisión de las neuronas en el sistema nervioso central. Esta simulación, calculada celda-a-celda (neurona-a-neurona), se basa en los conocimientos en neurofisiología acerca de las neuronas biológicas y las redes que conforman. Las redes neuronales artificiales son arquitecturas computacionales que permiten utilizar operaciones computacionales básicas (adición, multiplicación y elementos lógicos fundamentales) para resolver problemas matemáticos poco definidos, problemas no lineales o estocásticos [55].

#### 2.5.2.1 Fundamentos biológicos de las redes neuronales artificiales

Las redes neuronales biológicas se conforman de células nerviosas (neuronas) interconectadas entre sí, Figura 4.

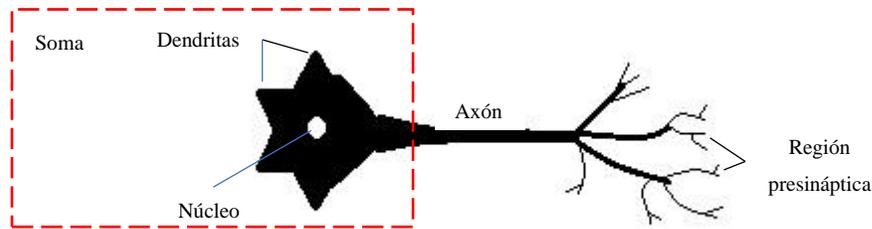


Figura 4. Neurona biológica.

El cuerpo de la neurona, también conocido como soma, es la zona donde se lleva a cabo la mayor parte del “cómputo” neural. El axón puede verse como un cable de conexión en el cual el mecanismo de conducción de la actividad neural se realiza mediante estímulos eléctricos causados por un proceso electroquímico de intercambio iónico a lo largo del axón y de difusión de moléculas de neurotransmisores a través de la membrana sobre el espacio sináptico, Figura 5. Este proceso se lleva a cabo a lo largo del axón y a través de las uniones sinápticas al final del axón y las dendritas y/o soma de la siguiente neurona, por medio de un estrecho espacio sináptico, a una velocidad promedio de 3m/s [55].

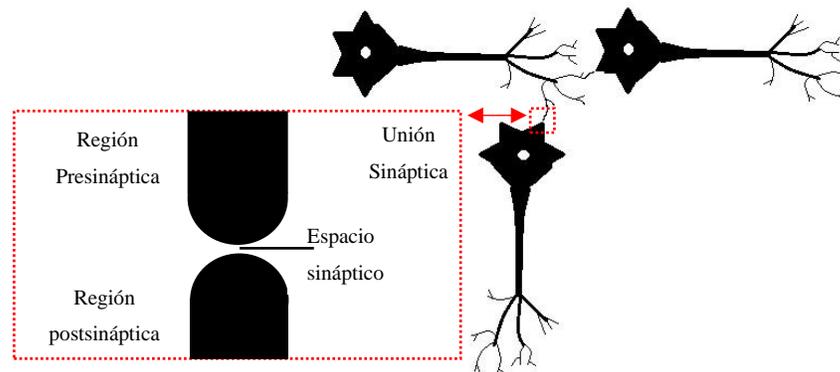


Figura 5. Conexión de neuronas biológicas.

Debido a la cantidad de axones terminales que tiene una neurona, cada neurona es capaz de enviar cientos de señales a diferentes neuronas. De igual manera, debido a la cantidad de dendritas que tiene el soma de una neurona, es capaz de recibir señales de diferentes neuronas. De esta manera se realiza la interconexión en red de una neurona biológica. Es importante notar que no todas las conexiones entre neuronas se realizan de la misma manera. Cada conexión entre neurona tiene una prioridad, peso, diferente debido a una propiedad denominada plasticidad sináptica la cual modifica la eficacia en la transferencia de la

información. Esta propiedad se debe a las diferencias químicas existentes en los transmisores y sustancias moduladoras dentro y alrededor de cada neurona.

La naturaleza de la red formada por las neuronas biológicas y la prioridad que tienen entre cada conexión sirven como base para la formación del modelo de las redes neuronales artificiales. De manera simple, un diagrama a bloques como el mostrado en la Figura 6, demuestra la relación entre ambos modelos. Mientras que la Figura 7, muestra cómo sería la conexión entre dos neuronas.

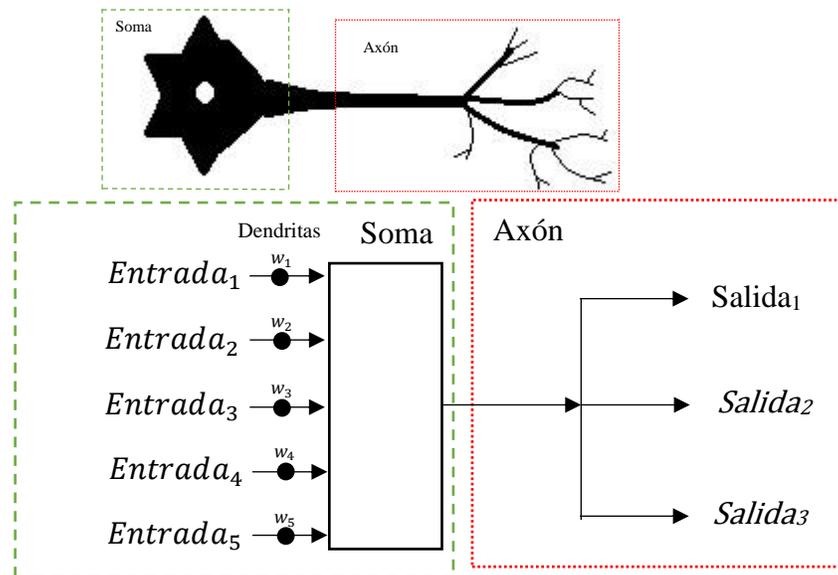


Figura 6. Diagrama esquemático de una neurona biológica. Donde  $W$  indica el peso sináptico para cada conexión.

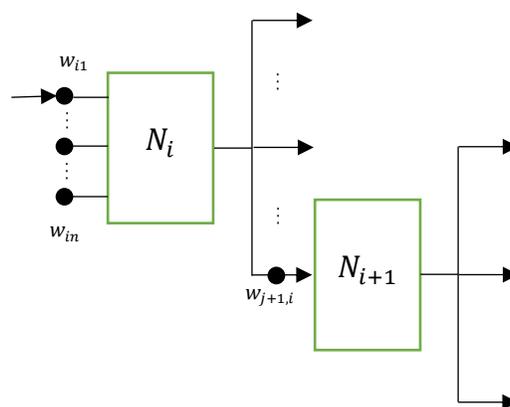


Figura 7. Representación esquemática de la neurona biológica y su conexión entre capas. Donde  $N$  representa una neurona, el subíndice "i" indica la capa en la que se encuentra y  $W$  son los pesos sinápticos entre las neuronas.

### 2.5.2.2 Threshold Logic Unit (TLU)

Los principios básicos de las redes neuronales artificiales fueron formulados por McCulloch y Pitts en 1943 dadas los siguientes cinco supuestos [56]:

- La actividad de una neurona es de todo o nada.
- Un cierto número de sinapsis mayores a uno debe ser excitado dentro de un intervalo de adición neuronal para que la neurona se excite.
- El único retraso significativo en el sistema neural es el retraso sináptico.
- La actividad de cualquier sinapsis inhibitora previene la excitación de la neurona.
- La estructura de conexión en la red neuronal no cambia con el tiempo.

Estos supuestos se postularon para su unidad lógica de umbral (TLU, *Threshold Logic Unit*), la cual es una forma básica de red neuronal artificial que consiste en una sola entrada con sus correspondientes pesos y una función de activación. Este modelo sirvió de inspiración para la formación posterior del perceptrón.

### 2.5.2.3 Perceptrón

El perceptrón posee la estructura fundamental de una neurona, varias entradas ponderadas que se conectan a las salidas de otras neuronas y en el lado de la salida se conectan con las entradas de otras neuronas, Figura 8, [57, 58].

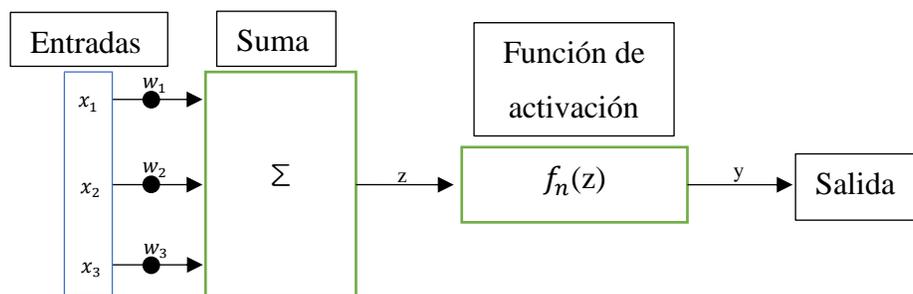


Figura 8. Estructura del perceptrón. Donde “x”, indica el patrón de entrada, “W” el peso sináptico, “z” la sumatoria del producto de los pesos sinápticos con sus entradas, “ $f_n$ ” la función de activación y “y” la salida de la red neuronal artificial.

El cálculo en la neurona consiste en la suma ponderada de las entradas seguida de una función no lineal. Esto simula la excitación/inhibición de la neurona, Ecuación (2):

$$z_i = \sum_{j=1}^m w_{ij} x_{ij} \quad (2)$$

Donde  $w_{ij}$  es el peso de la  $j$ -ésima entrada en la  $i$ -ésima neurona. Vectorialmente, la ecuación anterior puede escribirse como, Ecuación (3):

$$z_i = w_i^T x_i \quad (3)$$

Donde

$$w_i = [w_{i1} \dots w_{in}]^T \quad (4)$$

$$x_i = [x_{i1} \dots x_{in}] \quad (5)$$

T denota la transpuesta de  $w$ .

La suma de las entradas ponderadas utiliza una función de activación para determinar el estado de activación de la neurona el cual simula el potencial de acción de una neurona biológica. La función de activación mantiene los valores de salida de la neurona entre ciertos límites (dependientes del tipo de función) como en el caso de la neurona biológica. La función de activación más común es la función sigmoide la cual es una función diferenciable continua, Ecuación (6) [59].

$$y_i = \frac{1}{1 + e^{-z_i}} = f(z_i) \rightarrow \begin{cases} z_i < 0 \rightarrow y_i = 0 \\ z_i = 0 \rightarrow y_i = 0.5 \\ z_i > 0 \rightarrow y_i = 1 \end{cases} \quad (6)$$

Otras funciones comunes son las siguientes:

- Función de activación sigmoide hiperbólica, Ecuación (7).

$$y_i = \frac{1 - e^{-z_i}}{1 + e^{-z_i}} \rightarrow \begin{cases} z_i < 0 \rightarrow y_i = -1 \\ z_i = 0 \rightarrow y_i = 0 \\ z_i > 0 \rightarrow y_i = 1 \end{cases} \quad (7)$$

- Función de activación límite duro (*Hardlim*), Ecuación (8).

$$\begin{cases} z_i \geq 0 \rightarrow y_i = 1 \\ z_i < 0 \rightarrow y_i = 0 \end{cases} \quad (8)$$

- Función de activación unidad de rectificación lineal (*ReLU*), Ecuación (9).

$$\begin{cases} z_i < 0 \rightarrow y_i = 0 \\ z_i \geq 0 \rightarrow y_i = z_i \end{cases} \quad (9)$$

- Función de activación lineal, Ecuación (10).

$$\{y_i = z_i\} \quad (10)$$

A pesar de que el perceptrón es solo una neurona, estos permiten resolver problemas linealmente separables. Para resolver problemas que no son linealmente separables se realiza una generalización del perceptrón añadiendo más perceptrones en diferentes etapas creando lo que se conoce como perceptrón multi capas (MLP, *Multi-Layer Perceptron*).

#### 2.5.2.4 Perceptrón multi capas (MLP)

Los perceptrones multicapa son la aplicación de varios perceptrones interconectados para la creación de una red [59, 60]. El cálculo de la red se realiza neurona a neurona capa a capa y puede tener una o más salidas, Figura 9.

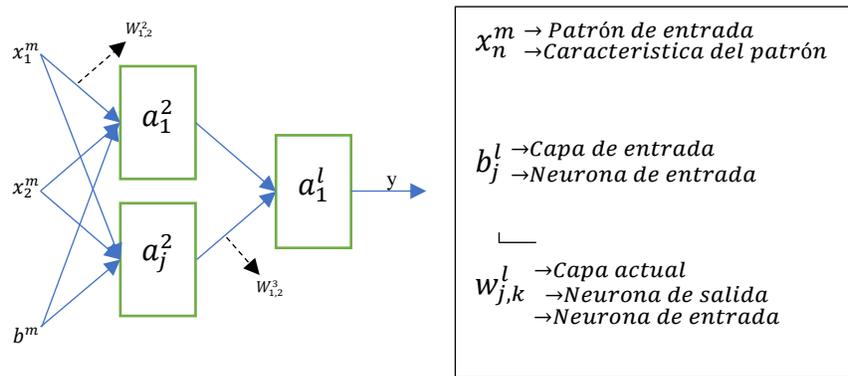


Figura 9. Estructura de un MLP.

Donde:  $x$  representa al vector de entradas en la red,  $b$  representa un valor de umbral (bias) el cual permite una tendencia a la excitación/inhibición en la conexión entre neuronas,  $w$  representa los pesos de cada entrada y entre neuronas;  $y$  a representa las neuronas. Las estructuras creadas por estos perceptrones dan la posibilidad de resolver problemas linealmente no separables.

#### 2.5.2.5 Otros tipos de redes neuronales artificiales

Otros tipos de redes neuronales artificiales que podemos encontrar son las redes neuronales convolucionales (CNN, *convolutional neural network*), redes neuronales recurrentes (RNN, *recurrent neural networks*), redes de función de base radial (RBFN, *radial basis function network*) [61].

Las redes neuronales convolucionales son redes neuronales de aprendizaje profundo utilizadas normalmente en imágenes para la identificación de objetos, rostros, siluetas y clasificación de escenas e imágenes en general. Estos modelos hacen uso de filtros (*kernels*) que se aplican a la imagen para la extracción de características importantes dentro de la imagen. El proceso de convolución entra al usar estos *kernels* para recorrer la imagen, se realiza un producto escalar para esta etapa, obteniendo un tamaño de la imagen menor con las características del *kernel* resaltadas. Esta nueva imagen será utilizada con un clasificador (por ejemplo, un MLP) para la identificación de las características que se buscan obtener en la imagen [62].

Las redes neuronales recurrentes se utilizan para el análisis de datos de series temporales permitiendo tratar el tiempo como una característica distinguible entre los datos a procesar. Como su nombre indica, estas redes tienen conexiones de retroalimentación entre las neuronas dentro las capas, pudiendo tener neuronas con una salida a sí misma. Esto ocasiona que en cada instante de tiempo la neurona recurrente reciba una entrada de la capa anterior, así como su propia salida de un instante de tiempo anterior [63].

Las redes de función de base radial se caracterizan por que las neuronas en la capa oculta calculan la distancia euclídea entre el vector de pesos sinápticos (en este tipo de redes se les llama centroides o redes de centro) y la entrada, y sobre esta distancia se aplica una función de activación de tipo radial con forma gaussiana. Su aplicación principal es de aproximador de funciones, predicción de series temporales, clasificación, y sistemas de control [64].

### **2.5.3 Métodos de aprendizaje**

#### *2.5.3.1 Retropropagación del error (BP)*

El entrenamiento de una red neuronal artificial consiste en la actualización de los pesos y bias con el fin de que el resultado obtenido a la salida de la red sea cercano al valor deseado para cada muestra de entrenamiento. El método de retropropagación del error consiste en calcular el error en la capa de salida (diferencia entre el valor obtenido y el valor deseado para cada neurona) y propagar el error de cada neurona de salida a cada una de la neuronas asociadas a dicha neurona de salida hasta llegar a la entrada de la red [55].

El proceso para realizar la retropropagación del error se puede dividir en 5 pasos:

- Cálculo de la salida de la red (Feed-forward).

- Cálculo del error de la salida de la red y propagación del error de la capa de salida.
- Actualización de los pesos y bias en la capa oculta.
- Cálculo del error de la capa oculta y propagación del error de la capa oculta.
- Actualización de los pesos y bias en la capa de entrada.

El cálculo de la salida de la red. Ecuaciones (11-14) se divide en cuatro cálculos matemáticos. El primero, Ecuación (11), es la sumatoria del producto entre el vector de entrada ( $x_k^1$ ) y los pesos sinápticos ( $W_{j,k}^2$ ) más el bias ( $b_j^2$ ) entre el vector de entrada y la capa oculta. El segundo, Ecuación (12), es la aplicación de la función de activación (sigmoide para este ejemplo) al valor obtenido ( $z_j^2$ ) en cada neurona de la capa oculta. El tercer cálculo, Ecuación (13), es la sumatoria del producto entre la salida de las neuronas en la capa oculta ( $a_j^2$ ) y los pesos sinápticos ( $W_{i,j}^3$ ) más el bias ( $b_i^3$ ) entre la capa oculta y la capa de salida. Por último, la salida de la red, Ecuación (14), se calcula utilizando la función de activación (nuevamente sigmoide para el ejemplo) al valor obtenido ( $z_i^3$ ) en cada neurona de la capa de salida.

$$z_j^2 = \sum (W_{j,k}^2 x_k^1 + b_j^2) \quad (11)$$

$$a_j^2 = \frac{1}{1 + e^{(-z_j^2)}} \quad (12)$$

$$z_i^3 = \sum (W_{i,j}^3 a_j^2 + b_i^3) \quad (13)$$

$$y_i^3 = \frac{1}{1 + e^{(-z_i^3)}} \quad (14)$$

El error de la salida de la red ( $\delta_i^3$ ) se calcula con la función de costo de la red ( $C_l$ ), Ecuación (15).

$$C_l = \frac{1}{2} (t_l - y_l^3)^2 \quad (15)$$

A continuación se propaga el error mediante la derivada parcial de la función de costo de la red con respecto a la salida de cada neurona en la capa oculta, Ecuación (16). El resultado de cada derivada parcial ( $\delta_i^3$ ) determina la contribución de cada neurona al error de la red.

$$\delta_i^3 = \frac{\partial C_l}{\partial z_j^3} \quad (16)$$

La actualización de pesos y bias en la capa oculta, Ecuaciones (17-19), se calcula a partir de la contribución al error de la red por parte de cada neurona de la capa oculta. Este proceso

consiste en calcular la contribución de cada peso sináptico al error de la red ( $\frac{\partial C_l}{\partial W_{l,j}^3}$ ). Para acelerar el proceso del entrenamiento se utiliza un factor de aprendizaje ( $\alpha$ ). Por ultimo, se suma el cambio en el valor del peso sináptico ( $\Delta W_n^3$ ) al valor del peso sináptico actual ( $W_n^3$ ) para obtener el peso sináptico actualizado ( $W_{n+1}^3$ ).

$$\frac{\partial C_j}{\partial W_{l,j}^3} = \delta_l^3 a_j^2 \quad (17)$$

$$\Delta W_{l,j}^3 = \alpha \delta_l^3 a_j^2 \quad (18)$$

$$W_{n+1}^3 = W_n^3 + \Delta W_n^3 \quad (19)$$

Del mismo modo se calcula el cambio en el valor del bias para la capa oculta, Ecuaciones (20-22).

$$\frac{\partial C_l}{\partial b_l^3} = \delta_l^3 \quad (20)$$

$$\Delta b_l^3 = \alpha \delta_l^3 \quad (21)$$

$$b_{n+1}^3 = b_l^3 + \Delta b_l^3 \quad (22)$$

El cuarto paso consiste en calcular el error en la capa oculta ( $\delta_j^2$ ). Esto se realiza calculando la contribución al error de la función de costo con respecto a cada neurona de la capa oculta, Ecuación (23).

$$\delta_j^2 = \frac{\partial C_l}{\partial z_j^2} \quad (23)$$

Al igual que en la actualización de pesos sinápticos y bias entre la capa oculta y la salida de la red, la actualización de pesos sinápticos en la capa de entrada, Ecuaciones (24-26), y el bias en la capa de entrada, Ecuaciones (27-29), se calcula con la contribución al error en la capa oculta por cada peso sináptico y bias.

$$\frac{\partial C_l}{\partial W_{j,k}^2} = \delta_j^2 x_k^1 \quad (24)$$

$$\Delta W_{j,k}^2 = \alpha \delta_j^2 x_k^1 \quad (25)$$

$$W_{n+1}^2 = W_{j,k}^2 + \Delta W_{j,k}^2 \quad (26)$$

$$\frac{\partial C_l}{\partial b_j^2} = \delta_j^2 \quad (27)$$

$$\Delta b_j^2 = \alpha \delta_j^2 \quad (28)$$

$$b_{n+1}^2 = b_j^2 + \Delta b_j^2 \quad (29)$$

### 2.5.3.2 Otros métodos de aprendizaje

Además del algoritmo de retropropagación del error, existen otros métodos para el ajuste de los pesos y bias de la red neuronal artificial durante su entrenamiento. A continuación, se mencionan algunos [58]:

- Mínimos cuadrados promedio (LSM, *least square means*): Es un método utilizado en análisis de regresión para aproximar funciones de acuerdo con el criterio de mínimos cuadrados. En redes neuronales artificiales se utiliza para crear un modelo en el que los pesos y bias se ajusten de tal manera que se minimice la suma de los errores al cuadrado entre los datos obtenidos y sus predicciones.
- Análisis discriminante lineal (LDA, *linear discriminant analysis*): Es un método de clasificación supervisado en el que se busca reducir la dimensionalidad de los datos al convertirlos en un plano de una dimensión para su clasificación de manera eficiente. Al hacer esto se minimiza la varianza entre datos de la misma clase y se maximiza la distancia entre los promedios de cada clase.
- Gradiente descendiente: Este método es la base de la retropropagación del error. El gradiente es el conjunto de todas las derivadas parciales de la función de costo en el que se buscan los parámetros para minimizan esta función.
- Aprendizaje Bayesiano: Este método utiliza el teorema de Bayes para optimizar los parámetros mediante distribuciones probabilísticas de los datos observados.
- Aprendizaje Hebbiano: Este método utiliza la teoría de Hebb para adecuar los pesos y bias del modelo bajo la premisa “las células que se activan unidas permanecen unidas”. Dicho de otro modo, las conexiones entre neuronas se refuerzan cuando se activan simultáneamente se hacen más fuertes y difíciles de romper. Esto indica que la búsqueda de optimización de los parámetros se basa en la identificación de las

neuronas que mayor peso tiene cuando se encuentra un resultado favorable para mantenerlas así durante el entrenamiento.

- k-means: Este método de aprendizaje no supervisado intenta agrupar datos basados en su similitud. Para este método se define un centroide para cada grupo a clasificar y con estos centroides se calcula la distancia entre los datos para clasificarlo como un grupo particular. La idea es que los datos que se encuentren más cerca de un centroide pertenecen a esa categoría debido a su similitud.

#### **2.5.4 Validación de los modelos de redes neuronales artificiales**

La validación del modelo de una red neuronal artificial permite identificar el sobreaprendizaje o pérdida de generalización [65]. El sobreaprendizaje de un modelo se identifica al exponer el modelo entrenado a un conjunto de datos desconocido (no utilizado para el entrenamiento) y éste entrega un resultado sesgado a una o varias clases aún cuando los datos corresponden a clases distintas. La pérdida de generalización de un modelo se identifica cuando se expone el modelo entrenado a un conjunto de datos (conocidos o desconocidos) y éste entrega, en su mayoría, resultados que pertenecen a más de una clase o a ninguna.

##### *2.5.4.1 Validación cruzada (cross-validation)*

La validación por k-fold o validación cruzada consiste en segmentar el conjunto de entrenamiento en K segmentos para generar K modelos entrenados independientemente, Figura 10.

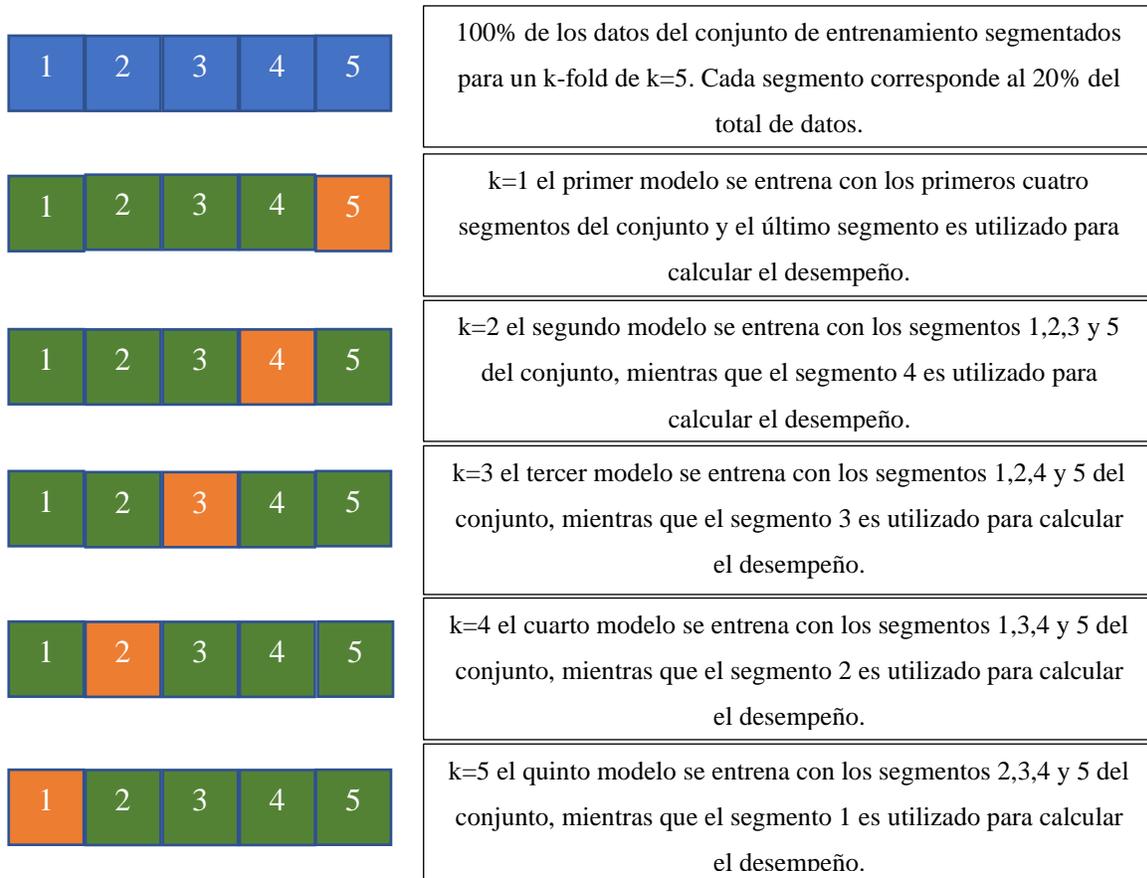


Figura 10. Segmentación del conjunto de entrenamiento por K-fold para una  $k=5$ .

Cada modelo consiste en el entrenamiento de  $k-1$  segmentos, mientras que el  $k$ -ésimo segmento es utilizado para calcular el desempeño del modelo. El propósito de esta técnica es el de utilizar al menos en una ocasión cada muestra como conjunto de validación para un modelo en el cual no se ha utilizado esa información. El desempeño de la validación se calcula con el promedio de los  $K$  modelos.

#### 2.5.4.2 Matrices de confusión

Las matrices de confusión son una herramienta utilizada en *machine learning* que permite visualizar el desempeño de un clasificador. Cada columna de la matriz corresponde a las predicciones de cada clase, mientras que cada fila corresponde a las instancias en la clase real. Para clasificadores multiclase, las matrices de confusión tiene tantas columnas como clases, mientras que las filas tener una clase extra en la que se tienen los datos mal clasificados ya sea porque su predicción fue con dos o más clases o bien por predecirlo como

ninguna clase. La diagonal principal de la matriz contiene los elementos correctamente clasificados para cada clase, por lo que con esta información es posible calcular el desempeño del clasificador. Por otra parte, los resultados que no se encuentran sobre la diagonal principal indican a con que clase se ha confundido una predicción. Esta información permite calcular la sensibilidad y especificidad del clasificador [66].

#### 2.5.4.3 Curvas de ROC

Las curvas características operativas del receptor (*ROC, Receiver Operating Characteristic, curve*) son una representación gráfica de la sensibilidad frente a la especificidad de un clasificador binario de acuerdo con el umbral de discriminación [67]. Para el caso de clasificadores multi clase, se utiliza una comparación uno-contra-todos (*One-vs-All*) en las que se utiliza la sensibilidad y especificidad de una clase en particular contra el resto de las clases. Estas curvas indican el punto de corte en el que se alcanza la sensibilidad y especificidad más alta, y la capacidad discriminativa del clasificador al estimar el área bajo la curva (*AUC, Area Under the Curve*) [68].

#### 2.5.4.4 Función de costo/perdida

Las funciones de costo perdida son una representación gráfica del entrenamiento de un modelo de red neuronal artificial. En ellas se compara el error entre los valores obtenidos en la salida del modelo de RNA y los objetivos que deben alcanzar. Esta información se utiliza en conjunto con el método de aprendizaje para determinar el desempeño de la RNA y actualizar los hiper-parámetros durante la fase de entrenamiento. El resultado de esta función también sirve para indicar si el modelo es capaz de aproximar los datos entrenados lo suficientemente cerca a los valores de los objetivos para señalar el momento en el que el modelo se encuentra entrenado. Esto último se determina mediante el error propuesto al que debe converger el modelo [69].

### Capítulo 3. Estado del arte

El estudio del movimiento humano mediante el uso de robots se realiza comparando la actividad realizada por un humano y precisión en la imitación que el brazo es capaz de realizar [35, 70-73]. La mayoría de estos robots están enfocados en la rehabilitación del movimiento de una persona [74, 75]. Comercialmente, existen robots que tiene la facultad para medir los movimientos de los segmentos durante los ejercicios de rehabilitación, pero debido a su alto costo, tamaño y complejidad de operación, no son tan accesibles al público [76, 77]. En investigación, se han utilizado robots que simulan actividades humanas para validar la respuesta de algoritmos para sensores IMU/MARG [78-80]. Los brazos robóticos en combinación con técnicas de *machine learning* han permitido optimizar las trayectorias y mejorar la precisión de la posición en las actividades que realizan los robots en la industria [81, 82], así como limitar la velocidad y potencia con la que actúan los robots con el fin de optimizar la producción [83, 84] y determinar los tiempos para los mantenimientos de los robots [85, 86]. Para el análisis de movimiento humano, se han utilizado redes neuronales artificiales en combinación de robots para mejorar las condiciones de movimiento en rehabilitación [87, 88] o para predecir la intención del movimiento [14, 89, 90]. La información presentada por estos modelos de redes neuronales artificiales también ha favorecido el control de movimiento de los robots para su colaboración con humanos [18, 91] e incluso se ha llegado a imitar el comportamiento humano [92, 93]. Algunos estudios se han enfocado en aplicar redes neuronales artificiales para el entendimiento del movimiento humano [16, 94-96]. A continuación, se resumen algunos trabajos contemporáneos en los que se emplea el uso de brazos robóticos para el estudio del movimiento de la extremidad superior humana Tabla 2.

Tabla 2. Estado del arte de robots para el estudio de movimiento de la extremidad superior humana.

Año	Autor(es)	Articulaciones	Control	Movimientos
2018	Ali et al. [97]	Hombro	PID y Lógica Difusa	Flexo-extensión de hombro
2019	Kapsalyamov et al. [98]	Codo	Redes neuronales artificiales y EEG con BCI.	Flexión-extensión de codo.
2020	Laksono et al. [99]	Hombro y Codo	EMG	Flexión de codo Flexión de hombro Flexión de hombro y codo (uppercut motion).
2021	Laksono et al. [100]	Hombro y Codo	Machine Learning (KNN, SVM y Ensemble) y EMG	Flexión de codo Flexión de hombro Flexión de hombro y codo (uppercut motion).
2021	Schabron et al. [101]	Hombro y Codo	RNA y sEMG	Flexión-extensión de hombro Abducción-aducción de hombro Flexión-extensión de codo
2021	Gulleta et al. [102]	Hombro, Codo y Muñeca	Virtual Robot Experimentation Platform y Denavit-Hartenberg	Pick & Place: Transportar, acerca y retraer.

El trabajo presentado por Ali et al. [97] propone el diseño de un control para robots de rehabilitación de extremidad superior para pacientes post accidente cerebrovascular en los que parametriza el movimiento de flexo-extensión de hombro mediante la combinación de lógica difusa y un controlador PID. Los resultados obtenidos en este trabajo muestran la

ejecución de flexo-extensión del hombro como una respuesta de 0 o 1 dependiendo si ha realizado o no la acción.

El trabajo de Kapsalyamov et al. [98] utiliza un registro de electroencefalografía con una interfaz cerebro-computadora (BCI) para la activación de actuadores. Una red neuronal artificial es utilizada para determinar la activación de los actuadores para el movimiento de flexo-extensión del codo.

Los trabajos de Laksono et al [99, 100], utilizan señales de electromiografía para la activación de los movimientos de flexo-extensión de hombro, flexo-extensión de codo y flexo-extensión conjunta de hombro y codo (*uppercut motion*) con un brazo robótico. En [99], los actuadores del brazo se activan una vez que el registro de electromiografía supera un umbral. Mientras que en [100] utilizan modelos de *machine learning*, k-vecino más próximos (KNN), Máquinas de soporte vectorial (SVM) y Modelos de ensamble (*Ensemble*), para clasificar los movimientos mencionados anteriormente. En total, generan 48 modelos en los que el desempeño varía de 74-98%, siendo Ensemble de 12 parámetros (KNN en subespacios aleatorios) el que mejores resultados obtuvo.

El trabajo presentado por Schabron et al. [101] utiliza señales de electromiografía superficial para registra posiciones de mano para la activación de un brazo robótico montado sobre un silla de ruedas. Se distinguen entre 10 posiciones diferentes para controlar cuatro movimientos del brazo robótico: flexo-extensión de hombro, abducción-aducción de hombro, flexo-extensión de codo y descanso. La clasificación de los movimientos obtuvo un desempeño ente el 87.7% y 97.4%.

El trabajo de Gulleta et al. [102] utiliza un sistema de visión para identificar objetos con el fin de evadir obstáculos y realizar tarea de *pick & place* con un brazo robótico. El sistema utiliza la información del sistema de visión para determinar la trayectoria a realizar por el brazo robótico siguiendo la convención Denavit-Hartenberg y un algoritmo propuesto denominado Planificador de movimiento de extremidad superior similar a un humano (HUMP, *Human-like Upper-limb Motion Planner*). En este trabajo se presenta un brazo robótico de 7 grados de libertad con movimientos de hombro, codo y muñeca, y 4 grados de libertad para un manipulador como efector final. En condiciones controladas, el desempeño del brazo robótico para simular la actividad de pick and place varía entre el 78-92%.

En el presente trabajo se propone el diseño de un brazo robótico que permita simular los movimientos de la extremidad superior humana en siete grados de libertad: 3 en el hombro, 1 en el codo, 2 en la muñeca y el movimiento de pronosupinación del antebrazo. Para medir la actividad del brazo robótico, se utilizarán los sensores Xsens colocados en los segmentos del brazo, antebrazo y mano para registrar su actividad. Además, se hará uso de redes neuronales artificiales para obtener un modelo que tenga la capacidad de reconocer patrones de movimiento relativos a actividades de la extremidad superior derecha. Estos movimientos se ejecutarán en actividades que involucran un grado de libertad en una de las articulaciones, la condición estática de la persona y el movimiento *Reach-to-Grasp*. Las actividades con movimiento en un grado de libertad seleccionados para clasificarse en el modelo de red neuronal artificial propuesto son: flexo-extensión del hombro, abducción-aducción del hombro, flexo-extensión del codo, flexo-extensión de muñeca, abducción-aducción de muñeca y la condición estática de la persona.

## Capítulo 4. Metodología

### 4.1 Consideraciones para el Diseño del Brazo Robótico

Con la idea de llevar a cabo el diseño de un brazo robótico para el estudio del movimiento de la extremidad superior humana se tomaron como referencia estudios de antropometría enfocados en la medición de los segmentos de la extremidad superior humana. Esta información permitirá definir los parámetros requeridos para el diseño del brazo robótico tales como el torque que requiere cada articulación para sus movimientos, seleccionando de esta manera los actuadores que se requieren para cada grado de libertad en las articulaciones de interés y las dimensiones de los elementos de enlace (segmentos) entre actuadores.

#### 4.1.1 Antropometría de la Extremidad Superior en México

El diseño del brazo robótico se realizó considerando las medidas antropométricas de la población mexicana adulta en la zona metropolitana de la Ciudad de México. El estudio, realizado por el Instituto Politécnico Nacional en 2015, contó con un total de 974 participantes entre los 18-64 años [103]. El criterio de medición para los segmentos se realizó de acuerdo con la imagen presentada en la Figura 11.

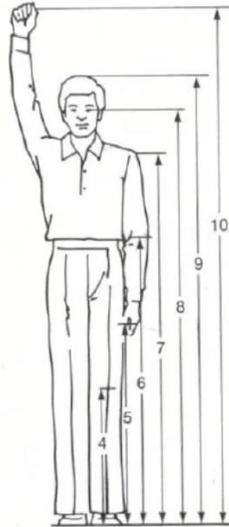


Figura 11. Método de medición de la extremidad superior [104].

Los resultados obtenidos en este estudio, enfocados en la extremidad superior, se resumen en la Tabla 3.

*Tabla 3. Medidas antropométricas de la extremidad superior en población de la zona metropolitana de la Ciudad de México en edad entre los 18 a 68 años.*

<b>Dimensiones</b>	<b>Percentiles</b>		
	<b>5</b>	<b>50</b>	<b>95</b>
<b>Peso</b>	55.46kg	70.26kg	96.55kg
<b>Altura</b>	162.12cm	170.86cm	185.67cm
<b>Distancia Hombro- Codo</b>	32.59cm	35.61cm	39.26cm
<b>Distancia Codo-Dedo medio</b>	42.00cm	45.49cm	49.12cm
<b>Largo de la mano</b>	16.43cm	18.14cm	19.59cm

Debido a la variabilidad antropométrica, se toma el percentil 50 como referencia para el diseño del brazo robótico. El segmento del brazo (distancia hombro-codo) tiene una medida promedio de 35.6cm, el segmento del antebrazo (distancia codo-muñeca), obtenido de la diferencia entre la distancia codo-dedo medio y largo de la mano, es de 27.35cm, mientras que el largo de la mano tiene una medida de 18.14cm.

El peso aproximado de una mano humana es de 400g [105], mientras que el antebrazo y el brazo representan un 2.3% y 5%, respectivamente del peso total del cuerpo de una persona [106, 107]. De acuerdo con la información de [103], el peso promedio de los sujetos de prueba fue de 73.709kg, con una desviación estándar de 11.201kg. Con esta información podemos estimar el peso de cada uno de los segmentos que tendría la extremidad superior y con ello realizar el cálculo teórico del torque que requieren los motores para simular los movimientos humanos.

#### 4.1.2 Selección de los actuadores

De acuerdo con [38] los centros de gravedad (cg) en proporción a la longitud los segmentos de la mano, antebrazo y brazo se encuentran en un 39.7%, 42.4% y 45.2%, respectivamente, de la distancia desde el punto proximal al punto distal (r). El cálculo del torque se realiza mediante la Ecuación (30)

$$\tau = kg_f * (r * cg) \quad (30)$$

Sin embargo, esta información solo permite calcular el torque que requieren los motores colocados en la muñeca, Ecuación (31).

$$\tau = 0.4 kg_f * (18.14 * 0.397) cm = \mathbf{2.88 kg_f \cdot cm} \quad (31)$$

Para el cálculo del torque necesario de los motores que se utilizarían en las articulaciones del codo y hombro, se consideró que el centro de gravedad se encuentra a la mitad de la distancia entre el punto proximal y el punto distal del segmento. Esto se debe a que, en el cálculo del centro de gravedad para cada uno de los segmentos involucrados, no se considera el peso de los segmentos contiguos, por lo tanto, se considera un factor de seguridad con el centro de gravedad al 50% de la distancia entre el punto proximal y el punto distal. El torque teórico necesario del motor para el movimiento del codo se calculó con la Ecuación (32).

$$\tau = (1.695 + 0.4)kg_f * ((27.35 + 18.14) * 0.5)cm = \mathbf{47.65kg_f \cdot cm} \quad (32)$$

Mientras que el cálculo para el torque teórico de los motores que se utilizarán para el movimiento del hombro se da con la Ecuación (33).

$$\begin{aligned} \tau &= (3.685 + 1.695 + 0.4)kg_f * ((35.6 + 27.35 + 18.14) * 0.5)cm \\ &= \mathbf{234.35kg_f \cdot cm} \end{aligned} \quad (33)$$

A partir de esta información, se realizó la búsqueda de los motores que cumplieran con las características necesarias para los torques teóricos en cada grado de libertad. Para los movimientos de flexo-extensión y abducción-aducción del hombro se utilizó el motor TZT (DH-03X, China) con un torque de 380 kg-cm, con un peso de 530g y una velocidad angular de 0.12s/60° a 24VCD, Figura 12.



Figura 12. TZT (DH-03X) Servomotor de 380 kg-cm de torque a 24VCD.

Debido a que el movimiento de rotación latero-medial del hombro no requiere competir contra la gravedad, el motor que se utilizó fue un DSServo (RDS5160, China) el cual tiene un torque de 60kg-cm, peso de 158g, velocidad angular de  $60^\circ$  en 0.17s cuando se energiza a 8.4VCD, Figura 13. Este modelo de motor también se utilizó en el movimiento de flexo-extensión del codo



Figura 13. DSServo (RDS5160) Servomotor de 60kg-cm de torque a 8.4VCD.

Finalmente, el motor DSServo (DS3235, China) con un torque de 35kg-cm, peso de 60g, velocidad angular  $60^\circ$  en 0.12s cuando se energiza a 7.4VCD, Figura 14, fue usado para los movimientos de pronosupinación, flexo-extensión de muñeca y abducción-aducción de muñeca.



Figura 14. DSServo (DS3235) Servomotor con 35kg-cm de torque a 7.4VCD

### 4.1.3 Diseño de las piezas del brazo robótico

Para simular los movimientos de la extremidad superior humana, se siguió el orden de colocación de los motores del hombro tal como se muestra en la Figura 15. Este orden permite simular la rotación del hombro sobre los tres ejes para realizar los movimientos de flexo-extensión, abducción-aducción y rotación latero-medial. El primer motor (M1) se colocó sobre una base vertical para simular el movimiento de flexo-extensión. El segundo (M2) se fijó a  $90^\circ$  con respecto a M1 para simular el movimiento de abducción-aducción. El tercero (M3) se orientó a  $90^\circ$  con respecto a M2, en posición vertical, para simular la rotación latero-medial. Para el caso del movimiento de flexo-extensión del codo, el cuarto motor (M4) se orientó en la misma dirección al segmento sobre el que se coloca. El quinto motor (M5) permite simular el movimiento de pronosupinación en el antebrazo, debido a que el antebrazo realiza un giro sobre su mismo eje, el diseño del segmento del antebrazo se realizó en dos partes: la primera parte permite continuar con el movimiento de flexión del codo; la segunda parte realiza la rotación mediante M5 para simular la pronosupinación. Finalmente, el sexto motor (M6) y el séptimo motor (M7) se orientaron a  $90^\circ$  uno respecto al otro para realizar los movimientos de flexo-extensión y abducción-aducción, respectivamente.

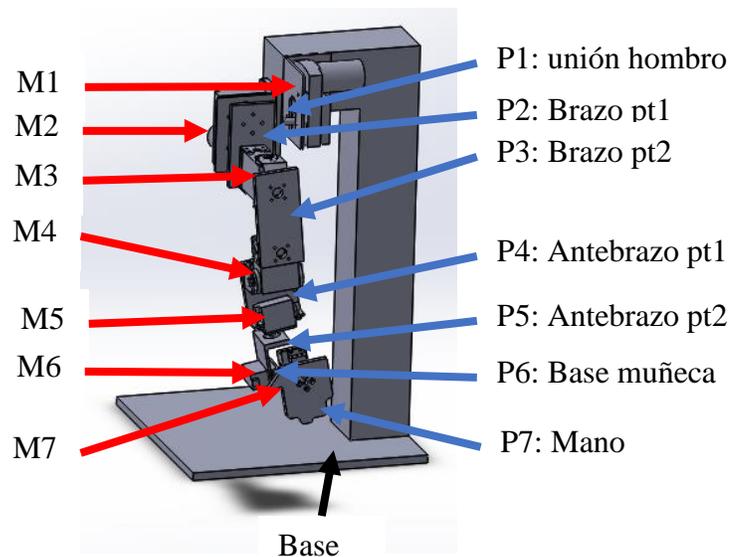


Figura 15. Diseño del brazo robótico y distribución de los motores en SolidWorks®. Donde M1-7 representan los motores del brazo robótico.

El diseño del brazo robótico requirió de siete piezas que sirven de enlace entre los motores y simulan los segmentos de la extremidad superior humana. La primera pieza de enlace (P1)

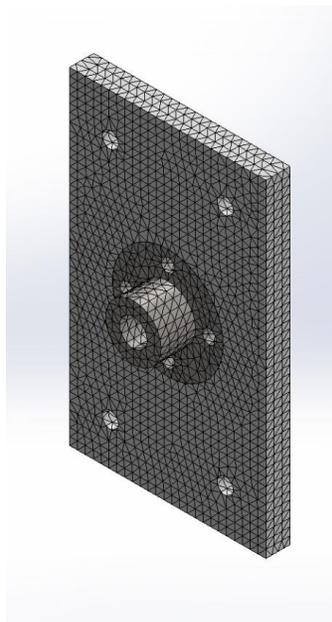
tiene la función de rotar el brazo con respecto a la posición de M1. El peso aproximado de esta pieza, considerando un relleno del 100%, fue de 37g de acuerdo con la simulación. La segunda pieza (P2) simula la primera parte del brazo humano y sirve de enlace entre M2 y M3; su peso estimado fue de 40g. La tercera pieza (P3) simula la segunda parte del brazo humano y sirve de enlace entre M3 y M4; su peso estimado fue de 45g. La cuarta pieza (P4) sirve para enlazar M4 y M5 y se considera la primera parte del antebrazo con un peso estimado en 37g. La quinta pieza simula la segunda parte del antebrazo, la cual rota sobre su eje (pronosupinación) de acuerdo con M5, su peso aproximado es de 17g y sirve para enlazar a M5 con M6. La sexta pieza, es una pieza de base para M7, enlaza a M6 con la mano y tiene un peso estimado en 18g. Finalmente, la séptima pieza (P7) simula la mano humana con un peso aproximado de 41g. El peso aproximado del brazo robótico, de acuerdo con la simulación, se detalla en la Tabla 4:

*Tabla 4. Detalle de los motores, piezas y peso del brazo robótico por segmentos.*

<b>Segmento</b>	<b>Motores (cantidad)</b>	<b>Accesorios para montaje (cantidad)</b>	<b>Piezas impresas (cantidad)</b>	<b>Peso (g)</b>
<b>Hombro</b>	DH-03X (2)	Base para motor (2) Accesorio para eje (2)	Unión hombro (1)	1,681.7
<b>Brazo</b>	RDS5160 (1)	Base de montaje (1) Accesorios para eje (3)	Brazo pt1 (1) Brazo pt2 (1)	296.72
<b>Codo</b>	RDS5160 (1)	Base de montaje (1) Accesorios para eje (3)		211.72
<b>Antebrazo</b>	DS3235 (1)	Accesorio para eje (1)	A_brazo pt1 (1) A_brazo pt2 (1)	117.8
Muñeca	DS3235 (2)	Accesorio para eje (2)	Base servo (1)	151.6
Mano			Mano (1)	18
<b>Total</b>	<b>7</b>	<b>15</b>	<b>7</b>	<b>2477.54</b>

## 4.2 Desarrollo del brazo robótico

Debido a la necesidad de contar con un factor de seguridad de las piezas de enlace que simularon los segmentos de la extremidad superior, se propuso un material ligero y con propiedades mecánicas que resistieron las cargas axiales a las que se sometieron. Para ello se realizó la simulación de diferentes materiales en los segmentos de mayor carga para determinar el material adecuado para esta aplicación en el software SolidWorks® 2018 con la herramienta de análisis de elementos finitos. Esta herramienta permite predecir el comportamiento del modelo mediante la combinación de la estructura de las piezas y las cargas externas a las que serán sometidas. Para ello se propuso una malla sólida con elementos cuadráticos de alto orden, los cuales se ajustan a la forma de las piezas para asegurar que la simulación sea de alta calidad, Figura 16.



*Figura 16. Pieza con trazado de calidad de malla de elementos cuadráticos de alto orden. Número de nodo: 38460. Número de elementos: 23688. Tamaño de elementos: 2.28mm. Tolerancia: 0.11mm.*

Las simulaciones determinadas fueron el análisis de tensión por Von Mises y el análisis de deformaciones unitarias. El análisis de tensión por Von Mises permite estimar si el diseño de las piezas es adecuado para soportar las cargas a las que serán sometidas, indicando las zonas

en las que existe una mayor tensión en el modelo mediante un gráfico arcoíris en color rojo, mientras que las de menor tensión tiene un color azul, Figura 17.

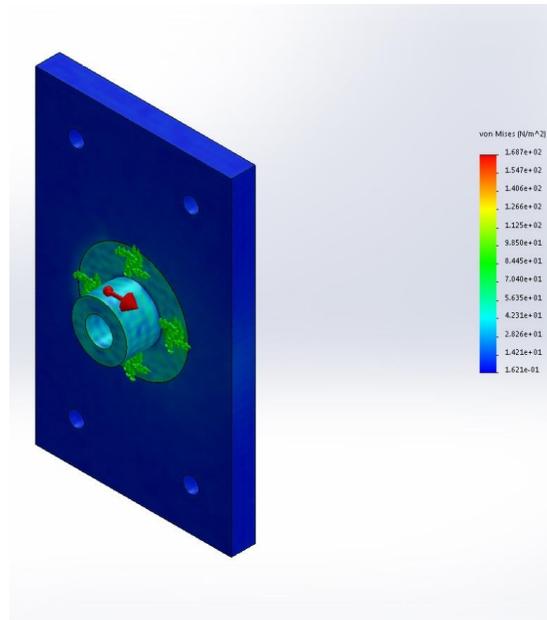


Figura 17. Simulación del análisis de tensión Von Mises en la pieza diseñada para soportar el peso del brazo robótico con material ABS. Máxima tensión:  $1.687e^{+02}N/m^2$ . Mínima tensión:  $1.621e^{-01}N/m^2$ .

Por su parte, el análisis de deformaciones unitarias permite estimar los cambios estructurales de la pieza en términos de longitud por unidad de longitud, Figura 18. Al igual que el análisis

de tensión por Von mises, este análisis muestra con un gráfico arcoíris las zonas de mayor deformación en rojo y de menor deformación en azul.

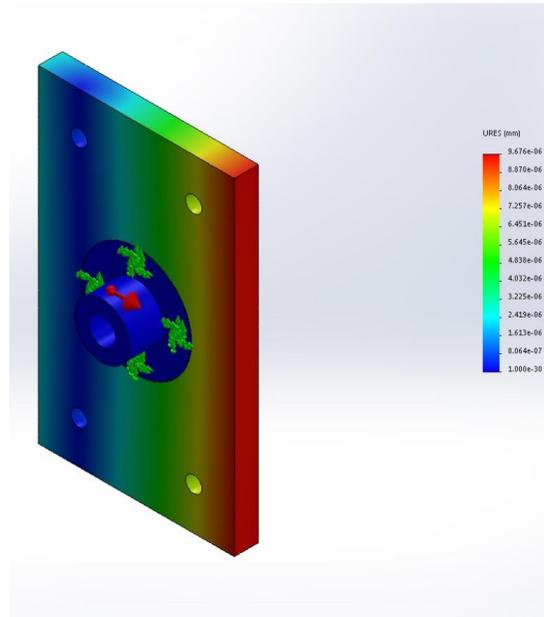


Figura 18. Simulación del análisis de deformaciones unitarias de la pieza diseñada para soportar el peso del brazo robótico con material ABS. Deformación unitaria máxima:  $9.676e^{-06}$ mm. Deformación unitaria mínima:  $1.00e^{-30}$ mm.

Ambos análisis permiten estimar las fallas estructurales que podrían tener las piezas de acuerdo con los parámetros de diseño y las cargas a los que serán sometidas. Para efectos de la simulación, se consideró que los puntos de sujeción de las piezas fueran zonas fijas (sin movimiento alguno), mientras que los puntos de carga se sometieron a fuerzas axiales en el punto de mayor carga (simulando el brazo a  $90^\circ$  con respecto a la vertical).

De acuerdo con la simulación, las piezas bajo estudio mostraron que el acrilonitrilo butadieno estireno (ABS, por sus siglas en inglés: *Acrylonitrile Butadiene Styrene*) es capaz de resistir

los esfuerzos y deformaciones a los que será sometida la pieza. El ABS cuenta con las siguientes propiedades mecánicas para su impresión en 3D [108]:

- Densidad: 1-1.4 g/cm<sup>3</sup>.
- Resistencia a la tracción: 24.63-33.7 MPa.
- Módulo elástico: 617.58-787.68 MPa.
- Límite elástico: 11.96-25.17 MPa (0.2% offset).
- Tensión de fractura: 0.062-0.113 mm/mm
- Dureza: 1.03-2.83 J/m<sup>3</sup>.

### **4.3 Sistema para el registro del movimiento humano**

#### **4.3.1 Diseño de los módulos para la medición del movimiento de la extremidad superior (MMES).**

Para obtener información relativa al movimiento de la extremidad superior humana que indique el movimiento del brazo robótico, se elaboraron cuatro módulos de monitoreo para la extremidad superior (MMES) para la medición de las actividades de la mano, antebrazo, brazo y tórax basados en sensores MARG [1, 2].

##### *4.3.1.1 Materiales*

Los dispositivos utilizados para el desarrollo de los MMES incluyeron un dispositivo para el seguimiento de movimiento GY-87® (WAVGAT®, China), un microprocesador DsPic30F6014A® (Microchip®, USA), un convertidor serial UART-USB FTDI232RL® (FTDI Chip®, UK), un dispositivo de comunicación inalámbrica X-Bee XB24API001 Serie 1 (Digikey®, USA) y una batería de polímero de litio (LiPo) de 550mAh a 3.7VCD, Figura 19.

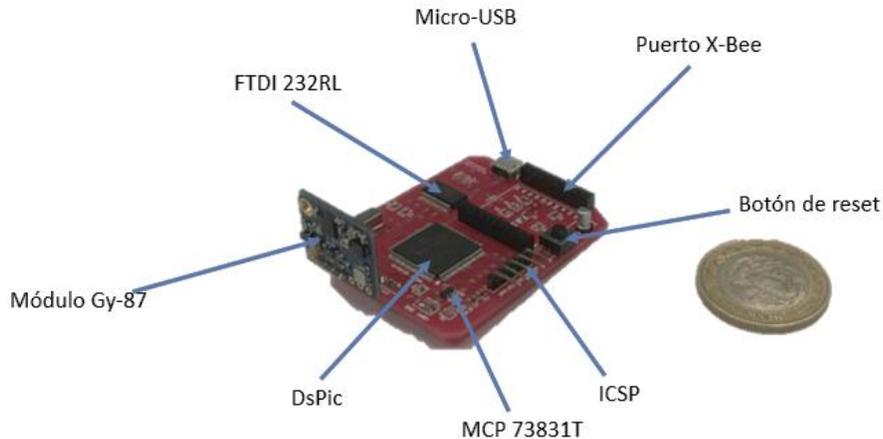


Figura 19. Módulo de medición (MMES) para el registro de las actividades de la mano, antebrazo, brazo y tórax [1].

El dispositivo GY-87 es un dispositivo de medición contenido en un empaquetado LGA que cuenta con 3 elementos de medición magneto-inerciales de 10 grados de libertad. En este empaquetado se tiene un MPU-6050® (InvenSense, USA), el cual corresponde a un sensor inercial de 6 grados de libertad en el que se combina un giroscopio de tres ejes y un acelerómetro de tres ejes; un magnetómetro HCM5883L® (Honeywell, USA) de tres ejes; un sensor digital de presión BMP180; y un procesador digital de movimiento (DMP, por sus siglas en inglés *Digital Motion Processor*). El MPU-6050 cuenta con tres convertidores análogo-digital (CAD) de 16-bits para digitalizar las salidas del giroscopio y tres CAD para digitalizar las salidas del acelerómetro. El giroscopio puede programarse de manera personalizada para el seguimiento de movimientos rápidos o lentos de manera precisa, con un rango de escala completa de  $\pm 250^\circ/s$ ,  $\pm 500^\circ/s$ ,  $\pm 1000^\circ/s$  y  $\pm 2000^\circ/s$ . El acelerómetro se puede programar con un rango de escala completa de  $\pm 2g$ ,  $\pm 4g$ ,  $\pm 8g$  y  $\pm 16g$  [109]. Por su parte, el HCM5883L® cuenta con un CAD de 12-bits proporcionando resoluciones de  $1^\circ$  a  $2^\circ$ . Su diseño permite medir la dirección y magnitud del campo magnético desde los 2 mG hasta  $\pm 8$  G [110].

El DsPic30F6014A® fue utilizado para programar las rutinas de adquisición y procesamiento de la información de los sensores para el cálculo de la orientación de los MMES. De igual manera fue utilizado para transmitir esta información vía inalámbrica al resto de los MMES o de manera alámbrica a una PC mediante el convertidor serial UART-USB FTDI232RL® [111]. Las características de este microcontrolador son [112]:

- 30 millones de instrucciones por segundo

- 68 pines de propósito general, de los cuales 8 se pueden adaptar como canales para PWM y 16 para ADC.
- 8Kbyte de memoria RAM.
- 4Kbyte de memoria EEPROM.
- Capacidad de reloj de hasta 40MHz.
- Oscilador interno de 4-10MHz.
- Módulo de comunicación I<sup>2</sup>C.
- 2 módulos UART direccionables.

El convertidor UART-USB, se utilizó uno para la comunicación vía serial-USB entre el MMES y una PC, mientras que el dispositivo de comunicación inalámbrica X-Bee fue utilizado para comunicar la información entre los MMES.

La comunicación entre el DsPic y el Gy-87 se realiza mediante el protocolo I<sup>2</sup>C (*Inter-Integrated Circuit*), el cual permite una comunicación bidireccional de datos a velocidades desde 0.1 hasta 3.4 Mbps y unidireccional a 5Mbps. La alimentación de los MMES se realizó mediante una batería recargable de LiPo de 550mAH a 3.7VCD con un controlador de gestión de carga MCP73831T® (Microchip®, USA). El algoritmo que emplea el MCP73831T® permite la carga de la batería a corriente/voltaje constante [113] con un tiempo de carga total de aproximadamente 6 horas y un tiempo de funcionamiento continuo entre 7-8 horas.

El diseño de los MMES se realizó en el software *Altium designer 2014*®, Figura 20. Mientras que la carcasa de protección se realizó en el software *SolidWorks*® 2014, Figura 21.

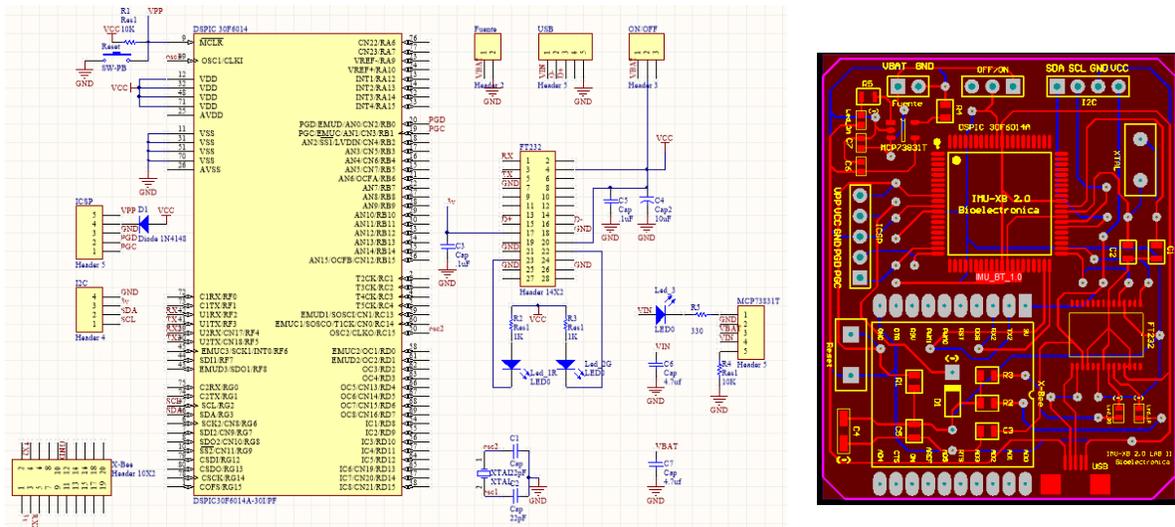


Figura 20. Diagrama esquemático y PCB de los MMES [1].

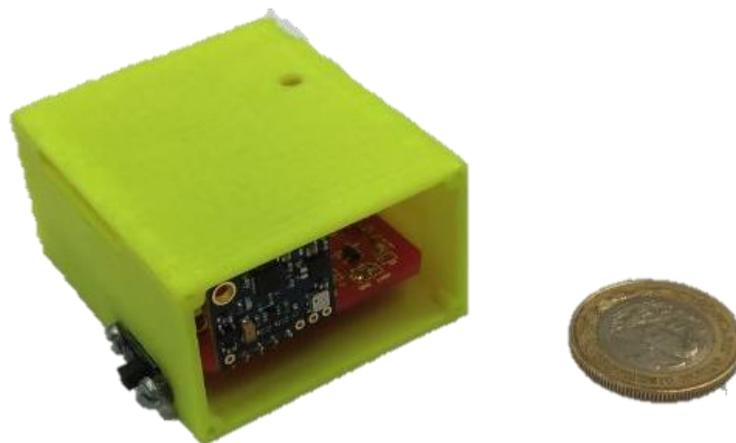


Figura 21. MMES con su carcasa de protección.

#### 4.3.1.2 Algoritmo para el cálculo de la orientación de los segmentos como objetos en el espacio 3D

A partir de la información que proporcionan los sensores con los que cuenta el módulo GY-87, se desarrolló un algoritmo para calcular la orientación en el espacio 3D de los MMES, Figura 22.

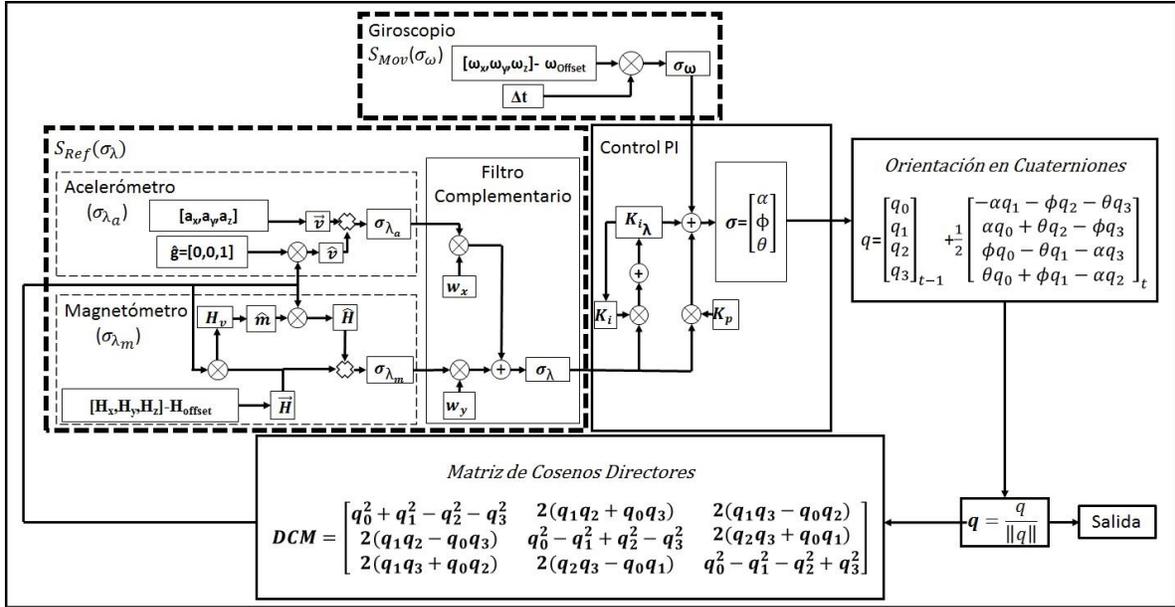


Figura 22. Diagrama a bloques del algoritmo [114].

#### 4.3.1.2.1 Estimación de la orientación para cada segmento

Dos sistemas coordinados son creados para estimar la orientación a partir de la información que entregan los sensores. El primero, utiliza la información del giroscopio para evaluar el movimiento del cuerpo ( $S_{Mov}$ ), generando un sistema de referencia móvil. El segundo, utiliza la información del acelerómetro y magnetómetro como referencia geodésica para generar un sistema coordinado inercial ( $S_{Ref}$ ) [50, 114].

#### 4.3.1.2.2 Sistema de referencia móvil

La información del giroscopio ( $\omega$ ), es utilizada para estimar la orientación del cuerpo durante el movimiento, creando el sistema de referencia móvil. La información del giroscopio es procesada para obtener la información del cuerpo a evaluar a través de la velocidad angular ( $\omega_{x,y,z}$ ), un valor de compensación ( $\omega_{offset}$ ), y una diferencial de tiempo ( $\Delta t$ ), Ecuación (34).

$$\left\{ \begin{array}{l} \omega_{xyz} = [\omega_x \quad \omega_y \quad \omega_z] \\ \omega_{offset} = \frac{\sum_{i=1}^n (\omega_{x,y,z})_i}{n} \end{array} \right\} \rightarrow \sigma_\omega = (\omega_{xyz} - \omega_{offset}) * \Delta t \quad (34)$$

#### 4.3.1.2.3 Sistema de referencia inercial

El Sistema de referencia inercial se definió mediante dos vectores de corrección de rotación ( $\sigma_{\lambda_a}$  and  $\sigma_{\lambda_m}$ ) calculados con los datos del acelerómetro y magnetómetro. Este sistema permitió compensar los errores variantes en el tiempo causados por la integración del ruido y deriva inherentes en las mediciones del giroscopio [115]. El primer vector ( $\sigma_{\lambda_a}$ ) utiliza la información del acelerómetro ( $a_{x,y,z}$ ) para compensar la deriva sobre los ejes paralelos al plano de Tierra. El cálculo de este vector resulta del producto cruz entre un vector inercial ( $\vec{v}$ ), el cual representa las mediciones del acelerómetro normalizados ( $a_{x,y,z}$ ) y el vector de la gravedad ( $\hat{v}$ ), correspondientes a los componentes del eje Z,  $\hat{g} = [0 \ 0 \ 1]$ , de una matriz de cosenos directores (DCM), Ecuación (35). La DCM describe la orientación del sistema coordinado móvil del cuerpo relativo al sistema coordinado de referencia inercial.

$$\left\{ \begin{array}{l} \vec{v} = \frac{[a_{x,y,z}]}{\|[a_{x,y,z}]\|} \\ \hat{v} = \hat{g} * \text{DCM} \end{array} \right\} \rightarrow \sigma_{\lambda_a} = \vec{v} \times \hat{v} \quad (35)$$

El segundo vector ( $\sigma_{\lambda_m}$ ) compensa la deriva en el eje perpendicular al plano de Tierra utilizando las mediciones del campo magnético ( $H_{x,y,z}$ ) por *hard iron* ( $H_{offset}$ ) y *soft iron* ( $\hat{m}$ ). Este vector se calcula mediante el producto cruz entre un vector generado con los componentes del flujo magnético en cada eje ( $\vec{H}$ ) y el vector direccional del campo magnético terrestre ( $\hat{H}$ ), Ecuación (36).

$$\sigma_{\lambda_m} = \vec{H} \times \hat{H} \quad (36)$$

El vector de flujo magnético ( $\vec{H}$ ) se determina con las mediciones del magnetómetro ( $H_{x,y,z}$ ) normalizados y la compensación del campo magnético causado por los elementos ferromagnéticos ( $H_{offset}$ ), Ecuación (37).

$$\left\{ H_{offset} = \frac{\max(H_{x,y,z}) - \min(H_{x,y,z})}{2} \right\} \rightarrow \vec{H} = \left( \frac{[H_{x,y,z}]}{\|[H_{x,y,z}]\|} \right) - H_{offset} \quad (37)$$

El vector direccional del campo magnético terrestre ( $\hat{H}$ ) se calculó mediante el vector de flujo magnético medido ( $\vec{H}$ ) y su rotación relativa a la DCM; esto define la dirección del campo magnético medido ( $H_v$ ), Ecuación (38).

$$H_v = \vec{H} * \text{DCM} \quad (38)$$

El campo magnético terrestre ( $H_v$ ) se representa en términos de la inclinación y declinación magnética (soft iron), los ejes horizontales y verticales del sistema de referencia usados para definir el vector direccional ( $\hat{m}$ ), Ecuación (39).

$$\hat{M} = \left[ \sqrt{H_{v_x}^2 + H_{v_y}^2}, \quad 0, \quad H_{v_z} \right] \quad (39)$$

Para considerar los componentes de soft iron ( $H_v$ ) que forman el vector de campo magnético ( $\vec{H}$ ), los valores del vector direccional ( $\hat{m}$ ) consideran la rotación usada en la DCM para definir el vector direccional del campo magnético terrestre ( $\hat{H}$ ), Ecuación (40).

$$\hat{H} = \hat{m} * \text{DCM} \quad (40)$$

#### 4.3.1.2.4 Fusión de datos de los sensores

La fusión de los datos de los sensores se realizó mediante un filtro complementario y un controlador Proporcional-Integral (PI). El filtro complementario compensa la actitud del sensor en altas frecuencias utilizando los vectores de corrección de rotación del acelerómetro ( $\sigma_{\lambda_a}$ ) y magnetómetro ( $\sigma_{\lambda_m}$ ), obteniendo la orientación del sistema coordinado inercial ( $\sigma_\lambda$ ), Ecuación (41).

$$\Sigma_\lambda = W_x * \sigma_{\lambda_a} + W_y * \sigma_{\lambda_m} \quad (41)$$

Los valores ponderados  $W_x$  y  $W_y$ , Ecuación (41), fueron seleccionados por la divergencia y convergencia calculados con ambos sensores [116], de tal manera que

$$W_y = 1 - W_x \quad (42)$$

El controlador PI integra gradualmente los sistemas coordinados inercial ( $\sigma_\lambda$ ) y móvil ( $\sigma_\omega$ ) para calcular la orientación. Además, la acción del control PI determina una respuesta estable del sistema, eliminando el error estacionario y obteniendo la orientación del cuerpo ( $\sigma$ ), Ecuación (43).

$$\Sigma = \sigma_\omega + K_p \sigma_\lambda + K_i \int_0^t f(\sigma_\lambda) = [\alpha \quad \phi \quad \theta] \quad (43)$$

Los valores  $K_p$  y  $K_i$  se definieron aplicando el *Good Gain Method* para sintonizar el controlador PI, considerando una respuesta suave y con bajo amortiguamiento inercial [117]. Las variables  $\alpha$ ,  $\phi$ , y  $\theta$  corresponden a la orientación estimada en ángulos de Euler.

#### 4.3.1.2.5 Cálculo de la orientación espacial usando cuaterniones y DCM

La orientación se obtiene a través de ángulos de Euler. El mayor inconveniente de esta técnica cinemática se debe al bloqueo de Cardán, *gimbal lock*, el cual ocurre en ciertas posiciones. Para resolver este inconveniente se propuso el uso de cuaterniones ya que estas singularidades no se presentan con esta técnica y son computacionalmente más eficientes comparados con los ángulos de Euler [118-120], Ecuación (44).

$$Q = q_{t-1} + \int_0^t q(dt) \rightarrow q_{t-1} \otimes q_t \rightarrow q = \begin{bmatrix} q_0 \\ q_1 \\ q_2 \\ q_3 \end{bmatrix}_{t-1} + \frac{1}{2} \begin{bmatrix} -\alpha q_1 - \phi q_2 - \theta q_3 \\ \alpha q_0 + \theta q_2 - \phi q_3 \\ \phi q_0 - \theta q_1 - \alpha q_3 \\ \theta q_0 + \phi q_1 - \alpha q_2 \end{bmatrix}_t \quad (44)$$

Un proceso de normalización a los datos de los cuaterniones se realiza para asegurar la ortogonalidad entre los elementos de los cuaterniones, Ecuación (45).

$$\mathbf{q} = \frac{q}{\|q\|} = [q_0 \quad q_1 \quad q_2 \quad q_3] \quad (45)$$

Cada elemento de la DCM corresponde al coseno del ángulo entre el vector unitario de rotación (filas) y el sistema coordinado de referencia (columnas). Cada fila puede considerarse como el resultado de rotar uno a uno los vectores unitarios del sistema de coordenadas de referencia por la rotación que describiría la DCM resultante [120], Ecuación (46).

$$DCM = \begin{bmatrix} q_0^2 + q_1^2 - q_2^2 - q_3^2 & 2(q_1q_2 + q_0q_3) & 2(q_1q_3 - q_0q_2) \\ 2(q_1q_2 - q_0q_3) & q_0^2 - q_1^2 + q_2^2 - q_3^2 & 2(q_2q_3 + q_0q_1) \\ 2(q_1q_3 + q_0q_2) & 2(q_2q_3 - q_0q_1) & q_0^2 - q_1^2 - q_2^2 + q_3^2 \end{bmatrix} \quad (46)$$

#### 4.3.1.2.6 Estimación de la orientación de las articulaciones

La relación especial entre dos segmentos corporales adyacentes se calculó para estimar la actividad articular. La relación espacial ( $q_c$ ) se calcula mediante el producto entre el cuaternión conjugado de un segmento ( $q_a$ )\* y el cuaternión del segmento adyacente ( $q_b$ ), Ecuación (47).

$$\mathbf{q}_c = (\mathbf{q}_a)^* \otimes \mathbf{q}_b = \begin{bmatrix} (\mathbf{q}_{0_a} * \mathbf{q}_{0_b}) + (\mathbf{q}_{1_a} * \mathbf{q}_{1_b}) + (\mathbf{q}_{2_a} * \mathbf{q}_{2_b}) + (\mathbf{q}_{3_a} * \mathbf{q}_{3_b}) \\ (\mathbf{q}_{0_a} * \mathbf{q}_{1_b}) - (\mathbf{q}_{1_a} * \mathbf{q}_{0_b}) - (\mathbf{q}_{2_a} * \mathbf{q}_{3_b}) + (\mathbf{q}_{3_a} * \mathbf{q}_{2_b}) \\ (\mathbf{q}_{0_a} * \mathbf{q}_{2_b}) + (\mathbf{q}_{1_a} * \mathbf{q}_{3_b}) - (\mathbf{q}_{2_a} * \mathbf{q}_{0_b}) - (\mathbf{q}_{3_a} * \mathbf{q}_{1_b}) \\ (\mathbf{q}_{0_a} * \mathbf{q}_{3_b}) + (\mathbf{q}_{1_a} * \mathbf{q}_{2_b}) + (\mathbf{q}_{2_a} * \mathbf{q}_{1_b}) - (\mathbf{q}_{3_a} * \mathbf{q}_{0_b}) \end{bmatrix} \quad (47)$$

La actividad articular se estima mediante el cálculo de esta relación espacial, Ecuaciones (48-50)

$$\mathbf{q}_{\text{shoulder}} = (\mathbf{q}_{\text{thorax}})^* \otimes \mathbf{q}_{\text{arm}} \quad (48)$$

$$\mathbf{q}_{\text{elbow}} = (\mathbf{q}_{\text{arm}})^* \otimes \mathbf{q}_{\text{forearm}} \quad (49)$$

$$\mathbf{q}_{\text{wrist}} = (\mathbf{q}_{\text{forearm}})^* \otimes \mathbf{q}_{\text{hand}} \quad (50)$$

## 4.4 Pruebas de movimiento de la extremidad superior humana con los MMES

### 4.4.1 Validación de los MMES

La validación de los MMES se realizó mediante dos pruebas en condiciones controladas de acuerdo con los métodos de evaluación para algoritmos de seguimiento de movimiento basados en sensores inerciales [115]. Los resultados obtenidos se referenciaron con una línea base (GT, *ground truth*) y se compararon con la respuesta del procesador digital de movimiento (DMP) del GY-87. El DMP se utilizó como herramienta de comparación ya que es capaz de calibrar la orientación del giroscopio y su precisión ha sido probada con software de procesamiento de imagen [121]. La primera prueba, denominada prueba estática, evalúa la capacidad del algoritmo cuando no se tiene movimiento. La segunda prueba, llamada prueba dinámica, evalúa la capacidad del algoritmo para seguir trayectorias sin perder orientación. Para la evaluación de ambas pruebas, se realizó un análisis estadístico con los parámetros utilizados para la evaluación de algoritmos de seguimiento de movimiento [115].

#### 4.4.1.1 Prueba estática

El módulo MMES con el algoritmo y el DMP, se coloca sobre una superficie plana, asegurándose que el sistema coordenado del GY-87 está alineado con el norte magnético

local. La información correspondiente a esta prueba se registra durante 600s para determinar la presencia de ruido y deriva.

#### *4.4.1.2 Prueba dinámica*

Para esta prueba, el módulo se monta sobre un servomotor el cual está programado para rotar de 0-90° simulando una mesa de inclinación la cual nos permite evaluar la precisión y el rango de movimiento [115, 122]. Para evaluar los tres ejes, en cada prueba se cambia la orientación del sensor con respecto al servomotor para hacerlo rotar en un eje diferente. Cada prueba consistió en dos etapas de 300 segundos. La primera etapa, 0-300s, registro la actividad del módulo durante 15 ciclos de movimiento de acuerdo con la siguiente descripción: 5s en etapa de reposo (0°), 5s en actividad (0-90°), 5s en reposo (90°) y 5s en actividad (90-0°). La segunda etapa, 301-600s, consiste en registrar la actividad del módulo en posición estática en 0° para confirmar que el algoritmo propuesto es capaz de mantener la orientación sin deriva después de algún movimiento.

#### **4.4.2 Pruebas de movimiento con personas**

Para evaluar la orientación en la extremidad superior se realizaron dos tipos de pruebas. El primero, llamado semi controlado, es el que se realiza ejecutando un movimiento en el que se involucra solo uno de los grados de libertad en la extremidad superior derecha. El segundo, llamado Prueba reach-to-grasp, es una prueba de movimiento en el que se involucran varios grados de libertad de la extremidad superior cuyo objetivo es alcanzar y tomar un objeto partiendo de una posición específica. Estas pruebas se realizaron con la aprobación del Comité de Bioética para la Investigación en Seres Humanos (COBISH-) del Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV-IPN) con el Folio 088/2022 Anexo A. Las pruebas se realizaron a voluntarios que cumplieran con los criterios de inclusión y exclusión, Tabla 5.

Tabla 5. Criterios de inclusión y exclusión para realizar las pruebas de movimiento con personas.

<b>Criterios de inclusión</b>	<b>Criterios de exclusión</b>
Personas sanas con movilidad del miembro superior sin problemas neuromusculares aparentes.	Voluntarios con molestias que impidan el movimiento en la extremidad superior derecha.
Edad mayor a 18 años.	Voluntarios con lesiones o cirugías recientes en la extremidad superior.
Sexo indistinto.	Voluntarios que se encuentren bajo el influjo de sustancias que puedan alterar la coordinación motora (medicamentos, alcohol, drogas, etc.).

Para las pruebas se contó con 10 sujetos sanos, mano dominante derecha, seis hombres y cuatro mujeres, con edad promedio de  $39 \pm 15.9$  años. A todos ellos se les informo de manera detallada en que consistió el estudio y se les pidió firmar la carta de consentimiento informado aprobada por el COBISH.

Los MMES se colocaron en la extremidad superior derecha de los voluntarios para obtener información de los desplazamientos angulares durante el movimiento de cada segmento, Figura 23. La ubicación de los MMES se realizó de la siguiente manera:

- MMES01: se colocó en la parte dorsal de la mano, sobre el hueso grande de la muñeca.
- IXB02: se colocó sobre el antebrazo, sobre el músculo extensor común de los dedos a 5cm de la muñeca, paralelo al plano coronal.
- IXB03: se ubica en la porción lateral externa del brazo, en la distancia media entre el acromion y el epicóndilo lateral del húmero, centrado en el plano coronal, tomando como referencia el punto medio entre los músculos bíceps braquial y tríceps braquial.
- IXB04: se coloca sobre el epigastrio, centrado en el plano sagital, tomando como referencia la apófisis xifoides.

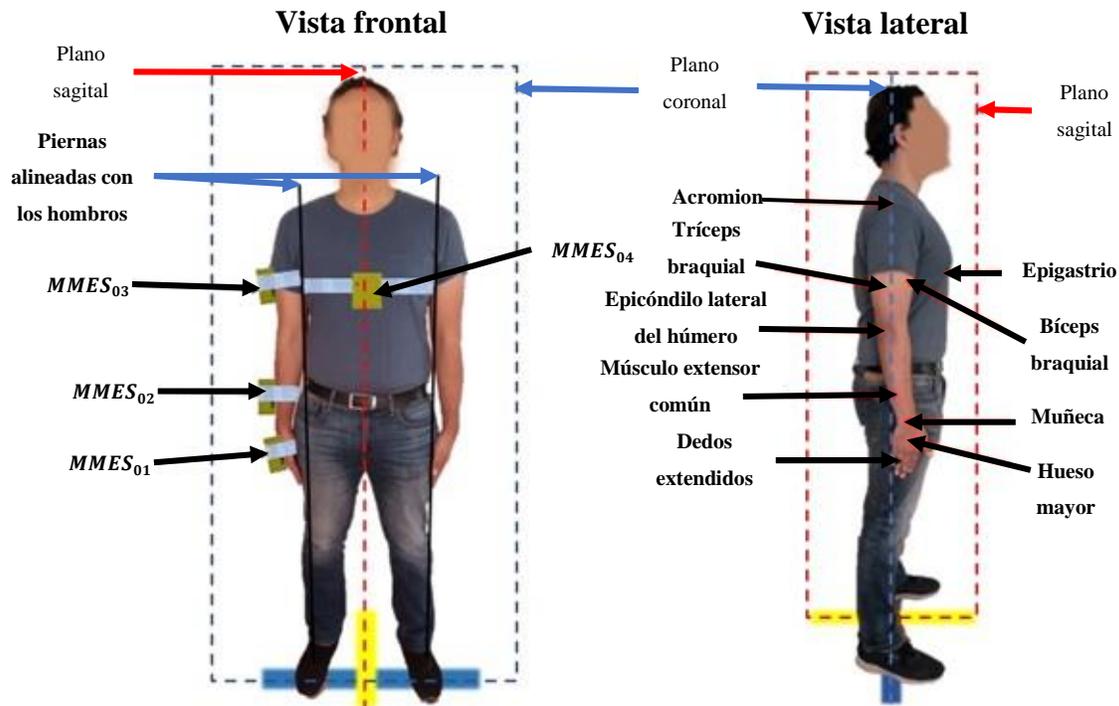


Figura 23. Ubicación y colocación de los MMES y posición N [114].

La posición de inicio tomada para las pruebas se le conoce como posición neutra (N-pose), la cual se define de la siguiente manera: Posición corporal erguida bipodal, piernas separadas a la misma altura de los hombros, plantas de los pies paralelas al piso, brazos extendidos colocados al costado del cuerpo, palmas de las manos paralelas al plano sagital apoyadas sobre el cuerpo y dedos extendidos.

#### 4.4.2.1 Pruebas semi controladas

Un total de seis actividades que involucran a la extremidad superior fueron elegidas para ser evaluadas. Cada movimiento comienza orientando al sujeto de prueba hacia el norte magnético terrestre y adoptando la N-pose, Figura 23. En un periodo de dos minutos, se repiten cada una de las actividades cuantas veces sea posible, tratando de cumplir con los siguientes objetivos para cada actividad:

- Posición estática: El sujeto de prueba se coloca en la N-pose y se mantiene en esa posición.

- Flexión del hombro a 90°: Partiendo de la N-pose, se realiza la flexión del hombro, rotando sobre el eje transversal, paralelo al plano sagital, hasta llegar a los 90°. Posteriormente se realiza la extensión del hombro hasta retomar la N-pose.
- Abducción del hombro a 90°: Partiendo de la N-pose, se realiza la abducción del hombro, rotando sobre el eje anteroposterior, paralelo al plano frontal, hasta alcanzar los 90°. Posteriormente se realiza la aducción del hombro hasta retomar la N-pose.
- Flexión del codo a 90°: Partiendo de la N-pose, se realiza la flexión del codo a 90°, rotando sobre el eje transversal, paralelo al plano sagital. Posteriormente se extiende el codo hasta retomar la N-pose.
- Flexión de la muñeca: Partiendo de la N-pose, se realiza la flexión total de la muñeca, rotando sobre el eje anteroposterior, hasta adoptar la flexión completa de la muñeca. Posteriormente se extiende la muñeca para retomar la N-pose.
- Abducción de la muñeca: Partiendo de la N-pose, se realiza la abducción de la muñeca, rotando sobre el eje transversal, hasta lograr la abducción completa. Posteriormente se realiza la aducción de la muñeca hasta retomar la N-pose.

El rango de movimiento, así como sus valores, están referenciados a la vertical de la persona, considerando 0° cuando la extremidad se encuentra en posición vertical; los valores positivos son considerados en las rotaciones hacia adelante y derecha, mientras que los valores negativos se consideran cuando las rotaciones son hacia atrás o izquierda de la persona.

#### *4.4.2.2 Prueba Reach-to-grasp*

Esta prueba requiere de la actividad conjunta de las tres articulaciones que se evaluaron en las pruebas semi controladas y permite evaluar la trayectoria descrita por la extremidad superior en una actividad del día a día. Esta actividad consiste en tomar un vaso de una repisa (a 150cm del piso), sujetarlo, soltarlo y retomar la posición de inicio. Para esta actividad, se pide a los sujetos de prueba pararse derechos frente a una repisa con su brazo derecho extendido hacia abajo. El vaso de agua se coloca sobre la superficie de la repisa a 10cm del borde. La prueba se repite constantemente durante 2 min, logrando tener varias repeticiones de un solo sujeto de prueba.

## **4.5 Desarrollo de una RNA para la identificación de los movimientos de la extremidad superior humana.**

A partir de las pruebas de movimientos con personas realizadas en el apartado 4.4.2, se construyó una base de datos para su clasificación mediante un perceptrón multi capas (MLP). Para evitar confusiones en la etapa de entrenamiento de la red, los movimientos menores a 10° con respecto a la N-pose se consideraron movimientos estáticos. Un total de 42,356 muestras de datos se tomaron de las 7 actividades: 12,805 de la actividad estática, 5,614 de la actividad de flexo-extensión del hombro, 6,110 de la actividad de abducción-aducción del hombro, 5,057 de la actividad de flexo-extensión del codo, 4,410 de la actividad de flexo-extensión de la muñeca, 4,686 de la actividad de abducción-aducción de la muñeca y 4,321 de la actividad reach-to-grasp.

### **4.5.1 Arquitectura de la red neuronal artificial**

La arquitectura de la red neuronal artificial se diseñó y programó para la clasificación de siete movimientos como siete diferentes clases. El enfoque común para ajustar el modelo utiliza una neurona por clase en la capa de salida; por lo tanto, la arquitectura propuesta para las neuronas en la capa de salida es siete. Las neuronas en el vector de entrada corresponden a la información de los sensores, siendo que la salida de cada sensor entrega un cuaternión; cada sensor entrega 4 datos de salida. El vector de la capa de entrada contiene dieciséis datos para cada muestra del movimiento. El número de neuronas en la capa oculta permite englobar los objetivos de cada clase en un espacio 3D, las cuales se definen por medio del método heurístico. Siete neuronas fueron suficientes para cumplir con la condición de englobar los objetivos de las siete clases por lo que la arquitectura de la red neuronal artificial fue 16-7-7, Figura 24.

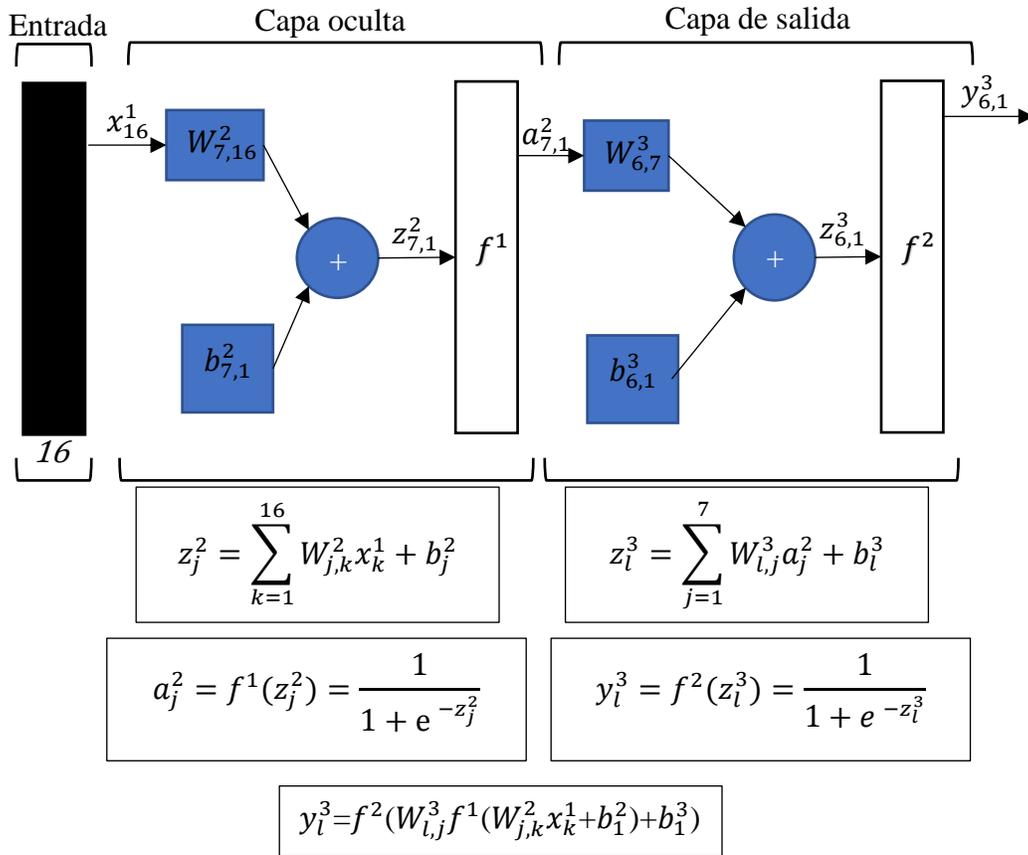


Figura 24 Representación resumida de la arquitectura de la red neuronal artificial.

#### 4.5.2 Validación de la arquitectura de la red neuronal artificial

Para determinar si la arquitectura elegida es robusta para clasificar las siete clases y evitar sesgos en el entrenamiento del modelo, se realizó una validación cruzada con el conjunto de datos. La base de datos se aleatorizó y dividió en dos conjuntos para el entrenamiento y pruebas de la red neuronal artificial. El primer conjunto, con el 75% de la base de datos total, se utilizó para el entrenamiento y validación cruzada del modelo, segmentando el conjunto en  $k=3$ , Figura 25. El 25% de datos restante fue utilizado para las pruebas.

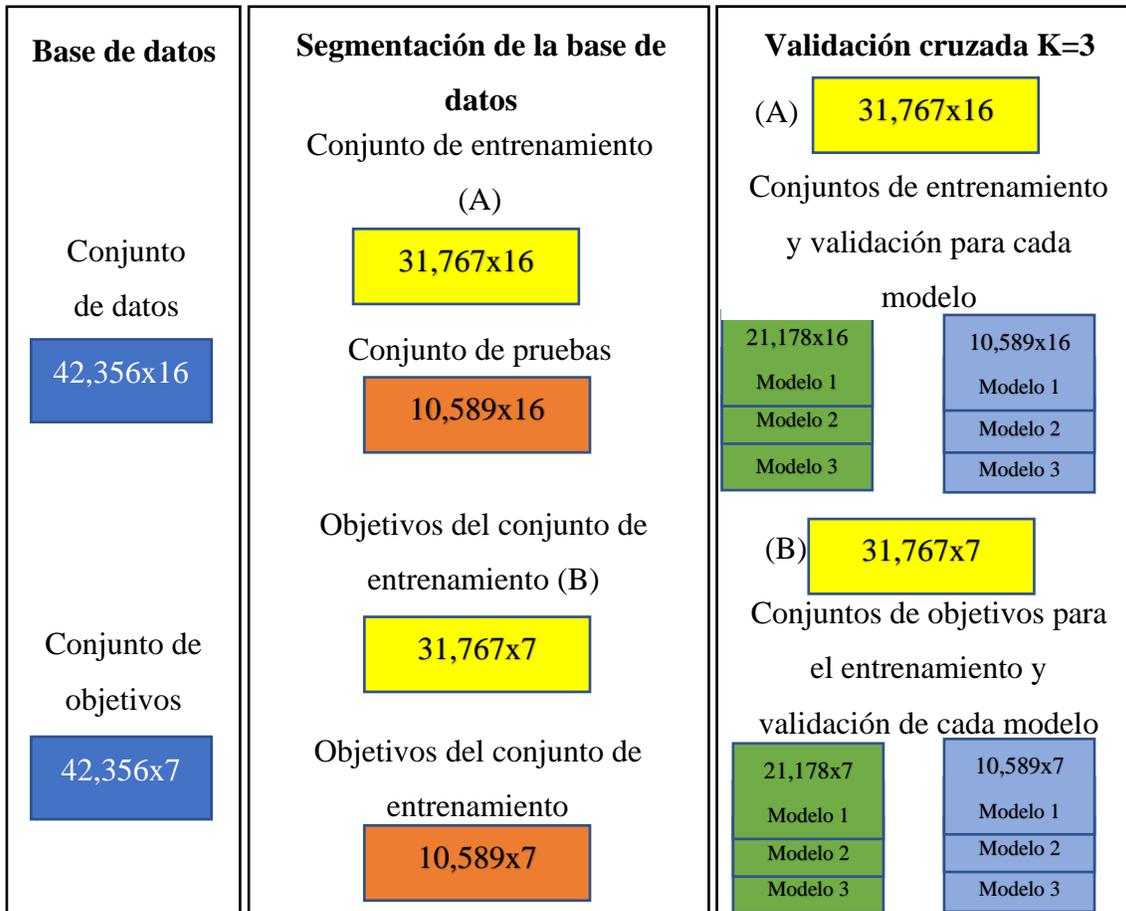


Figura 25. Segmentación de la base de datos para la validación cruzada (k=3) del conjunto de entrenamiento.

### 4.5.3 Aprendizaje del modelo de red neuronal

El proceso de aprendizaje del modelo de red neuronal artificial propuesto se llevó a cabo mediante el algoritmo de retropropagación del error (Backpropagation) para la actualización de los pesos y bias utilizados. El error del modelo se calcula a partir de la diferencia entre el valor objetivo ( $\hat{y}$ ) y el valor obtenido ( $y$ ) en la salida de la red neuronal artificial, Ecuación (51).

$$Error_{salida} = \hat{y} - y \quad (51)$$

Este error es propagado hacia las neuronas en la capa oculta para determinar la influencia de cada neurona de esta capa en el resultado, mediante la derivada parcial de la función de activación con respecto al peso o bias de cada neurona en la capa oculta, Ecuaciones (52,53).

$$\Delta\omega_{i,j}^3 = \alpha * Error_{salida} * a_{j,1}^2 \quad (52)$$

$$\Delta b_l^3 = \alpha * a_{j,1}^2 \quad (53)$$

Donde  $\Delta\omega_{l,j}^3$  y  $\Delta b_l^3$  corresponden a los valores de actualización para los pesos y bias de la capa oculta, respectivamente;  $\alpha$  corresponde al factor de entrenamiento; y  $a_{j,1}^2$  es la salida de las neuronas de la capa oculta.

A continuación, se calcula el error en la capa oculta con la sumatoria del producto de la derivada parcial de la función de activación en la capa de salida y los pesos de las neuronas en la capa oculta, Ecuación (54).

$$Error_{oculta} = Error_{salida} * \omega_{l,j}^3 \quad (54)$$

Con este error, se calculan los valores de actualización para los pesos ( $\Delta\omega_{l,j}^2$ ) y bias ( $\Delta b_l^2$ ) de la capa de entrada, Ecuaciones (55,56).

$$\Delta\omega_{l,j}^2 = \alpha * Error_{oculta} * x_{1,16}^1 \quad (55)$$

$$\Delta b_l^2 = \alpha * x_{1,16}^1 \quad (56)$$

El valor actualizado de los pesos y bias para ambas capas se calcula con las ecuaciones (57-60).

$$\omega_{l,j}^3 = \omega_{l,j}^3 - \Delta\omega_{l,j}^3 \quad (57)$$

$$b_l^3 = b_l^3 - \Delta b_l^3 \quad (58)$$

$$\omega_{l,j}^2 = \omega_{l,j}^2 - \Delta\omega_{l,j}^2 \quad (59)$$

$$b_l^2 = b_l^2 - \Delta b_l^2 \quad (60)$$

#### 4.5.4 Métodos estadísticos para la validación del modelo

Los resultados obtenidos para este modelo de red neuronal artificial se presentaron mediante curvas de aprendizaje, matrices de confusión y curvas de características de funcionamiento del receptor (ROC). Las curvas de aprendizaje permiten observar el proceso en el que se reduce el error de salida durante el aprendizaje del modelo para las siete clases en cada iteración. Las matrices de confusión permiten visualizar el desempeño del modelo de la red comparando los valores predichos con los valores obtenidos después del entrenamiento. Las curvas ROC permiten observar la capacidad de discriminación de un clasificador de acuerdo

con un umbral; estas curvas se grafican con el método uno contra todos (1-vs-all) para cada clase. Además, las curvas ROC dan un parámetro que determina la capacidad del modelo para distinguir entre clases, área bajo la curva (AUC).

La matriz de confusión permite calcular la precisión, sensibilidad, y especificidad del modelo. La precisión se calcula mediante la Ecuación (61).

$$\text{Precisión} = (VP + VN)/(VP + VN + FP + FN) \quad (61)$$

Donde VP son los datos verdaderos positivos, el resultado de una prueba que indica correctamente la presencia de una condición o característica. VN son los datos verdaderos negativos de una prueba que indican la ausencia de una condición o característica. FP son los datos falsos positivos de una prueba que indican erróneamente la presencia de una condición o característica. FN son los datos falsos negativos de una prueba que indican erróneamente la ausencia de una condición o característica.

La sensibilidad, la probabilidad de que una prueba de positivo cuando verdaderamente lo es, se calcula con la Ecuación (62).

$$\text{Sensibilidad} = VP/(VP + FN) \quad (62)$$

La especificidad, corresponde a la probabilidad de que una prueba de negativo cuando verdaderamente lo es y se calcula con la Ecuación (63).

$$\text{Especificidad} = VN/(VN + FP) \quad (63)$$

## 4.6 Pruebas de movimiento del brazo robótico

Las pruebas de movimiento del brazo robótico se llevaron a cabo con los registros obtenidos en el apartado 4.4.2. A partir de estos registros se calculó la actividad articular de los segmentos con las Ecuaciones (48). Posteriormente, los cuaterniones de la actividad articular se convirtieron en ángulos de Euler para representar la rotación sobre cada eje de la articulación, Ecuación (64).

$$\begin{bmatrix} \phi \\ \theta \\ \psi \end{bmatrix} = \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} \text{atan2}(2(q_0q_1 + q_2q_3), 1 - 2(q_1^2 + q_2^2)) \\ \text{asin}(2(q_0q_2 - q_1q_3)) \\ \text{atan2}(2(q_0q_3 + q_1q_2), 1 - 2(q_2^2 + q_3^2)) \end{bmatrix} \quad (64)$$

Para evitar condiciones de singularidad con esta conversión, se utilizó el arco tangente de dos parámetros (atan2) para calcular los ángulos superiores a 90° y menores a -90° teniendo

un rango total de  $\pm 180^\circ$ . Este ángulo, nos permite trabajar con los cuatro cuadrantes para determinar el ángulo de rotación sobre el que se está registrando la información del movimiento. Con estas rotaciones se programó una tarjeta Arduino con el vector de datos correspondientes a los ángulos para cada actuador para su representación con el brazo robótico.

#### 4.6.1 Movimientos del brazo robótico y validación con Xsens

Los movimientos del apartado 4.4.2.1 se utilizaron para el movimiento del brazo robótico muestreando las diferentes posiciones de movimiento para realizar un arreglo para el movimiento de los actuadores, Figura 26.

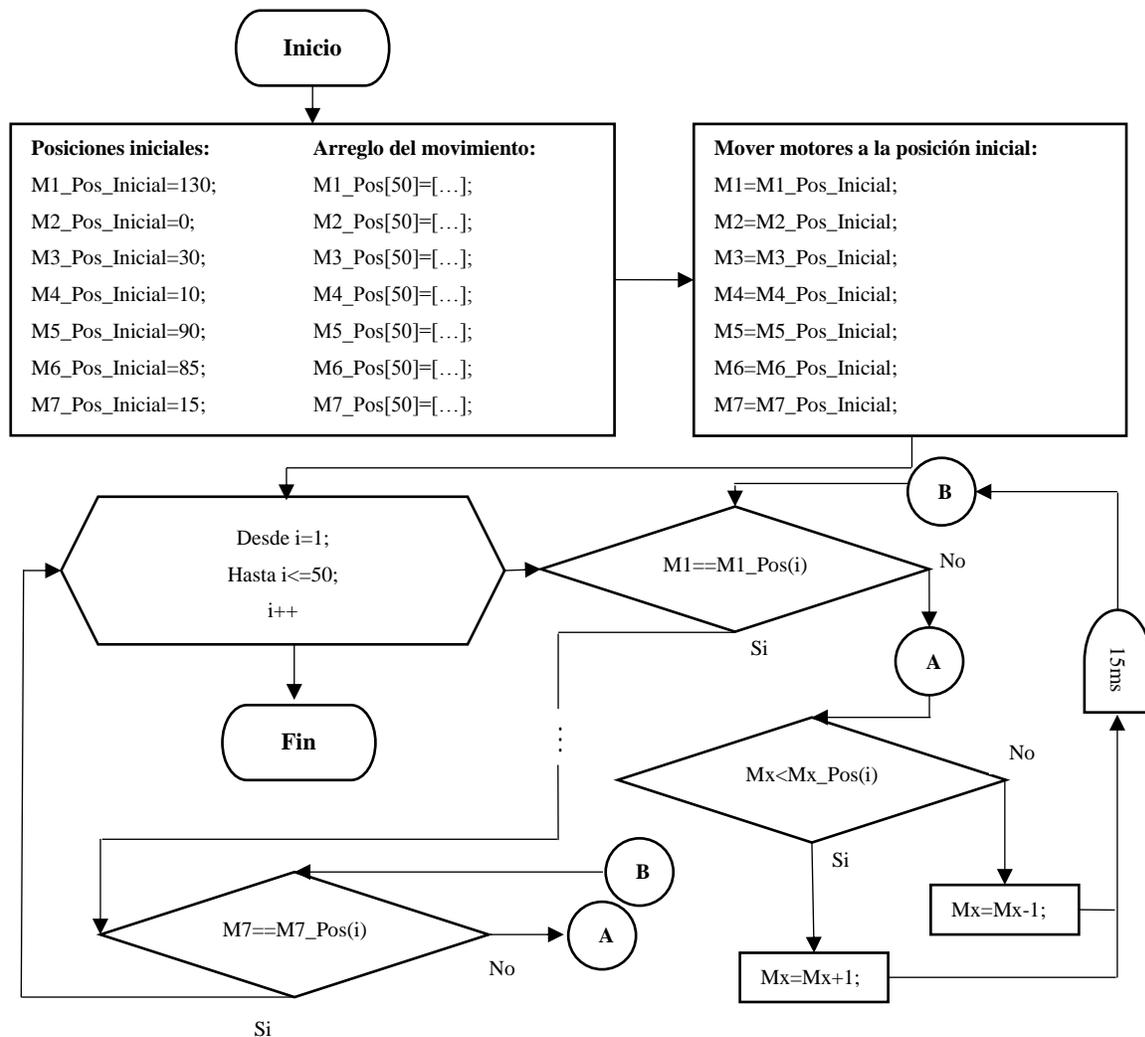


Figura 26. Diagrama de flujo del programa utilizado para el movimiento de los actuadores del brazo robótico.  $M_x$  indica el número de motor del 1 al 7 para el cambio de posición.

El movimiento del brazo robótico se registró con los sensores Xsens dot (Xsens, Países bajos) colocados en los segmentos correspondientes al tórax, brazo, antebrazo y mano del brazo robótico. Los registros obtenidos con los Xsens dot fueron comparados con los registros originales de dicho movimiento para comparar la respuesta obtenida mediante un análisis estadístico.

## Capítulo 5. Resultados

### 5.1 Brazo robótico

De acuerdo con los resultados obtenidos en la simulación por tensiones Von Mises, Figura 17, el material ABS tiene una tensión mínima de  $0.1621 \text{ N/m}^2$  y una tensión máxima de  $168.7 \text{ N/m}^2$  con un desplazamiento unitario, Figura 18, máximo de  $1.345 \times 10^{-8} \text{ mm}$ . Estos resultados se encuentran por debajo de las propiedades mecánicas marcadas para el material ABS en impresión 3D [108], por lo que aún con un factor de seguridad en la simulación, el ABS es un material viable para su uso en esta aplicación. Para la construcción del brazo robótico, Figura 27, se hizo uso de una base de hierro fundido sobre la que se colocaron los motores que simularán ser la articulación del hombro.



*Figura 27. Brazo robótico simulando la flexión del hombro.*

### 5.2 Sensores

La validación de los sensores para su uso como un dispositivo que entrega información confiable para uso en el estudio del movimiento se realizó mediante dos pruebas. La primera, llamada prueba estática, que evalúa la respuesta del algoritmo usado en sensores MARG sin

movimiento durante 600s, a fin de obtener información relativa a la deriva y ruido que pudieran registrar los sensores, Figura 28.

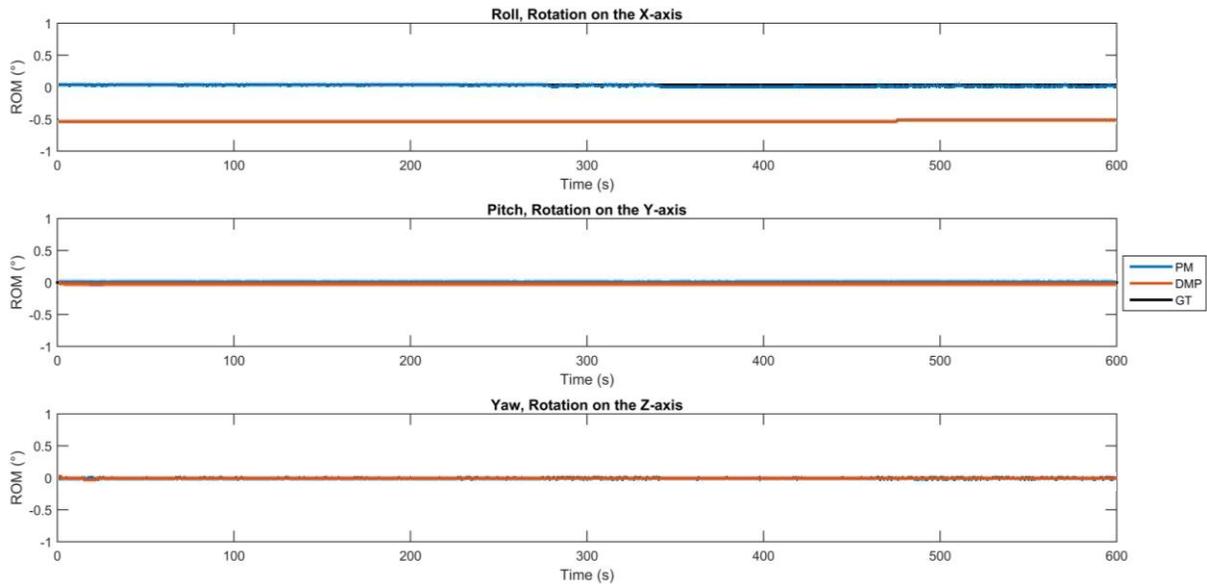


Figura 28. Respuesta del sensor sobre sus tres ejes durante la prueba estática.

Visualmente, se aprecia que los sensores con el algoritmo tienen la capacidad de reducir el ruido y eliminar la deriva. Para corroborar esta información se realizó un análisis estadístico con los parámetros de evaluación para los métodos utilizados en seguimiento de trayectorias con sensores inerciales [115] y su comparación con un procesador digital de movimiento (DMP), Tabla 6.

Tabla 6. Análisis estadístico de la prueba estática. Promedio (°): el valor promedio de la señal durante la prueba en grado;  $\sigma$  (°): Desviación estándar;  $S^2$  (°<sup>2</sup>): Varianza; RECM (°): Raíz del error cuadrático medio. PM: Respuesta del algoritmo propuesto para los sensores; DMP: Respuesta del procesador digital de movimiento utilizado para comparar los resultados.

	Promedio (°)		$\sigma$ (°)		$S^2$ (° <sup>2</sup> )		RECM (°)	
	PM	DMP	PM	DMP	PM	DMP	PM	DMP
Eje X	<b>0.0026</b>	0.0045	0.0063	<b>0.0031</b>	$3.96 \times 10^{-5}$	<b><math>9.86 \times 10^{-6}</math></b>	$4.65 \times 10^{-5}$	<b><math>2.98 \times 10^{-5}</math></b>
Eje Y	<b><math>-3.71 \times 10^{-4}</math></b>	-0.02	0.001	<b><math>7.32 \times 10^{-4}</math></b>	$1.49 \times 10^{-6}$	<b><math>5.35 \times 10^{-7}</math></b>	<b><math>1.63 \times 10^{-6}</math></b>	$3.80 \times 10^{-4}$
Eje Z	<b>-0.01</b>	-0.44	<b>0.012</b>	0.017	<b><math>1.45 \times 10^{-4}</math></b>	$2.95 \times 10^{-4}$	<b><math>2.85 \times 10^{-4}</math></b>	0.19

La segunda prueba, llamada prueba dinámica, consiste en evaluar la respuesta de los sensores en movimiento para ver la capacidad de los sensores para el seguimiento del movimiento.

Para ello se realizó una prueba *tilt table*, la cual consiste en rotar el sensor en diferentes direcciones, controlando su límite de movimiento y registrar su comportamiento [115, 122]. Para simular esta prueba, se colocó el sensor en un servomotor para hacerlo girar sobre un eje, simulando la prueba *tilt table* y cambiando la posición del sensor para girar sobre sus tres ejes, Figura 29.

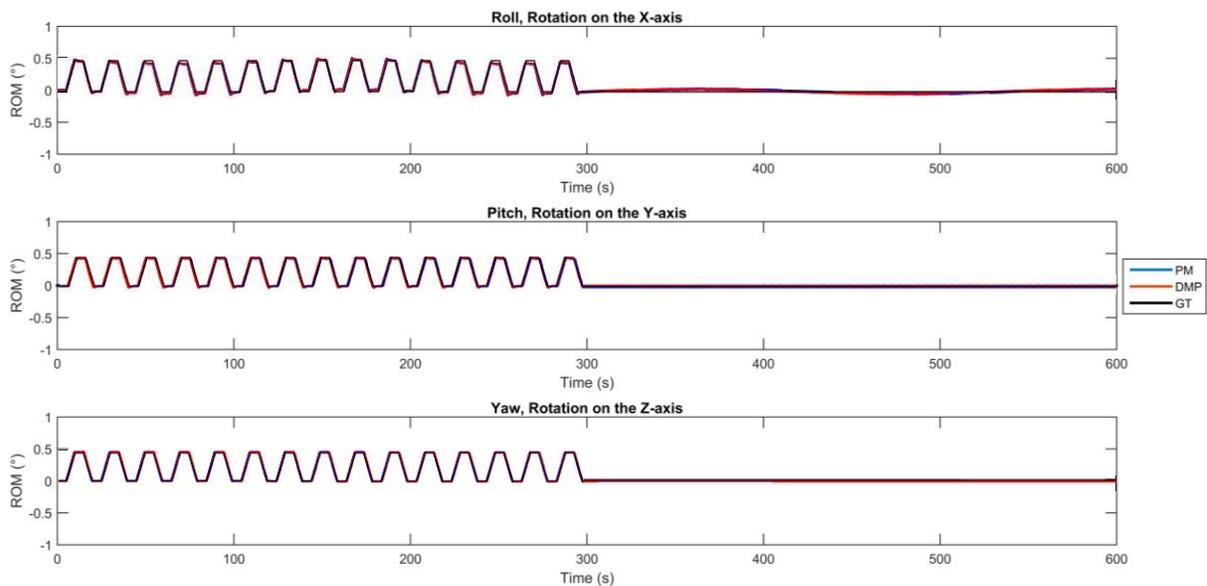


Figura 29. Respuesta del sensor sobre sus tres ejes durante las pruebas dinámicas.

Al igual que en las pruebas estáticas, el comportamiento del sensor y el DMP es muy similar; no se presentaron diferencias significativas, ni altos niveles de ruido o deriva entre ambos dispositivos. Nuevamente, un análisis cuantitativo se realizó para corroborar esto, Tabla 7.

Tabla 7. Análisis cuantitativo de las pruebas dinámicas. Etapa 1: Etapa de movimiento, se realizan quince ciclos de movimiento de 0-90° durante los primeros 300s. Etapa 2: Etapa estática en la que se puede observar la capacidad de los dispositivos para mantener la orientación y sus niveles de deriva y ruido. Promedio<sub>Max</sub> (°): Promedio de las muestras de la señal en los 90° de los ciclos; Promedios<sub>Min</sub> (°): Promedios de las muestras de la señal en los 0° de los ciclos;  $\sigma$  (°): Desviación estándar;  $S^2$  (°<sup>2</sup>): Varianza; PM<sub>X,Y,Z</sub>: Resultados para las rotaciones sobre los ejes X,Y,Z del sensor con el algoritmo propuesto; DMP<sub>X,Y,Z</sub>: Resultados para las rotaciones sobre los ejes X,Y,Z del procesador digital de movimiento.

Etapa 1 (0-300 s)	PM <sub>X</sub>	DMP <sub>X</sub>	PM <sub>Y</sub>	DMP <sub>Y</sub>	PM <sub>Z</sub>	DMP <sub>Z</sub>
Promedio <sub>Max</sub> (°)	<b>90.17</b>	89.26	<b>89.91</b>	89.01	<b>89.94</b>	90.86
Promedio <sub>Min</sub> (°)	<b>0.23</b>	-0.5	<b>-0.15</b>	-0.84	<b>0.06</b>	0.84
$\sigma$ (°)	<b>0.73</b>	3.48	<b>0.46</b>	0.99	<b>0.72</b>	0.85
$S^2$ (° <sup>2</sup> )	<b>0.53</b>	12.13	<b>0.21</b>	0.98	<b>0.52</b>	0.73
RECM (°)	<b>0.53</b>	12.13	<b>0.21</b>	0.98	<b>0.51</b>	0.73
Etapa 2 (301-600 s)	PM <sub>X</sub>	DMP <sub>X</sub>	PM <sub>Y</sub>	DMP <sub>Y</sub>	PM <sub>Z</sub>	DMP <sub>Z</sub>
Promedio (°)	<b>0.25</b>	0.77	-0.24	<b>0.01</b>	<b>0.04</b>	1.90
$\sigma$ (°)	<b>0.52</b>	3.43	0.42	<b>0.15</b>	<b>0.20</b>	0.42
$S^2$ (° <sup>2</sup> )	<b>0.26</b>	11.73	0.19	<b>0.02</b>	<b>0.04</b>	0.18
RECM (°)	<b>0.25</b>	11.73	0.19	<b>0.02</b>	<b>0.04</b>	0.18

Estos resultados indican que tanto el algoritmo con los sensores y el DMP son capaces de seguir trayectorias de movimiento sin perder la orientación y con niveles de ruido y deriva bajos, a pesar de tener condiciones de campo magnético y vibraciones causados por el servomotor.

Con la validación de los sensores con el algoritmo propuesto para su uso para el estudio del movimiento humano, se realizaron pruebas para analizar el movimiento de la extremidad superior, Figura 30-35, con los movimientos mencionados en el apartado 4.4.2.

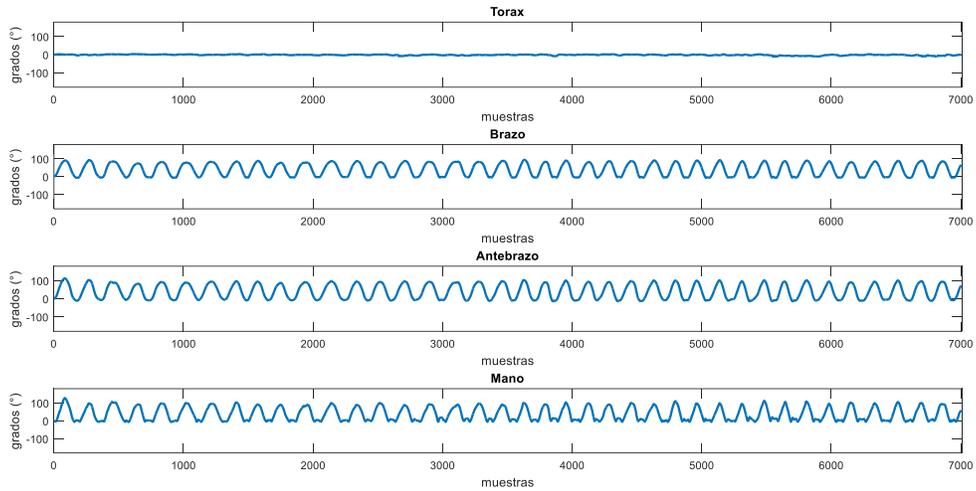


Figura 30. Seguimiento de los sensores con el algoritmo para el movimiento de flexo-extensión del hombro.

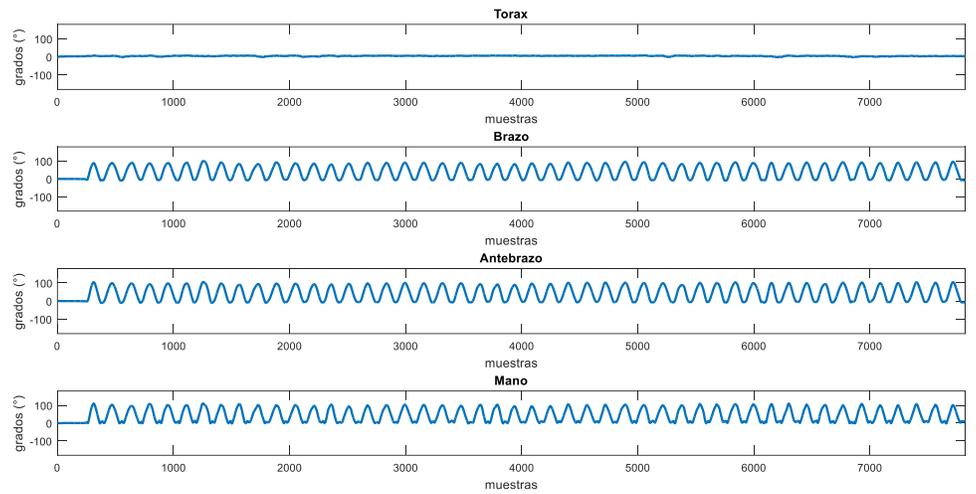


Figura 31. Seguimiento de los sensores con el algoritmo para el movimiento de abducción-aducción del hombro.

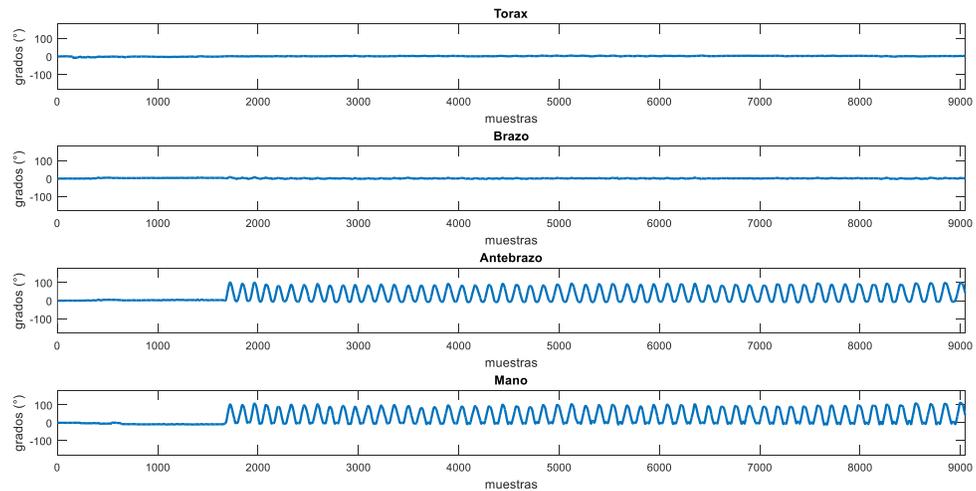


Figura 32. Seguimiento de los sensores con el algoritmo para el movimiento de flexo-extensión del codo.

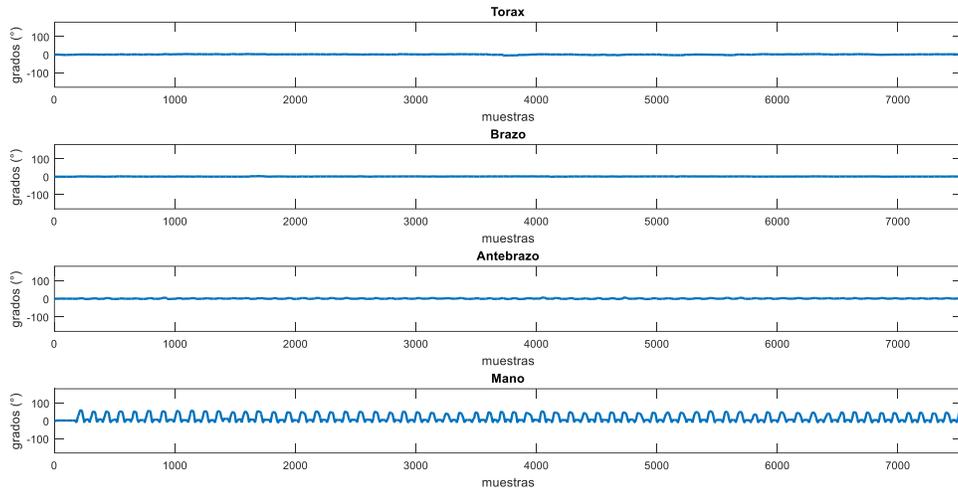


Figura 33. Seguimiento del movimiento de flexo-extensión de la muñeca con los sensores con el algoritmo.

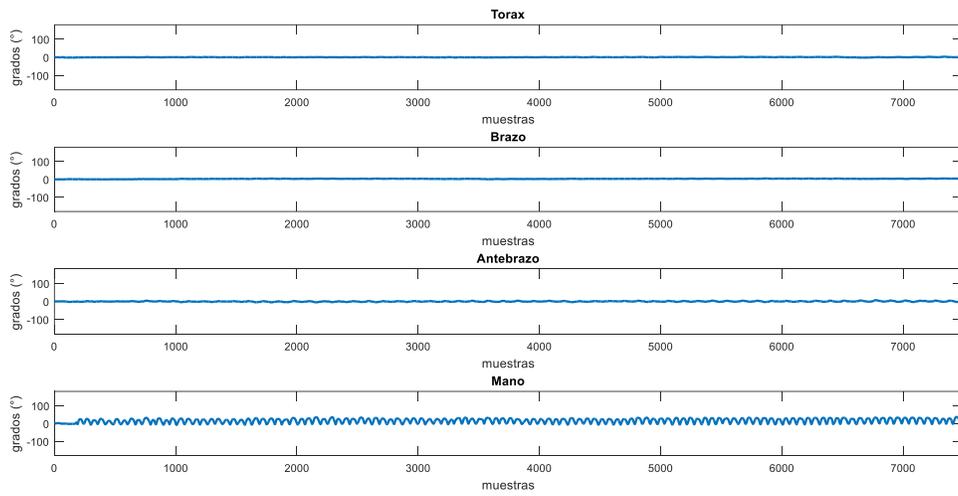


Figura 34. Seguimiento del movimiento de abducción-aducción de muñeca con los sensores con el algoritmo.

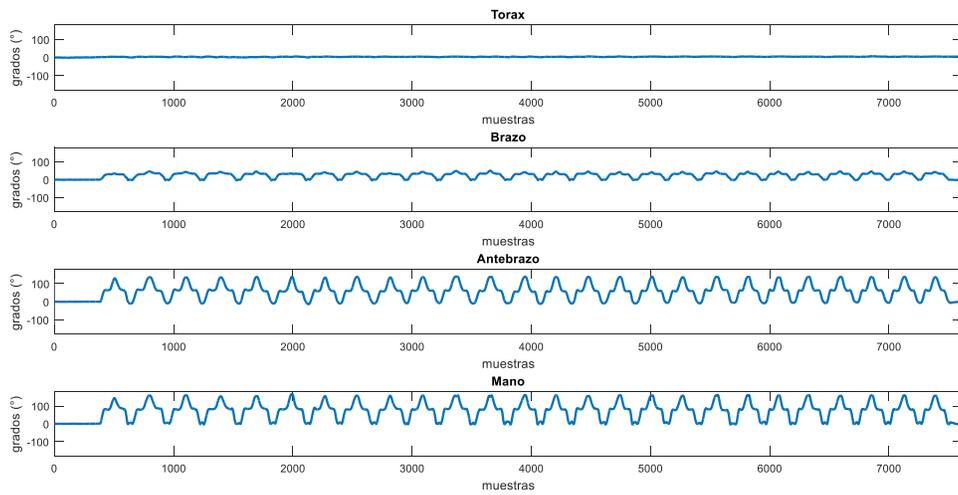


Figura 35. Seguimiento del movimiento Reach-to-Grasp con los sensores con el algoritmo.

Con la información del seguimiento de la trayectoria registrada por los sensores con el algoritmo, se realizó un análisis estadístico con respecto a la respuesta del DMP para los movimientos de flexo-extensión del hombro, flexo-extensión del codo, abducción-aducción de la muñeca y el movimiento *Reach-to-Grasp*, Tabla 8.

*Tabla 8. Resultados del análisis estadístico de los movimientos de flexo-extensión del hombro, flexo-extensión del codo, abducción-aducción de muñeca y Reach-to-Grasp.  $\sigma$  ( $^{\circ}$ ): desviación estándar;  $S^2$  ( $^{\circ 2}$ ): varianza; RECM vs DMP: Raíz del error cuadrático medio comparando de la señal del sensor con respecto al procesador digital de movimiento; CC vs DMP: Coeficientes de correlación de la señal del sensor con respecto al procesador digital de movimiento.*

<b>Movimiento</b>	<b>Promedio de rango de movimiento (<math>^{\circ}</math>)</b>	<b><math>\sigma</math> (<math>^{\circ}</math>)</b>	<b><math>S^2</math> (<math>^{\circ 2}</math>)</b>	<b>RECM vs DMP</b>	<b>CC vs DMP</b>
<b>Flexo-extensión de hombro</b>	-22.27 – 83.22	1.57	1.54	2.6746 $^{\circ}$	0.9956
<b>Flexo-extensión de codo</b>	-1.72 – 88.78	1.29	1.48	2.65 $^{\circ}$	0.997
<b>Abducción-aducción de muñeca</b>	55.09 – 106.08	1.91	1.94	3.98 $^{\circ}$	0.9948
<b><i>Reach-to-Grasp</i></b>	-	1.02 $^{\circ}$	1.11 $^{\circ}$	1.34 $^{\circ}$	0.9916

### 5.3 Red neuronal artificial

Las pruebas realizadas para el movimiento de la extremidad superior humana mencionadas en el apartado 4.4.2 dieron un total de 42,356 muestras, los cuales se segmentaron para generar los conjuntos de entrenamiento, validación y pruebas como se muestra en la Figura 25. El entrenamiento de la red neuronal artificial requirió de 6 iteraciones para converger al error propuesto de 0.01 en la identificación de las siete clases correspondientes a cada movimiento, Figura 36.

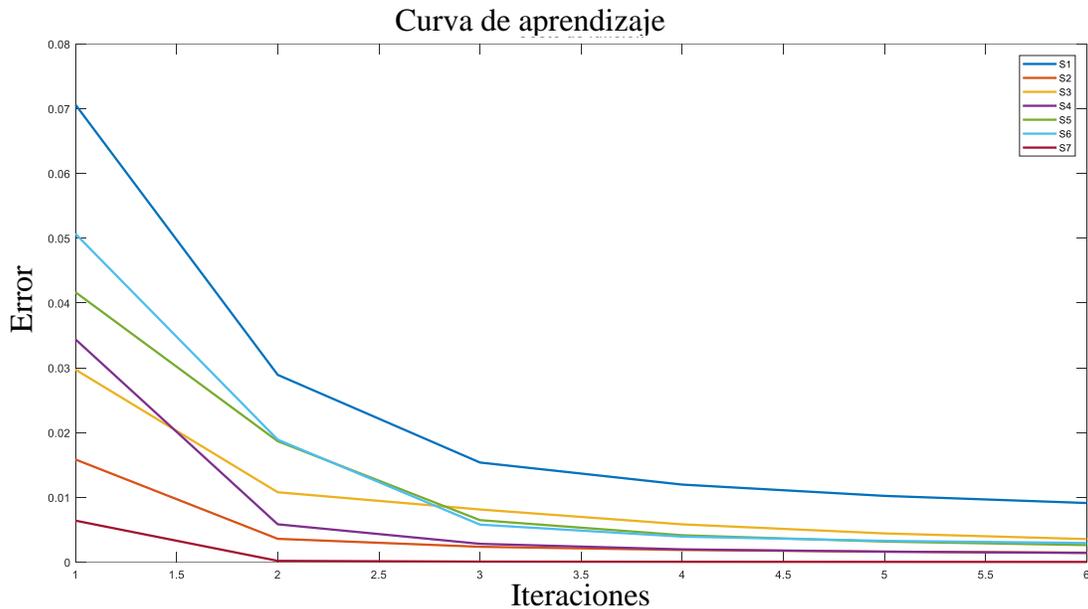


Figura 36. Curva de aprendizaje para la arquitectura 16-7-7 propuesta de la red neuronal artificial.

De acuerdo con la validación cruzada utilizada para evaluar la arquitectura del modelo de red neuronal artificial propuesta el promedio de la precisión entre los tres modelos ( $K=3$ ) con respecto a los datos correctamente clasificados fue de 97.28%. Este resultado permitió confiar en que la red neuronal artificial propuesta no se encontraba sobre entrenada y permitía generalizar los datos para su uso en la clasificación de los movimientos realizados [123].

A partir de este resultado se utilizó el conjunto de pruebas con los parámetros de la red neuronal artificial entrenados para determinar el desempeño con datos nuevos para el modelo. El desempeño fue del 97.51% el cual se presenta en la siguiente matriz de confusión, Tabla 9.

Tabla 9. Matriz de confusión para el conjunto de pruebas. Clase 1: Posición N; Clase 2: Flexión del hombro; Clase 3: Abducción del hombro; Clase 4: Flexión del codo; Clase 5: Flexión de muñeca; Clase 6: Abducción de muñeca; Clase 7: Movimiento Reach-to-Grasp.; MC: Datos mal clasificados.

<b>Matriz de Confusión</b>	<b>Clase 1</b>	<b>Clase 2</b>	<b>Clase 3</b>	<b>Clase 4</b>	<b>Clase 5</b>	<b>Clase 6</b>	<b>Clase 7</b>
<b>Clase 1</b>	3146	29	29	28	1	14	0
<b>Clase 2</b>	0	1286	0	0	0	0	0
<b>Clase 3</b>	0	0	1434	0	0	0	0
<b>Clase 4</b>	0	0	0	1183	0	0	0
<b>Clase 5</b>	21	0	0	0	1127	0	0
<b>Clase 6</b>	32	0	0	0	0	1204	0
<b>Clase 7</b>	0	0	0	0	0	0	897
<b>MC</b>	50	21	11	20	2	2	0
<b>Desempeño</b>	96.83%	96.26%	97.29%	96.10%	99.73%	98.67%	100%

Se realizó una comparativa uno-contra-todos (*one-vs-all*) para determinar la sensibilidad, especificidad y curva de la característica operativa del receptor (ROC, *receiver operating characteristic*) de cada movimiento para el modelo de red neuronal propuesto, Tabla 10 y Figura 37.

Tabla 10. Comparación estadística uno-contra-todos para cada clase.

<b>Clase</b>	<b>Área bajo la curva</b>	<b>Sensibilidad</b>	<b>Especificidad</b>	<b>Precisión</b>
<b>1-vs-todos</b>	0.977	0.935	0.993	97.39%
<b>2-vs-todos</b>	0.972	0.853	0.995	97.39%
<b>3-vs-todos</b>	0.976	0.859	0.997	97.39%
<b>4-vs-todos</b>	0.971	0.841	0.995	97.39%
<b>5-vs-todos</b>	0.971	0.818	0.996	97.39%
<b>6-vs-todos</b>	0.96	0.842	0.993	97.39%
<b>7-vs-todos</b>	0.986	0.753	1.000	97.39%

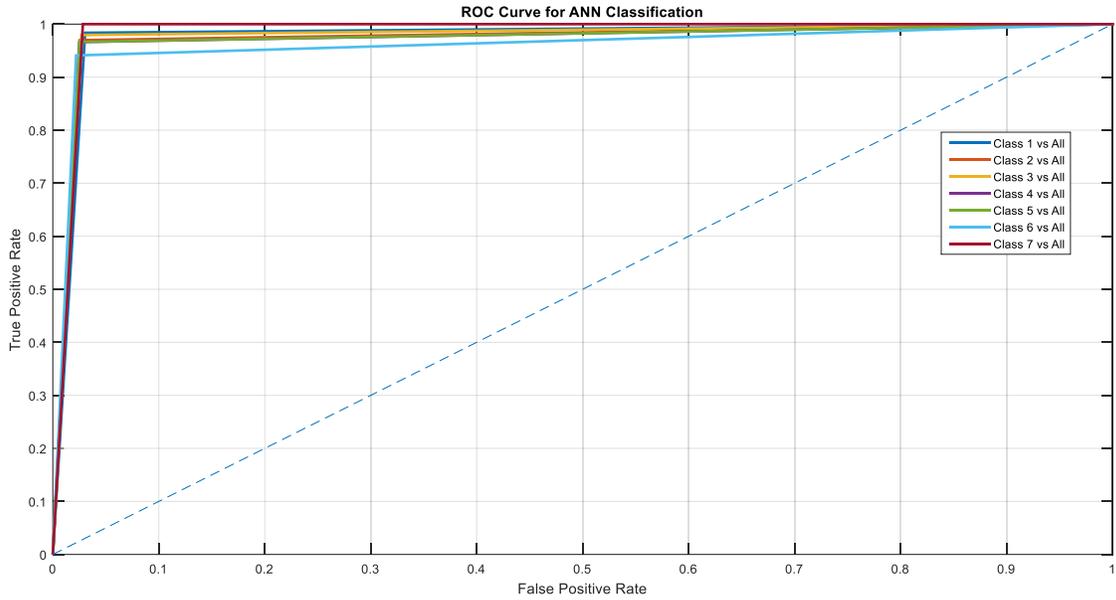


Figura 37. Curva ROC de cada clase en uno-contra-todos.

## 5.4 Validación de los movimientos con el brazo robótico

Los registros obtenidos por parte de los voluntarios se utilizaron para indicar el movimiento que debe realizar el brazo robótico. Para validar los movimientos del brazo robótico se analizó la repetibilidad de los movimientos, Figura 38-48.

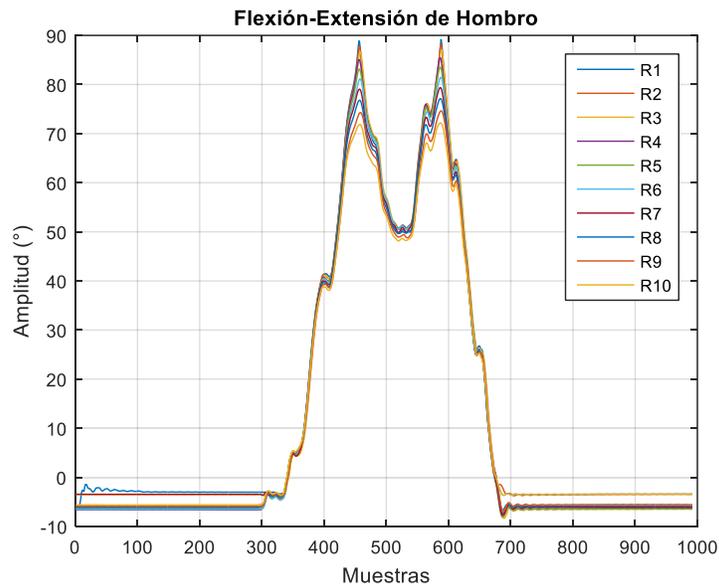


Figura 38. Registro de las repeticiones del movimiento de flexo-extensión de hombro con el brazo robótico.

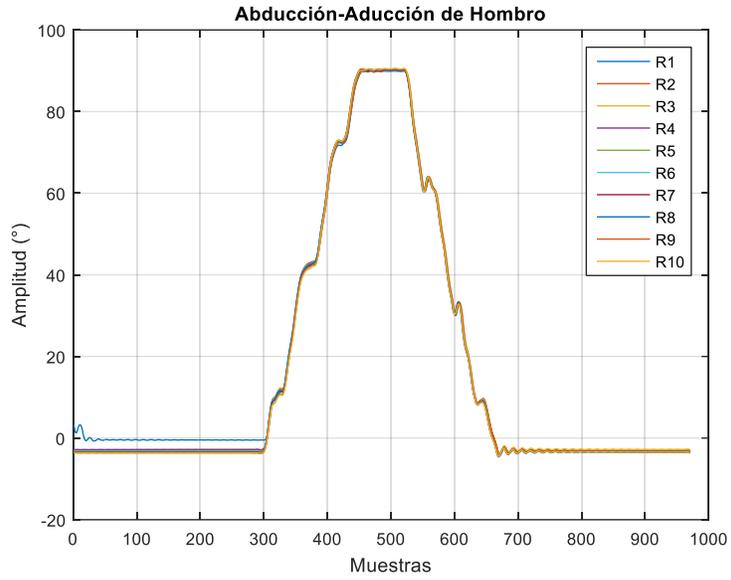


Figura 39. Registros de las repeticiones del movimiento de Abducción-aducción de hombro con el brazo robótico

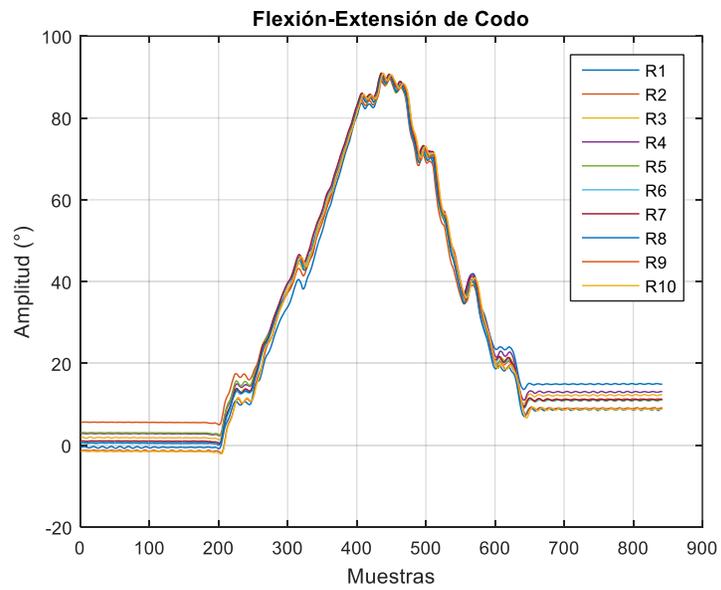


Figura 40. Registro de las repeticiones del movimiento de flexo-extensión de codo con el brazo robótico.

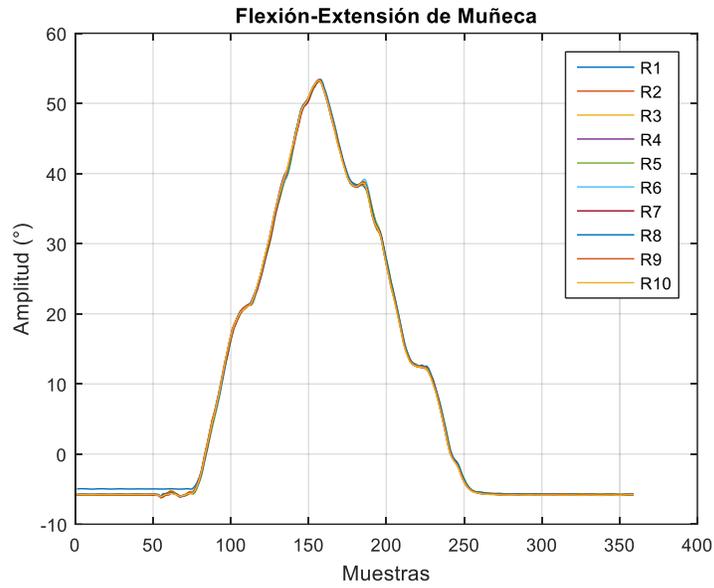


Figura 41. Registro de las repeticiones del movimiento de flexo-extensión de la muñeca con el brazo robótico.

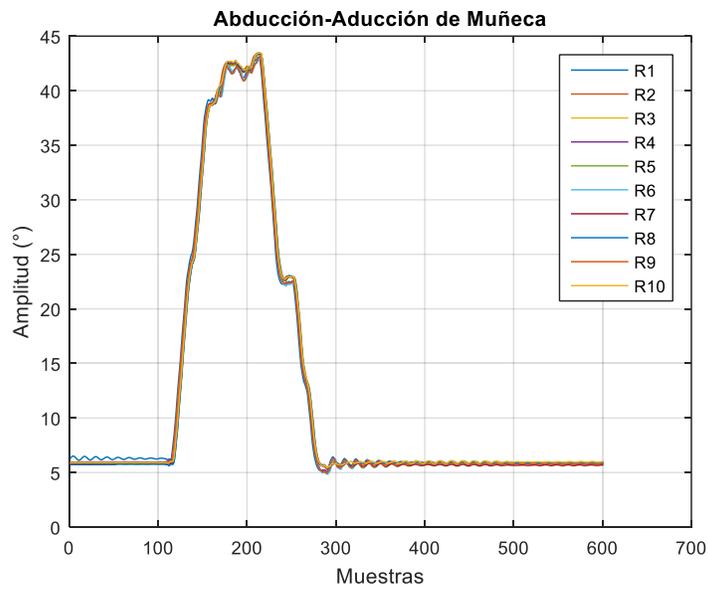


Figura 42. Registro de las repeticiones del movimiento de abducción-aducción de muñeca con el brazo robótico.

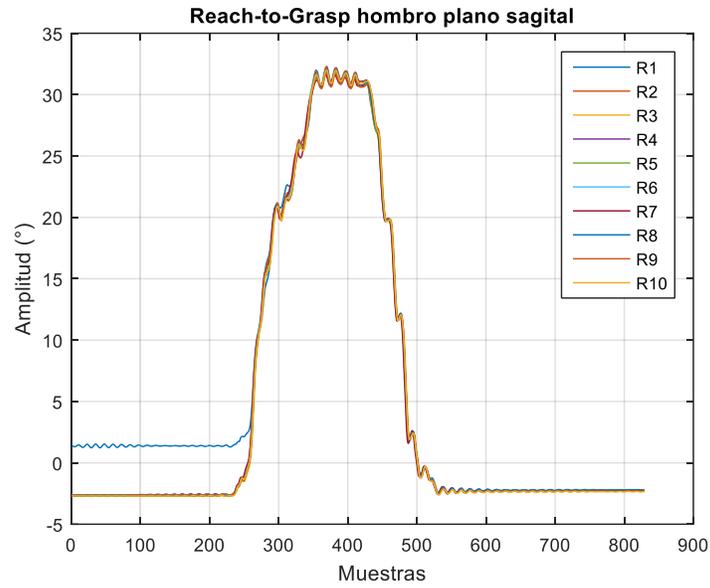


Figura 43. Registro de las repeticiones del movimiento Reach-to-Grasp en la actividad sobre el plano sagital del hombro con el brazo robótico.

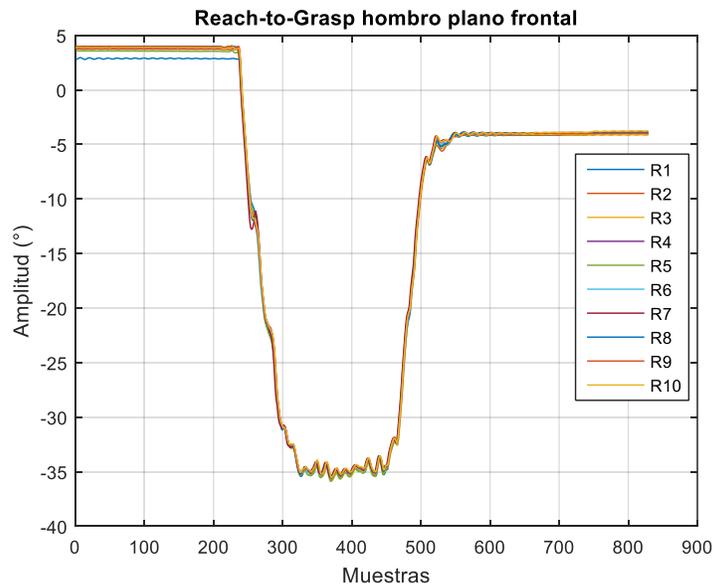


Figura 44. Registro de las repeticiones del movimiento Reach-to-Grasp en la actividad sobre el plano frontal del hombro con el brazo robótico.

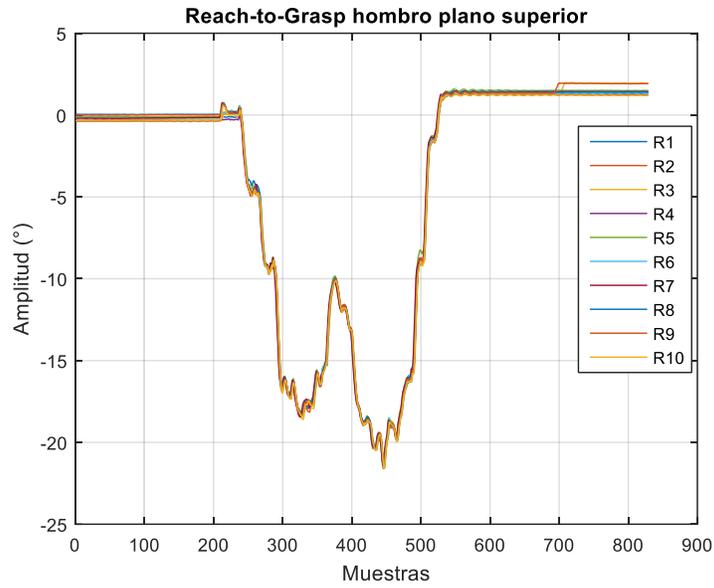


Figura 45. Registro de las repeticiones del movimiento Reach-to-Grasp en la actividad sobre el plano superior del hombro con el brazo robótico

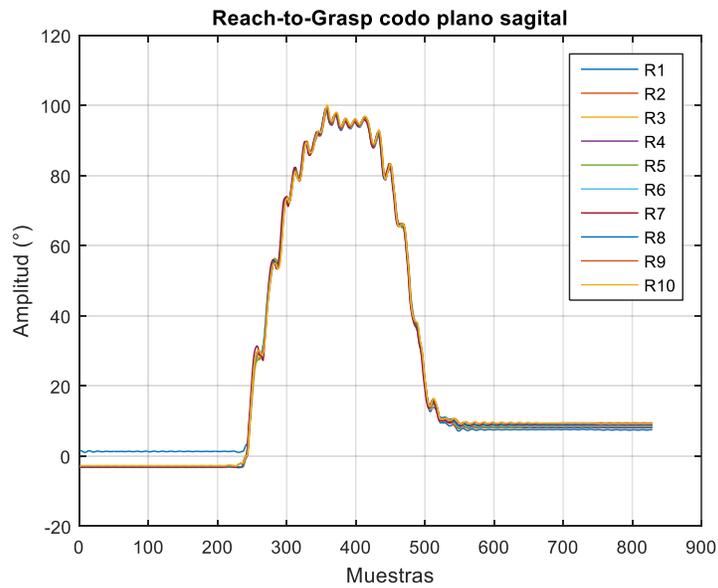


Figura 46. Registro de las repeticiones del movimiento Reach-to-Grasp en la actividad sobre el plano sagital del codo con el brazo robótico.

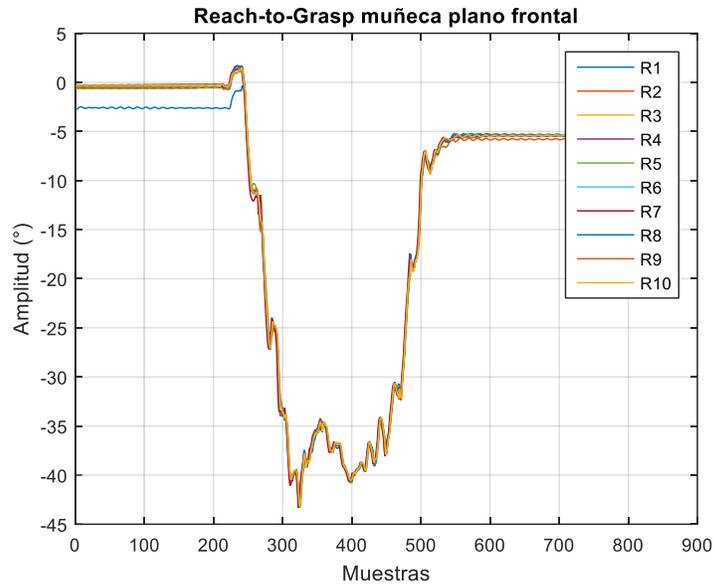


Figura 47. Registro de las repeticiones del movimiento Reach-to-Grasp en la actividad sobre el plano frontal de la muñeca con el brazo robótico.

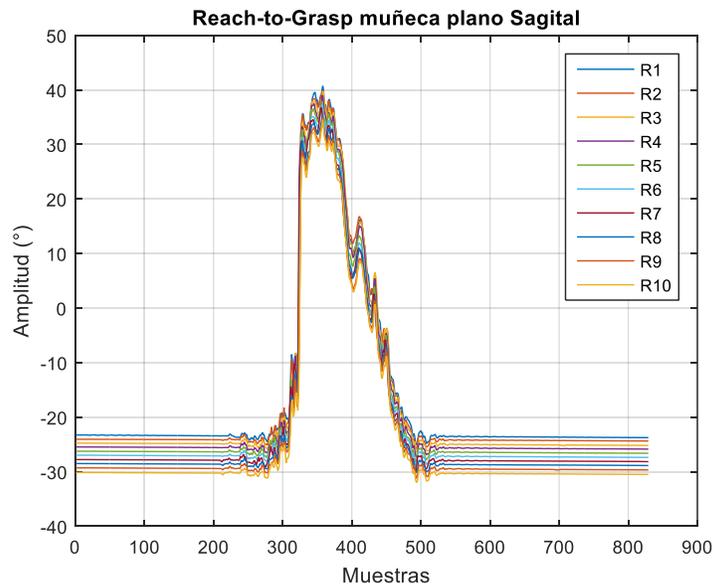


Figura 48. Registro de las repeticiones del movimiento Reach-to-Grasp en la actividad sobre el plano sagital de la muñeca con el brazo robótico.

Las repeticiones se compararon haciendo un análisis estadístico en el que se calcularon el valor promedio de las señales, la desviación estándar y la correlación mediante un análisis Bland-Altman, Tabla 11.

Tabla 11. Estadística de la repetibilidad de las pruebas de movimiento del brazo robótico.

Movimientos	Promedio	Desviación estándar	Correlación
Flexo-Extensión del Hombro	-0.6219°	2.0269°	0.9983
Abducción-Aducción del Hombro	-0.4966°	0.8420°	0.9997
Flexo-Extensión del Codo	-0.70487°	1.6659°	0.9980
Flexo-Extensión de la Muñeca	-0.0518°	0.3814°	0.9844
Abducción-Aducción de la Muñeca	0.0157°	0.4217°	0.9991
Reach-to-Grasp Hombro	-0.0191°	0.2531°	0.9997
Reach-to-Grasp Codo	0.6535°	0.8283°	0.9788
Reach-to-Grasp Muñeca	-0.6223°	1.5159°	0.9988

Los valores promedio obtenidos indican las diferencias que hay entre las repeticiones para cada movimiento, siendo las repeticiones del codo las de mayor diferencia. Por otra parte, los registros con una mayor dispersión entre los datos se encuentran entre las repeticiones de la flexo-extensión del hombro. Sin embargo, los coeficientes de correlación son superiores a los 0.97 entre las repeticiones de los seis movimientos. Una vez comprobada la repetibilidad del brazo robótico, se compararon las repeticiones con los registros originales mediante un análisis Bland-Altman, Figura 49-55.

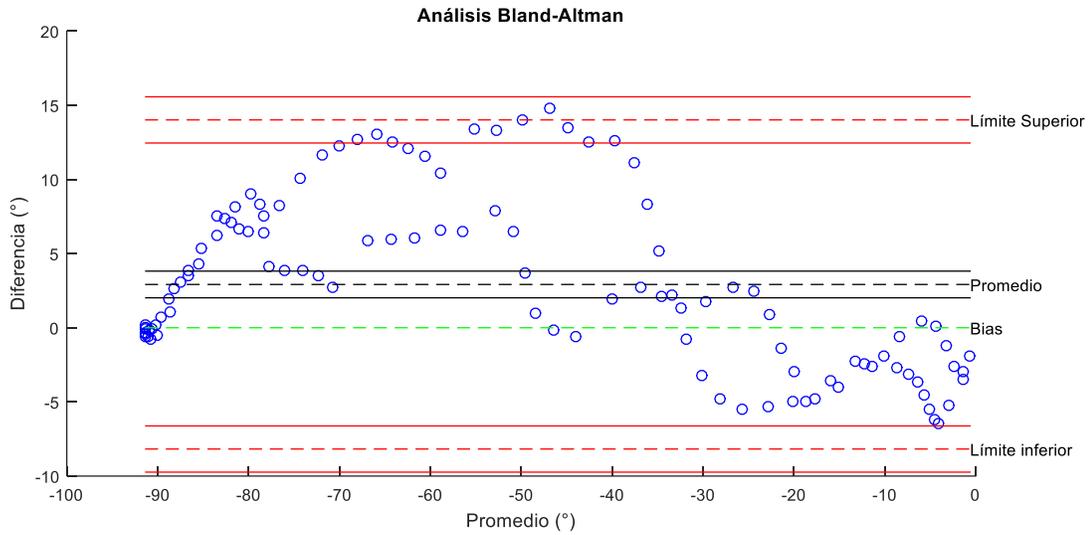


Figura 49. Análisis Bland-Altman para el movimiento de Flexo-Extensión del hombro entre el registro de una persona y su repetición con el brazo robótico.

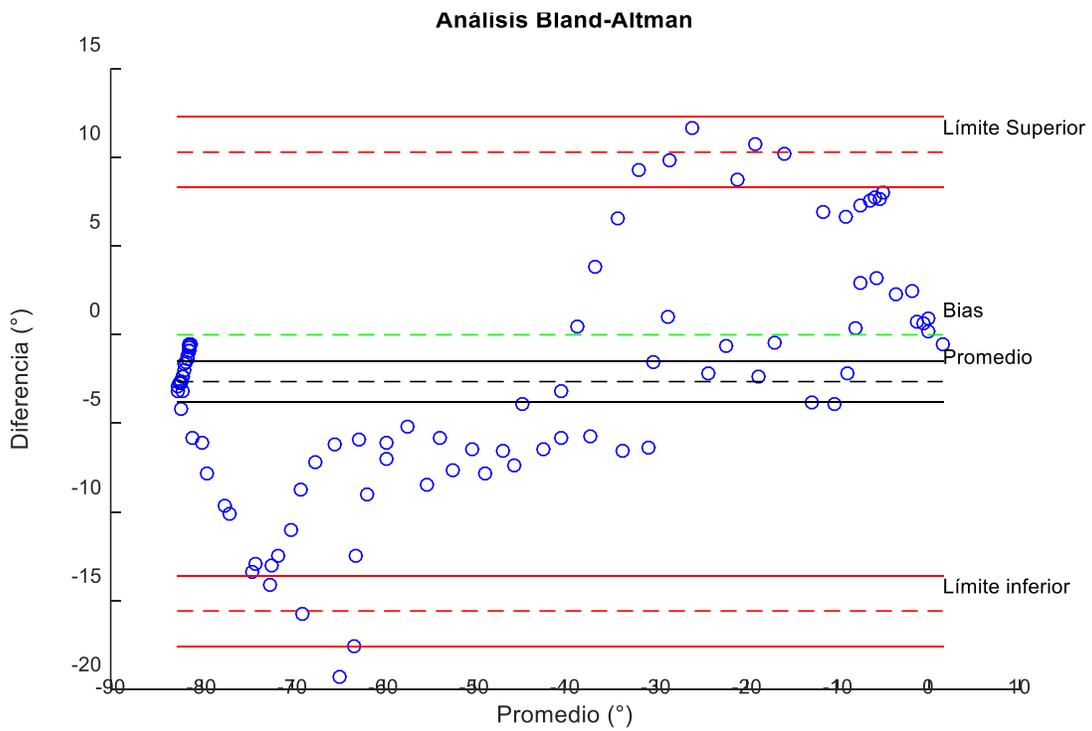


Figura 50. Análisis Bland-Altman para el registro de Abducción-aducción del hombro entre el registro de una persona y su repetición con el brazo robótico.

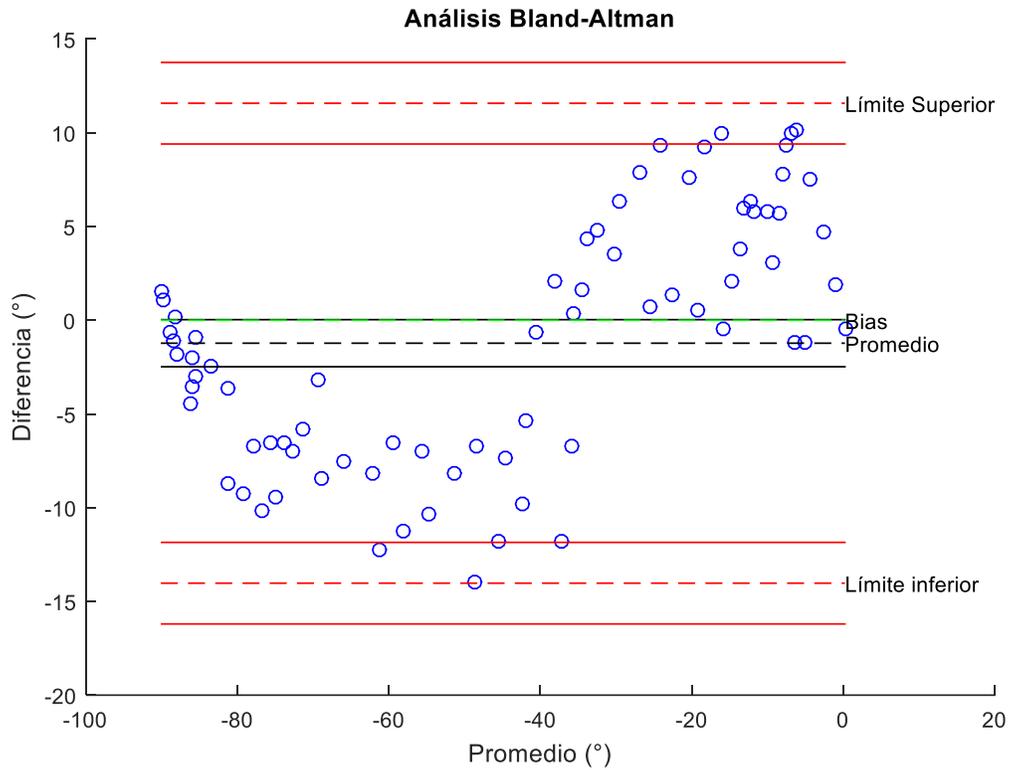


Figura 51. Análisis Bland-Altman para el movimiento de flexo-extensión del codo entre el registro de una persona y su repetición con el brazo robótico.

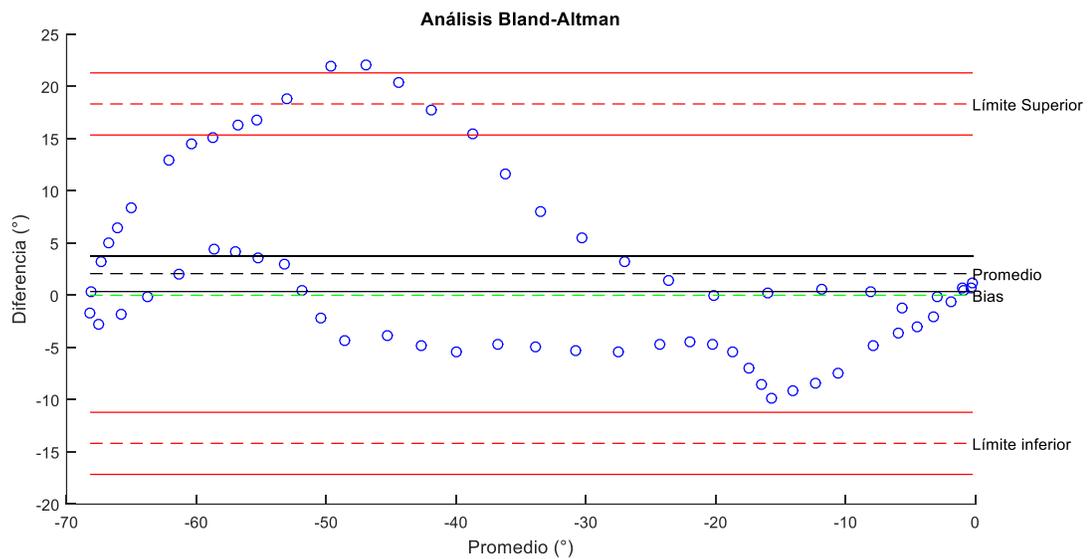


Figura 52. Análisis Bland-Altman para el movimiento de flexo-extensión de muñeca entre el registro de una persona y su repetición con el brazo robótico.

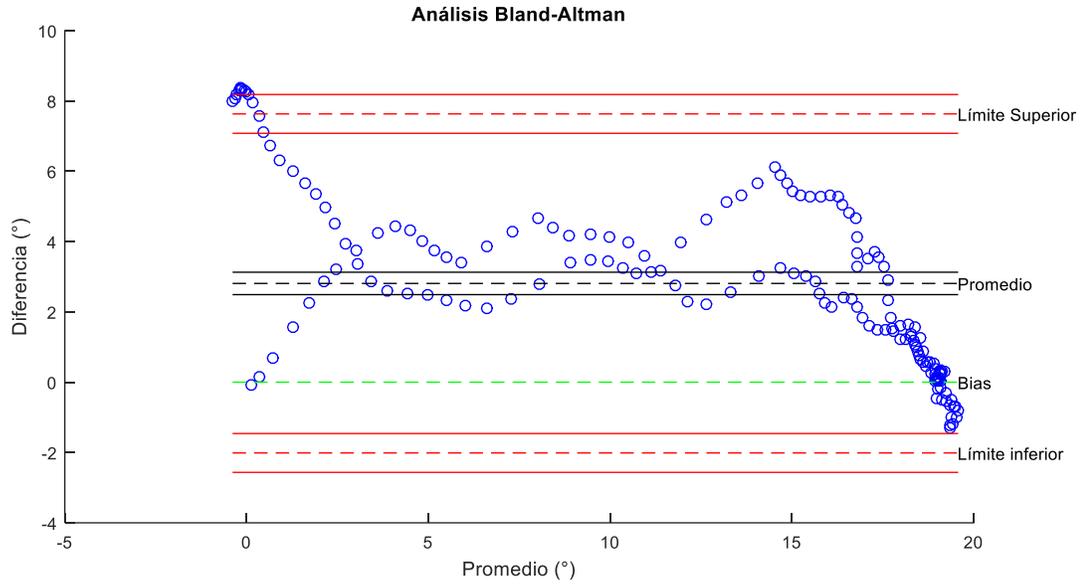


Figura 53. Análisis Bland-Altman para el movimiento del hombro durante la ejecución Reach-to-Grasp entre el registro de una persona y su repetición con el brazo robótico.

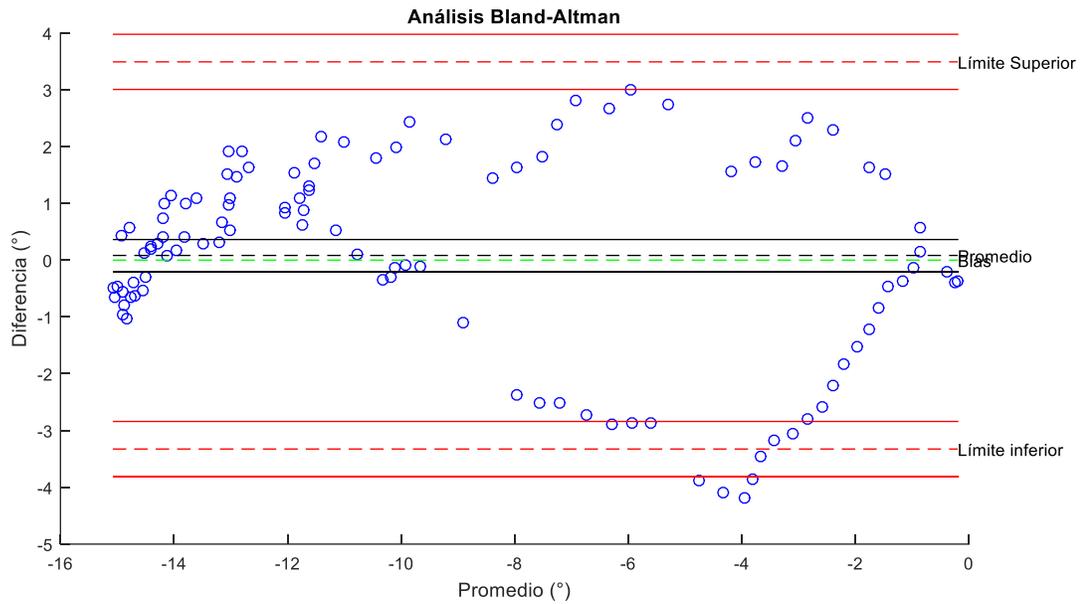


Figura 54. Análisis Bland-Altman para el movimiento del codo durante la ejecución Reach-to-Grasp entre el registro de una persona y su repetición con el brazo robótico.

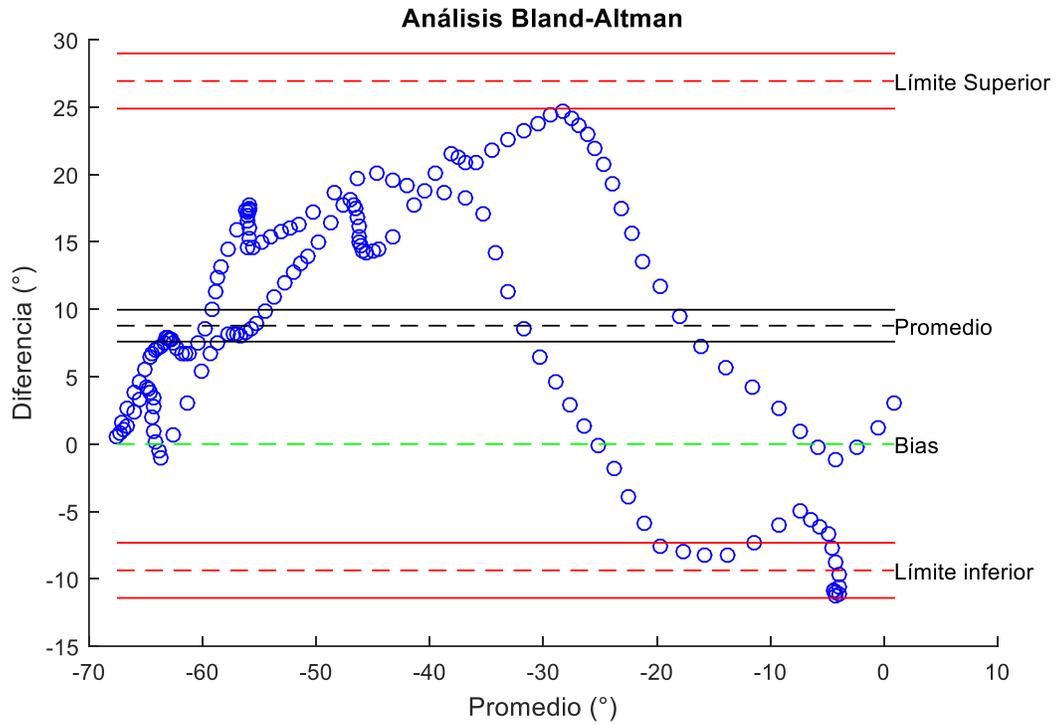


Figura 55. Análisis Bland-Altman para el movimiento de la muñeca durante la ejecución Reach-to-Grasp entre el registro de una persona y su repetición con el brazo robótico.

Los resultados obtenidos por el análisis Bland-Altman, se reportan en la Tabla 12.

Tabla 12. Análisis estadístico obtenido a partir del análisis Bland-Altman para los registros con personas y su repetición con el brazo robótico.

Movimientos	Promedio	Desviación Estándar	Correlación
Flexo-Extensión Hombro	2.9176°	3.66°	0.987
Abducción- Aducción Hombro	-2.6435	3.6077°	0.983
Flexo-Extensión Codo	-1.2242	3.5317°	0.9848
Flexo-Extensión Muñeca	2.0734	4.2914°	0.9471
Abducción- Aducción Muñeca	0.7461	3.8186°	0.9429
<i>Reach-to-Grasp</i> Hombro	2.8088	2.4599°	0.9667
<i>Reach-to-Grasp</i> Codo	0.0822	1.7329°	0.9429
<i>Reach-to-Grasp</i> Muñeca	2.7798	2.2619°	0.9118

Los valores promedio reportados en la Tabla 12, indican el sesgo que tiene la medición del registro del brazo robótico con respecto a el registro obtenido por una persona. El valor de desviación estándar indica que tan dispersos son los valores obtenidos en el registro del movimiento del brazo robótico con respecto al indicado por el registro de la persona. Estos dos parámetros permiten indicar límites de concordancia para las mediciones del brazo. Para ello se utilizó un margen de error estimado a partir de un intervalo de confianza del 95% mediante una distribución T de *Student* para los diferentes grados de libertad de cada señal comparada. Por último, los coeficientes de correlación para los seis movimientos son superior a 0.91.

## Capítulo 6. Discusión

Los valores de precisión en la evaluación del movimiento de la extremidad superior humana utilizando sensores IMU/MARG se consideran aceptables en errores menores al 5° [115, 124], mientras que los coeficientes de correlación mayores a 0.95 se consideran de alta relación entre dos señales [35]. Las pruebas utilizadas para validar los sensores con el algoritmo mostraron la capacidad de éstos para seguir la trayectoria con niveles de ruido y deriva bajos, aún con fuentes de vibración y campo magnético cerca de ellos en las pruebas con un servomotor. Los resultados de estas pruebas mostraron que los sensores con el algoritmo obtienen resultados similares al de un procesador digital de movimiento (DMP). Por otro lado, las pruebas en humanos, Figura 30-35, muestran la capacidad de los módulos de monitoreo para la extremidad superior (MMES) y el algoritmo desarrollado para la estimación de la orientación en el seguimiento de la trayectoria del movimiento de la extremidad superior humana como una cadena articulada [114]. Los resultados obtenidos se encuentran dentro del rango reportado en publicaciones para algoritmos de sensores IMU/MARG [115].

Con la red neuronal artificial diseñada se logró la identificación de movimientos de la extremidad superior humana a partir de los registros de los sensores MARG. El bajo número de iteraciones necesarios para converger al error propuesto indica que la arquitectura propuesta fue adecuada para entrenar el modelo para la clasificación de los movimientos registrados [125, 126]. La precisión del reconocimiento del 97.39% mostró que el modelo es capaz de reconocer los patrones de las siete actividades. Este resultado permite determinar que el clasificador tiene un buen desempeño, ya que la probabilidad de clasificar patrones supera el 90% [127, 128]. El error de 2.61% puede deberse al límite propuesto para diferenciar entre la posición estática y los movimientos ejecutados. Este error podría disminuir si el límite se establece mediante un rango (por ejemplo: de 15° a 16° se considera como umbral sin decisión, menor a 15° es posición estática y mayor a 16° es el movimiento) en lugar de definirlo como un punto específico (menor a 15° se considera posición estática y mayor a 15° se considera el movimiento). El área bajo la curva obtenida en las curvas ROC para las siete comparativas sugiere que la red neuronal artificial propuesta tiene una buena capacidad para distinguir los movimientos, ya que los valores cercanos a uno indican una alta fiabilidad para predecir las clases [129]. Esto último se confirma con la precisión obtenida,

ya que estos valores se encuentran dentro del rango reportado para la predicción de la intención del movimiento de la extremidad superior humana [130, 131].

Durante las pruebas con el brazo robótico, se obtuvieron movimientos que podrían no considerarse normales si se comparan con los movimientos de la extremidad superior. Particularmente, en el hombro se aprecian estos movimientos de mayor manera. Estas actividades se deben a dos causas. La primera es que la articulación del hombro en el brazo robótico está separada en tres etapas (una por cada motor), esto ocasiona que los movimientos de la extremidad superior humana registrados sean más perceptibles. La segunda causa, es que los segmentos del brazo robótico son rígidos y no cambian su forma cuando se realiza un movimiento como lo hace la extremidad superior humana. Estos errores presentes en la medición de las actividades del brazo robótico pueden deberse a que los artefactos por tejido suave no se presenten de la misma manera en que lo hace durante los movimientos humanos ya que los segmentos de la extremidad superior humana cambian de acuerdo con las características de los voluntarios a quienes se les hace el registro: grasa corporal, contracción muscular, movimiento de la piel, etc. [132, 133].

Las Figura 38-48 y la Tabla 11, indican que el brazo robótico es capaz de repetir con un alto grado de confianza un mismo movimiento a partir de un registro en particular. Sin embargo, en algunos registros se obtienen diferencias notables en algunas repeticiones los cuales pueden deberse a las siguientes causas:

- Vibración causada por los actuadores.
- Inercia de los movimientos.
- Artefactos de tejido suave.

La vibración causada por los actuadores se propaga por las piezas y esto hace que los sensores registren este movimiento. Esto podría mejorar al utilizar actuadores que no ocasionen tanta vibración durante su actividad [134, 135] y un modelo de control antivibración [136, 137].

La inercia causada por el movimiento del brazo robótico hace que los sensores registren actividades involuntarias. Estos registros podrían mejorarse aplicando un sistema de control retroalimentado a las funciones de movimiento del brazo robótico que permita disminuir la inercia cuando el movimiento esté por terminar [138-140].

Los artefactos de tejido suave registrados en la actividad en personas se manifiestan en la actividad del brazo robótico. Estos artefactos se magnifican debido a la colocación de los

motores y la rigidez de las piezas que simulan los segmentos de la extremidad superior. Esto podría mejorarse al incluir una compensación para los registros de acuerdo con las condiciones del tejido suave para cada voluntario de prueba [34, 141-143].

El análisis Bland-Altman, Figura 49-55 y Tabla 12, permite estimar el intervalo de concordancia entre el registro obtenido por una persona y su repetición con el brazo robótico indicando si el 95% de las diferencias se encuentran dentro de este intervalo comparando los sesgos y las diferencias medias entre ambos registros [144]. De acuerdo con [144] los límites de concordancia no indican si las diferencias obtenidas son aceptables o no, para ello los límites de concordancia deben definirse de acuerdo con la condición del estudio. Los límites aceptables definidos para el estudio de movimiento humano se mencionan en [145-147]. Los resultados obtenidos con el análisis Bland-Altman indican que el brazo robótico se encuentra dentro de los límites de concordancia aceptados para su uso en el estudio del movimiento humano.

## Capítulo 7. Conclusión y trabajo a futuro

En este trabajo se presentó el diseño y elaboración de un brazo robótico para el estudio del movimiento humano. El diseño partió de estudios antropométricos para realizar el cálculo de las dimensiones del brazo y los actuadores necesarios para su aplicación. El estudio de movimiento se realizó mediante un sistema de medición basado en sensores MARG y un algoritmo para la estimación de la orientación con los sensores desarrollados para la medición y registro de los tres segmentos de la extremidad superior humana con mayor rango de movimiento y una referencia en el tórax que indica la orientación general de la persona. Esta información fue utilizada en la programación de un modelo de red neuronal artificial para la clasificación de siete movimientos de la extremidad superior humana. Un análisis por Bland-Altman se realizó para evaluar el desempeño del brazo robótico con respecto a los registros de personas en cinco movimientos básicos de la extremidad superior y una actividad de la vida diaria. Los resultados de los análisis Bland-Altman realizados a los registros obtenidos con el movimiento del brazo robótico y el registro de una persona indican que el brazo es útil para su uso en el estudio de movimiento humano.

Los logros obtenidos en este trabajo se describen en cuatro apartados:

- A) Simulación de las piezas diseñadas para el brazo robótico con un análisis de mallas en SolidWorks® Simulation. En este apartado también se muestra el brazo robótico hecho con la técnica de modelado por deposición fundida (FDM) con impresión 3D en material ABS.
- B) Validación del algoritmo y los sensores en pruebas de laboratorio para su uso en el estudio del movimiento humano y las pruebas realizadas en movimientos de la extremidad superior humana.
- C) Modelo diseñado de red neuronal artificial para la clasificación de los movimientos registrados con los sensores.
- D) Estudio y pruebas del movimiento del brazo robótico con los registros de los sensores validados con los sensores XSens para los movimientos sobre un eje y del movimiento *Reach-to-Grasp*.

Los resultados obtenidos en este proyecto demuestran que el brazo robótico diseñado en combinación con el sistema de medición basado en sensores MARG y el algoritmo propuesto hacen viable el estudio del movimiento de la extremidad superior humana. Por su parte, los resultados de la red neuronal artificial mostraron la capacidad del modelo entrenado para

generalizar los movimientos de la extremidad superior en actividades de la vida diaria permitiendo estudiar el movimiento humano a partir de los patrones de cada movimiento obtenidos con los sensores MARG y el algoritmo propuesto.

A partir de las conclusiones presentadas en este trabajo, las perspectivas de trabajo a futuro son:

- Dar continuidad al proyecto para la mejora del diseño del brazo robótico con el objetivo de realizar un exoesqueleto para evaluar la condición de una extremidad superior humana y dar seguimiento en procesos de rehabilitación.
- Realizar más pruebas con el sistema para registrar movimientos de la extremidad superior en actividades del día a día.
- Utilizar el sistema en el registro de actividades deportivas.
- Investigar modelos de redes neuronales artificiales de aprendizaje profundo para la clasificación de los movimientos registrados con el sistema.
- Considerando las capacidades del sistema para determinar la posición y orientación de los segmentos de la extremidad superior humana, podrían utilizarse los registros para el desarrollo de estrategias de control para prótesis, ortesis, brazos robóticos y exoesqueletos en tiempo continuo.
- Investigar métodos para la compensación de los artefactos por tejido suave.

## Referencias

- [1] L. A. Contreras-Rodríguez, "Desarrollo de un sistema ambulatorio para el análisis de movimientos de la extremidad superior," Maestría, Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV-IPN), Ciudad de México, 2017.
- [2] J. A. Barraza-Madrigal, "Diseño y desarrollo de un sistema ambulatorio de análisis de movimiento: monitoreo, reproducción y seguimiento de hombro," Doctorado, Ingeniería Eléctrica, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional (CINVESTAV-IPN), Ciudad de México, 2016.
- [3] E. B. Mazomenos, D. Biswas, A. Cranny, A. Rajan, K. Maharatna, J. Achner, *et al.*, "Detecting elementary arm movements by tracking upper limb joint angles with MARG sensors," *IEEE journal of biomedical and health informatics*, vol. 20, pp. 1088-1099, 2015.
- [4] C.-L. Kuo and G.-C. Hu, "Post-stroke spasticity: a review of epidemiology, pathophysiology, and treatments," *International Journal of Gerontology*, vol. 12, pp. 280-284, 2018.
- [5] M. Risteiu, S. Rosca, and M. Leba, "3D modelling and simulation of human upper limb," in *IOP Conference Series: Materials Science and Engineering*, 2019, p. 012094.
- [6] E. Van der Kruk and M. M. Reijne, "Accuracy of human motion capture systems for sport applications; state-of-the-art review," *European journal of sport science*, vol. 18, pp. 806-819, 2018.
- [7] D. R. Seshadri, R. T. Li, J. E. Voos, J. R. Rowbottom, C. M. Alfes, C. A. Zorman, *et al.*, "Wearable sensors for monitoring the internal and external workload of the athlete," *NPJ digital medicine*, vol. 2, pp. 1-18, 2019.
- [8] E. Preatoni, E. Bergamini, S. Fantozzi, L. I. Giraud, A. S. Orejel Bustos, G. Vannozzi, *et al.*, "The use of wearable sensors for preventing, assessing, and informing recovery from sport-related musculoskeletal injuries: a systematic scoping review," *Sensors*, vol. 22, p. 3225, 2022.
- [9] V. Medved, "History of the Study of Human Locomotion and Elements of Current Research Methodology," in *Measurement and Analysis of Human Locomotion*, ed: Springer, 2021, pp. 13-37.
- [10] B. Wahl, A. Cossy-Gantner, S. Germann, and N. R. Schwalbe, "Artificial intelligence (AI) and global health: how can AI contribute to health in resource-poor settings?," *BMJ global health*, vol. 3, p. e000798, 2018.
- [11] T. Davenport and R. Kalakota, "The potential for artificial intelligence in healthcare," *Future healthcare journal*, vol. 6, p. 94, 2019.
- [12] R. Gassert and V. Dietz, "Rehabilitation robots for the treatment of sensorimotor deficits: a neurophysiological perspective," *Journal of neuroengineering and rehabilitation*, vol. 15, pp. 1-15, 2018.
- [13] H. M. Qassim and W. Wan Hasan, "A review on upper limb rehabilitation robots," *Applied Sciences*, vol. 10, p. 6976, 2020.
- [14] L.-Y. Gui, K. Zhang, Y.-X. Wang, X. Liang, J. M. Moura, and M. Veloso, "Teaching robots to predict human motion," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2018, pp. 562-567.

- [15] A. Rudenko, L. Palmieri, M. Herman, K. M. Kitani, D. M. Gavrila, and K. O. Arras, "Human motion trajectory prediction: A survey," *The International Journal of Robotics Research*, vol. 39, pp. 895-935, 2020.
- [16] T. Yoshikawa, V. Losing, and E. Demircan, "Machine learning for human movement understanding," *Advanced Robotics*, vol. 34, pp. 828-844, 2020.
- [17] F. I. Khawaja, A. Kanazawa, J. Kinugawa, and K. Kosuge, "A Human-Following Motion Planning and Control Scheme for Collaborative Robots Based on Human Motion Prediction," *Sensors*, vol. 21, p. 8229, 2021.
- [18] K. Dröder, P. Bobka, T. Germann, F. Gabriel, and F. Dietrich, "A machine learning-enhanced digital twin approach for human-robot-collaboration," *Procedia Cirp*, vol. 76, pp. 187-192, 2018.
- [19] A. Hentout, M. Aouache, A. Maoudj, and I. Akli, "Human-robot interaction in industrial collaborative robotics: a literature review of the decade 2008-2017," *Advanced Robotics*, vol. 33, pp. 764-799, 2019.
- [20] A. Mohebbi, "Human-robot interaction in rehabilitation and assistance: a review," *Current Robotics Reports*, vol. 1, pp. 131-144, 2020.
- [21] B. Dariush, "Human motion analysis for biomechanics and biomedicine," *Machine Vision and Applications*, vol. 14, pp. 202-205, 2003.
- [22] J. K. Aggarwal and Q. Cai, "Human motion analysis: A review," *Computer vision and image understanding*, vol. 73, pp. 428-440, 1999.
- [23] L. Wang, W. Hu, and T. Tan, "Recent developments in human motion analysis," *Pattern recognition*, vol. 36, pp. 585-601, 2003.
- [24] S. Rafique, M. Najam-l-Islam, and A. Mahmood, "Synthesis of sit-to-stand movement using SimMechanics," in *International Conference on Smart Innovation, Ergonomics and Applied Human Factors*, 2019, pp. 386-392.
- [25] D. V. Knudson and D. Knudson, *Fundamentals of biomechanics* vol. 183: Springer, 2007.
- [26] S. L. Colyer, M. Evans, D. P. Cosker, and A. I. Salo, "A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system," *Sports medicine-open*, vol. 4, pp. 1-15, 2018.
- [27] M. A. R. Ahad, "Vision and sensor-based human activity recognition: challenges ahead," in *Advancements in Instrumentation and Control in Applied System Applications*, ed: IGI Global, 2020, pp. 17-35.
- [28] E. Halilaj, A. Rajagopal, M. Fiterau, J. L. Hicks, T. J. Hastie, and S. L. Delp, "Machine learning in human movement biomechanics: Best practices, common pitfalls, and new opportunities," *Journal of biomechanics*, vol. 81, pp. 1-11, 2018.
- [29] B. Moradi, M. Aghapour, and A. Shirbandi, "Compare of machine learning and deep learning approaches for human activity recognition," in *2022 30th International Conference on Electrical Engineering (ICEE)*, 2022, pp. 592-596.
- [30] P. Wang, H. Liu, L. Wang, and R. X. Gao, "Deep learning-based human motion recognition for predictive context-aware human-robot collaboration," *CIRP annals*, vol. 67, pp. 17-20, 2018.
- [31] K. Li and J. W. Burdick, "Human motion analysis in medical robotics via high-dimensional inverse reinforcement learning," *The International Journal of Robotics Research*, vol. 39, pp. 568-585, 2020.

- [32] C. Prakash, R. Kumar, and N. Mittal, "Recent developments in human gait research: parameters, approaches, applications, machine learning techniques, datasets and challenges," *Artificial Intelligence Review*, vol. 49, pp. 1-40, 2018.
- [33] I. Klöpfer-Krämer, A. Brand, H. Wackerle, J. Müßig, I. Kröger, and P. Augat, "Gait analysis—Available platforms for outcome assessment," *Injury*, vol. 51, pp. S90-S96, 2020.
- [34] C. P. Walmsley, S. A. Williams, T. Grisbrook, C. Elliott, C. Imms, and A. Campbell, "Measurement of upper limb range of motion using wearable sensors: a systematic review," *Sports medicine-open*, vol. 4, pp. 1-22, 2018.
- [35] M. Yahya, J. A. Shah, K. A. Kadir, Z. M. Yusof, S. Khan, and A. Warsi, "Motion capture sensing techniques used in human upper limb motion: A review," *Sensor Review*, 2019.
- [36] N. G. PUNCHIHEWA, S. Miyazaki, E. Chosa, and G. Yamako, "Efficacy of inertial measurement units in the evaluation of trunk and hand kinematics in baseball hitting," *Sensors*, vol. 20, p. 7331, 2020.
- [37] M. J. Wheare, M. J. Nelson, R. Lumsden, A. Butfield, and R. G. Crowther, "Reliability and Validity of the Polhemus Liberty System for Upper Body Segment and Joint Angular Kinematics of Elite Golfers," *Sensors*, vol. 21, p. 4330, 2021.
- [38] A. Freivalds, *Biomechanics of the upper limbs: mechanics, modeling and musculoskeletal injuries*: CRC press, 2011.
- [39] Editorial. (2013, 28/08). *Posición anatómica*. Available: <https://www.importancia.org/posicion-anatomica.php>
- [40] K. L. Moore and A. F. Dalley, *Anatomía con orientación clínica*: Ed. Médica Panamericana, 2009.
- [41] A. I. Kapandji, *Fisiología articular* vol. 1: Médica Panamericana, 1998.
- [42] M. Gurgul, *Industrial robots and cobots: Everything you need to know about your future co-worker*: Michał Gurgul, 2018.
- [43] Y. Chen and G. De Luca, "Technologies supporting artificial intelligence and robotics application development," *Journal of Artificial Intelligence and Technology*, vol. 1, pp. 1-8, 2021.
- [44] A. Barrientos, "Fundamentos de robótica," 2007.
- [45] X. Robert-Lachaine, H. Mecheri, A. Muller, C. Larue, and A. Plamondon, "Validation of a low-cost inertial motion capture system for whole-body motion analysis," *Journal of biomechanics*, vol. 99, p. 109520, 2020.
- [46] J.-L. Ren, Y.-H. Chien, E.-Y. Chia, L.-C. Fu, and J.-S. Lai, "Deep learning based motion prediction for exoskeleton robot control in upper limb rehabilitation," in *2019 International Conference on Robotics and Automation (ICRA)*, 2019, pp. 5076-5082.
- [47] N. Bai, Y. Tian, Y. Liu, Z. Yuan, Z. Xiao, and J. Zhou, "A high-precision and low-cost IMU-based indoor pedestrian positioning technique," *IEEE Sensors Journal*, vol. 20, pp. 6716-6726, 2020.
- [48] S. Mansoor, U. I. Bhatti, A. I. Bhatti, and S. M. D. Ali, "Improved attitude determination by compensation of gyroscopic drift by use of accelerometers and magnetometers," *Measurement*, vol. 131, pp. 582-589, 2019.
- [49] S. O. Madgwick, S. Wilson, R. Turk, J. Burrige, C. Kapatatos, and R. Vaidyanathan, "An extended complementary filter for full-body MARG orientation estimation," *IEEE/ASME Transactions on Mechatronics*, vol. 25, pp. 2054-2064, 2020.

- [50] J. A. B. Madrigal, J. C. Negrete, R. M. Guerrero, L. A. C. Rodríguez, and H. Sossa, "3D motion tracking of the shoulder joint with respect to the thorax using MARG sensors and data fusion algorithm," *Biocybernetics and Biomedical Engineering*, vol. 40, pp. 1205-1224, 2020.
- [51] N. F. Ribeiro and C. P. Santos, "Inertial measurement units: A brief state of the art on gait analysis," in *2017 IEEE 5th Portuguese Meeting on Bioengineering (ENBENG)*, 2017, pp. 1-4.
- [52] Xsens, "Xsens DOT User Manual," XD0502P ed. Netherland, 2020, p. 34.
- [53] M. J. Pinto-Bernal, A. Aguirre, C. A. Cifuentes, and M. Munera, "Wearable sensors for monitoring exercise and fatigue estimation in rehabilitation," in *Internet of Medical Things*, ed: CRC Press, 2021, pp. 83-110.
- [54] Z.-H. Zhou, *Machine learning*: Springer Nature, 2021.
- [55] D. Graupe, *Principles of artificial neural networks* vol. 7: World Scientific, 2013.
- [56] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, pp. 115-133, 1943.
- [57] G. J. Gibson, "A combinatorial approach to understanding perceptron capabilities," *IEEE transactions on neural networks*, vol. 4, pp. 989-992, 1993.
- [58] S. Haykin, *Neural networks and learning machines, 3/E*: Pearson Education India, 2009.
- [59] M. T. Hagan, H. B. Demuth, and M. Beale, *Neural network design*: PWS Publishing Co., 1997.
- [60] M. W. Gardner and S. Dorling, "Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences," *Atmospheric environment*, vol. 32, pp. 2627-2636, 1998.
- [61] A. Gulli and S. Pal, *Deep learning with Keras*: Packt Publishing Ltd, 2017.
- [62] K. O'Shea and R. Nash, "An introduction to convolutional neural networks," *arXiv preprint arXiv:1511.08458*, 2015.
- [63] R. Pascanu, C. Gulcehre, K. Cho, and Y. Bengio, "How to construct deep recurrent neural networks," *arXiv preprint arXiv:1312.6026*, 2013.
- [64] Q. Que and M. Belkin, "Back to the future: Radial basis function networks revisited," in *Artificial intelligence and statistics*, 2016, pp. 1375-1383.
- [65] D. Berrar, "Cross-Validation," ed, 2019.
- [66] S. Visa, B. Ramsay, A. L. Ralescu, and E. Van Der Knaap, "Confusion matrix-based feature selection," *MAICS*, vol. 710, pp. 120-127, 2011.
- [67] L. Gonçalves, A. Subtil, M. R. Oliveira, and P. de Zea Bermudez, "ROC curve estimation: An overview," *REVSTAT-Statistical journal*, vol. 12, pp. 1–20–1–20, 2014.
- [68] J. Cerda and L. Cifuentes, "Uso de curvas ROC en investigación clínica: Aspectos teórico-prácticos," *Revista chilena de infectología*, vol. 29, pp. 138-141, 2012.
- [69] H.-G. R. Choi, M.-H. Park, and E. Salisbury, "Optimal tolerance allocation with loss functions," *J. Manuf. Sci. Eng.*, vol. 122, pp. 529-535, 2000.
- [70] D. Popescu, C. P. Copilusi, H. Roibu, M. I. Marin, L. Rusu, and L. C. Popescu, "Upper Limb Motions Analysis for Development of an Upper Limb Rehabilitation Robotic System," in *World Congress on Medical Physics and Biomedical Engineering 2018*, 2019, pp. 797-802.

- [71] A. Bilezan, "Development and Accuracy Analysis of a Human Motion Capturing Method Using a Single IR Camera," 北海道大学, 2021.
- [72] S. Gong, J. Zhao, and B. Xie, "Robot Motion Planning with Human-Like Motion Patterns based on Human Arm Movement Primitive Chains," in *2021 IEEE International Conference on Robotics and Automation (ICRA)*, 2021, pp. 8373-8379.
- [73] N. Taghavi, J. Berdichevsky, N. Balakrishnan, K. C. Welch, S. K. Das, and D. O. Popa, "Online Dynamic Time Warping Algorithm for Human-Robot Imitation," in *2021 IEEE International Conference on Robotics and Automation (ICRA)*, 2021, pp. 3843-3849.
- [74] J. Burrige, M. Alt Murphy, J. Buurke, P. Feys, T. Keller, V. Klamroth-Marganska, *et al.*, "A systematic review of international clinical guidelines for rehabilitation of people with neurological conditions: what recommendations are made for upper limb assessment?," *Frontiers in neurology*, vol. 10, p. 567, 2019.
- [75] A. Scheidig, B. Jaeschke, B. Schuetz, T. Q. Trinh, A. Vorndran, A. Mayfarth, *et al.*, "May I keep an eye on your training? gait assessment assisted by a mobile robot," in *2019 IEEE 16th International Conference on Rehabilitation Robotics (ICORR)*, 2019, pp. 701-708.
- [76] H. I. Krebs, M. Ferraro, S. P. Buerger, M. J. Newbery, A. Makiyama, M. Sandmann, *et al.*, "Rehabilitation robotics: pilot trial of a spatial extension for MIT-Manus," *Journal of neuroengineering and rehabilitation*, vol. 1, pp. 1-15, 2004.
- [77] Q. Meng, Q. Xie, and H. Yu, "Upper-limb rehabilitation robot: State of the art and existing problems," in *Proceedings of the 12th International Convention on Rehabilitation Engineering and Assistive Technology*, 2018, pp. 155-158.
- [78] L. Ricci, F. Taffoni, and D. Formica, "On the orientation error of IMU: Investigating static and dynamic accuracy targeting human motion," *PloS one*, vol. 11, p. e0161940, 2016.
- [79] S. Wilson, H. Eberle, Y. Hayashi, S. O. Madgwick, A. McGregor, X. Jing, *et al.*, "Formulation of a new gradient descent MARG orientation algorithm: Case study on robot teleoperation," *Mechanical Systems and Signal Processing*, vol. 130, pp. 183-200, 2019.
- [80] M. Lapresa, C. Tamantini, F. S. Di Luzio, M. Ferlazzo, G. Sorrenti, F. Corpina, *et al.*, "Validation of Magneto-Inertial Measurement Units for Upper-Limb Motion Analysis through an Anthropomorphic Robot," *IEEE Sensors Journal*, 2022.
- [81] R. Kluz, K. Antosz, T. Trzepieciński, and A. Gola, "Predicting the error of a Robot's positioning repeatability with artificial neural networks," in *International Symposium on Distributed Computing and Artificial Intelligence*, 2019, pp. 41-48.
- [82] E. Uhlmann, M. Polte, J. Blumberg, Z. Li, and A. Kraft, "Hyperparameter optimization of artificial neural networks to improve the positional accuracy of industrial robots," *Journal of Machine Engineering*, vol. 21, 2021.
- [83] K. Kokkalis, G. Michalos, P. Aivaliotis, and S. Makris, "An approach for implementing power and force limiting in sensorless industrial robots," *Procedia CIRP*, vol. 76, pp. 138-143, 2018.
- [84] M. B. Jamshidi, A. Lalbakhsh, N. Alibeigi, M. R. Soheyli, B. Oryani, and N. Rabbani, "Socialization of industrial robots: An innovative solution to improve productivity," in *2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, 2018, pp. 832-837.

- [85] K. Onur, O. T. Kaymakci, and M. Mercimek, "Advanced Predictive Maintenance with Machine Learning Failure Estimation in Industrial Packaging Robots," in *2020 International Conference on Development and Application Systems (DAS)*, 2020, pp. 1-6.
- [86] S. Morettini, "Machine learning in predictive maintenance of industrial robots," ed, 2021.
- [87] V. Khoshdel and A. Akbarzadeh, "An optimized artificial neural network for human-force estimation: consequences for rehabilitation robotics," *Industrial Robot: An International Journal*, 2018.
- [88] Z. Zhou, B. Liang, G. Huang, B. Liu, J. Nong, and L. Xie, "Individualized Gait Generation for Rehabilitation Robots Based on Recurrent Neural Networks," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 29, pp. 273-281, 2020.
- [89] H. Liu and L. Wang, "Human motion prediction for human-robot collaboration," *Journal of Manufacturing Systems*, vol. 44, pp. 287-294, 2017.
- [90] D. Sirintuna, I. Ozdamar, Y. Aydin, and C. Basdogan, "Detecting human motion intention during pHRI using artificial neural networks trained by EMG signals," in *2020 29th IEEE International Conference on Robot and Human Interactive Communication (RO-MAN)*, 2020, pp. 1280-1287.
- [91] L. Roveda, J. Maskani, P. Franceschi, A. Abdi, F. Braghin, L. Molinari Tosatti, *et al.*, "Model-based reinforcement learning variable impedance control for human-robot collaboration," *Journal of Intelligent & Robotic Systems*, vol. 100, pp. 417-433, 2020.
- [92] R. Kaushik and A. LaViers, "Imitation of human motion by low degree-of-freedom simulated robots and human preference for mappings driven by spinal, arm, and leg activity," *International Journal of Social Robotics*, vol. 11, pp. 765-782, 2019.
- [93] Y. Wei and J. Zhao, "Designing Human-like Behaviors for Anthropomorphic Arm in Humanoid Robot NAO," *Robotica*, vol. 38, pp. 1205-1226, 2020.
- [94] L. Zhang and F. Liang, "Monitoring and analysis of athletes' local body movement status based on BP neural network," *Journal of Intelligent & Fuzzy Systems*, vol. 40, pp. 2325-2335, 2021.
- [95] B. Debnath, M. O'brien, M. Yamaguchi, and A. Behera, "A review of computer vision-based approaches for physical rehabilitation and assessment," *Multimedia Systems*, pp. 1-31, 2021.
- [96] J. Lee, K. Kwon, and W.-H. Yeo, "Recent advances in wearable exoskeletons for human strength augmentation," *Flexible and Printed Electronics*, 2022.
- [97] A. Ali, S. F. Ahmed, K. A. Kadir, M. K. Joyo, and R. S. Yarooq, "Fuzzy PID controller for upper limb rehabilitation robotic system," in *2018 IEEE international conference on innovative research and development (ICIRD)*, 2018, pp. 1-5.
- [98] A. Kapsalyamov, S. Hussain, A. Sharipov, and P. Jamwal, "Brain-computer interface and assist-as-needed model for upper limb robotic arm," *Advances in Mechanical Engineering*, vol. 11, p. 1687814019875537, 2019.
- [99] P. W. Laksono, K. Matsushita, M. S. A. b. Suhaimi, T. Kitamura, W. Njeri, J. Muguro, *et al.*, "Mapping three electromyography signals generated by human elbow and shoulder movements to two degree of freedom upper-limb robot control," *Robotics*, vol. 9, p. 83, 2020.

- [100] P. W. Laksono, T. Kitamura, J. Muguro, K. Matsushita, M. Sasaki, and M. S. Amri bin Suhaimi, "Minimum mapping from EMG signals at human elbow and shoulder movements into two DoF upper-limb robot with machine learning," *Machines*, vol. 9, p. 56, 2021.
- [101] B. Schabron, J. Desai, and Y. Yihun, "Wheelchair-mounted upper limb robotic exoskeleton with adaptive controller for activities of daily living," *Sensors*, vol. 21, p. 5738, 2021.
- [102] G. Gulletta, E. C. e. Silva, W. Erlhagen, R. Meulenbroek, M. F. P. Costa, and E. Bicho, "A Human-like Upper-limb Motion Planner: Generating naturalistic movements for humanoid robots," *International Journal of Advanced Robotic Systems*, vol. 18, p. 1729881421998585, 2021.
- [103] A. I. Rangel-Elizalde, "Estudio antropométrico de la población mexicana masculina laboralmente productiva," *Científica*, vol. 19, pp. 11-15, 2015.
- [104] J. González-Leija. (2010, 29/08). *Datos antropométricos México*. Available: <https://es.slideshare.net/juangonzalezleija/cfakepathdatos-antropometricos-3925719>
- [105] R. Chandler, D. Clauser, J. McConville, H. Reynolds, and J. Young, "Investigation of inertial properties of the human hand," *Washington (DC): US Department of Transportation*, 1975.
- [106] N. P. Fromme, M. Camenzind, R. Riener, and R. M. Rossi, "Need for mechanically and ergonomically enhanced tremor-suppression orthoses for the upper limb: a systematic review," *Journal of neuroengineering and rehabilitation*, vol. 16, pp. 1-15, 2019.
- [107] C. E. Clauser, J. T. McConville, and J. W. Young, "Weight, volume, and center of mass of segments of the human body," *Antioch Coll Yellow Springs OH*1969.
- [108] M. Samykano, S. Selvamani, K. Kadirgama, W. Ngui, G. Kanagaraj, and K. Sudhakar, "Mechanical property of FDM printed ABS: influence of printing parameters," *The International Journal of Advanced Manufacturing Technology*, vol. 102, pp. 2779-2796, 2019.
- [109] InvenSense. (2013, MPU-6000 and MPU-6050 Product Specification Revision 3.4. Available: [www.invensense.com](http://www.invensense.com)
- [110] Honeywell. (2011, 3-Axis Digital Compass IC HMC5883L. Available: [www.honeywell.com/magneticsensors](http://www.honeywell.com/magneticsensors)
- [111] F. T. D. I. Limited. (2015, FT232R USB UART IC Datasheet. Available: [www.ftdichip.com/FTProducts.htm](http://www.ftdichip.com/FTProducts.htm)
- [112] M. Technology. (2011, dsPIC30F6011A/6012A/6013A/6014A Data Sheet. Available: [www.microchip.com](http://www.microchip.com)
- [113] Microchip. (2014, Miniature Single-Cell, Fully Integrated Li-Ion, Li-Polymer Charge Management Controllers. Available: [www.microchip.com](http://www.microchip.com)
- [114] L. A. C. Rodríguez, J. A. B. Madrigal, E. Cardiel, and P. R. Hernández, "Upper limb orientation assessment as an articulated body chain," *Medical Engineering & Physics*, vol. 107, p. 103852, 2022.
- [115] A. Filippeschi, N. Schmitz, M. Miezal, G. Bleser, E. Ruffaldi, and D. Stricker, "Survey of motion tracking methods based on inertial sensors: A focus on upper limb human motion," *Sensors*, vol. 17, p. 1257, 2017.
- [116] S. Ghasemi-Moghadam and M. Homaeinezhad, "Attitude determination by combining arrays of MEMS accelerometers, gyros, and magnetometers via

- quaternion-based complementary filter," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 31, p. e2282, 2018.
- [117] F. Haugen, "The Good Gain method for simple experimental tuning of PI controllers," 2012.
- [118] D. Pavllo, D. Grangier, and M. Auli, "Quaternet: A quaternion-based recurrent model for human motion," *arXiv preprint arXiv:1805.06485*, 2018.
- [119] C. Yi, J. Ma, H. Guo, J. Han, H. Gao, F. Jiang, *et al.*, "Estimating three-dimensional body orientation based on an improved complementary filter for human motion tracking," *Sensors*, vol. 18, p. 3765, 2018.
- [120] N. H. Hughes, "Quaternion to/from Euler angle of arbitrary rotation sequence & direction cosine matrix conversion using geometric methods," 2017.
- [121] Z. C. Ong, Y. Seet, S. Y. Khoo, and S. Noroozi, "Development of an economic wireless human motion analysis device for quantitative assessment of human body joint," *Measurement*, vol. 115, pp. 306-315, 2018.
- [122] P. Picerno, A. Cereatti, and A. Cappozzo, "A spot check for assessing static orientation consistency of inertial and magnetic sensing units," *Gait & Posture*, vol. 33, pp. 373-378, 2011.
- [123] T.-T. Wong and P.-Y. Yeh, "Reliable accuracy estimates from k-fold cross validation," *IEEE Transactions on Knowledge and Data Engineering*, vol. 32, pp. 1586-1594, 2019.
- [124] H. Ahmed and M. Tahir, "Improving the accuracy of human body orientation estimation with wearable IMU sensors," *IEEE Transactions on instrumentation and measurement*, vol. 66, pp. 535-542, 2017.
- [125] B. Ronen, D. Jacobs, Y. Kasten, and S. Kritchman, "The convergence rate of neural networks for learned functions of different frequencies," *Advances in Neural Information Processing Systems*, vol. 32, 2019.
- [126] R. Grazzi, L. Franceschi, M. Pontil, and S. Salzo, "On the iteration complexity of hypergradient computation," in *International Conference on Machine Learning*, 2020, pp. 3748-3758.
- [127] V. Klyachkin, Y. E. Kuvayskova, and D. Zhukov, "The use of aggregate classifiers in technical diagnostics, based on machine learning," in *CEUR Workshop Proceedings*, 2017, pp. 32-35.
- [128] J. A. Richards, "Classifier performance and map accuracy," *Remote sensing of environment*, vol. 57, pp. 161-166, 1996.
- [129] J. V. Carter, J. Pan, S. N. Rai, and S. Galandiuk, "ROC-ing along: Evaluation and interpretation of receiver operating characteristic curves," *Surgery*, vol. 159, pp. 1638-1645, 2016.
- [130] J.-W. Cui, Z.-G. Li, H. Du, B.-Y. Yan, and P.-D. Lu, "Recognition of Upper Limb Action Intention Based on IMU," *Sensors*, vol. 22, p. 1954, 2022.
- [131] H. Lu, L. R. Schomaker, and R. Carloni, "IMU-based deep neural networks for locomotor intention prediction," in *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2020, pp. 4134-4139.
- [132] A. Fallah and A. Maleki, "The compensation of biomechanical errors in electrogoniometric measurements of the upper extremity kinematics," *Sensors and Actuators A: Physical*, vol. 315, p. 112170, 2020.

- [133] V. Rosso, V. Agostini, R. Takeda, S. Tadano, and L. Gastaldi, "Influence of BMI on gait characteristics of young adults: 3D evaluation using inertial sensors," *Sensors*, vol. 19, p. 4221, 2019.
- [134] M. Gourishankar, M. Ruby, S. Shubham, and G. Taniya, "Real-Time Vibration Analysis of a Robotic Arm Designed for CT Image Guided Diagnostic Procedures," in *Advances in Interdisciplinary Engineering*, ed: Springer, 2019, pp. 163-171.
- [135] Z. Wang and P. Keogh, "Active vibration control for robotic machining," in *ASME International Mechanical Engineering Congress and Exposition*, 2017, p. V002T02A079.
- [136] J. de Jesus Rubio, P. Cruz, L. A. Paramo, J. A. Meda, D. Mujica, and R. S. Ortigoza, "PID anti-vibration control of a robotic arm," *IEEE Latin America Transactions*, vol. 14, pp. 3144-3150, 2016.
- [137] T. Meng and W. He, "Iterative learning control of a robotic arm experiment platform with input constraint," *IEEE Transactions on Industrial Electronics*, vol. 65, pp. 664-672, 2017.
- [138] T. Bitz, F. Zahedi, and H. Lee, "Variable damping control of a robotic arm to improve trade-off between agility and stability and reduce user effort," in *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 2020, pp. 11259-11265.
- [139] F. Zahedi and H. Lee, "Human arm stability in relation to damping-defined mechanical environments in physical interaction with a robotic arm," in *2021 IEEE International Conference on Robotics and Automation (ICRA)*, 2021, pp. 2681-2686.
- [140] J. Li, D. Wang, X. Wu, K. Xu, and X. Liu, "Vibration Prediction of the Robotic Arm Based on Elastic Joint Dynamics Modeling," *Sensors*, vol. 22, p. 6170, 2022.
- [141] A. Leardini, L. Chiari, U. Della Croce, and A. Cappozzo, "Human movement analysis using stereophotogrammetry: Part 3. Soft tissue artifact assessment and compensation," *Gait & posture*, vol. 21, pp. 212-225, 2005.
- [142] M. Lapinski, C. Brum Medeiros, D. Moxley Scarborough, E. Berkson, T. J. Gill, T. Kepple, *et al.*, "A wide-range, wireless wearable inertial motion sensing system for capturing fast athletic biomechanics in overhead pitching," *Sensors*, vol. 19, p. 3637, 2019.
- [143] I. Weygers, M. Kok, M. Konings, H. Hallez, H. De Vroey, and K. Claeys, "Inertial sensor-based lower limb joint kinematics: A methodological systematic review," *Sensors*, vol. 20, p. 673, 2020.
- [144] D. Giavarina, "Understanding bland altman analysis," *Biochemia medica*, vol. 25, pp. 141-151, 2015.
- [145] J. Zhang, W. S. Ndou, N. Ng, P. Gaston, P. M. Simpson, G. J. Macpherson, *et al.*, "Robotic-arm assisted total knee arthroplasty is associated with improved accuracy and patient reported outcomes: a systematic review and meta-analysis," *Knee Surgery, Sports Traumatology, Arthroscopy*, pp. 1-19, 2021.
- [146] E. L. Hampp, M. Chughtai, L. Y. Scholl, N. Sodhi, M. Bhowmik-Stoker, D. J. Jacofsky, *et al.*, "Robotic-arm assisted total knee arthroplasty demonstrated greater accuracy and precision to plan compared with manual techniques," *The Journal of Knee Surgery*, vol. 32, pp. 239-250, 2019.

- [147] B. Guo, Y. Ma, J. Yang, Z. Wang, and X. Zhang, "Lw-CNN-based myoelectric signal recognition and real-time control of robotic arm for upper-limb rehabilitation," *Computational Intelligence and Neuroscience*, vol. 2020, 2020.

# Anexos

## A. Carta de consentimiento

### A.1 Dictamen



CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS  
DEL INSTITUTO POLITÉCNICO NACIONAL

COMITÉ DE BIOÉTICA PARA LA INVESTIGACIÓN EN SERES HUMANOS  
(COBISH)-CINVESTAV

Folio 088/2022

#### DICTAMEN

**Director del Proyecto:** Dr. Pablo Rogelio Hernández Rodríguez

**Departamento:** Ingeniería Eléctrica-Sección de Bioelectrónica

**Título del Proyecto:** "Desarrollo de un exoesqueleto para la extremidad superior de humanos".

El Comité de Bioética para la Investigación en Seres Humanos del Centro de Investigación y de Estudios Avanzados del IPN (COBISH), después de revisar la información de los instrumentos que se utilizarán para realizar su estudio y que sometió para su evaluación, dictamina:

Que el estudio: "Desarrollo de un exoesqueleto para la extremidad superior de humanos" cumple con los lineamientos bioéticos establecidos para la investigación en seres humanos.

Se firma el presente a los treinta días del mes de junio del 2022, en el Centro de Investigación y de Estudios Avanzados del IPN.

**Dra. María Betzabet Quintanilla Vega**  
Presidenta del COBISH

c.c.p. Expediente

Av. Instituto Politécnico Nacional # 2508, Col. San Pedro Zacatenco, Ciudad de México.  
c.p. 07360 Tel. +(52)- 5557473800

Figura 56. Dictamen del Comité de Bioética para la Investigación en Seres Humano (COBISH-) CINVESTAV.

## A.2 Formato de carta de consentimiento informado

 <b>CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS AVANZADOS DEL I.P.N.</b> <b>Guía Operacional para la Evaluación Ética de los Proyectos de Investigación en Seres Humanos</b>
<b>FOLIO # 088/2022</b>
<b>CARTA DE CONSENTIMIENTO INFORMADO</b>
<p>El que suscribe, Sr/Sra/Srita _____, de _____ años de edad, sexo _____, declaro que autorizo y consiento voluntariamente en participar en el proyecto de investigación: "<b>Desarrollo de un exoesqueleto para la extremidad superior de humanos</b>", el cual se lleva a cabo bajo la supervisión de "<b>Dr. Pablo Rogelio Hernández Rodríguez</b>". También declaro que he sido ampliamente informado en un lenguaje que entiendo claramente sobre los objetivos de este proyecto, los cuales consisten en "Registrar la actividad de los segmentos corporales tórax, brazo, antebrazo y mano, mediante una unidad de procesamiento para el análisis de movimiento para su análisis mediante una serie de pruebas que involucran su actividad".</p> <p>Mi participación consiste en permitir el registro de la actividad de los segmentos de la extremidad superior mediante el uso de sensores portables colocados en la mano, antebrazo, brazo y tórax. Dichos sensores serán colocados mediante cintas elásticas, sin adhesivo y de material no tóxico o agresivo.</p> <p>Manifiesto que he sido ampliamente informado sobre los beneficios y riesgos que representa participar en este estudio. Como principal beneficio para la sociedad es que se obtendrá un instrumento para el monitoreo, reproducción y seguimiento de la extremidad superior, abriendo oportunidades para ser utilizado como una herramienta para diagnóstico, rehabilitación e investigación. Asimismo, recibiré reportes por escrito de los resultados que se me practiquen los cuales pueden ser útiles para mi expediente clínico, como son: "<i>hallazgos sobre posibles lesiones musculares o articulares que sirvan para un diagnóstico por parte de un especialista</i>".</p> <p>Se me ha informado y acepto los riesgos a que me someteré al participar en el estudio, los cuales son clasificados como mínimos, considerando que pudiera sentir una ligera sensación de cansancio muscular en el brazo, piernas y espalda.</p> <p>Se me ha informado que durante todo el curso del trabajo será tratado con decoro, dignidad y discreción. Asimismo, todos los estudios correspondientes al trabajo de investigación serán gratuitos y en el remoto caso de sufrir algún daño, resultado de los procedimientos empleados en este proyecto, la atención profesional para su resolución será gestionada sin costo.</p> <p>Se me ha notificado que la información que se obtenga será confidencial y que será empleada solo para los fines de la investigación y que tengo el derecho de retirarme del estudio cuando así lo decida, sin ser sujeto a alguna medida de presión.</p> <p>Para cualquier duda o aclaración favor de contactarse con el M.C. Lauro Armando Contreras Rodríguez al correo: <a href="mailto:lauro.contreras@cinvestav.mx">lauro.contreras@cinvestav.mx</a> o al teléfono móvil (+52)667-390-3426.</p> <p>Ciudad de México, a _____ del mes de _____, de 20__.</p> <p>Sr/Sra/Srita. _____ Firma _____ Teléfono: _____ Correo electrónico: _____</p> <p>Investigador Responsable: Pablo Rogelio Hernández Rodríguez Firma _____ Teléfono: <u>5557473800 ext. 6201.</u> Correo electrónico: <a href="mailto:pablo.rogeli@cinvestav.mx">pablo.rogeli@cinvestav.mx</a></p> <p>Testigo _____ Firma _____ Teléfono: _____ Correo electrónico: _____</p> <p>Testigo _____ Firma _____ Teléfono: _____ Correo electrónico: _____</p>

Figura 57. Formato de la carta de consentimiento informado presentada a los voluntarios del estudio.

## B. Diseño de las piezas

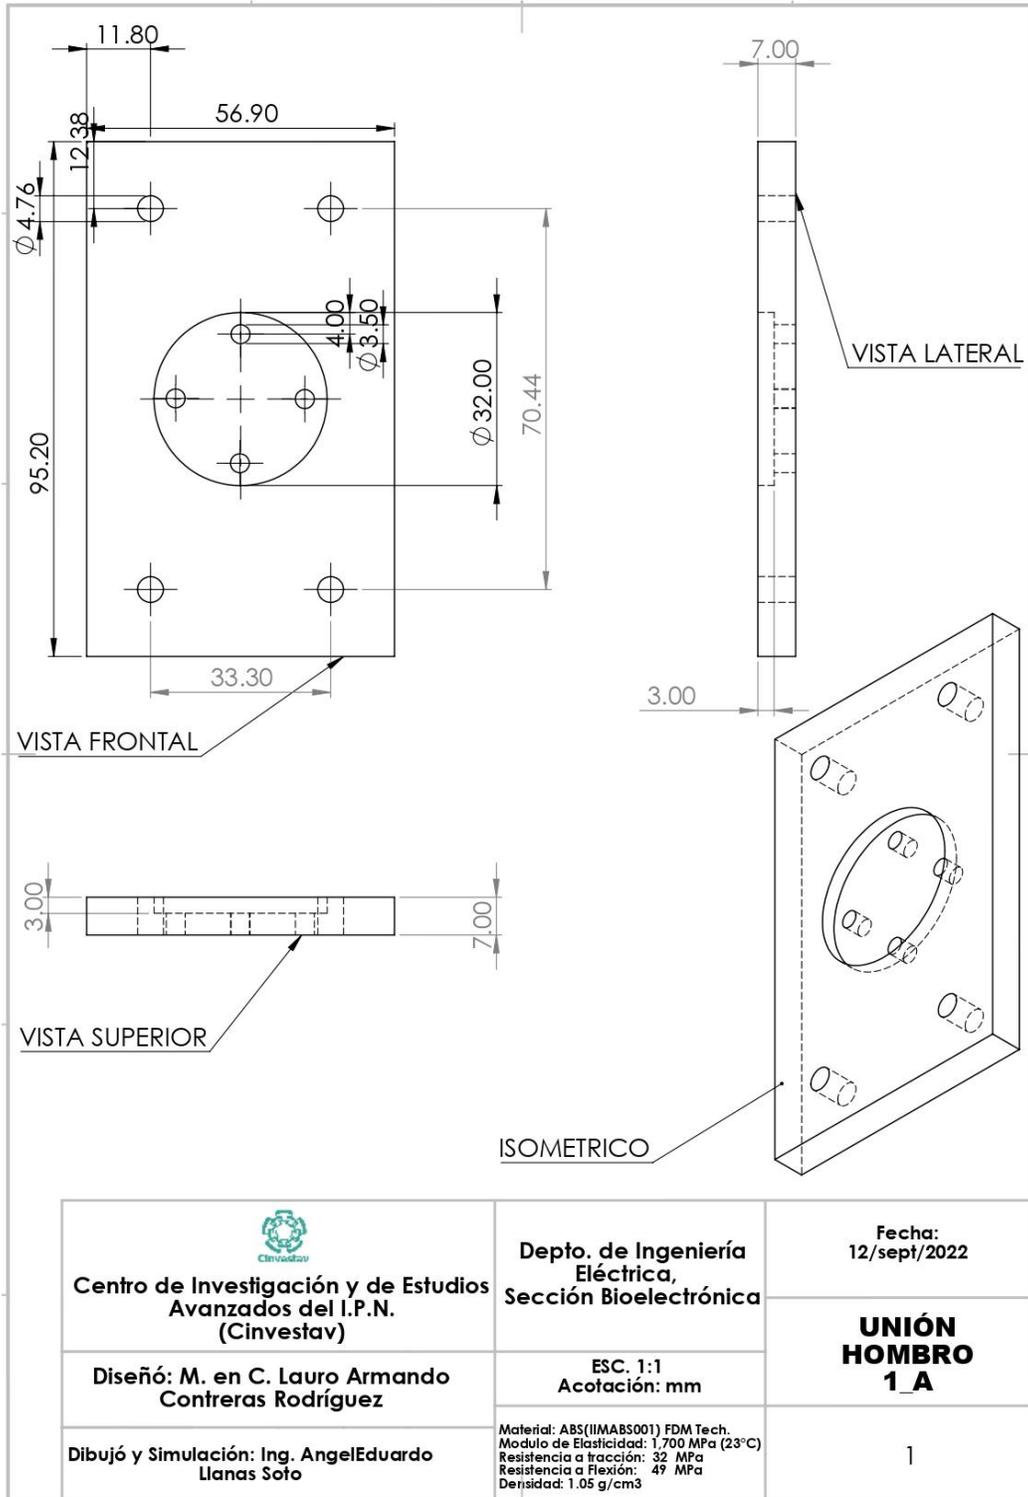


Figura 58. Diseño de la pieza 1. Unión hombro 1\_A.

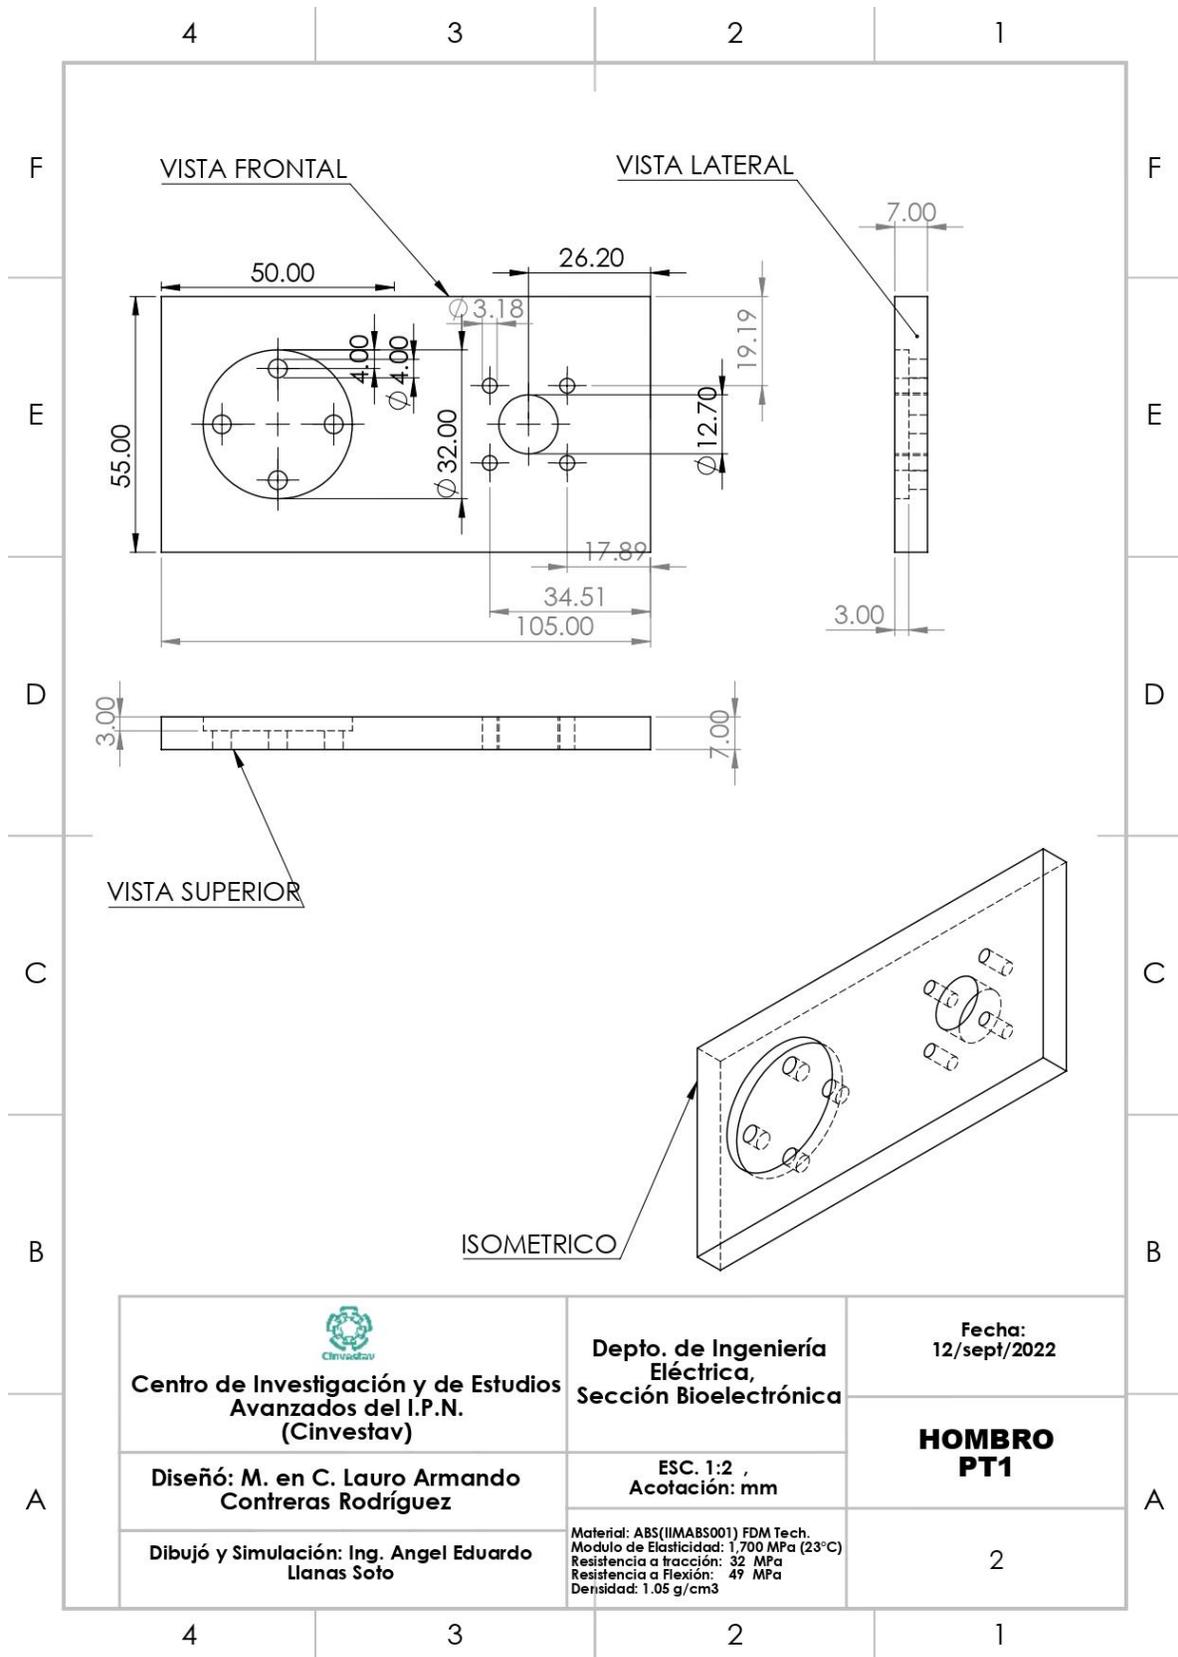


Figura 59. Diseño de la pieza 2. Hombro\_Partel.

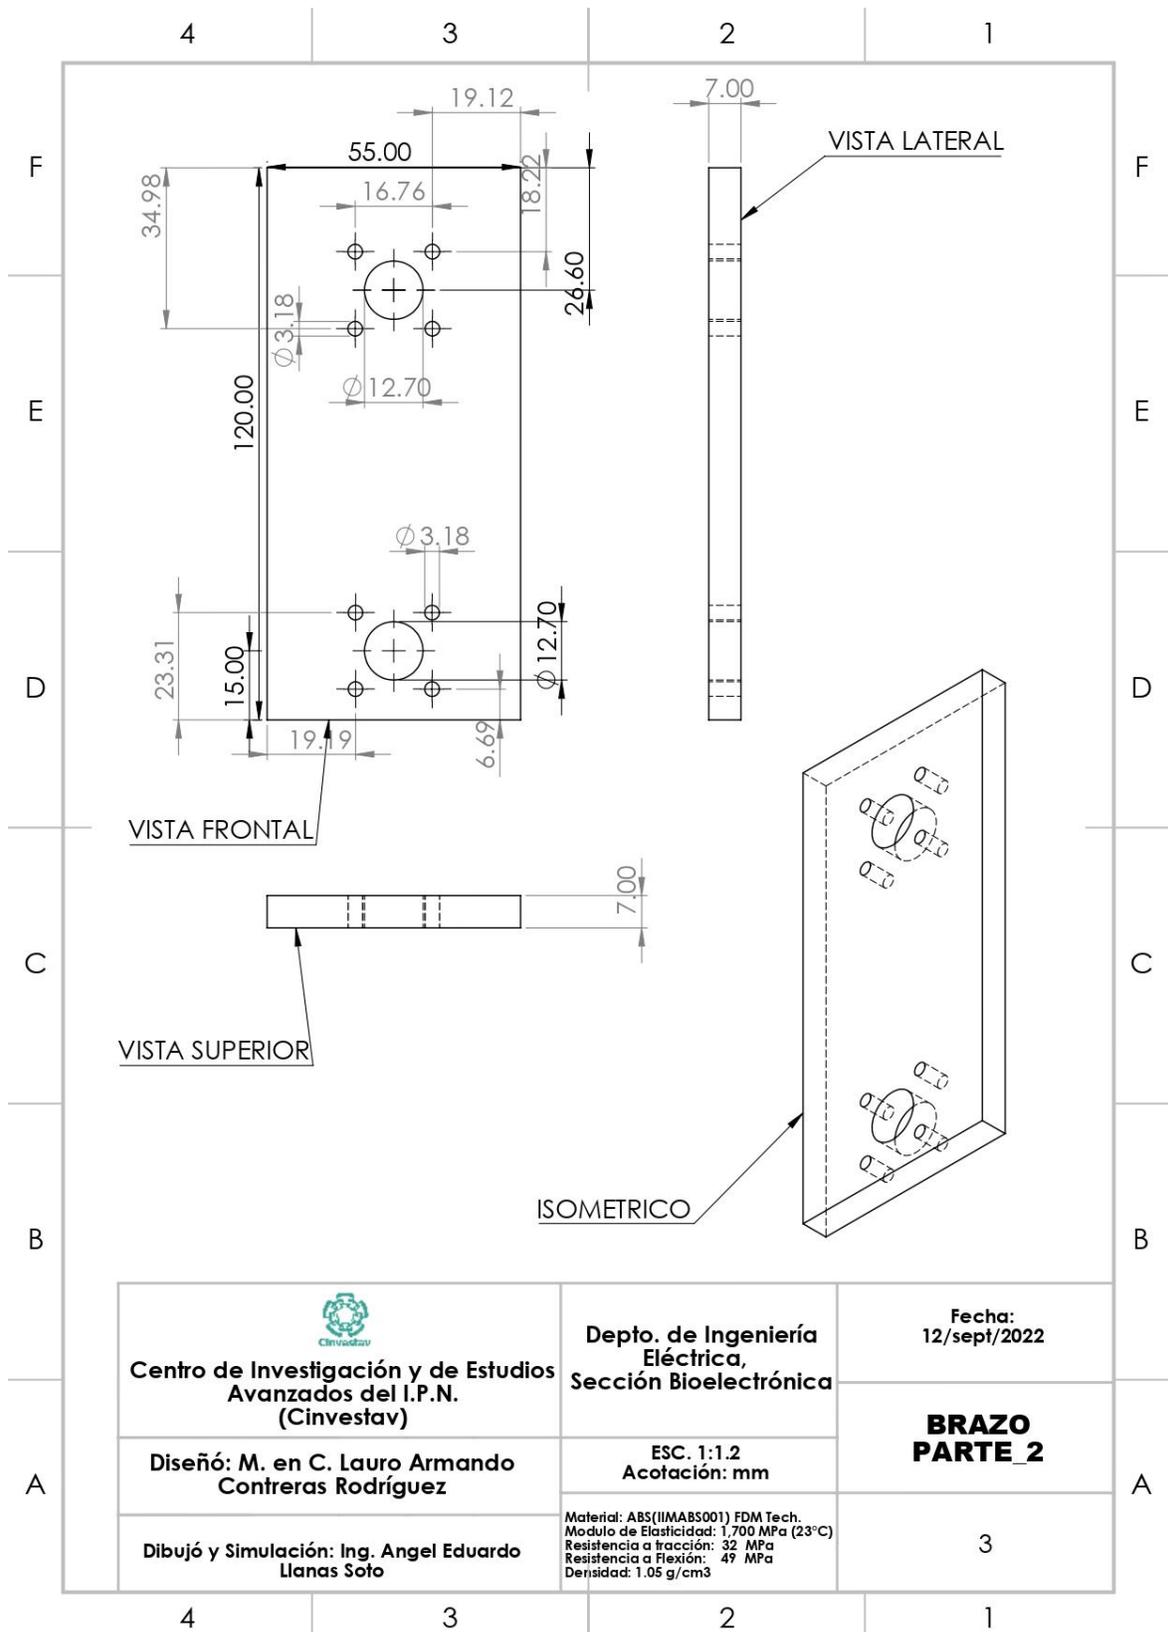


Figura 60. Diseño de la pieza 3. Brazo\_Parte2.

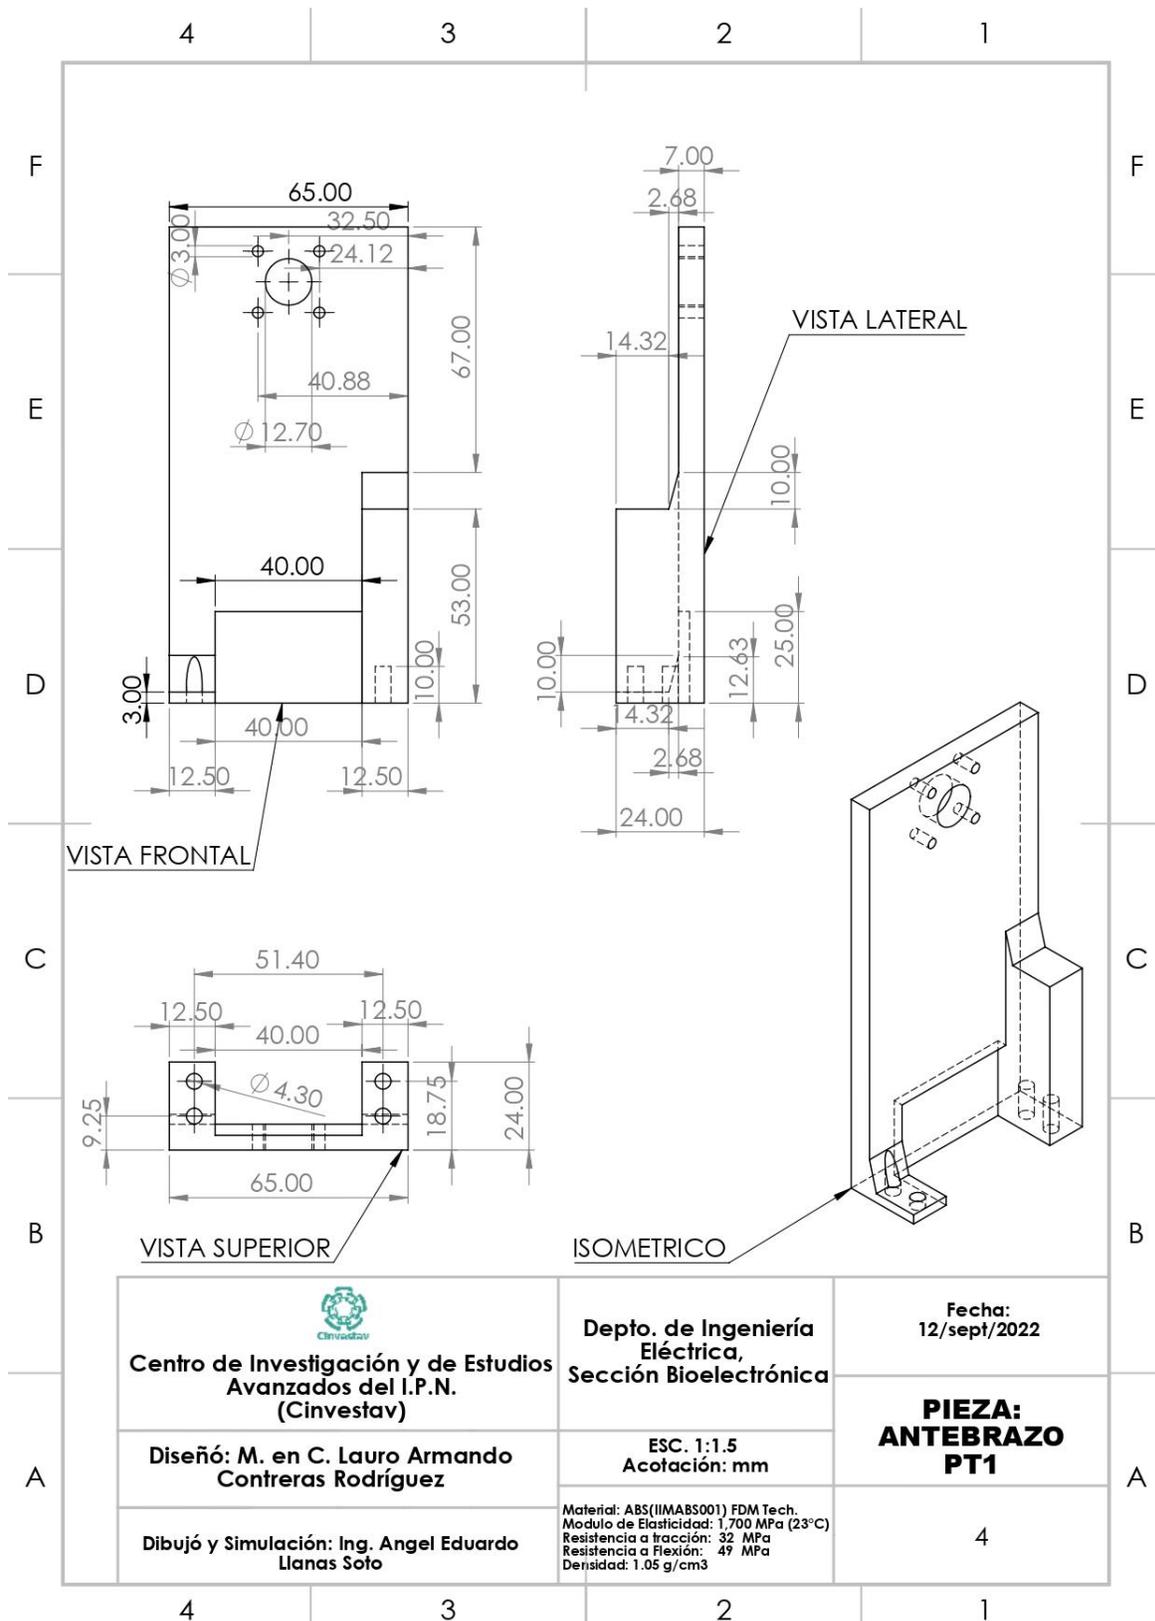


Figura 61. Diseño de la pieza 4. Antebrazo\_Parte1.

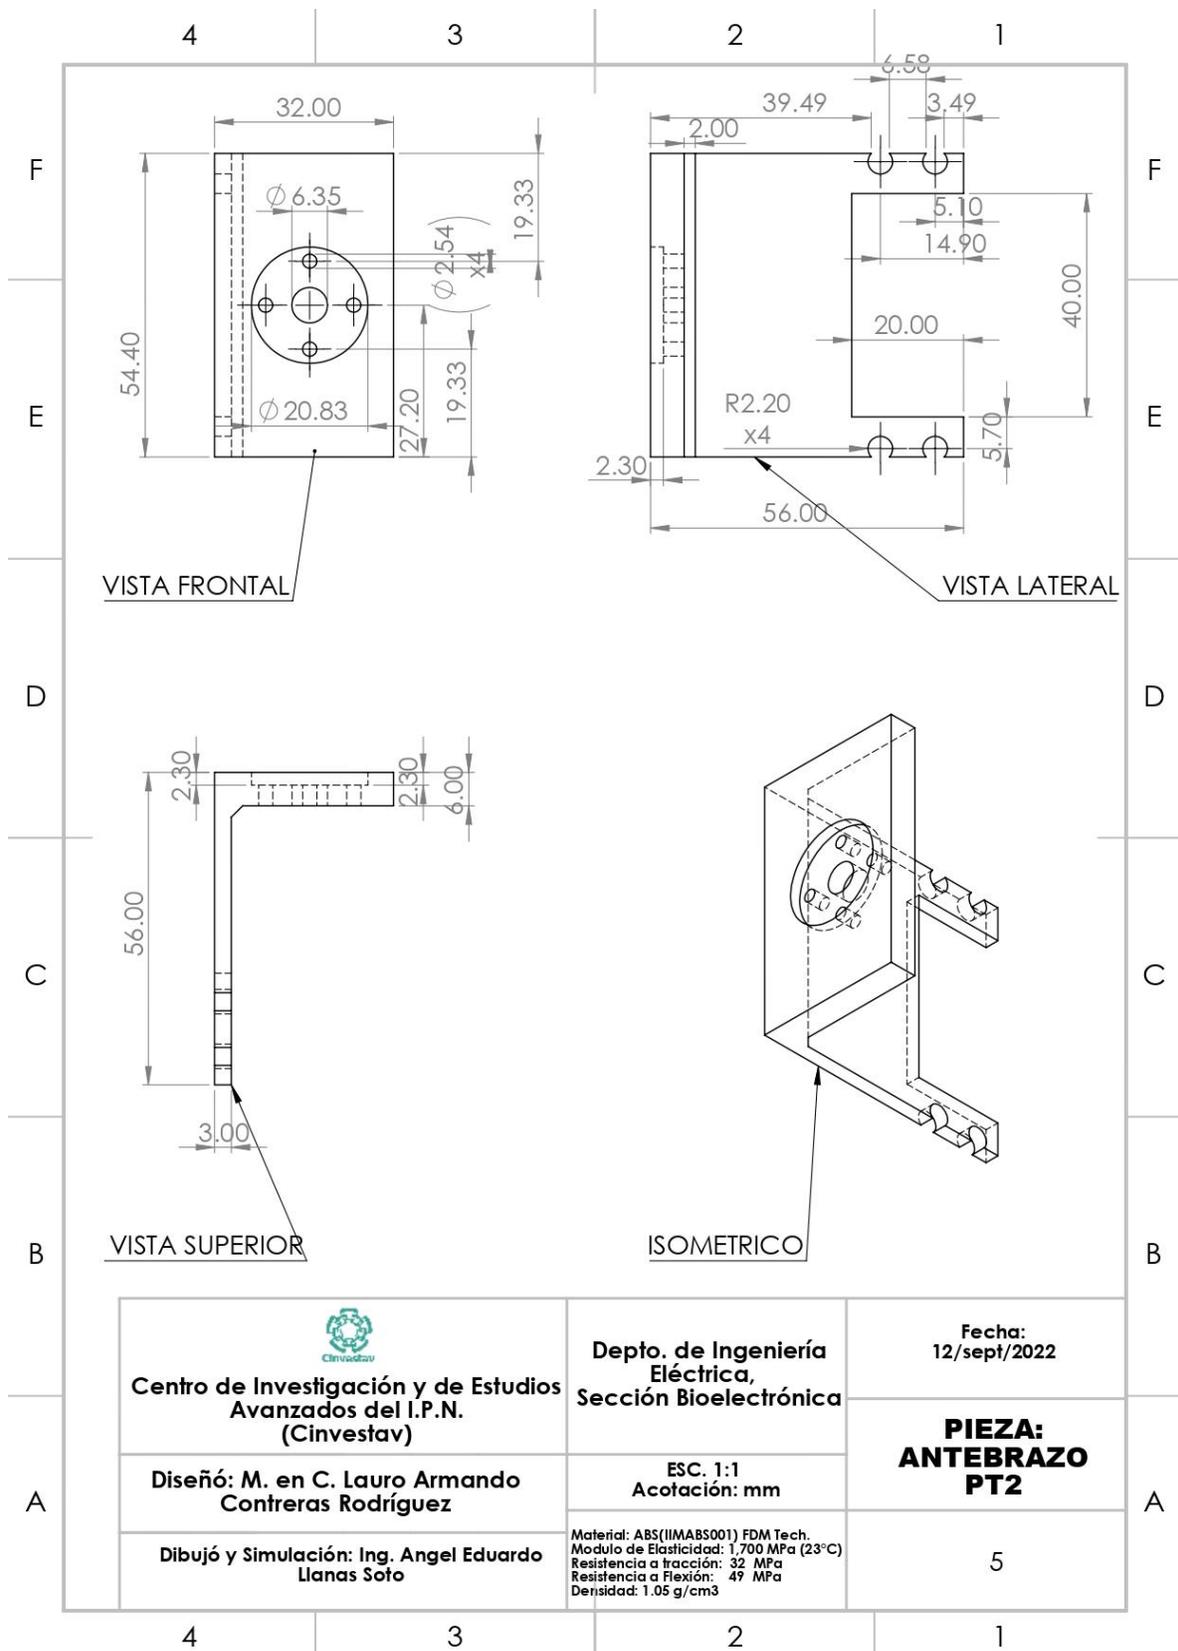


Figura 62. Diseño de la pieza 5. Antebrazo\_Parte2.

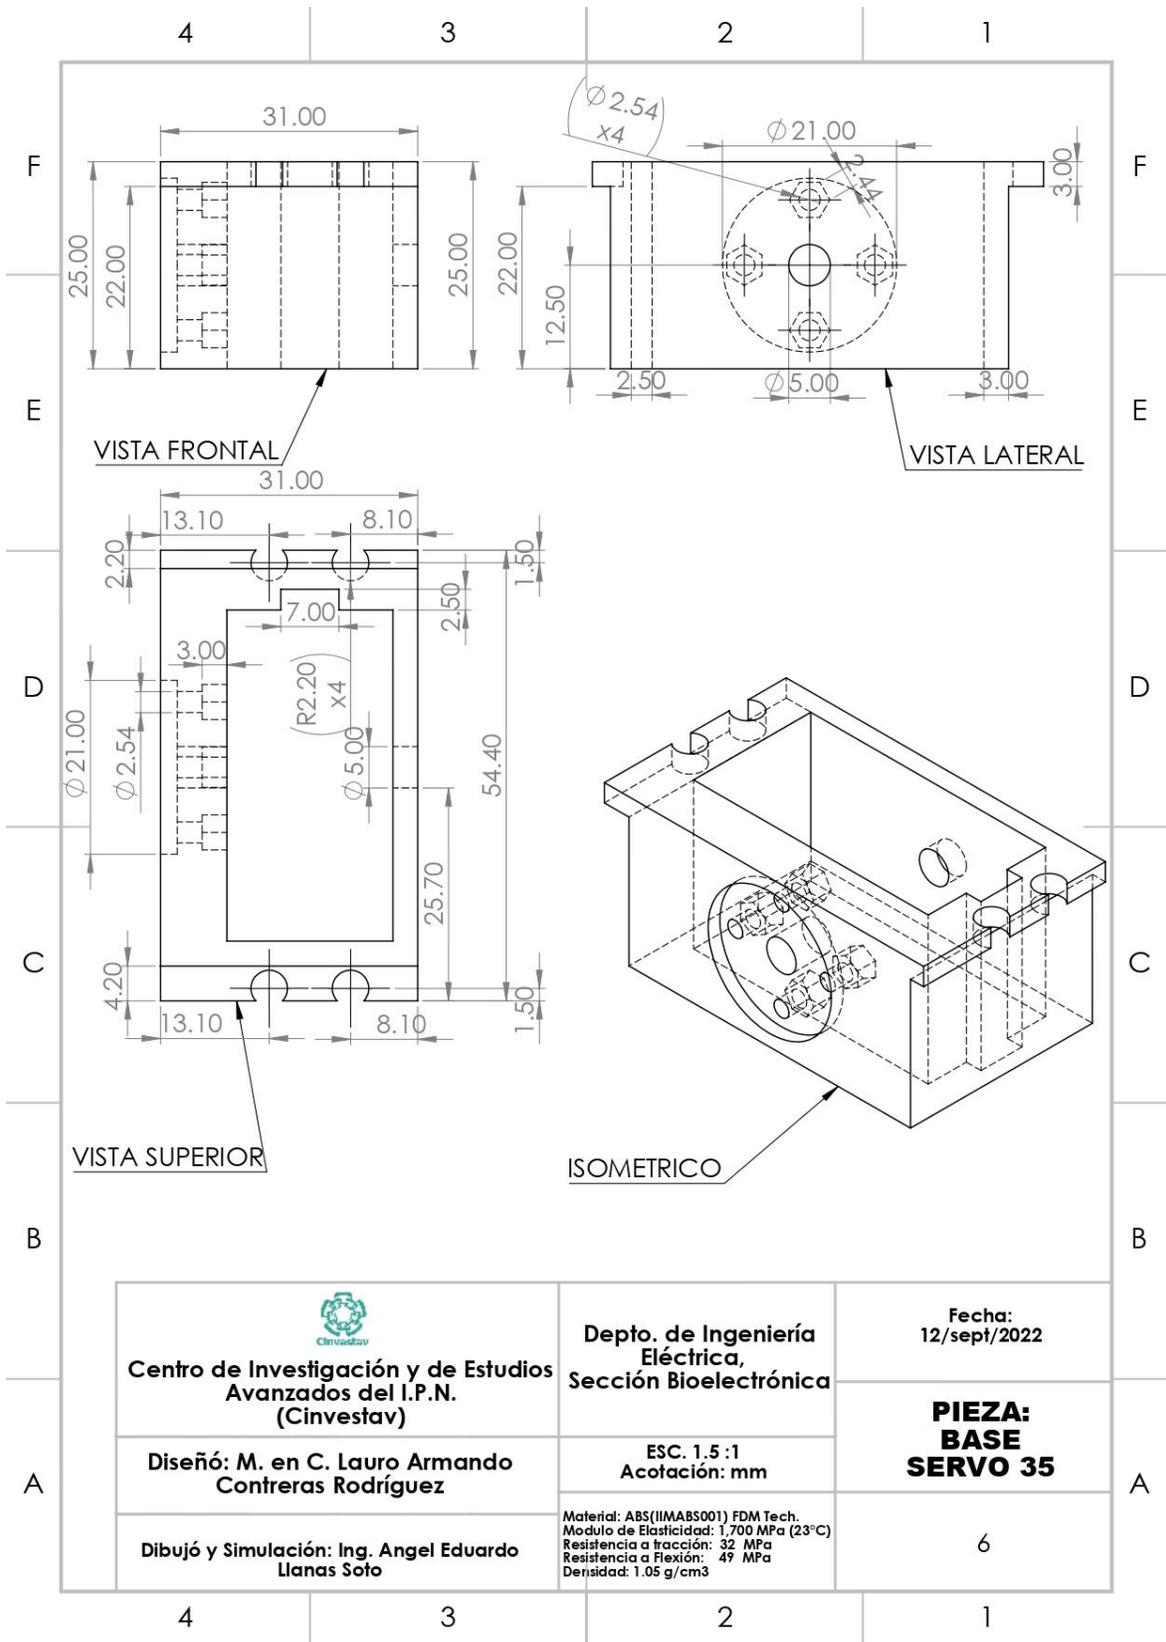


Figura 63. Diseño de la pieza 6. Base\_servo\_35.

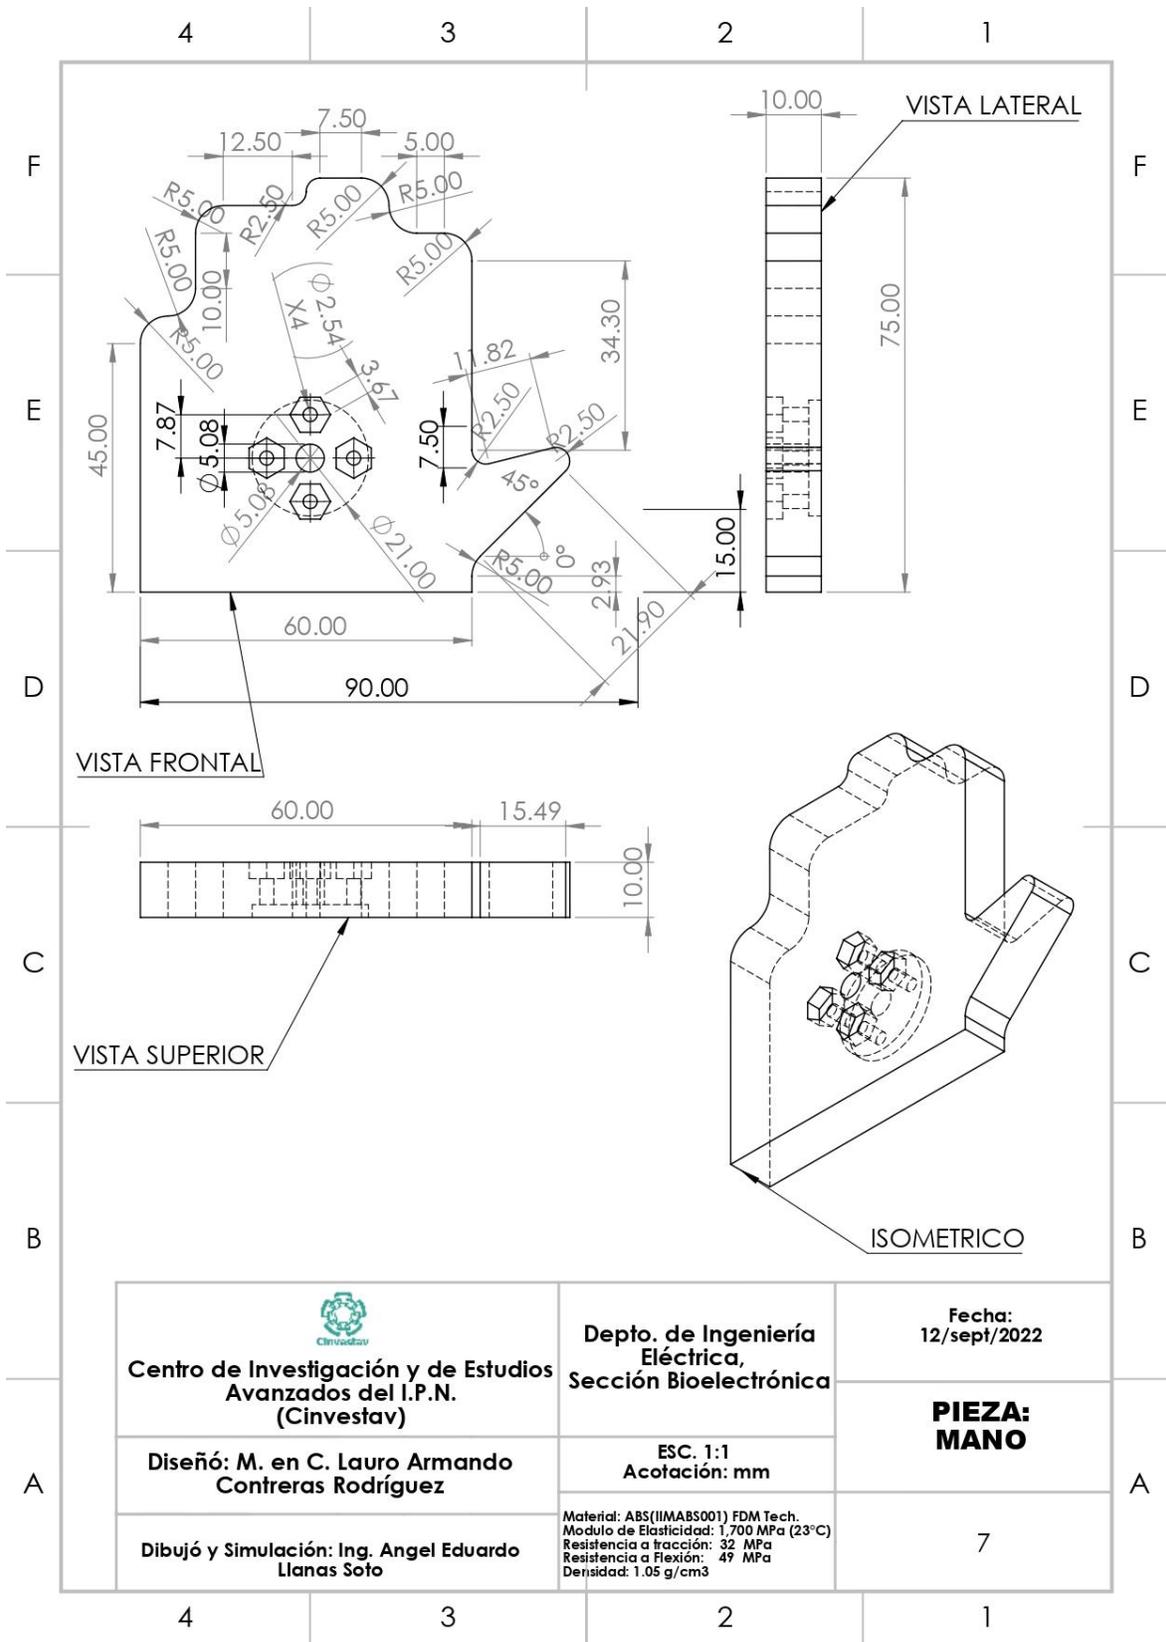


Figura 64. Diseño de la pieza 7. Mano.

## C. Productos

### C.1 Artículo de Congreso

2022 19th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE). Mexico City, Mexico. November 9-11, 2022

## Human Upper Limb Motion Recognition Using IMU sensors and Artificial Neural Networks

Lauro Armando Contreras Rodríguez  
*Electrical Engineering Department,  
Bioelectronics section  
CINVESTAV-IPN  
Mexico City, Mexico  
lauro.contreras@cinvestav.mx*

Eladio Cardiel  
*Electrical Engineering Department,  
Bioelectronics section  
CINVESTAV-IPN  
Mexico City, Mexico  
ecardiel@cinvestav.mx*

Ángel Llanas Soto  
*Electrical Engineering Department,  
Bioelectronics section  
CINVESTAV-IPN  
Mexico City, Mexico  
angel@cinvestav.mx*

José Antonio Barraza Madrigal  
*Departamento de Formación Básica,  
Academia de Física  
ESIQIE-Instituto Politécnico Nacional  
Ciudad de México, México  
jabaraza@ipn.mx*

Pablo Rogelio Hernández Rodríguez  
*Electrical Engineering Department,  
Bioelectronics section  
CINVESTAV-IPN  
Mexico City, Mexico  
pablo.rogeli@cinvestav.mx*

**Abstract**— Computer vision researchers have been tasked with developing applications to recognize the human body's structure, movements, and tracking. Recognizing human upper limb movements has brought benefits in physical therapy, virtual reality, human-robot systems, sports. This paper presents a multi-layer perceptron (MLP) artificial neural network (ANN) designed to recognize the upper limb movements performance in daily life tasks. For this, inertial measurement units (IMU) were employed to acquire information regarding of the upper limb movement. The performance of the model was assessed through a confusion matrix and the receiver operator characteristic (ROC) curves. Recognition accuracy obtained for the ANN model was 97.39%, the mean area under the curve (AUC) of the ROC curves was 0.973. According to the results, the proposed ANN could recognize upper limb movements in daily life tasks. Further research is suggested to test the model with fine movements.

**Keywords**— *Upper Limb, Human Motion Recognition, MLP, ANN.*

#### I. INTRODUCTION

Research on human motion try to explain how the musculoskeletal system interacts while doing activities of daily living. Since the end of the last century, computer vision researchers have increasingly investigated human motion analysis. The focus of these investigations has been carried out in three areas: (1) Motion analysis of the human body structure, (2) Tracking of the human motion, and (3) Recognition of human movements [1, 2].

For motion performance recognition, artificial neural networks (ANN) have been of great help in detecting patterns that identify activities. EMG signals, vision systems, and wearable sensors are the common data source for this application. However, the average efficiency of EMG signal is around 70% and requires advanced detection, decomposition, processing, and classification methods before using ANN [3]. Vision systems require specific conditions for data acquisition, such as light and several cameras to avoid occlusion and markers. The need for outdoor analysis remains an open challenge for these systems [4]. Finally, wearable sensors have become the most popular option in recent years. These sensors provide information related to human

movements in three-dimensional space and they are non-invasive. However, because the devices include a magnetometer, they are susceptible to electromagnetic signals that could affect the sensors' measurements [5-7].

Recent studies have reported the use of wearable sensors and ANN to classify activities such as walking, running, standing, walking upstairs, or walking downstairs [8, 9]. However, recognizing upper limb movements remains challenging since the number of identified joints is limited [10, 11]. Upper limb activities are usually limited to hand gesture recognition or trajectory prediction to compensate for limb tremors for orthoses [12, 13]. Also, some works aim to locomotor intention prediction of the upper limb action [14, 15].

This paper presents the design of a multi-layer perceptron (MLP) ANN model for the classification of seven daily life tasks of the upper limb based on IMU sensors. The MLP architecture (16-7-7) and a backpropagation training algorithm allowed the model to classify the seven upper limb movements in daily life tasks.

#### II. METHODOLOGY

This work consisted in training a multi-layer perceptron (MLP) artificial neural network with data acquired from human upper limb movements by motion capture devices. The data corresponded to the three joints with the greatest range of motion (shoulder, elbow, and wrist, with reference to the chest) when performing seven daily life tasks. These movements included activities performed on the anatomical planes and combined movements for the joints.

##### A. Materials

Xsens dot (Xsens, Netherland), a wearable platform developed to provide an accurate 3D orientation in any environment, was used to measure the movements [16, 17]. The platform consisted of four wireless measurement units, four straps to attach the units, and the Xsens dot app. The anatomical attachment of the sensors was defined to guarantee to map full range of the movements. The first sensor was located in the thorax, at the sternum level, and serves as a reference to the other sensors. The second sensor was located

at the external lateral portion of the arm, between the acromion and the lateral epicondyle of the humerus, referenced at the midpoint between the brachii biceps and brachii triceps muscles. The third sensors was placed on the *extensor digitorum communis* muscle, 5cm from the wrist. While the fourth sensor was located on the back of the hand.

## B. Artificial Neural Network

### a) Database

A database of the sensors' recordings corresponding to the seven activities of the right upper limb was generated to train, validate, and test the artificial neural network (ANN). Ten healthy, right-handed volunteers, six males and four females, age  $39 \pm 15.9$  years, were recruited to conduct the activities. The sensor's sampling rate was 60Hz with a 16-bit resolution using the Xsens' latest Kalman filter core algorithm (XKFCore) for sensor fusion, optimized for human motions [18]. The first activity, called the static position, recorded the n-pose of the volunteer. The following five activities were performed with one degree of motion for a single joint. These movements were recorded by the sensors, while repeating a shoulder flexion-extension, shoulder abduction-adduction, elbow flexion-extension, wrist flexion-extension, or wrist abduction-adduction starting at the n-pose. The seventh activity was a grasp-to-reach test. This test required the volunteer to take a glass from a table, bring it to his mouth and leave it on the table. The activities were performed only once per volunteer and in only one action without constraints in the time required to execute. Each sensor provides a quaternion related to the activity of the measured segments; therefore, four data samples are provided in each sample per sensor. To avoid confusion in the training stage, the movement below  $10^\circ$  from the n-pose was considered static. A total of 42,356 data samples were taken from the seven activities: 12,805 samples for the static position; 5,614 samples for the shoulder flexion-extension activity; 6,110 samples for the shoulder abduction-adduction; 5,057 samples for the elbow flexion-extension; 4,410 samples for the wrist flexion-extension; 4,686 samples for the wrist abduction-adduction; and 4,321 samples for the reach-to-grasp test. The raw data provided by the sensors, quaternions, were used to feed the ANN without preprocessing.

### b) MLP Architecture

The ANN architecture was designed and programmed to classify the seven movements as seven different classes. The common approach to fit the model uses one neuron per class at the output layer; therefore, the proposed architecture of the ANN has seven neurons in the output layer. The input layer corresponded to the sensors' information since the output of each sensor gives the orientation measured in quaternions; the input vector for each sampled position has 16 data. The number of neurons in the hidden layer was allowed to encompass the targets for each class in three-dimensional space. Seven neurons fulfilled the previous condition, so the final architecture for the ANN was 16-7-7. Both the hidden layer and the output layer use a sigmoid function due to its derivative properties [19].

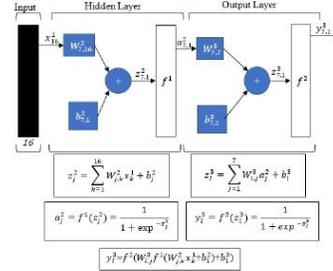


Figure 1. Summarized representation for the architecture of the ANN

### c) Cross-Validation

The database was randomized and segmented into two sets before the training and tests processes to avoid a biased dataset. The first set, 75% of the entire database, was used as the training set, while the second one, the remaining 25%, was used for the test. The training set was validated using a cross-validation process which consisted of segmenting the training set in k-segments with equal samples to create k-models. Each model used k-1 segments for training and the kth segment to validate the model. The validation set was different for each model. The performance of the artificial neural network during the training process was calculated with the average of the accuracy of the k-models. The value of K used for this study was 3 since it was sought to have 66.6% data for training and 33.3% data for validation in each model.

### d) Learning

The learning process used for this architecture was the backpropagation (BP) algorithm. This algorithm calculates the output error of the architecture on each iteration and propagates the error backwards to each neuron on the network determining the paths with the most influence on the output. This process is carried out on each layer to tune the weight and bias along the network. The BP algorithm evaluates the derivative of the output layer activation function as a product of derivatives between each layer. The gradient of the weight and bias between each layer is a modification of the partial products [20].

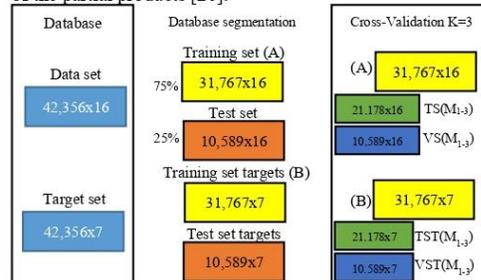


Figure 2. Segmentation of the database for the training and test sets and segmentation of the training set using cross-validation with  $k=3$ .  $TS(M_{1,3})$ : Training sets for model 1, 2 and 3,  $VS(M_{1,3})$ : Validation sets for model 1, 2 and 3,  $TST(M_{1,3})$ : Training sets targets for model 1, 2 and 3,  $VST(M_{1,3})$ : Validation sets targets for model 1, 2 and 3

### e) Statistical methods

The results presented in this work, learning curve, confusion matrix, and receiver operating characteristic (ROC) curves, are the tools used for classifiers. The learning curve allowed observing the model learning process to reduce the output error for all classes in each iteration. The confusion matrix allowed visualizing the performance of the ANN by comparing the predicted values respect to the output values after training the ANN. The ROC curve illustrated the discrimination capacity of a classifier according to the threshold; these curves will be plotted in a one-vs-all graph for each class. Another ROC curve parameter is the area under the curve (AUC) which determines the model's capacity to distinguish between classes.

Besides, the confusion matrix identifies the model's accuracy, sensitivity, and specificity. The model accuracy was calculated with Eq. (1).

$$Accuracy = TP + TN / TP + TN + FP + FN \quad (1)$$

Where, TP stands for true positive, a test result that correctly indicates the presence of a condition or characteristic; TN means true negative, a test result that correctly indicates the absence of a condition or characteristic; FP, false positive, a test result which wrongly indicates that a particular condition or characteristic is present; FN, false negative, a test result which wrongly indicates that a specific condition or characteristic is absent.

Sensibility, the probability of a positive test, conditioned on truly being positive, can be calculated with Eq. (2)

$$Sensibility = TP / TP + FN \quad (2)$$

Specificity, the probability of a negative test, conditioned on truly being negative, was calculated with Eq. (3)

$$Specificity = TN / TN + FP \quad (3)$$

## III. RESULTS

### A. Learning Curve

Six iterations were required to achieve the proposed error, 0.01, to identify the seven classes, figure 3.

### B. Confusion Matrix

The accuracy, calculated through the main diagonal of the confusion matrix, Table 1, indicates the correctly classified classes giving a 97.39% with a mean performance of 97.84%. The last row of the confusion matrix indicated a sample mistake.

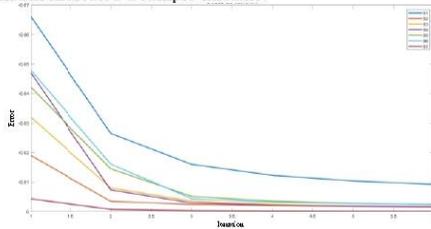


Figure 3. The learning curve for the ANN architecture.

### C. ROC curve

The ROC curve analysis results for seven different combinations are shown in figure 4. Each combination contrasts the results obtained for a particular class against the rest in a one-vs-all classification.

Note that the 97.39% accuracy obtained for all comparisons is due to the fact that the sum of the TP and TN are the same for all the confusion matrices in each comparison.

## IV. DISCUSSION

The present work explores the possibility to recognize movements in the human upper limb using IMU sensors combined with the designed artificial neural network. The low number of iterations required to achieve the proposed error during training indicated that the architecture adequately trained the model. The recognition accuracy of 97.39% showed that the model could classify according to the patterns of the seven daily life tasks. The 2.61% model error may be due to the threshold defined for identifying movements as static positions. This could be improved by extending the boundary used to distinguish between movements, however, the purpose of the threshold allowed the decision line to be placed as close as possible between two or more classes.

The average value of the area under the curve (AUC) from the seven comparisons was 0.973; the result suggest a good ANN capacity to distinguish between classes, since a value close to 1 indicates that the model can predict between classes with a high-reliability [21].

The accuracy value obtained for this work of 97.39% using four IMU sensors and executing five degrees of freedom movements for the upper limb in daily task activities. This accuracy is in the range of the performance reported for intention prediction of the upper limb movement [14, 15].

The limitation of this work focus on the lack of activities with similar movement patterns that could compromise the performance of the ANN, such as shaking hands, opening a doorknob, and receiving an object. Future studies are pending to test the model's capacity for distinguishing these activities. Furthermore, deep learning neural networks have shown better generalization for these applications, so their use in future works may improve the performance.

Table 1. Confusion matrix for the test set. The overall performance is determined by the average of the correctly classified samples of each class divided by the total of samples. C1-7: Classes 1-7.

Confusion Matrix	C1	C2	C3	C4	C5	C6	C7
C1	3146	29	29	28	1	14	0
C2	0	1286	0	0	0	0	0
C3	0	0	1434	0	0	0	0
C4	0	0	0	1183	0	0	0
C5	21	0	0	0	1127	0	0
C6	32	0	0	0	0	1204	0
C7	0	0	0	0	0	0	897
MC	50	21	11	20	2	2	0
Performance (%)	96.83	96.26	97.29	96.10	99.73	98.67	100

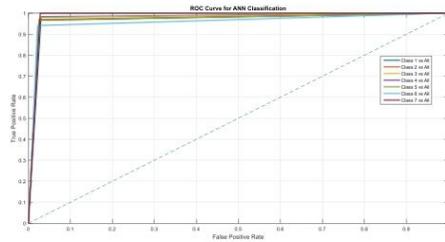


Figure 4. ROC curves for the one-vs-all comparison for each class.

## V. CONCLUSION

The results of this work indicated that it is possible to recognize specific movements of the human upper limb in daily life tasks with IMU sensors and ANN. The recognition of these movements can provide information about a person's condition that could be useful for medical diagnosis and rehabilitation or the prevention of injuries and performance improvements in sports applications by predicting the outcome of the move according to the patterns in the initial stages of the activity. Additionally, this information can be used in industry and virtual environments to determine optimal trajectories required by robots for a specific application.

## ACKNOWLEDGMENT

Authors express thanks to the Consejo Nacional de Ciencia y Tecnología (CONACyT, México), for the scholarship granted to Lauro Armando Contreras-Rodríguez for the PD studies. The authors would like to acknowledge the valuable contributions of Dr. Roberto Muñoz Guerrero (1960-2019) to this work.

Table 2. Summary of the defined statistical parameters for the one-vs-all confusion matrix for each class according to the equations (1-3) and the ROC curves' AUC.

Table 2. One-vs-all statistical comparison for each class.

Class	AUC	Sensitivity	Specificity	Accuracy
1-vs-All	0.977	0.935	0.993	97.39%
2-vs-All	0.972	0.853	0.995	97.39%
3-vs-All	0.976	0.859	0.997	97.39%
4-vs-All	0.971	0.841	0.995	97.39%
5-vs-All	0.971	0.818	0.996	97.39%
6-vs-All	0.96	0.842	0.993	97.39%
7-vs-All	0.986	0.753	1.000	97.39%

## REFERENCES

- [1] Wang L, Hu W, Tan T. Recent developments in human motion analysis. *Pattern recognition*. 2003;36:585-601.
- [2] Patrona F, Chatzitofis A, Zarpalas D, Daras P. Motion analysis: Action detection, recognition, and evaluation based on motion capture data. *Pattern Recognition*. 2018;76:612-22.
- [3] Gohel V, Mehendale N. Review on electromyography signal acquisition and processing. *Biophysical Reviews*. 2020;12:1361-7.
- [4] Colyer SL, Evans M, Cosker DP, Salo AI. A review of the evolution of vision-based motion analysis and the integration of advanced computer vision methods towards developing a markerless system. *Sports medicine-open*. 2018;4:1-15.
- [5] Iosa M, Picerno P, Paolucci S, Morone G. Wearable inertial sensors for human movement analysis. *Expert review of medical devices*. 2016;13:641-59.
- [6] Picerno P, Iosa M, D'Souza C, Benedetti MG, Paolucci S, Morone G. Wearable inertial sensors for human movement analysis: A five-year update. *Expert review of medical devices*. 2021;18:79-94.
- [7] Filippeschi A, Schmitz N, Miezal M, Bleser G, Ruffaldi E, Stricker D. Survey of motion tracking methods based on inertial sensors: A focus on upper limb human motion. *Sensors*. 2017;17:1257.
- [8] Ramasamy Ramamurthy S, Roy N. Recent trends in machine learning for human activity recognition—A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*. 2018;8:e1254.
- [9] Xu Y, Qiu TT. Human activity recognition and embedded application based on convolutional neural network. *Journal of Artificial Intelligence and Technology*. 2021;1:51-60.
- [10] Elkholy HA, Azar AT, Magd A, Marzouk H, Ammar HH. Classifying upper limb activities using deep neural networks. *The International Conference on Artificial Intelligence and Computer Vision*: Springer; 2020. p. 268-82.
- [11] Wei W, Kunita K, Kuang J, Gao A. Real-Time Limb Motion Tracking with a Single IMU Sensor for Physical Therapy Exercises. 2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC): IEEE; 2021. p. 7152-7.
- [12] Oudah M, Al-Naji A, Cahil J. Hand gesture recognition based on computer vision: a review of techniques. *Journal of Imaging*. 2020;6:73.
- [13] Shahtalebi S, Atashzar SF, Samotus O, Patel RV, Jog MS, Mohammadi A. Phtnet: Characterization and deep mining of involuntary pathological hand tremor using recurrent neural network models. *Scientific reports*. 2020;10:1-19.
- [14] Cui J-W, Li Z-G, Du H, Yan B-Y, Lu P-D. Recognition of Upper Limb Action Intention Based on IMU. *Sensors*. 2022;22:1954.
- [15] Lu H, Schomaker LR, Carloni R. IMU-based deep neural networks for locomotor intention prediction. 2020 IEEE/RJSJ International Conference on Intelligent Robots and Systems (IROS): IEEE; 2020. p. 4134-9.
- [16] Schepers M, Giuberti M, Bellusci G. Xsens mvn: Consistent tracking of human motion using inertial sensing. *Xsens Technol*. 2018;1.
- [17] Rana M, Mittal V. Wearable sensors for real-time kinematics analysis in sports: a review. *IEEE Sensors Journal*. 2020;21:1187-207.
- [18] Xsense. Xsens DOT User Manual. Netherlands: XUF; 2022. (available on: Xsense.com) view date: august 30, 2022.
- [19] Nayak J, Naik B, Behera HS. Solving nonlinear classification problems with black hole optimisation and higher order Jordan Pi-sigma neural network: a novel approach. *International Journal of Computational Systems Engineering*. 2016;2:236-51.
- [20] Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *nature*. 1986;323:533-6.
- [21] Carter JV, Pan J, Rai SN, Galanduk S. ROC-ing along: Evaluation and interpretation of receiver operating characteristic curves. *Surgery*. 2016;159:1638-45.

## C.2 Artículo de revista

Medical Engineering and Physics (2022).

ISSN 1350-4533.

<https://doi.org/10.1016/j.medengphy.2022.103852>

Medical Engineering and Physics 107 (2022) 103852



Contents lists available at ScienceDirect

Medical Engineering and Physics

journal homepage: [www.elsevier.com/locate/medengphy](http://www.elsevier.com/locate/medengphy)



Technical note

### Upper limb orientation assessment as an articulated body chain

Lauro Armando Contreras Rodríguez<sup>a,\*</sup>, José Antonio Barraza Madrigal<sup>b</sup>, Eladio Cardiel<sup>c</sup>, Pablo Rogelio Hernández<sup>d</sup>

<sup>a</sup> Electrical Engineering Department, Center for Research and Advanced Studies IPN, Mexico City, Mexico, Electrical Engineering Department/Bioelectronics Section, Av. IPN 2508 Col. San Pedro Zacatenco, Mexico City, C.P. 07360, Mexico

<sup>b</sup> Departamento de Formación Básica, Academia de Física, Escuela Superior de Ingeniería Química e Industrias Extractivas ESIQIE-IPN, Instituto Politécnico Nacional, Instituto Politécnico Nacional, Edificio 6, Unidad Profesional "Adolfo López Mateos", Col. Zacatenco, Deleg. Gustavo A. Madero, Ciudad de México, México, ESIQIE, C.P. 07738, México

<sup>c</sup> Electrical Engineering Department, Center for Research and Advanced Studies IPN, Mexico City, Mexico, Electrical Engineering Department/Bioelectronics Section, Av. IPN 2508 Col. San Pedro Zacatenco, Mexico City, Mexico, C.P. 07360

<sup>d</sup> Electrical Engineering Department, Center for Research and Advanced Studies IPN, Mexico City, Mexico, Electrical Engineering Department/Bioelectronics Section, Av. IPN 2508 Col. San Pedro Zacatenco, Mexico City, C.P. 07360, Mexico



#### ABSTRACT

Upper limb orientation estimation based on Magnetic, Angular Rate, and Gravity sensors considering multiple body segments is presented in this work. The proposal allowed assessing the activity of two or more body segments individually and jointly, regardless of their spatial relationship. A custom-made system was developed incorporating a complementary filter and a proportional-integral control for data sensor merging and noise and instrumentation error reduction. Two controlled tests were carried out to assess the performance of the system. The former evaluated the response of the method in motionless conditions, while the latter assessed the feasibility to follow trajectories in 3D space. Ten volunteers were recruited to evaluate the system performance in three semi-controlled and daily life task tests. The system was evaluated using the common parameters in motion tracking methods and relied on a digital motion processor. The system's outcome presented a root mean square error in the range of 2.65°-3.98° for the semi-controlled tests and 0.48°-1.289° for the daily life task test. The system tests analysis proved that the proposal permitted obtaining the articulated body chain information of multiple segments when three or more MARG sensors are used.

#### 1. Introduction

Evaluation of an object's position, speed, and acceleration has been enhanced by advances in microtechnology for Magnetic, Angular Rate, and Gravity (MARG) sensors [1–6]. Compared to marker and marker-less systems, these devices provide portable, reliable, and occlusion-free systems for assessing human movement [7]. MARG sensors include a gyroscope, accelerometer, and magnetometer to measure the angular rate, gravity, and magnetic field.

Orientation accuracy remains a challenge when assessing human segments as an articulated body chain. Accuracy is required because an error in measuring the segment's activity related to the reference will be magnified in the distal segment's information [8–13].

Commercial motion capture systems use MARG sensors (Xsens®, Shimmer sensing®, MicroStrain®) to overcome the orientation accuracy issues. However, reports indicate that the information obtained with these systems does not allow access to the data in the intermediate stages during data processing, thus limiting its use for other applications [9,14,15].

This proposal of this work consists of assessing the orientation of multiple body segments, performing a complete motion analysis of four segments related to the upper limb. A custom-made system (the proposed method, PM), a set of four-measuring modules based on MARG sensors' raw data, was developed to calculate upper limb orientation while tracking human motion. Each measuring module uses a complementary filter (CF) and a Proportional-Integral (PI) control. The complementary filter was used to merge the accelerometer and magnetometer data and to reduce instrumentation error [11,16–18]. The PI control was proposed in this work to gradually merge both an inertial reference coordinate system and a mobile coordinate system for orientation calculation. A direction cosine matrix (DCM) described the orientation relationship between the two coordinate systems, and Quaternions simplified the obtained information, avoiding singularity conditions.

Two tests were applied to assess the proposal's performance under controlled conditions to validate its use for human motion tracking. The former evaluated static conditions, while the latter evaluated dynamic conditions. Finally, the measurement system was used to obtain the

\* Corresponding author.

E-mail address: [lauro.contreras@cinvestav.mx](mailto:lauro.contreras@cinvestav.mx) (L.A. Contreras Rodríguez).

<https://doi.org/10.1016/j.medengphy.2022.103852>

Received 2 March 2022; Received in revised form 8 July 2022; Accepted 12 July 2022

Available online 14 July 2022

1350-4533/© 2022 IPPEM. Published by Elsevier Ltd. All rights reserved.

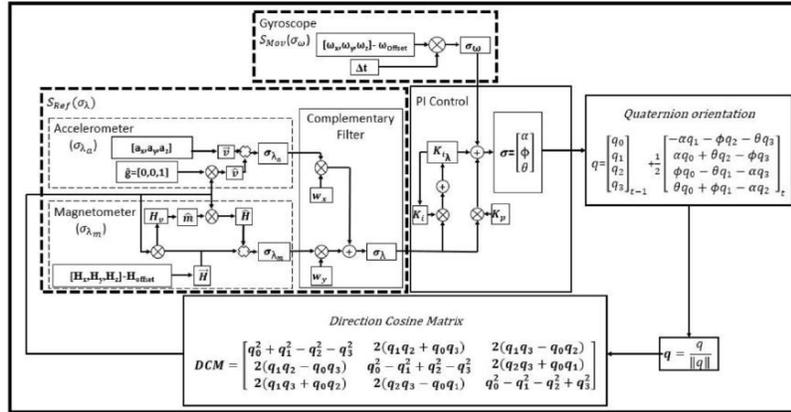


Fig. 1. Block diagram for the orientation estimation of upper limb segments.

action information of multiple body segments individually [19,20] and to estimate the joint movements through the active measurement of two consecutive segments [21–23] as an articulated body chain. These tests were performed under the ethical principles established in the Declaration of Helsinki.

The obtained results are the range of motion values and the trajectory described by the upper limb evaluated with the common parameters for the human motion assessment [11,24–28].

## 2. Methodology

In order to assess the orientation of the upper limb as an articulated body chain, a custom-made system was developed. The system consisted of four-measuring modules based on MARG sensors. These sensors were used to acquire the information related to each segment. A mathematical procedure to estimate the orientation was programmed on each measuring module of the system, Fig. 1. A complementary filter combined with a PI Control were proposed to merge the data sensors in the orientation estimation process. Information from the gyroscope helped to create a moving reference system, while data from the accelerometer and magnetometer served to establish a fixed reference on the three-coordinate axes [11,12].

### 2.1. Orientation estimation for each segment

For the orientation estimation, two coordinate systems were created from the sensors information, one to evaluate the body's movements ( $S_{Mov}$ ) based on the gyroscope, and the other took the geodesic system as a reference to generate an inertial coordinate system ( $S_{Ref}$ ) taking advantage of the accelerometer and magnetometer properties.

#### 2.1.1. Mobile reference system

The information from the gyroscope ( $\omega$ ) was used to estimate the orientation of the body with the purpose to create a mobile reference system. It is noteworthy that the gyroscope's data was processed to obtain the orientation of the evaluated body through the angular velocity ( $\omega_{xyz}$ ), an offset ( $\omega_{offset}$ ), and a time differential ( $\Delta t$ ), Equation (1).

$$\left\{ \begin{array}{l} \omega_{xyz} = [\omega_x \ \omega_y \ \omega_z] \\ \omega_{offset} = \frac{\sum_{i=1}^n (\omega_{xyz})_i}{n} \end{array} \right\} \rightarrow \sigma_\omega = (\omega_{xyz} - \omega_{offset}) * \Delta t \quad (1)$$

#### 2.1.2. Inertial reference system

The inertial reference system was defined by two rotation correction vectors ( $\sigma_{x,z}$  and  $\sigma_{y,m}$ ) calculated by the accelerometer and magnetometer data. This system allowed to compensate for the time-varying errors inherent in the gyroscope output caused by the integration of noise and drift [11]. The first vector ( $\sigma_{x,z}$ ) used the information from the accelerometer ( $a_{x,y,z}$ ) to compensate for the drift on the axes parallel to the ground plane. The calculation of this vector resulted in the cross product between an inertial vector ( $\vec{v}$ ), which represents the normalization of the accelerometer measurement ( $a_{x,y,z}$ ), and the vector of gravity ( $\hat{v}$ ), corresponding to the Z-components,  $\hat{z} = [0 \ 0 \ 1]$ , of the direction cosine matrix (DCM), Equation (2). The DCM described the orientation of the body mobile coordinate system concerning the inertial reference coordinate system.

$$\left\{ \begin{array}{l} \vec{v} = \frac{[a_{x,y,z}]}{\| [a_{x,y,z}] \|} \\ \hat{v} = \hat{z} * \text{DCM} \end{array} \right\} \rightarrow \sigma_{x,z} = \vec{v} \times \hat{v} \quad (2)$$

The second vector ( $\sigma_{y,m}$ ) compensated for the drift on the axis perpendicular to the ground plane using the magnetic field measurement ( $H_{x,y,z}$ ) by hard iron ( $H_{offset}$ ) and soft iron ( $\hat{m}$ ). This vector was calculated by the cross product between a vector generated by the components of the magnetic flux on each axis ( $\vec{H}$ ) and the Earth's magnetic field directional vector ( $\hat{H}$ ) Equation (3).

$$\sigma_{y,m} = \vec{H} \times \hat{H} \quad (3)$$

The magnetic flux vector ( $\vec{H}$ ) was determined with the normalized magnetometer measurements ( $H_{x,y,z}$ ) and the magnetic field offset caused by ferromagnetic elements ( $H_{offset}$ ), Equation (4).

$$\left\{ H_{offset} = \frac{\max(H_{x,y,z}) - \min(H_{x,y,z})}{2} \right\} \rightarrow \vec{H} = \left( \frac{[H_{x,y,z}]}{\| [H_{x,y,z}] \|} \right) - H_{offset} \quad (4)$$

The Earth's magnetic field directional vector ( $\hat{H}$ ) was calculated by the magnetic flux vector measured ( $\vec{H}$ ) and its rotation relative to the

DCM; this defined the direction of the Earth's magnetic field measured ( $H_v$ ), Equation (5).

$$H_v = \vec{H} * \text{DCM} \quad (5)$$

The Earth's magnetic field ( $H_v$ ) was represented in terms of magnetic inclination and declination (soft iron), horizontal and vertical axes of the reference system used to define the directional vector ( $\hat{m}$ ), Equation (6).

$$\hat{m} = \left[ \sqrt{H_{vx}^2 + H_{vy}^2}, 0, H_{vz} \right] \quad (6)$$

To consider, the soft iron components ( $H_v$ ) that form the magnetic field vector ( $\vec{H}$ ), the directional vector ( $\hat{m}$ ) values considered its rotation using DCM to define the directional vector of the Earth's magnetic field ( $\hat{H}$ ), Equation (7).

$$\hat{H} = \hat{m} * \text{DCM} \quad (7)$$

### 2.1.3. Sensors data merging

The sensors data merging was performed through a complementary filter and a Proportional Integral (PI) Control. The complementary filter compensates the sensor attitude at high frequency using the rotation correction vectors of the accelerometer ( $\sigma_{ia}$ ) and magnetometer ( $\sigma_{im}$ ), obtaining the orientation of the inertial coordinate system ( $\sigma_i$ ), Equation (8).

$$\sigma_i = W_x * \sigma_{ia} + W_y * \sigma_{im} \quad (8)$$

The weighted values  $W_x$  and  $W_y$ , Equation (9), were selected from the divergence and convergence calculated of both sensors [29]. So that,

$$W_y = 1 - W_x \quad (9)$$

The PI control gradually merges the inertial coordinate system ( $\sigma_i$ ) and the mobile reference system ( $\sigma_m$ ) for the orientation calculation. Besides, the PI control action determined a stable response of the system without stationary error, obtaining the orientation of the object ( $\sigma$ ), Equation (10).

$$\sigma = \sigma_m + K_p \sigma_i + K_i \int_0^t I(\sigma_i) = [\alpha \quad \varphi \quad \theta] \quad (10)$$

$K_p$  and  $K_i$  were defined applying the Good Gain method to tune the PI control, considering a smooth and low inertial damping response [30].  $\alpha$ ,  $\varphi$ , and  $\theta$  variables correspond to the estimated orientation in Euler's angles.

### 2.1.4. Calculus of spatial orientation using quaternions and DCM

The orientation was obtained through Euler's angles. The biggest drawback of this kinematic technique is due to gimbal lock, which occurs at certain positions. Quaternions were proposed to solve this drawback since these singularities do not manifest and are computationally more efficient [31–33], Equation (11).

$$q = q_{t-1} + \int_0^t q(dt) \rightarrow q_{t-1} \otimes q_t \rightarrow q = \begin{bmatrix} q_0 \\ q_1 \\ q_2 \\ q_3 \end{bmatrix}_{t-1} + \frac{1}{2} \begin{bmatrix} -\alpha q_1 - \varphi q_2 - \theta q_3 \\ \alpha q_0 + \theta q_2 - \varphi q_3 \\ \varphi q_0 - \theta q_1 - \alpha q_3 \\ \theta q_0 + \varphi q_1 - \alpha q_2 \end{bmatrix}_1 \quad (11)$$

A normalization process of the quaternion data was carried out to ensure the orthogonality between the quaternion elements, Equation (12).

$$q = \frac{q}{\|q\|} = [q_0 \quad q_1 \quad q_2 \quad q_3] \quad (12)$$

For the DCM determination, each element of the matrix corresponds to the cosine of the angle between the rotation unit vector (rows) and the reference coordinate system (columns). Each row can be considered as the result of rotating one by one the unit vectors of the reference

coordinate system by the rotation that the resulting DCM would describe [33], Equation (13).

$$\text{DCM} = \begin{bmatrix} q_0^2 + q_1^2 - q_2^2 - q_3^2 & 2(q_1 q_2 + q_0 q_3) & 2(q_1 q_3 - q_0 q_2) \\ 2(q_1 q_2 - q_0 q_3) & q_0^2 - q_1^2 + q_2^2 - q_3^2 & 2(q_2 q_3 + q_0 q_1) \\ 2(q_1 q_3 + q_0 q_2) & 2(q_2 q_3 - q_0 q_1) & q_0^2 - q_1^2 - q_2^2 + q_3^2 \end{bmatrix} \quad (13)$$

### 2.1.5. Orientation estimation of the joints

The spatial relationship between two adjacent body segments was calculated by estimating the joint's activity. The product between a segment's conjugated quaternion ( $q_a$ )<sup>\*</sup> and the adjacent segment's quaternion ( $q_b$ ) was calculated to get this spatial relationship ( $q_c$ ), Equation (14).

$$q_c = (q_a)^* \otimes q_b = \begin{bmatrix} (q_{0a} * q_{0b}) + (q_{1a} * q_{1b}) + (q_{2a} * q_{2b}) + (q_{3a} * q_{3b}) \\ (q_{0a} * q_{1b}) - (q_{1a} * q_{0b}) - (q_{2a} * q_{3b}) + (q_{3a} * q_{2b}) \\ (q_{0a} * q_{2b}) + (q_{1a} * q_{3b}) - (q_{2a} * q_{0b}) - (q_{3a} * q_{1b}) \\ (q_{0a} * q_{3b}) + (q_{1a} * q_{2b}) + (q_{2a} * q_{1b}) - (q_{3a} * q_{0b}) \end{bmatrix} \quad (14)$$

The joint's activity was estimated by this process, Equations (15–17):

$$q_{\text{shoulder}} = (q_{\text{torax}})^* \otimes q_{\text{arm}} \quad (15)$$

$$q_{\text{elbow}} = (q_{\text{arm}})^* \otimes q_{\text{forearm}} \quad (16)$$

$$q_{\text{wrist}} = (q_{\text{forearm}})^* \otimes q_{\text{hand}} \quad (17)$$

## 2.2. Materials

The measuring modules of the system include a GY-87<sup>®</sup> motion tracking device (WAVGAT<sup>®</sup>, China), a DsPic30F6014A<sup>®</sup> microprocessor (Microchip<sup>®</sup>, USA), a UART-USB FTDI232RL<sup>®</sup> serial converter (FTDI Chip<sup>®</sup>, UK), a lithium polymer battery (550mAh @ 3.7DCV), and an X Bee XB24API001 series 1 wireless communication device (Digi-Key<sup>®</sup>, USA) at 9600 baud rate. In respect to the GY-87 device, it is composed of an MPU-6050<sup>®</sup> inertial sensor of 6 degrees of freedom (InvenSense<sup>®</sup>, USA) in which a three-axis gyroscope and a three-axis accelerometer are included; a three-axis HCM5883L<sup>®</sup> magnetometer (Honeywell, USA), and a digital motion processor (DMP). The typical sensor range values to evaluate joints kinematics were  $\pm 200^\circ/\text{s}$  to  $\pm 600^\circ/\text{s}$  for the gyroscope, while  $\pm 2g$  to  $\pm 5g$  for the accelerometer [34–37]. For this work, the scale values for each sensor were  $\pm 250^\circ/\text{s}$  for gyroscope,  $\pm 2g$  for accelerometer, and  $\pm 1.3G$  for magnetometer, with a digital resolution of 0.92mG/LSb.

### 2.3. Validation of the Measuring System

Before the upper limb orientation assessment, two activities under controlled conditions were conducted for validation. The results were relied on ground truth and compared against the GY-87's digital motion processor output (DMP). DMP was used as a reference to compare results since it is capable of calibrating the gyroscope orientation and accuracy has been compared with an image processing software [38]. The first activity, named static test, evaluated the performance of the proposal in a motionless state. The second activity, called dynamic test, appraised the system's feasibility of following a trajectory. For both activities, qualitative and quantitative analyses were implemented to assess the proposal. The qualitative analysis displays the trajectory relative to the proposed orientation estimation during the test. The quantitative analysis assesses the proposal's accuracy using the common parameters for evaluating motion tracking devices: arithmetic mean (Mean), standard deviation ( $\sigma$ ), variance ( $S^2$ ), root mean square error (RMSE), and correlation coefficients (CC) [11].

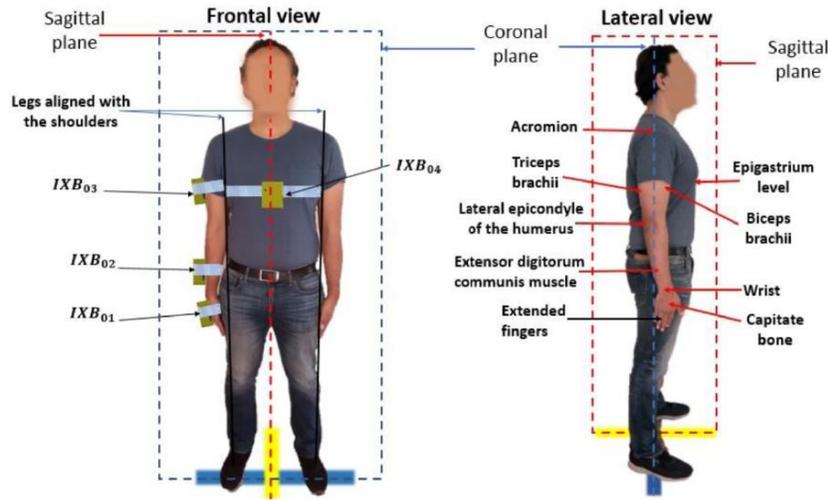


Fig. 2. Measuring module's location and N-pose.

#### 2.3.1. Static test

Each measuring module was placed on a flat surface, ensuring that the GY-87's local coordinate reference was aligned with the Earth's north magnetic pole. The information data was recorded for 600 seconds to determine the presence of noise and drift.

#### 2.3.2. Dynamic tests

For this test, the measuring module was mounted on a servomotor to rotate the sensor from  $0^\circ$  to  $90^\circ$  on the three axes as a proposal for simulating a tilt table method for accuracy assessment [11, 39]. Each test consisted of two 300-second stages. In the first stage, 0-300 seconds, the activity of fifteen cycles was recorded according to the following description: five seconds at rest position ( $0^\circ$ ), a five-second rotation from  $0^\circ$  to  $90^\circ$ , five-second at rest position ( $90^\circ$ ) and a five-second turn back to  $0^\circ$ . The second stage, 301-600 seconds, consisted of recording the module's response in a static position at  $0^\circ$  to confirm that the proposal could keep the orientation without drift after a movement.

#### 2.4. Assessment of the upper limb orientation

Three semi-controlled tests and a daily life task activity (reach-to-grasp test) were proposed to assess the upper limb orientation while tracking human motion. Ten healthy, right-handed volunteers, six males and four females, age  $39 \pm 15.9$  years, were recruited to conduct this study. They signed an informed consent letter, submitted to the institutional Bioethics Committee for Research on Human Beings of CINVESTAV-IPN. The PM modules were placed on the volunteers' upper right limb to obtain information regarding the angular displacements during the movements of each segment, Figure 2.

Module IXB<sub>01</sub> was placed on the back of the hand. The module IXB<sub>02</sub> was placed on the *extensor digitorum communis* muscle, 5cm from the wrist. The module IXB<sub>03</sub> was placed on the external lateral portion of the arm, at the middle distance between the acromion and the lateral epicondyle of the humerus, referenced at the midpoint between the brachii biceps and brachii triceps muscles. Finally, the module IXB<sub>04</sub> was placed at the epigastrium, taking the xiphoid apophysis as a reference.

#### 2.4.1. Semi-controlled test

Three movements of the upper limb on the sagittal plane were selected to be evaluated fifteen times. Every movement begins by orienting the study participant toward the Earth's north magnetic pole in the sagittal plane and adopting the neutral position (N-pose), Figure 2.

Each movement of interest was executed three times for the tests. In the first movement, volunteers were asked to perform a shoulder flexion until reaching  $90^\circ$ , followed by a shoulder extension until  $-20^\circ$ , and finally, resume the starting position at  $0^\circ$ . For the second movement, volunteers were asked to perform an elbow flexion until reaching  $90^\circ$ , then return to the starting position at  $0^\circ$ . For the third movement, volunteers were asked to perform an elbow flexion to  $90^\circ$ , followed by the movement of interest: wrist total adduction,  $55^\circ$ , wrist total abduction,  $105^\circ$ , and resume the starting position, wrist adduction to  $90^\circ$ . The test ends when the volunteer extends the elbow to  $0^\circ$  resuming the N-pose.

#### 2.4.2. Reach-to-grasp test

This test involves the action of the three joints at the same time, that was defined to assess the trajectory described by the upper limb in a daily life task. The task consisted of grabbing a glass from a table, take it to the mouth, and placing it back on the table. Volunteers began the activity by sitting upright in front of the table and their right arm extended downwards. The glass was placed on the table surface 10cm from the edge. The volunteers were asked to wait for an audible indicator to begin the test.

### 3. Results

#### 3.1. Evaluation in the static test

Figure 3 a) shows the measuring system (PM) and DMP values relied on ground truth on the three axes for qualitative analysis. Visually, the estimated orientation allows observing the PM's capacity to reduce noise and eliminate drift according to the hypothesis of suitable compensation of the raw measurements from the MARG sensors. The yaw rotation graph (Z-axis rotation) presented a  $0.5^\circ$  offset for the DMP's output due to a misalignment of the GY-87 in the measuring module; this is attended in the calibration process before motion

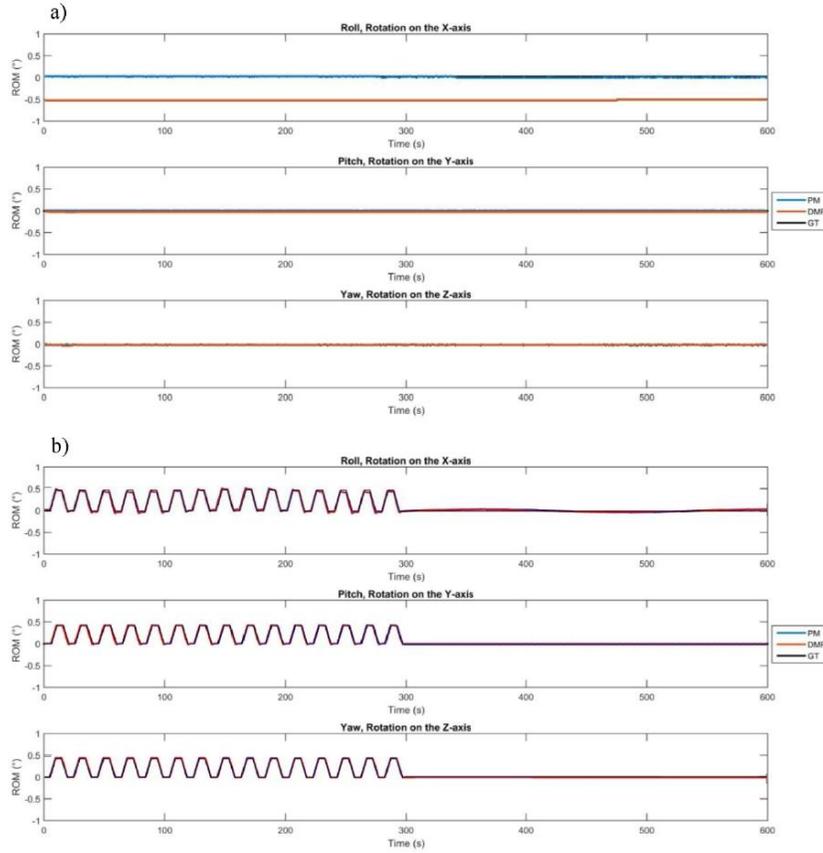


Fig. 3. Sensors response on the three axes during the static test (a) and dynamic tests (b).

Table 1

Quantitative analysis of the static test. Mean: Average;  $\sigma$ : standard deviation; S2: variance; RMSE: root mean square error; PM: System; DMP: Digital Motion Processor. The best performance for each comparison is marked in bold.

	Mean (°)		$\sigma$ (°)		S <sup>2</sup> (° <sup>2</sup> )		RMSE (°)	
	PM	DMP	PM	DMP	PM	DMP	PM	DMP
X-axis	<b>0.0026</b>	0.0045	0.0063	<b>0.0031</b>	$3.96 \times 10^{-5}$	$9.86 \times 10^{-6}$	$4.65 \times 10^{-5}$	$2.98 \times 10^{-5}$
Y-axis	$-3.71 \times 10^{-4}$	-0.02	0.001	$7.32 \times 10^{-4}$	$1.49 \times 10^{-6}$	$5.35 \times 10^{-7}$	$1.63 \times 10^{-6}$	$3.80 \times 10^{-4}$
Z-axis	<b>-0.01</b>	-0.44	<b>0.012</b>	0.017	$1.45 \times 10^{-4}$	$2.95 \times 10^{-4}$	$2.85 \times 10^{-4}$	0.19

assessment.

It should be noted the low levels of noise and drift. Table 1 shows a data comparison between the PM and DMP outputs based on ground truth.

It is worth noting that the mean values close to 0° show that the system and DMP are calibrated for the test. The standard deviation and variance results reveal that the measured noise and drift do not affect the estimated orientation. Finally, the RMSE values show good accuracy for the system for static conditions.

### 3.2. Evaluation in dynamic tests

For these tests, the measuring module was placed on a servomotor programmed to repeat fifteen movement cycles from 0° to 90°. The sensor's axes were aligned with respect to the Earth's north magnetic pole. Figure 3 b) shows the response of the system and DMP output relied on the ground truth of the fifteen cycles of activity in the first five minutes (0-300 s) and the response during the second five minutes (301-600 s) in a static position.

Visually, in both the rotations and the static stages, no significant

**Table 2**

Quantitative analysis of the dynamic tests on the three axes. Mean<sub>Max/Min</sub>: Average of the maximum and minimum points;  $\sigma$ : Standard deviation;  $S^2$ : Variance; RMSE: root mean square error; PM<sub>X,Y,Z</sub>/DMP<sub>X,Y,Z</sub>: Evaluation of the system and digital motion processor on the X-Y-Z axes, respectively. The best performance for each comparison is marked in bold.

Stage 1 (0–300 s)	PM <sub>x</sub>	DMP <sub>x</sub>	PM <sub>y</sub>	DMP <sub>y</sub>	PM <sub>z</sub>	DMP <sub>z</sub>
Mean <sub>Max</sub> (°)	90.17	89.26	<b>89.91</b>	89.01	<b>89.94</b>	90.86
Mean <sub>Min</sub> (°)	0.23	-0.5	-0.15	-0.84	0.06	0.84
$\sigma$ (°)	0.73	3.48	<b>0.46</b>	0.99	<b>0.72</b>	0.85
$S^2$ (° <sup>2</sup> )	0.53	12.13	<b>0.21</b>	0.98	<b>0.52</b>	0.73
RMSE (°)	0.53	12.13	<b>0.21</b>	0.98	<b>0.51</b>	0.73
Stage 2 (301–600 s)	PM <sub>x</sub>	DMP <sub>x</sub>	PM <sub>y</sub>	DMP <sub>y</sub>	PM <sub>z</sub>	DMP <sub>z</sub>
Mean (°)	0.25	0.77	-0.24	0.01	0.04	1.90
$\sigma$ (°)	0.52	3.43	0.42	0.15	0.20	0.42
$S^2$ (° <sup>2</sup> )	0.26	11.73	0.19	0.02	0.04	0.18
RMSE (°)	0.25	11.73	0.19	0.02	0.04	0.18

differences were observed between the system and the DMP measurements, indicating the system's feasibility for trajectory tracking without losing orientation. Despite the vibration and magnetic interferences caused by the servomotor, the noise and drift are maintained at low levels. Table 2 shows the quantitative analysis of the dynamic tests

obtained on both defined stages.

3.3. Semi-controlled tests analysis

Figure 4 shows the performance of a sample test for the elbow flexion-extension movement on the sagittal plane. This figure was divided into two sections. Section one indicates the measurements of each module located on the upper limb segments and the thorax. Section

**Table 3**

Results of the quantitative analysis of the semi-controlled tests, in volunteers, for rotation on the sagittal plane. Evaluation of the shoulder flexion-extension activity (Shoulder FE); Evaluation of the elbow flexion-extension activity (Elbow FE); Evaluation of the wrist abduction-adduction (Wrist Abd-Add); Standard deviation ( $\sigma$ ); Variance ( $S^2$ ); Root mean square error compared to DMP (RMSE vs DMP); Correlation coefficient compared to DMP (CC vs DMP).

Movement	Average range of motion (°)	$\sigma$ (°)	$S^2$ (° <sup>2</sup> )	RMSE vs DMP	CC vs DMP
Shoulder FE	-22.27 – 83.22	1.57	1.54	2.6746°	0.9956
Elbow FE	-1.72 – 88.78	1.29	1.48	2.65°	0.997
Wrist Abd-Add	55.09 – 106.08	1.91	1.94	3.98°	0.9948

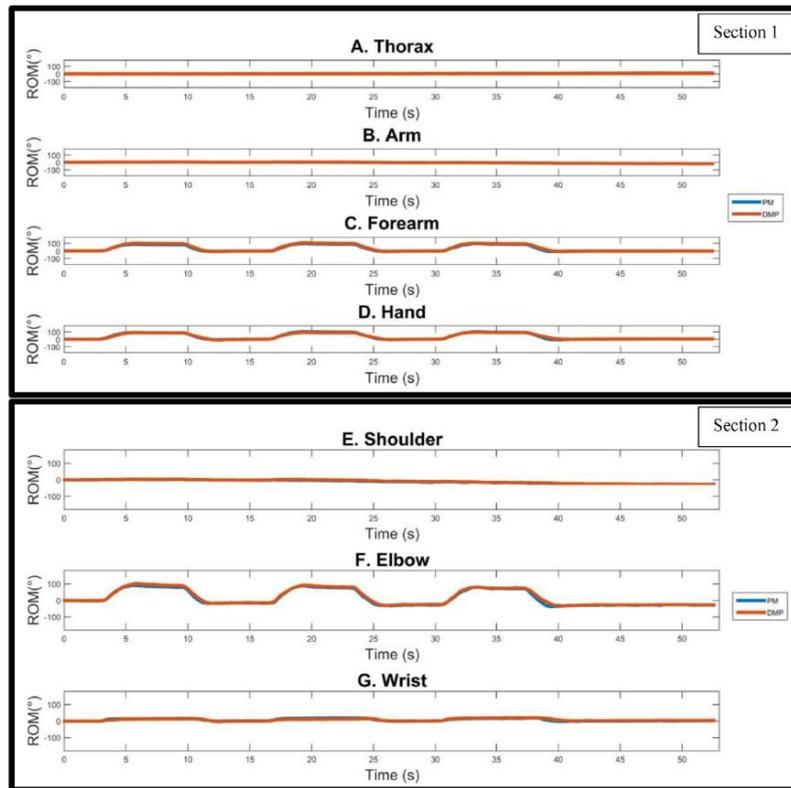


Fig. 4. Results of the elbow flexion-extension test (results from one sample test). Rotation on sagittal plane.

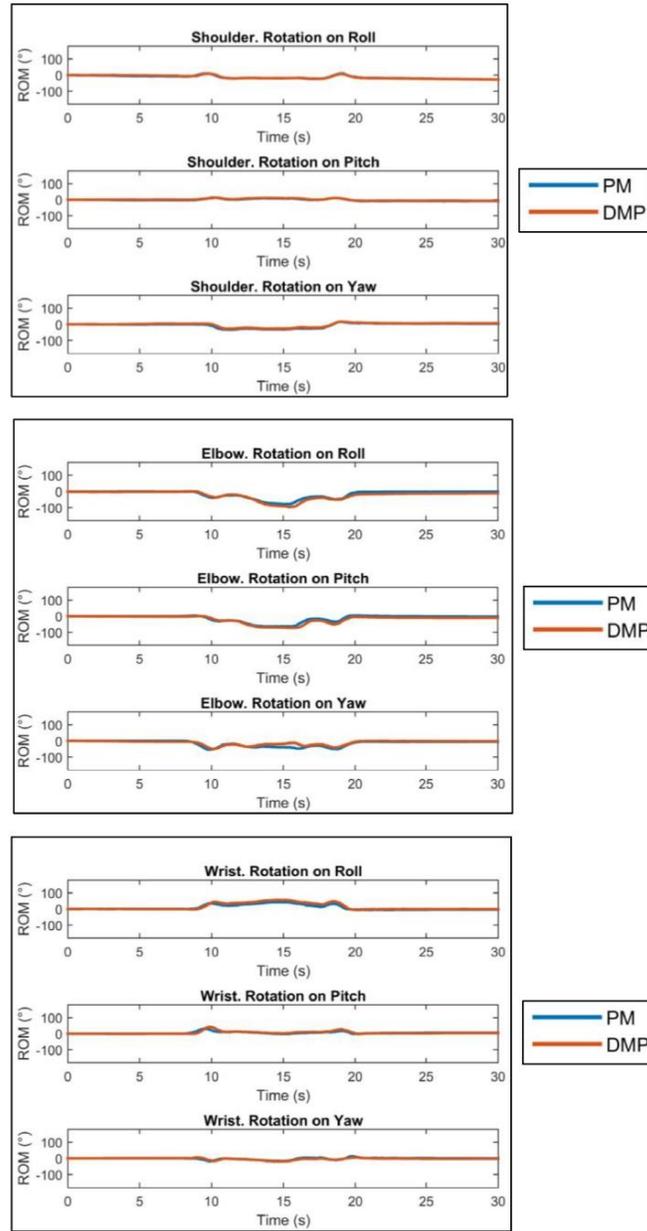


Fig. 5. Orientation estimation of the joints activity during the Reach-to-Grasp tests (results from one sample test).

two presents the joint's angles estimated when compensating for the two contiguous segments, Equation (14).

Table 3 presents the quantitative analysis for the three movements. The accuracy for these tests relied on DMP's output calculating RMSE and correlation coefficients.

#### 3.4. Reach-to-Grasp tests analysis

In Figure 5, each graph was divided into four stages for the qualitative analysis of the Reach-to-Grasp test. Stage A showed the volunteer's activity before movement, the absence of activity in this stage indicated that the sensor was correctly calibrated. Stage B displayed the activity executed by the volunteer to bring the hand from the starting position to the glass on the table, hold the glass, and take the glass to the mouth. During this stage, it was observed a slight movement of the arm in the three axes, an elbow flexion measured in the forearm to reach the glass, a hand flexion to hold the glass, and a flexion greater than 90° by the elbow to bring the glass to the mouth. Stage C exhibited the opposite activity of stage B, starting by removing the glass from the mouth and returning it to the table, resuming the initial position. Finally, stage D demonstrated that the system could keep orientation without noise or drift after executing the movement.

The quantitative analysis for this test produced a correlation value between the system and the DMP of 0.9916-0.9964 and an RMSE value of 0.48°-1.389°.

#### 4. Discussion

Acceptable accuracy values to assess the upper limb joint measurements using IMU sensors are below 5.0° of error [13, 25], while a correlation coefficient value greater than 0.95 is considered a high ratio between both signals [27]. The RMSE and the correlation coefficients, 0.48°-3.98° and 0.9916-0.997, respectively, obtained in this work when assessing multiple body segments as an articulated body chain are in the range reported for this application.

To guarantee that the custom-made system could be used for assessing human motion, accuracy, noise, and drift at a low level should be assured [11, 38, 40]. The static test showed an RMSE accuracy of  $2.85 \times 10^{-4}$  degrees. There were no significant noise and drift levels in a lengthy trial assessment, ten minutes. The dynamic tests also allowed evaluating the system feasibility to follow a defined trajectory and maintaining low drift levels after an activity, besides low noise levels with vibration and magnetic interference caused by a servo, Figure 5. The result of these tests indicates that the accuracy of the system is reliable when compared with a DMP for human motion assessment.

Semi-controlled tests and Reach-to-Grasp were defined to observe the performance of the measuring system for human motion tracking. This procedure allowed identifying the orientation of the segments as an articulated chain just as the body segments activity in the upper limb.

The CF allowed reducing noise and minimizing the instrumentation error [16]. The experimental results during the dynamic tests showed that the system could handle the presence of magnetic disturbances and external vibrations, where no drift was observed. The PI control gradually incorporated the angular displacements between the coordinate systems of the sensors, reducing the steady-state errors [41]. This could be seen in human motion and dynamic test results because the system could track movements without losing orientation.

Unconstrained tests are required to demonstrate that it can be used outdoors with the presence of magnetic and vibrational disturbances due to the magnetic fields near the magnetometer in real-world settings that could influence the results by causing a bias by ferromagnetic elements.

#### 5. Conclusions

The tests analysis proved that the proposal permitted obtaining the

articulated body chain information of multiple segments when three or more MARG sensors are used. Results indicate that the system provides reliable performance for the human motion orientation estimation according to the scopes of related works and commercial devices.

As the performance of the proposal was assessed using raw data of a commercial MARG sensor, the system can be replicated in devices with an accelerometer, gyroscope, and magnetometer as independent or embedded sensors. Tests show that the system could handle the high-frequency vibration of a motor without losing orientation while tracking trajectories.

#### Funding

None.

#### Ethical Approval

The consent letter was submitted to the institutional Bioethics Committee for Research on Human Beings (COBISH, Comité de Bioética para la Investigación en Seres Humanos) of Center for Research and Advanced Studies of National Polytechnic Institute (CINVESTAV-IPN).

#### CRedit authorship contribution statement

**Lauro Armando Contreras Rodríguez:** Conceptualization, Data curation, Formal analysis, Investigation, Methodology, Project administration, Resources, Software, Supervision, Validation, Visualization, Writing – original draft, Writing – review & editing. **José Antonio Barraza Madrigal:** Conceptualization, Data curation, Formal analysis, Investigation, Methodology, Project administration, Resources, Software, Supervision, Validation, Visualization, Writing – original draft, Writing – review & editing. **Eladio Cardiel:** Conceptualization, Data curation, Formal analysis, Investigation, Methodology, Project administration, Resources, Software, Supervision, Validation, Visualization, Writing – original draft, Writing – review & editing. **Pablo Rogelio Hernández:** Conceptualization, Data curation, Formal analysis, Investigation, Methodology, Project administration, Resources, Software, Supervision, Validation, Visualization, Writing – original draft, Writing – review & editing.

#### Declaration of Competing Interest

None.

#### Acknowledgment

The author express thanks to Consejo Nacional de Ciencia y Tecnología (CONACyT) for the scholarship granted to Lauro Armando Contreras Rodríguez for the PhD studies.

The authors would like to acknowledge the valuable contributions of Dr. Roberto Muñoz Guerrero (1960-2019) to this work.

#### References

- [1] Zhu R, Zhou Z. A real-time articulated human motion tracking using tri-axis inertial/magnetic sensors package. *IEEE Trans Neural Syst Rehabil Eng* 2004;12: 295–302.
- [2] Milosevic B, Leardini A, Farella E. Kinect and wearable inertial sensors for motor rehabilitation programs at home: state of the art and an experimental comparison. *Biomed Eng Online* 2020;19:1–26.
- [3] Gallagher A, Matsuoka Y, Ang W-T. An efficient real-time human posture tracking algorithm using low-cost inertial and magnetic sensors. In: 2004 IEEE/RSJ international conference on intelligent robots and systems (IROS)(IEEE Cat No 04CH37566); IEEE; 2004. p. 2967–72.
- [4] Sabatini AM. Estimating three-dimensional orientation of human body parts by inertial/magnetic sensing. *Sensors* 2011;11:1489–525.
- [5] Iosa M, Piccinio P, Paolucci S, Morone G. Wearable inertial sensors for human movement analysis. *Expert Rev Med Devices* 2016;13:641–59.

- [6] Madrigal JAB, Cardiel E, Rogeli P, Salas LL, Guerrero RM. Evaluation of suitability of a micro-processing unit of motion analysis for upper limb tracking. *Med Eng Phys* 2016;38:793–800.
- [7] Kyriatini M, Wang X, Gräser A. Comparison of vision-based and sensor-based systems for joint angle gait analysis. In: 2015 IEEE international symposium on Medical Measurements and Applications (MeMeA) proceedings: IEEE; 2015. p. 375–9.
- [8] Ricci L, Taffoni F, Formica D. On the orientation error of IMU: investigating static and dynamic accuracy targeting human motion. *PLoS One* 2016;11(9):1–15. <https://doi.org/10.1371/journal.pone.0161940>.
- [9] Fourati H. Heterogeneous data fusion algorithm for pedestrian navigation via foot-mounted inertial measurement unit and complementary filter. *IEEE Trans Instrum Meas* 2014;64:221–9.
- [10] Chelius G, Brailion C, Pasquier M, Horvais N, Gibollet RP, Espiau B, et al. A wearable sensor network for gait analysis: a six-day experiment of running through the desert. *IEEE/ASME Trans Mechatron* 2011;16:878–83.
- [11] Filippeschi A, Schmitz N, Miezal M, Bleser G, Ruffaldi E, Stricker D. Survey of motion tracking methods based on inertial sensors: a focus on upper limb human motion. *Sensors* 2017;17:1257.
- [12] Mansoor S, Bharti UI, Bharti AI, Ali SMD. Improved attitude determination by compensation of gyroscopic drift by use of accelerometers and magnetometers. *Measurement* 2019;131:1582–9.
- [13] Robert-Lachaine X, Mecheri H, Larue C, Plamondon A. Validation of inertial measurement units with an optoelectronic system for whole-body motion analysis. *Med Biol Eng Comput* 2017;55:609–19.
- [14] Valenti RG, Dryanovski I, Xiao J. Keeping a good attitude: a quaternion-based orientation filter for IMUs and MARGs. *Sensors* 2015;15:19302–30.
- [15] Zabat M, Ababou A, Ababou N, Dumas R. IMU-based sensor-to-segment multiple calibration for upper limb joint angle measurement—a proof of concept. *Med Biol Eng Comput* 2019;57:2449–60.
- [16] Du J, Gerdman C, Linden M. Signal quality improvement algorithms for MEMS gyroscope-based human motion analysis systems: a systematic review. *Sensors* 2018;18:1123.
- [17] Pesce V, Haydu MF, Lavagna M, Lovera M. Comparison of filtering techniques for relative attitude estimation of uncooperative space objects. *Aerosp Sci Technol* 2019;84:318–28.
- [18] Phan G-H, Hansen C, Tommasino P, Hussain A, Formica D, Campolo D. A complementary filter design on SE (3) to identify micro-motions during 3D motion tracking. *Sensors* 2020;20:5864.
- [19] Qiu S, Wang Z, Zhao H, Qin K, Li Z, Hu H. Inertial/magnetic sensors based pedestrian dead reckoning by means of multi-sensor fusion. *Inf Fusion* 2018;39:108–19.
- [20] Qiu S, Liu L, Zhao H, Wang Z, Jiang Y. MEMS inertial sensors based gait analysis for rehabilitation assessment via multi-sensor fusion. *Micromachines (Basel)* 2018; 9:442.
- [21] Barraza Madrigal J, Cantillo-Negrete J, Muñoz-Guerrero R, Contreras-Rodríguez L, Sossa H. 3D motion tracking of the shoulder joint with respect to the thorax using MARG sensors and data fusion algorithm. *Biocybern Biomed Eng* 2020;40: 1205–24.
- [22] Joukov V, Česić J, Westermann K, Marković I, Kulić D, Petrović I. Human motion estimation on Lie groups using IMU measurements. In: 2017 IEEE/RSJ international conference on intelligent robots and systems (IROS); IEEE; 2017. p. 1965–72.
- [23] Joukov V, Česić J, Westermann K, Marković I, Petrović I, Kulić D. Estimation and observability analysis of human motion on Lie groups. *IEEE Trans Cybern* 2019;50: 1321–32.
- [24] Madgwick S. An efficient orientation filter for inertial and inertial/magnetic sensor arrays. Report x-io and University of Bristol (UK). 2010;25:113–8.
- [25] Ahmed H, Tahir M. Improving the accuracy of human body orientation estimation with wearable IMU sensors. *IEEE Trans Instrum Meas* 2017;66:535–42.
- [26] Walmsley CP, Williams SA, Grisbrook T, Elliott C, Innes C, Campbell A. Measurement of upper limb range of motion using wearable sensors: a systematic review. *Sports Med Open* 2018;4:1–22.
- [27] Fahya M, Shah JA, Kadir KA, Yusof ZM, Khan S, Warsi A. Motion capture sensing techniques used in human upper limb motion: a review. *Sensor Review* 2019;39(4): 504–11. <https://doi.org/10.1108/SR-10-2018-0270>.
- [28] Miezal M, Tacta B, Bleser G. On inertial body tracking in the presence of model calibration errors. *Sensors* 2016;16:1132.
- [29] Ghasemi-Moghadam S, Homaeinezhad M. Attitude determination by combining arrays of MEMS accelerometers, gyros, and magnetometers via quaternion-based complementary filter. *Int J Numer Modell Electron Netw Devices Fields* 2018;31: e2282.
- [30] Haugen F. The good gain method for simple experimental tuning of PI controllers. 2012.
- [31] Pavlo D, Grangier D, Auli M. Quaternion: A quaternion-based recurrent model for human motion. arXiv preprint arXiv:180506485. 2018.
- [32] Yi C, Ma J, Guo H, Han J, Gao H, Jiang F, et al. Estimating three-dimensional body orientation based on an improved complementary filter for human motion tracking. *Sensors* 2018;18:3765.
- [33] Hughes N.H. Quaternion to/from Euler angle of arbitrary rotation sequence & direction cosine matrix conversion using geometric methods. 2017.
- [34] Morin E, Reid S, Stevenson J. Characterization of upper body accelerations for task performance in humans. In: Proceedings of the 25th annual international conference of the IEEE engineering in medicine and biology society (IEEE Cat No 03CH37439); IEEE; 2003. p. 1859–62.
- [35] Tadino S, Takeda R, Miyagawa H. Three dimensional gait analysis using wearable acceleration and gyro sensors based on quaternion calculations. *Sensors* 2013;13: 9321–43.
- [36] Luinge HJ, Veltink PH. Measuring orientation of human body segments using miniature gyroscopes and accelerometers. *Med Biol Eng Comput* 2005;43:273–82.
- [37] Olivares A, Górriz J, Ramírez J, Olivares G. Accurate human limb angle measurement: sensor fusion through Kalman, least mean squares and recursive least-squares adaptive filtering. *Meas Sci Technol* 2010;22:025801.
- [38] Ong ZC, Seet Y, Khoo SY, Noroozi S. Development of an economic wireless human motion analysis device for quantitative assessment of human body joint. *Measurement* 2018;115:306–15.
- [39] Picerno P, Cereatti A, Cappozzo A. A spot check for assessing static orientation consistency of inertial and magnetic sensing units. *Gait Posture* 2011;33:373–8.
- [40] Ruiz-Olaya AF, Callejas-Cuervo M, CN Lara Herrera. Wearable low-cost inertial sensor-based electrogoniometer for measuring joint range of motion. *Dyns (Medellin)* 2017;84:180–5.
- [41] Lai Y-C, Chang C-C, Tzai C-M, Huang S-C, Chiang K-W. A knowledge-based step length estimation method based on fuzzy logic and multi-sensor fusion algorithms for a pedestrian dead reckoning system. *ISPRS Int J Geoinf* 2016;5:70.

### C.3 Derechos de autor



2022. "Año de Ricardo Flores Magón"

SUBDIRECCIÓN DE VINCULACIÓN  
TECNOLÓGICA SVT/244/22

Ciudad de México, a 10 de octubre de 2022

**A quien corresponda**

Presente

En respuesta a su solicitud de registro del proyecto denominado "**Desarrollo de un brazo robótico para el estudio de los movimientos de la extremidad superior de humanos**", realizado en colaboración conjunta por el Dr. Pablo Rogelio Hernández Rodríguez, Ángel Eduardo Llanas Soto, Lauro Armando Contreras Rodríguez, y otro, tengo a bien comunicarle que parte de los resultados obtenidos se están evaluando actualmente para su registro ante el Instituto Nacional del Derecho de Autor y en breve se presentará ante dicha autoridad.

Dicho oficio se extiende a solicitud de los interesados, responsables del mencionado proyecto.

Sin otro particular por el momento, aprovecho la ocasión para enviarle un cordial saludo.

Atentamente

**Dr. José Carlos Anaya Aguas**  
Subdirector

JCAA\*paoc