

Fusión de características geométricas y señales  
electromiográficas para la identificación off-line de  
movimientos de muñeca utilizados en rehabilitación

---

Irving Herrera Luna

*Septiembre, 2019*



Universidad Veracruzana



Centro de Investigación en Inteligencia Artificial  
Maestría en Inteligencia Artificial

**Fusión de características geométricas y señales  
electromiográficas para la identificación off-line  
de movimientos de muñeca utilizados en  
rehabilitación**

TESIS

QUE PARA OBTENER EL TÍTULO DE:

**Maestro en Inteligencia Artificial**

P R E S E N T A

Irving Herrera Luna

ASESOR

Dra. Ericka Janet Rechy Ramírez

Septiembre, 2019

**Irving Herrera Luna**

*Fusión de características geométricas y señales electromiográficas para la identificación off-line de movimientos de muñeca utilizados en rehabilitación*

Septiembre, 2019

Asesor: Dra. Ericka Janet Rechy Ramírez

**Universidad Veracruzana**

Maestría en Inteligencia Artificial

Centro de Investigación en Inteligencia Artificial

Sebastián Camacho # 5

91090 and Xalapa, Ver

# Resumen

Las enfermedades cerebro vasculares tienen repercusión en distinta partes del cuerpo. Aquellas que se presentan en las extremidades superiores debido a accidentes, tienden a inhibir la movilidad o pérdida de la función del brazo y la mano dependiendo del nivel de lesión. Con el objetivo de ayudar a la rehabilitación del paciente y al experto en la administración de tareas repetitivas, se han incorporado tecnologías de asistencia y sensores en el entorno clínico, que permiten monitorear y detectar señales fisiológicas del cuerpo. Este estudio se enfoca en la fusión off-line de dos modalidades, considerando características geométricas - postura - obtenidas por el sensor Leap Motion Controller y señales electromiográficas - actividad muscular - obtenidas con el sensor Myo Armband, para identificar los movimientos de muñeca usados en rehabilitación (extensión, flexión, neutro, desviación radial y desviación ulnar). A partir de las dos modalidades, se extrajeron características geométricas para el sensor Leap y características del dominio del tiempo para el sensor Myo (cuatro características para la actividad muscular, una combinación de tres características geométricas para la postura y cuatro características que fusionan ambas modalidades). Se implementó una red neuronal para clasificar los datos y medir el desempeño mediante las métricas de especificidad, sensibilidad y exactitud. Finalmente, se encontró que la fusión de los datos, bajo la modalidad características geométricas y la característica promedio absoluto de la señal electromiográfica, mostró el mejor desempeño con un 97% en promedio de las tres métricas para el reconocimiento de movimientos de muñeca usados en rehabilitación.



# Índice general

<b>1</b>	<b>Introducción</b>	<b>1</b>
1.1	Motivación . . . . .	2
1.2	Planteamiento del problema . . . . .	3
1.2.1	Preguntas de investigación . . . . .	4
1.3	Objetivos . . . . .	4
1.3.1	Objetivo general . . . . .	4
1.3.2	Objetivos específicos . . . . .	4
1.4	Hipótesis . . . . .	5
1.5	Contribución principal . . . . .	5
1.5.1	Publicación . . . . .	6
<b>2</b>	<b>Estado del arte</b>	<b>7</b>
2.1	Categorías de los artículos en rehabilitación de manos . . . . .	9
2.2	Año de publicación y calidad de artículos . . . . .	10
2.3	Movimientos para la rehabilitación en muñeca . . . . .	11
2.4	Sensores para el monitoreo de rehabilitación en muñeca . . . . .	12
2.5	Fusión de sensores en rehabilitación de muñeca . . . . .	13
2.5.1	Etapas de la fusión de sensores . . . . .	14
2.5.2	Técnicas implementadas en la fusión de sensores . . . . .	15
<b>3</b>	<b>Metodología general de la investigación</b>	<b>17</b>
3.1	Equipo y software . . . . .	17
3.1.1	Leap motion controller . . . . .	17
3.1.2	Myo armband . . . . .	18
3.1.3	TensorFlow . . . . .	18
3.2	Identificación de movimientos de muñeca usados en rehabilitación . . . . .	19
3.3	Modalidades implementadas . . . . .	19
3.4	Etapas de implementación . . . . .	20
3.4.1	Adquisición de los datos . . . . .	21
3.4.2	Segmentación de los datos . . . . .	21
3.4.3	Extracción de las características . . . . .	21
3.4.4	Clasificación (Red neuronal artificial) . . . . .	22
3.5	Métricas de evaluación . . . . .	25
3.6	Diseño experimental . . . . .	26

<b>4</b>	<b>Modalidad basada en características geométricas</b>	<b>29</b>
4.1	Adquisición . . . . .	30
4.2	Segmentación de datos . . . . .	31
4.3	Extracción de características . . . . .	32
4.4	Clasificación . . . . .	33
4.5	Resultados . . . . .	34
<b>5</b>	<b>Modalidad basada en señales electromiográficas</b>	<b>37</b>
5.1	Adquisición de la señal . . . . .	38
5.2	Segmentación de la señal . . . . .	38
5.3	Extracción de características . . . . .	39
5.4	Clasificación . . . . .	40
5.5	Resultados . . . . .	41
<b>6</b>	<b>Fusión de las modalidades basada en señales electromiográficas y ca- racterísticas geométricas</b>	<b>47</b>
6.1	Etapas equivalentes . . . . .	47
6.2	Clasificación . . . . .	48
6.3	Resultados . . . . .	50
<b>7</b>	<b>Discusión de las modalidades</b>	<b>55</b>
7.1	Discusión para el movimiento de extensión . . . . .	57
7.2	Discusión para el movimiento de flexión . . . . .	59
7.3	Discusión para el movimiento neutro . . . . .	61
7.4	Discusión para el movimiento radial . . . . .	62
7.5	Discusión para el movimiento ulnar . . . . .	64
7.6	Discusión general . . . . .	66
<b>8</b>	<b>Conclusiones y trabajo futuro</b>	<b>69</b>
<b>A</b>	<b>Test de Edimburgo</b>	<b>71</b>
<b>B</b>	<b>Código para adquirir las características geométricas del sensor LMC</b>	<b>73</b>
<b>C</b>	<b>Código para extracción de características de la señal EMG</b>	<b>77</b>
<b>D</b>	<b>Código de RNA en Tensorflow</b>	<b>79</b>
<b>E</b>	<b>Resultados de las métricas para cada usuario</b>	<b>83</b>
	<b>Bibliografía</b>	<b>87</b>



# Introducción

” *Sólo podemos ver un poco del futuro, pero lo suficiente para darnos cuenta de que hay mucho por hacer*

— **Alan Turing**  
(Matemático)

Las lesiones debido a un accidente cerebro-vascular, suelen causar enfermedades como apoplejía, enfermedades neurológicas, síndrome de Guillain-Barré, entre otros. Por lo tanto, las personas pueden sufrir inmovilidad prevalente en ciertas partes del cuerpo, por lo cual es necesario realizar un proceso de rehabilitación para recuperar la movilidad parcial o total de la extremidad. Según [34], la rehabilitación podría definirse como “*un proceso dinámico de cambio adaptativo planificado en el estilo de vida en respuesta a un cambio no planificado impuesto al individuo por enfermedad o incidente traumático*”.

Actualmente, las investigaciones en tecnologías de asistencia y las aplicaciones de sensores, permiten monitorear y detectar señales fisiológicas del cuerpo humano. Desde una perspectiva tecnológica, según [36] y [37], los sensores pueden ser extremadamente útiles para proporcionar datos precisos y confiables sobre las actividades y comportamientos de las personas, monitoreando los parámetros fisiológicos con la ayuda de sensores para la detección de señales biológicas, movimientos corporales e inerciales.

Adicionalmente, los datos de estos sensores se pueden fusionar para obtener información precisa del cuerpo. Existen una variedad de definiciones de fusión de sensores, de acuerdo con [47] la fusión de sensores es “*un proceso que se trata de asociación, correlación y combinación de datos e información de fuentes únicas y múltiples para lograr estimaciones de identidad y posición refinadas, evaluaciones completas y oportunas*”. Según [27], las ventajas de la fusión de sensores son las siguientes: i) múltiples sensores proporcionan información redundante, en consecuencia, la incertidumbre podría reducirse y la confiabilidad podría aumentar en caso de una falla de algún sensor (sistema tolerante a fallas); ii) múltiples sensores proporcionan información complementaria, por lo tanto, se pueden obtener características del entorno utilizando múltiples sensores; y iii) múltiples sensores pueden presen-

tar información oportuna. Además, de acuerdo con [6], existen distintos esquemas de clasificación para la fusión de datos, por ejemplo, basados en: i) los tipos de datos de entrada / salida y su naturaleza, ii) el nivel de abstracción de los datos utilizados y iii) los niveles de fusión de datos establecidos. Cuando un sistema de interacción humano computadora plantea el uso de dos o más sensores, es decir, el uso de dos o más modalidades de entrada o salida paralela de computadora, se considera como una interacción multimodal [43].

En general, esta área de investigación abre un campo para explorar la fusión de sensores (fusión de datos), técnicas de procesamiento de señales digitales y técnicas para el reconocimiento de patrones. El desarrollo de esta investigación se enfoca en la fusión de señales de electromiográficas (actividad muscular) y características geométricas (postura), para la identificación off-line de movimientos de muñeca usados en rehabilitación. Cada una de las señales (actividad muscular y postura) representa una modalidad a estudiar. La finalidad de la investigación es medir el desempeño de una red neuronal a partir de las dos modalidades por separado y la fusión de ambas.

La estructura general de la tesis se constituye por ocho capítulos. En el capítulo 2 *estado del arte* se lleva a cabo una revisión de los trabajos relacionados con la fusión de sensores utilizados en aplicaciones para la rehabilitación de manos. Además, se emplearon protocolos de búsqueda y calidad para filtrar los artículos y evaluar sus cualidades. Posteriormente, el capítulo 3 *metodología general de la investigación*, presenta las etapas de la investigación, sensores utilizados, software, adquisición de las señales, pre-procesamiento de las señales, segmentación de la señal y clasificación, así como las métricas que se ocuparon para medir el desempeño de la red neuronal artificial. Los capítulos 4-6, presentan a detalle el tratamiento de las señales a través de las etapas implementadas. En el capítulo 7 se lleva a cabo una discusión de los resultados obtenidos en todas las modalidades. Finalmente, el capítulo 8 expone las conclusiones finales, así como los trabajos futuros de la investigación.

## 1.1 Motivación

Las condiciones médicas y los accidentes pueden causar inmovilidad en ciertas partes del cuerpo. Para ayudar a los pacientes en el proceso de rehabilitación; la tecnología de asistencia a través de sensores permiten obtener bio-señales del cuerpo, que a su vez se pueden fusionar para monitorear distintas partes del cuerpo. Además, se pueden crear sistemas con ambientes virtuales, con la finalidad de ayudar al especialista en un monitoreo más preciso. La motivación de este trabajo de investigación es estudiar la viabilidad de la fusión de un sensor para detectar actividad muscular

y un sensor de postura para identificar movimientos usados en rehabilitación de muñeca.

## 1.2 Planteamiento del problema

De acuerdo con la Organización Mundial de la Salud (OMS), 15 millones de personas sufren un accidente cerebro-vascular cada año, 5 millones de ellas están discapacitadas. Algunos de estos pacientes tendrán impedimentos motores [26]. El deterioro del movimiento de la muñeca es una de las lesiones con mayor frecuencia en accidentes cerebro-vascular, ya que afecta las tareas simples de la vida cotidiana, por ejemplo apretar una pelota, o sostener un objeto. En las lesiones de muñeca existe una alta probabilidad de recuperar la funcionalidad total, siempre y cuando se lleve un tratamiento adecuado. Sin embargo, existen lesiones donde quedan deterioros que limitan la funcionalidad de la muñeca. En consecuencia, cuando una lesión no es revertida, el costo y tiempo de recuperación incrementan de manera significativa. De acuerdo con datos proporcionados por el Instituto Mexicano del Seguro Social (IMSS): un 26 % de los accidentes laborales se presentan en la muñecas y en manos. El costo de la rehabilitación está relacionado con el nivel de lesión, el tipo de tratamiento, futuras complicaciones, incapacidad temporal y pensiones.

Dada la naturaleza del problema, existen diversas técnicas para rehabilitación en muñeca, los métodos más comunes son los supervisados por especialistas, que consiste en realizar series de movimientos constantes (rehabilitación tradicional). Sin embargo, estas técnicas son repetitivas y en algunos casos dolorosas, además, no existe un estímulo o retroalimentación para el paciente, en consecuencia, el paciente podría dejar la rehabilitación y presentar lesiones post-traumáticas a largo plazo.

En este estudio, nos concentraremos en la fusión off-line, de las características geométricas (postura) adquiridas por el sensor Leap Motion y las señales electromiográficas (actividad muscular) adquiridas con el sensor Myo Armband, para detectar los movimientos usados en rehabilitación de muñeca.

Las señales electromiográficas (EMG) han sido empleadas para la clasificación de movimientos o detección de gestos de manos. Sin embargo, algunas de las desventajas que puede existir para la adquisición de las señales EMG son: fatiga muscular, sudoración e impedancia eléctrica por parte del usuario; estos parámetros afectan la lectura de los electrodos.

El sensor Leap Motion Controller (LMC) también ha sido objeto de estudio para la clasificación de gestos de mano. Permite posicionar la mano desde un marco de referencia del mismo sensor, obteniendo características geométricas como ángulos y vectores, además, proporciona velocidades, aceleraciones e imágenes. Sin embargo, por ser una cámara infrarroja (IR), puede presentar errores de medidas respecto a la radiación del ambiente, por lo tanto, para obtener mediciones óptimas, es necesario estar bajo condiciones ideales de iluminación.

### 1.2.1 Preguntas de investigación

Este estudio pretende responder a preguntas que se derivan del estado del arte y del planteamiento del problema. Las preguntas de investigación son las siguientes:

- ¿Cuáles son las técnicas de investigación relacionadas con las aplicaciones en la rehabilitación de manos, utilizando la fusión de sensores?
- ¿Es posible identificar los movimientos de muñeca usados en rehabilitación, a partir de las de señales adquiridas por los sensores Leap Motion (características geométricas) y Myo Armband (señales electromiográficas)?
- A partir de los datos obtenidos por ambos sensores, ¿Es posible para una red neuronal identificar los movimientos de muñeca usados en rehabilitación?
- ¿La fusión de ambos sensores tendrá un mejor desempeño para identificar los movimientos de muñeca usados en rehabilitación?

## 1.3 Objetivos

### 1.3.1 Objetivo general

Comparar el desempeño individual y la fusión de dos modalidades, para la clasificación de movimientos de muñeca usados en rehabilitación, a partir de características geométricas (postura) y señales electromiográficas (actividad muscular).

### 1.3.2 Objetivos específicos

1. Identificar los movimientos de muñeca usados en rehabilitación a partir de características geométricas (CG) proporcionadas por el sensor Leap Motion.

2. Identificar los movimientos de muñeca usados en rehabilitación a partir de las señales electromiográficas (EMG) proporcionadas por el sensor Myo Armband.
3. Implementar una red neuronal para clasificar los datos adquiridos de ambas modalidades.
4. Analizar los resultados mediante técnicas estadísticas para ambas modalidades.

## 1.4 Hipótesis

A partir de la fusión de sensores (características geométricas y señales electromiográficas), es posible mejorar la confiabilidad y aumentar la precisión de movimientos de muñeca usados en rehabilitación (extensión, flexión, radial, ulnar y neutro) en comparación con el rendimiento de un solo sensor.

## 1.5 Contribución principal

Dada las ventajas y desventajas de ambos sensores, la contribución de la investigación es explorar el rendimiento de la fusión de las señales, a través de una red neuronal, mediante el análisis y clasificación de los datos. Las aportaciones en esta investigación son las siguientes:

- Medir el rendimiento de una red neuronal para una sola modalidad.
- Medir el rendimiento de una red neuronal para la fusión de ambas modalidades.
- Corroborar que la fusión de ambos sensores permite monitorear la postura y la actividad muscular de la muñeca, con la finalidad de obtener información redundante e inhibir las desventajas de ambos sensores.
- Comparar el desempeño de las modalidades a través de métricas estadísticas.

## 1.5.1 Publicación

Como resultado del estudio del estado del arte, se publicó una revisión sistemática titulada *sensor Fusion in Applications Rehabilitation: a Systematic Review*. [16]

- Authors: I. Herrera-Luna, E. J. Rechy-Ramirez, H. Vladimir Rios-Figueroa and A. Marin-Hernandez
- Published in: IEEE Sensors Journal (Volume:19, Issue:10, May15, 2019, Page(s): 3581 - 3592)
- Date of Publication: 1 February 2019
- INSPEC Accession Number: 18613227
- DOI: 10.1109/JSEN.2019.2897083
- JCR Impact factor 2018: 3.076

## Estado del arte

” *Hay que tomar como modelo el comportamiento humano, no un ideal del pensamiento*

— **Peter Norving**  
(Informático)

En esta investigación se realizó una búsqueda en las bases de datos IEEE Xplore, Web of Science, ACM y PubMed utilizando la siguientes combinaciones palabras: (a) sensor fusion hand rehabilitation, (b) sensor fusion wrist rehabilitation, (c) data fusion hand rehabilitation y (d) data fusion wrist rehabilitation. Esta revisión se limitó a los artículos publicados entre 2007 y 2018.

Nuestra búsqueda inicial reportó 169 artículos en total. Sin embargo, se encontró que existían artículos repetidos, por lo tanto, el protocolo PRISMA [32] se utilizó para eliminar estos artículos en nuestros resultados. Como resultado, se repitieron 67 artículos (39.64%); por lo tanto, la búsqueda inicial se redujo a 102 artículos. Además, para refinar la búsqueda, se aplicaron criterios de inclusión a los artículos filtrados. Estos criterios de inclusión fueron: (1) los artículos deben estar relacionados con la rehabilitación de la muñeca / mano y (2) los artículos deben realizar la fusión de sensores.

Inicialmente, se excluyeron 23 artículos de los 102, porque se enfocaban en temas completamente diferentes a la rehabilitación de manos usando la fusión de datos. Posteriormente, se analizaron 79 artículos para evaluar si cumplen con nuestros dos criterios de inclusión. Únicamente 29 artículos (13 en la base de datos ACM, nueve en la base de datos IEEE, cuatro en la base de datos Web of science y tres en la base de datos PubMed) cumplieron con los dos criterios de inclusión. En la Fig.2.1 se puede observar la búsqueda sistemática mediante el protocolo PRISMA.

Adicionalmente, en la Fig.2.2 se muestran los parámetros que se estudiaron para cada uno de los artículos.

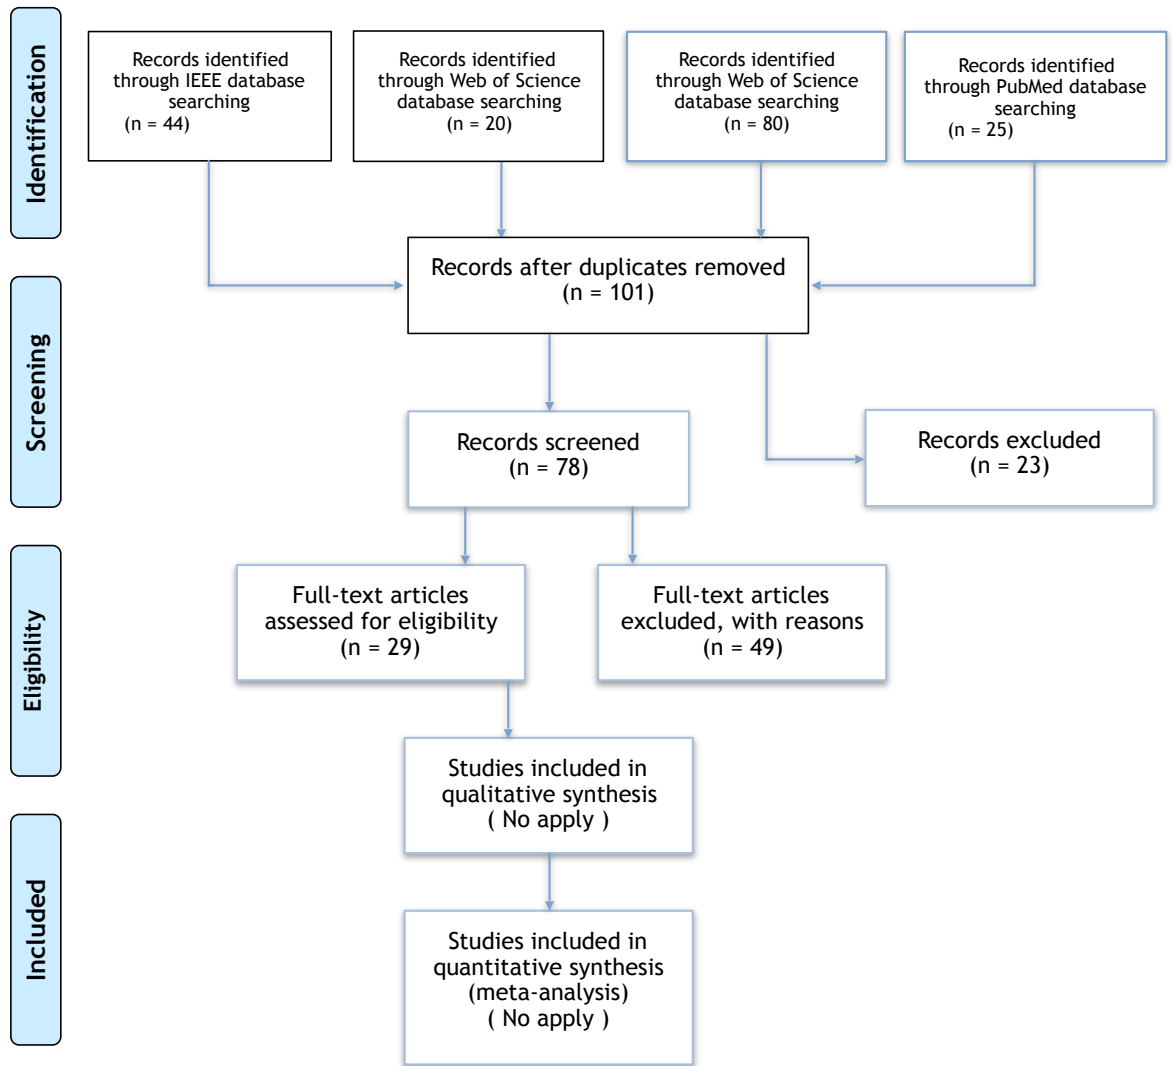


Fig. 2.1.: Secuencia del protocolo PRISMA.





Fig. 2.2.: Parámetros de estudio para los artículos de búsqueda.


## 2.1 Categorías de los artículos en rehabilitación de manos

Los artículos incluidos en esta revisión se pueden clasificar en tres categorías según sus propósitos:

- Fusión de sensores para detectar movimientos de las manos: esta categoría presenta artículos enfocados en la fusión de sensores para predecir y clasificar los movimientos de las manos utilizados en la rehabilitación.
- Fusión de sensores para aplicaciones de control de exoesqueleto: esta categoría presenta artículos enfocados en la fusión de sensores para desarrollar exoesqueletos y prótesis de extremidades superiores.
- Fusión de sensores en juegos serios para la rehabilitación de manos: esta categoría se describe la fusión de sensores para la rehabilitación de manos a través de un juego serio. De acuerdo con [52], un juego serio podría definirse como "un concurso mental, que utiliza el entrenamiento para promover la capacitación gubernamental, corporativa, educación, salud, política y comunicación estratégica". Además, los juegos serios ofrece un medio único en el que la rehabilitación puede ser proporcionada dentro de un contexto funcional, útil y motivador, donde se puede clasificar y documentar los resultados fácilmente.

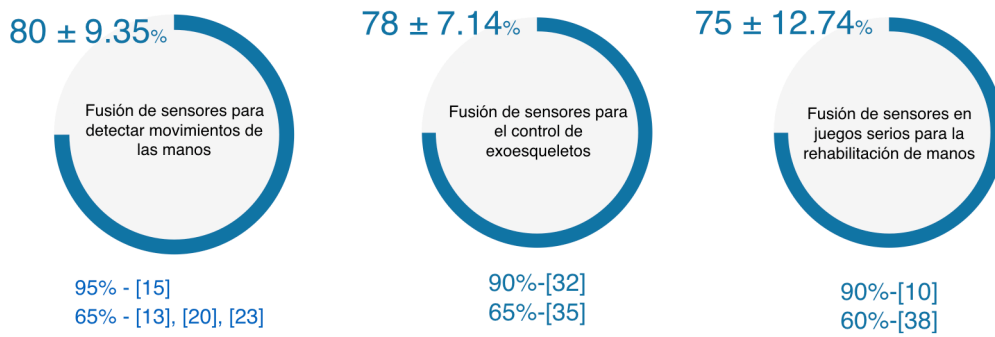
## 2.2 Año de publicación y calidad de artículos

La Fig.2.3 muestra el número de artículos publicados por año, correspondiente a cada una de las categorías. Evidentemente la categoría de “*detección y clasificación de movimientos en manos*” presenta un mayor número de artículos publicados. De los 29 artículos que cumplen con los criterios de inclusión, 16 estudios [50, 22, 25, 21, 4, 51, 8, 10, 40, 7, 45, 12, 13, 28, 4, 51] corresponden a esta categoría (55.17%). Respecto a la categoría “*control de exoesqueletos*” de los 29 artículos que cumplen con los criterios de inclusión, diez estudios [24, 38, 49, 15, 48, 41, 29, 33, 17, 46] corresponden a esta categoría (34.48%). Finalmente, la categoría de “*juegos serios para la rehabilitación en manos*” mostró solo cuatro estudios (13.8%) [50, 39, 9, 18].



**Fig. 2.3.:** Número de publicaciones por año en las tres categorías.

El estándar QualSyst [20] compuesto por 14 ítems que evalúan la metodología, el número de muestra, la descripción de las variables, los resultados y las conclusiones, se utilizó para evaluar la calidad de los 29 artículos. El resultado final de QualSyst de cada artículo se presenta en términos de porcentajes. La Fig.2.4 muestra el mayor porcentaje, el menor porcentaje y la media respecto a cada categoría.



**Fig. 2.4.:** Porcentaje obtenido del QualSyst, incluyendo el porcentaje mayor, el menor y la media para cada categoría.

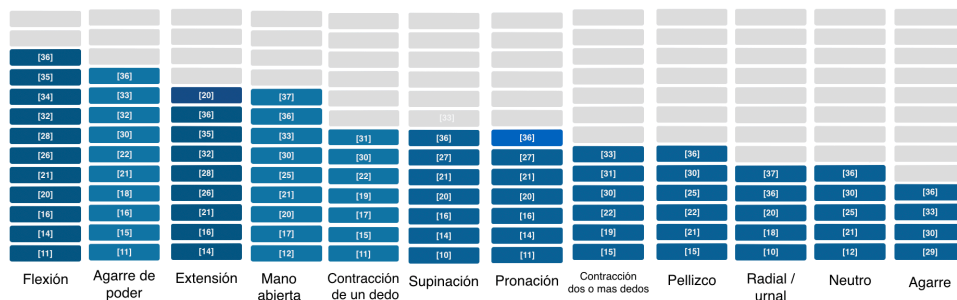
## 2.3 Movimientos para la rehabilitación en muñeca

El proceso de rehabilitación en lesiones de muñeca evalúa dos aspectos motrices, la movilidad y el esfuerzo muscular del usuario. Los movimientos de rehabilitación permiten al especialista evaluar el progreso de recuperación del usuario. Dependiendo del tipo de lesión, es conveniente realizar distintos gestos para una recuperación favorable. En primer lugar, es conveniente realizar estiramientos de la musculatura flexora y extensora de la muñeca y de los dedos, es decir en este punto es conveniente realizar movimientos como flexión, extensión, pronación, supinación, desviación radial y urnal. Posteriormente, si no existe presencia de dolor, o no ha aumentado, es el momento de empezar a ganar fuerza con bandas elásticas o una pelota de goma e incluso únicamente apretando el puño. La Fig.2.5 muestra los movimientos de muñeca usados en rehabilitación reportados en la literatura.



**Fig. 2.5.:** Movimientos para rehabilitación en manos reportados por la literatura. Imagen tomada de [16].

La Fig.2.6 presenta el número de estudios que han analizado el movimiento de mano utilizado en la rehabilitación. Es evidente que los estudios se han centrado principalmente en los movimientos de la mano de flexión y agarre de poder.



**Fig. 2.6.:** Frecuencia de estudios por movimiento de mano.

## 2.4 Sensores para el monitoreo de rehabilitación en muñeca

La actividad muscular se puede evaluar utilizando señales electromiográficas (EMG) que mide la actividad muscular, sensores de miografía de fuerza (FMG) y sensores hápticos. En términos de EMG: Existen sensores como Myo Armband, BiTalino y MyoWare que obtienen la señal EMG del usuario. Por ejemplo, el brazalete Myo es un brazalete compuesto por ocho sensores EMG, que se coloca en el antebrazo del usuario. El brazalete Myo se ha utilizado en las siguientes aplicaciones: i) control de imágenes médicas y entornos domésticos inteligentes, y ii) navegación en entornos virtuales [42]. Otro sensor utilizado en la rehabilitación de muñeca es BiTalino, que consta de una placa con sensores para detectar actividad de electrocardiografía (ECG), señales electromiográficas (EMG), señales electrodérmicas (EDA) y señales electroencefalográficas (EEG).

Los sensores hápticos como Omega 7 pueden integrarse para realizar tareas de forma bimanual, con siete grados de libertad. Este sensor se ha utilizado para una terapia de rehabilitación bilateral del brazo [50]. Por otro lado, la posición de la extremidad del usuario puede evaluarse principalmente utilizando cámaras, acelerómetros y giroscopios. Específicamente, las cámaras (por ejemplo, el controlador de movimiento Kinect y Leap Motion) se han utilizado ampliamente en la rehabilitación de manos. El sensor Kinect es un dispositivo capaz de capturar, reconocer y posicionar el esqueleto humano. Algunas aplicaciones del sensor Kinect se pueden encontrar en las siguientes revisiones: [21, 40, 18].

Por otra parte, el sensor Leap Motion es un dispositivo compuesto por tres leds infrarrojos y dos cámaras infrarrojas, que son capaces de identificar y rastrear los movimientos de las manos y los dedos. Leap se ha empleado en las siguientes aplicaciones: i) reconocimiento del lenguaje de señas, ii) control de imágenes médicas, iii) tele-operación de robots, iv) control de entornos virtuales, v) rehabilitación [42].

Otros sensores usados en rehabilitación de manos son los acelerómetros, que se utilizan para medir la aceleración a lo largo de un eje sensible y en un rango particular de frecuencias, para medir la orientación de la postura del usuario [36]. Además, la combinación de acelerómetros, giroscopios y magnetómetros aumenta la confiabilidad del cálculo de la cinemática del movimiento [5].

Por otro lado, otros trabajos han analizado la fuerza y la posición de la rehabilitación de la extremidad en la mano del usuario mediante el uso de guantes. Por

ejemplo, [19, 2] utilizaron guantes que combinan sensores de flexión, acelerómetros y sensores de fuerza.

## 2.5 Fusión de sensores en rehabilitación de muñeca

La fusión de sensores es el acto de combinar los datos adquiridos de dos o más fuentes de sensores, la combinación resultante de información proporciona una descripción más segura de los factores observados por los sensores separados, en comparación de observar la información adquirida de un solo sensor [11]. La fusión de sensores existe en muchas aplicaciones para inferencia y control. Entre los ejemplos de aplicaciones incluyen: sistemas inteligentes, sistemas automatizados, sistemas de asistencia médica, sistemas para automóviles, entre otros. Los beneficios de la fusión de sensores sobre una fuente única se observan en la Fig.2.7.



**Fig. 2.7.:** Beneficios de la fusión de sensores

La literatura menciona que se han fusionado los datos de los sensores utilizando la siguiente combinación de sensores para la rehabilitación de manos: i) EMG y dispositivo táctil [7]; ii) EMG y acelerómetros [12, 28]; iii) EMG y FMG [8]; iv) cámaras infrarrojas y dispositivos hápticos [50]; v) cámara infrarroja y sensores de luz [13]; vi) sensor de luz y acelerómetros [4]; vii) fuerza y acelerómetros [10]; viii) EMG y dielectric elastometer [22]; ix) magnetómetros con sensores de inercia [21]; x) dos IMU [35]; xi) sistema de sensores de EMG [3, 15]; xii) sensores de EMG y sensores IR [17]; xiii) EMG e IMU [29]; xiv) se integraron EMG, torque y sensores angulares [46]; xv) sensor de inercia y sensor de mecanografía (MMG)


[48]; xvi) sensores de EMG y Oculus Rift [39]; xvii) Leap y Omega 7 [50]; xviii) Leap, Oculus rift y multi-fragrance olfactory (MFOD) [9] y xiv) Kinect, sensor de fuerza y un IMU [18].

## 2.5.1 Etapas de la fusión de sensores

De acuerdo con [6], la fusión de sensores se puede producir en distintos niveles de abstracción: Esta revisión del estado del arte sigue el esquema basado en los niveles de abstracción de los datos, es decir, la fusión de datos se podría realizar en tres niveles de abstracción:

1. Mediciones (M): se presenta en la entrada de la fusión de datos, son los datos sin procesar o datos en bruto.
2. Extracción de características (E): extracción de información clave de los datos del nivel anterior u otras características calculadas.
3. Decisión / Clasificación (D): la fusión de características para obtener decisiones a través de algoritmos de clasificación.

La Fig.2.8 ilustra el nivel de abstracción en la que cada autor fusionó sus datos.



**Fig. 2.8.:** Etapa de fusión de sensores basado en los niveles de abstracción de los datos y sensores fusionados. (M) mediciones, (E) extracción de características y (C) decisión / clasificación.

Por otra parte, el nivel de *decisión* donde se realizó la fusión, resultó ser el más utilizado por los trabajos con un 48.2% (14 artículos), seguido por el nivel de *mediciones* con un 27.5% (8 artículos). Finalmente, el menor nivel para realizar la fusión de sensores en la literatura fue la *extracción de características* con 24.1% (7 artículos). La Fig.2.9 muestra la frecuencia de los niveles de fusión de sensores por cada categoría.




Fig. 2.9.: Porcentaje de niveles de fusión por cada categoría.

## 2.5.2 Técnicas implementadas en la fusión de sensores

En esta sección nos referimos a la *técnica* como los métodos o algoritmos encontrados en nuestra búsqueda sistemática.

Se encontraron técnicas tradicionales de aprendizaje automático (por ejemplo, Máquinas de vectores de soporte (SVM), discretionales lineales, vecinos más cercanos (K-NN), redes neuronales (ANN), árboles de decisión, regresión lineal, Guillin Hills, Naive Bayes (NB) y discriminante de mínimos cuadrados parciales (PLSD) [22, 3, 35, 10, 10, 7, 12, 13, 51, 15, 48, 29, 33, 17]. El resto de los trabajos desarrollaron otros algoritmos, por ejemplo: registro de conjunto de puntos, modelo de dedos proxy, minería de datos, algoritmo de Madgwick y cinemática en movimientos de exoesqueletos.

La técnica con mayor frecuencia fueron las máquinas de soporte vectorial (SVM) con un 17.2% (cinco artículos), seguido de las redes neuronales con un 10.3% (3 artículos).





# Metodología general de la investigación

” *Las leyes del pensamiento no solo dependen de las propiedades de las células cerebrales, sino del modo en que están conectadas*


— **Marvin Minsky**  
(Informático)

Este capítulo describe la metodología general a emplear durante el trabajo de investigación. Se describe una justificación de los métodos a desarrollar y las etapas de la investigación. Además, se especifica cada una de las modalidades empleadas. Finalmente, se describe el diseño experimental.

## 3.1 Equipo y software

### 3.1.1 Leap motion controller

El sensor Leap Motion Controller (LMC) es un dispositivo compuesto por tres leds infrarrojos y dos cámaras infrarrojas. LMC se puede clasificar como un sistema de seguimiento óptico basado en el principio de visión estéreo. Según la información oficial ([www.developer.leapmotion.com](http://www.developer.leapmotion.com)), el software analiza los objetos observados en el campo de visión del dispositivo. LMC reconoce las manos, los dedos, gestos y movimientos discretos reportando las posiciones. El alcance efectivo del LMC se extiende desde aproximadamente 25 a 600 milímetros por encima del dispositivo, proporciona un campo de visión de 150° con aproximadamente ocho pies cúbicos de espacio interactivo 3D. LMC se programa a través de las interfaces de programación de aplicaciones (API), con soporte para una variedad de lenguajes de programación, desde C++, Python, C# y Java. Además tiene soporte para motores de juego como Unity y Unreal. Las posiciones de los objetos reconocidos se adquieren a través de estas API. Sin embargo, debe tenerse en cuenta que la frecuencia de muestreo no es estable, no se puede configurar y varía significativamente. La Fig.3.1 se muestra el sensor Leap con su sistema de coordenadas.



**Fig. 3.1.:** Sistema de coordenadas del sensor Leap motion para describir las posiciones de las manos en el espacio.

### 3.1.2 Myo armband

El brazalete Myo Armband (Myo) es un dispositivo portátil inalámbrico desarrollado por Thalmic Labs, capaz de grabar señales electromiográficas (EMG) a través de ocho electrodos superficiales. Además, cuenta con un sensor de unidad de medida inercial (IMU) de nueve ejes, retroalimentación háptica y comunicación Bluetooth ([www.myo.com/techspecs](http://www.myo.com/techspecs)). La principal desventaja de Myo es su frecuencia de muestreo limitada de 200Hz, mientras que las señales EMG tienen una frecuencia de muestreo de 20Hz-400Hz. Myo se programa a través de las interfaces de programación de aplicaciones (SDK), con soporte para una variedad de lenguajes de programación, desde C++, Python y C#. Además tiene soporte para motores de juego como Unity. La Fig.3.2 muestra el sensor Myo con sus electrodos categorizados.

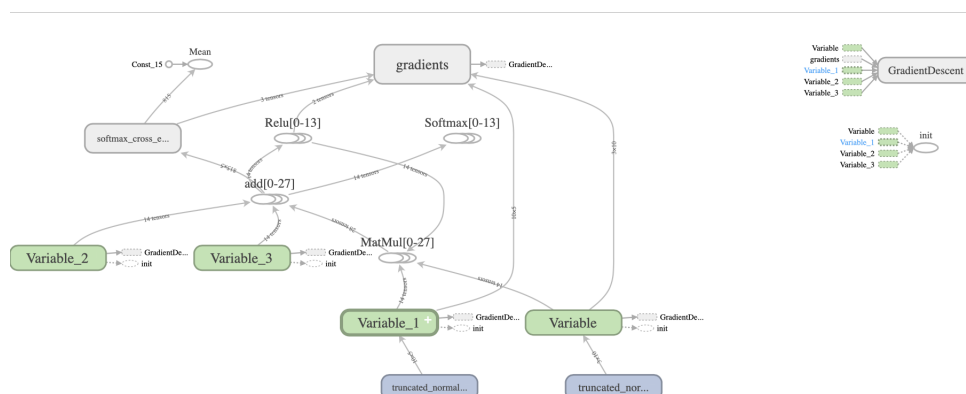


**Fig. 3.2.:** Sensor Myo armband con sus electrodos categorizados.

### 3.1.3 TensorFlow

TensorFlow es una biblioteca de software libre que se utiliza para realizar cálculos numéricos mediante diagramas de flujo de datos, enfocado en el aprendizaje máquina. Los nodos de los diagramas representan operaciones matemáticas y las aristas reflejan las matrices de datos multidimensionales (tensores) conectadas entre ellas. La Fig3.3 ilustra un grafo de una red neuronal en TensorFlow. Además solo se re-


quiere de un API para desplegar el sistema en una o varias CPU o GPU. Cuenta con soporte en Windows, MacOS, Linux, Raspberry Pi. El desarrollo de esta API se puede usar en Python, C, Java, Swift y Go [1].



**Fig. 3.3.:** Diagrama del flujo de datos de una red neuronal en TensorFlow.

## 3.2 Identificación de movimientos de muñeca usados en rehabilitación

En esta investigación se identificaron cinco movimientos usados en rehabilitación de muñeca: Extensión, flexión, radial, ulnar y neutro (Fig. 3.4). De acuerdo con [16], los movimientos de flexión y extensión, se encuentran dentro de los más analizados en los trabajos de rehabilitación, mientras que los movimientos de radial, ulnar y neutro son los menos frecuentes de acuerdo con los autores.



**Fig. 3.4.:** Movimientos de manos usados en rehabilitación en esta investigación.

## 3.3 Modalidades implementadas

El objetivo de la investigación es evaluar el desempeño de los sensores. Cada sensor representa una modalidad, además, cada modalidad contiene sus propias características. A continuación se describen las modalidades y la fusión entre ellas. La Fig.3.5 ilustra las modalidades empleadas y la fusión de ellas, a partir de sus características.

- Modalidad basada en características geométricas (CG): Estudiar el desempeño de la clasificación de los datos adquiridos por LMC. Dado que LMC es una cámara, es posible obtener las imágenes para realizar la identificación de movimientos. Sin embargo, el costo computacional del procesamiento de imágenes es más elevado que procesar arreglos geométricos. Por lo tanto, se optó por estudiar características como ángulos y vectores para la identificación de los movimientos.
- Modalidad basada en señales electromiográficas (EMG): Estudia el desempeño de la clasificación de los datos adquiridos por el sensor Myo. Se estudiaron características del dominio del tiempo: *i*) Mean Absolute Value (MAV), Root Mean Square (RMS), Variance (VAR) y Wavelength (WL).
- Fusión de las modalidades: Estudia el desempeño de la clasificación de los datos de ambas modalidades. Considerando las siguiente combinación de características: CG-MAV, CG-VAR, CG-RMS y CG-WL.

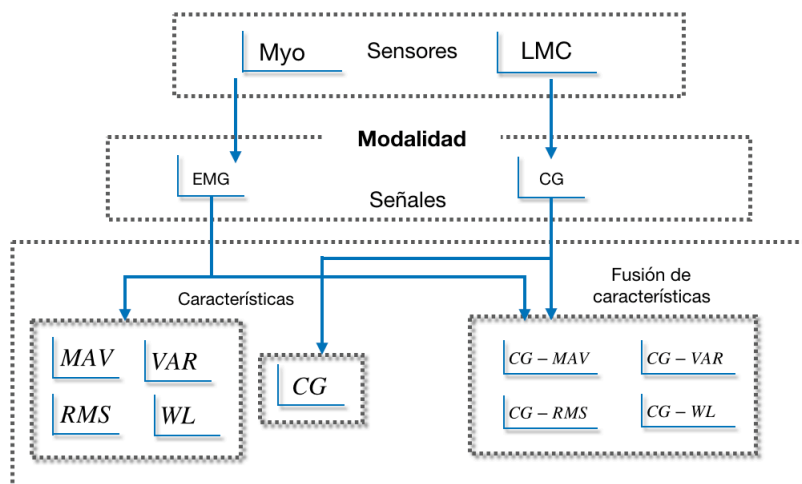


Fig. 3.5.: Modalidades implementadas en la investigación.

### 3.4 Etapas de implementación

En esta sección se describen las etapas para el tratamiento de las señales adquiridas a partir de ambos sensores, desde la adquisición de datos, segmentación, extracción de características, clasificación de los datos y finalmente el análisis de los datos mediante técnicas estadísticas.

### 3.4.1 Adquisición de los datos

En esta etapa se realiza la adquisición de registros del usuario. Consiste en grabar un conjunto de datos de señales EMG y señales CG, a partir de la ejecución de los movimientos de rehabilitación de muñeca durante un tiempo determinado. Además, se requiere de una etapa de acondicionamiento de las señales, que adecua la señal a niveles compatibles para su procesamiento digital.

### 3.4.2 Segmentación de los datos

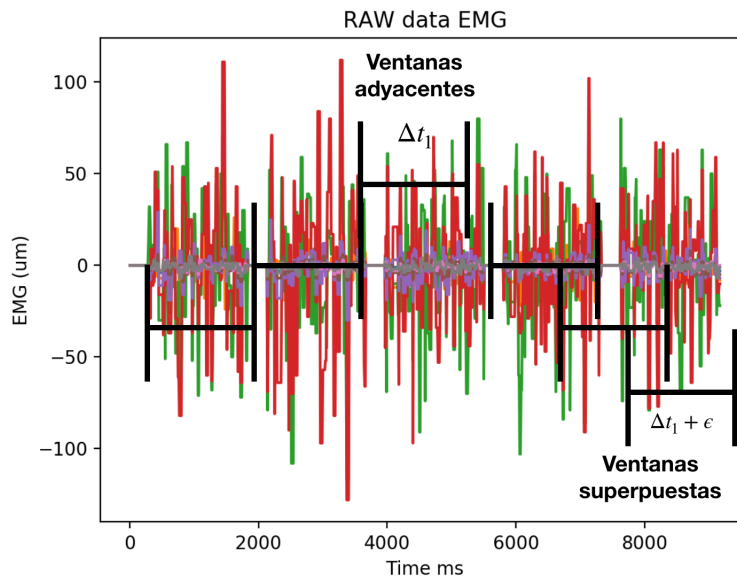
De acuerdo con [14], un segmento es un intervalo de tiempo para adquirir datos de una señal. Además, debido a restricciones de tiempo real, un segmento de ventana, más el tiempo de procesamiento de la señal debe ser menor o igual  $300ms$ . Además los autores mencionan que para la extracción de características, ventanas entre  $126ms$  y  $250ms$  consideran las limitaciones de un retardo aceptable, incluyendo la velocidad de procesamiento.

Existen dos técnicas principales en la segmentación de datos: ventanas adyacentes y ventanas superpuestas. En las ventanas adyacentes, como se muestra en la Fig.3.6 para una señal EMG, los segmentos están separados con una longitud predefinida  $\Delta t$ . Esta técnica trabaja con el supuesto que la extracción de características puede llevarse a cabo mientras que el nuevo segmento es adquirido. Mientras que las ventanas superpuestas consideran que el nuevo segmento se desliza sobre el segmento actual con un tiempo de incremento  $\epsilon$  menor que la longitud del segmento.  $\epsilon$  debe ser mayor que el tiempo de procesamiento, debido a que el procesador debe calcular el conjunto de características y generar una decisión antes de que el siguiente segmento llegue. Sin embargo, se ha demostrado que los segmentos superpuestos sólo aumentan el tiempo de procesamiento, sin proporcionar una mejora significativa en la precisión de funciones de tiempo-frecuencia [14].

Una vez analizadas las características de los tipos de ventanas, esta investigación se consideró aplicar una segmentación adyacente de  $250ms$  a cada registro de los usuarios.

### 3.4.3 Extracción de las características

En esta etapa se consideran las características que pueden aportar información crucial en el proceso de clasificación de los datos. En esta investigación se utilizarán características geométricas en la modalidad basada en LMC y características del dominio de tiempo para señales EMG en la modalidad basada en Myo.



**Fig. 3.6.:** Registro de una señal EMG, segmentada en ventanas adyacentes y superpuestas.

Basado en la modalidad de señales CG; se evalúan tres características geométricas, en función de ángulos y la dirección de vectores. Estos parámetros geométricos pertenecen a los movimientos generados por la muñeca.

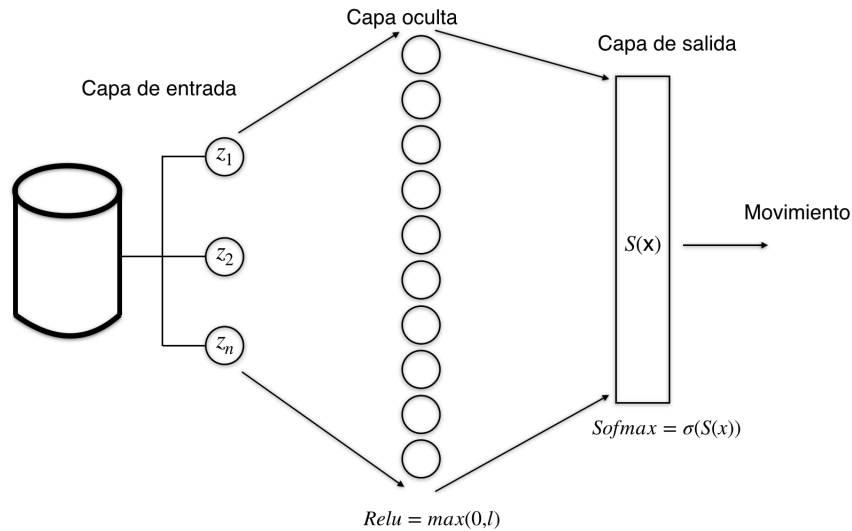
Por otra parte, para la modalidad basada en Myo, se utilizarán características del dominio de tiempo para señales EMG. Debido a su simplicidad computacional, este tipo de características son las más populares en la clasificación de señales EMG y se basan en la amplitud de la señal. De acuerdo con [14], las características del dominio del tiempo más usadas para señales EMG son: Mean Absolute Value (*MAV*), Root Mean Square (*RMS*), Variance (*VAR*) y wavelenght (*WL*). Estas características serán empleadas para la extracción de patrones a partir de los registros de cada usuario.

### 3.4.4 Clasificación (Red neuronal artificial)

Las características extraídas deben clasificarse en clases distintivas para el reconocimiento de los movimiento deseados. Debido a la naturaleza de los datos (EMG y geométricas), es razonable esperar una gran variación en el valor de una característica en particular. Además, existen factores externos por parte del sensor Myo como la posición variable del electrodo, fatiga muscular, sudoración e impedancia eléctrica. Por parte del sensor LMC las variables pueden ser la iluminación externa y desfase en la posición de los puntos del esqueleto de la mano. Estas variables pueden causar cambios en un patrón de señal a lo largo del tiempo. En esta investigación se desarrolló una red neuronal artificial (RNA). La ventaja de RNA es su

capacidad para representar relaciones tanto lineales como no lineales, aprendiendo esas relaciones directamente de los datos que se están modelando [14].

El modelo de RNA implementada en esta investigación se desarrolló en Python 2.7, con la API TensorFlow (V 2.0). La red contiene un total de tres capas: *i*) la capa de entrada contiene el número de características de la base de datos respecto a cada modalidad; *ii*) la capa oculta contiene diez neuronas y *iii*) la capa de salida se define mediante una función de probabilidad para datos multiclase. (Fig.3.7).




**Fig. 3.7.:** Estructura general de la red neuronal.

El vector de entradas  $z_n$  corresponde al vector de características por cada modalidad. Sea  $w_{ij}$  una matriz con el conjunto de pesos generados de manera aleatoria. Posteriormente se realiza el producto punto de los pesos y las entradas mediante  $l = \sum z_n w_{ij} + b_1$ , donde  $b_1$  es valor del bias.

La función de activación para la capa oculta es ReLU (Rectified Linear Unit)  $f(x) = \max(0, x)$ . De acuerdo con [23], una forma en que la función ReLU mejora una red neuronal, es acelerando el entrenamiento. El cálculo del gradiente es 0 ó 1 dependiendo del signo de  $l$ , observe la Fig.3.8. Además, ReLU toma cualquier elemento negativo y lo establece en 0 - sin operaciones matemáticas -. Los gradientes de las redes con funciones de activaciones logísticas e hiperbólicas son más pequeños que la parte positiva de la ReLU; esto significa que la parte positiva se actualiza más rápidamente a medida que avanza el entrenamiento. Sin embargo, esto tiene un costo, el gradiente en el lado izquierdo presenta un problema llamado "neuronas muertas", en el que una actualización de gradiente establece los valores entrantes en una ReLU, de modo que la salida siempre es cero.

Por lo tanto el valor de activación de la capa oculta está dado por la ecuación 3.1:



**Fig. 3.8.:** Función ReLu y función Softmax

$$x = f(l) = \max(0, l) \quad (3.1)$$

De acuerdo con [14], el modelo de Regresión logística se puede generalizar para admitir múltiples clases directamente, sin tener que entrenar y combinar múltiples clasificadores binarios. Esto se denomina regresión de Softmax o regresión logística multinomial. Considere la segunda capa de transición del modelo de la red neuronal de Fig.3.7; cuando se tiene una instancia  $x$ , el modelo de regresión de softmax calcula una puntuación  $S_k(x)$  para cada clase  $k$  -gestos a reconocer-, luego estima la probabilidad de cada clase aplicando la función softmax (también llamada exponencial normalizado) al vector  $S_k(x)$ . Una vez que se haya calculado la puntuación de cada clase para la instancia  $x$ , se puede estimar la probabilidad  $\hat{P}_k$  de que la instancia pertenece a la clase  $k$  ejecutando las puntuaciones a través de la función softmax, calculando la exponencial de cada puntuación (ecuación 3.2)

$$\hat{P}_k = \sigma(s(x))_k = \frac{\exp(s_k(x))}{\sum_{j=1}^k (\exp(s_j(x)))} = \frac{e^{\Theta}}{\sum_{j=1}^k e^{\Theta}} \quad (3.2)$$

Finalmente, el clasificador de regresión softmax predice la clase con la probabilidad más alta (clase con la puntuación más alta), como se muestra en la ecuación 3.3.

$$\hat{y} = \operatorname{argmax}(\hat{P}_k) \quad (3.3)$$



El objetivo es tener un modelo que estime una probabilidad alta para la clase gesto. En consecuencia, el objetivo es minimizar la función de costo. Para la estructura de nuestra RNA aplicamos entropía cruzada. Esta función se usa frecuentemente para medir qué tan bien un conjunto de probabilidades de clase estimadas coinciden con las clases objetivo [14], es decir, ¿Qué tan cerca está la distribución predicha de la distribución real?. La función de entropía cruzada está dada por la ecuación 3.4.

$$\mathbf{J}(\Theta) = -\frac{1}{m} \sum_{i=1}^m \sum_{k=1}^k y_k^{(i)} \log(\hat{P}_k^{(i)}) \quad (3.4)$$

De donde  $y_k^{(i)}$  es la probabilidad objetivo de que la instancia  $i$  pertenezca a la clase  $k$ . En general,  $y_k$  es igual a 1 ó 0, dependiendo de si la instancia pertenece a la clase o no.  $m$  es el número de instancias.

La entropía cruzada es una de las muchas funciones de pérdida posibles. Esta función de pérdida se pueden usar dentro del descenso de gradiente, que es un marco iterativo para mover los parámetros (o coeficientes) hacia los valores óptimos de la RNA ( ecuación 3.5). El código de la RNA se encuentra en el apéndice D

$$\Theta \leftarrow \Theta - \lambda \frac{\partial}{\partial \Theta} \mathbf{J}(\Theta) \quad (3.5)$$

## 3.5 Métricas de evaluación

A partir de los valores positivos y negativos dados por un clasificador, es posible evaluar el desempeño mediante el uso de métricas. Existen distintas métricas que se pueden usar para medir el rendimiento de un clasificador, además, existen preferencias para métricas específicas debido a diferentes objetivos. Por ejemplo, en medicina a menudo se usan la sensibilidad y la especificidad, mientras que en ciencia de la computación se prefiere la exactitud (accuracy).

Para evaluar las modalidades de acuerdo al desempeño de la salida de la RNA, se calcula la matriz de confusión para determinar el número de verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN) respecto a cada movimiento [30]. Estos valores permiten calcular las siguientes métricas:

- Sensibilidad (Sensitivity) : Mide la proporción de valores positivos reales que se identifican correctamente.

- Especificidad (Specificity): Mide la proporción de negativos reales que se identifican correctamente.
- Exactitud (Accuracy): Mide la proporción de resultados verdaderos (tanto positivos verdaderos como negativos verdaderos) entre el número total de casos.

Las fórmulas para calcular estas métricas a partir de los valores de la matriz de confusión son las siguientes:

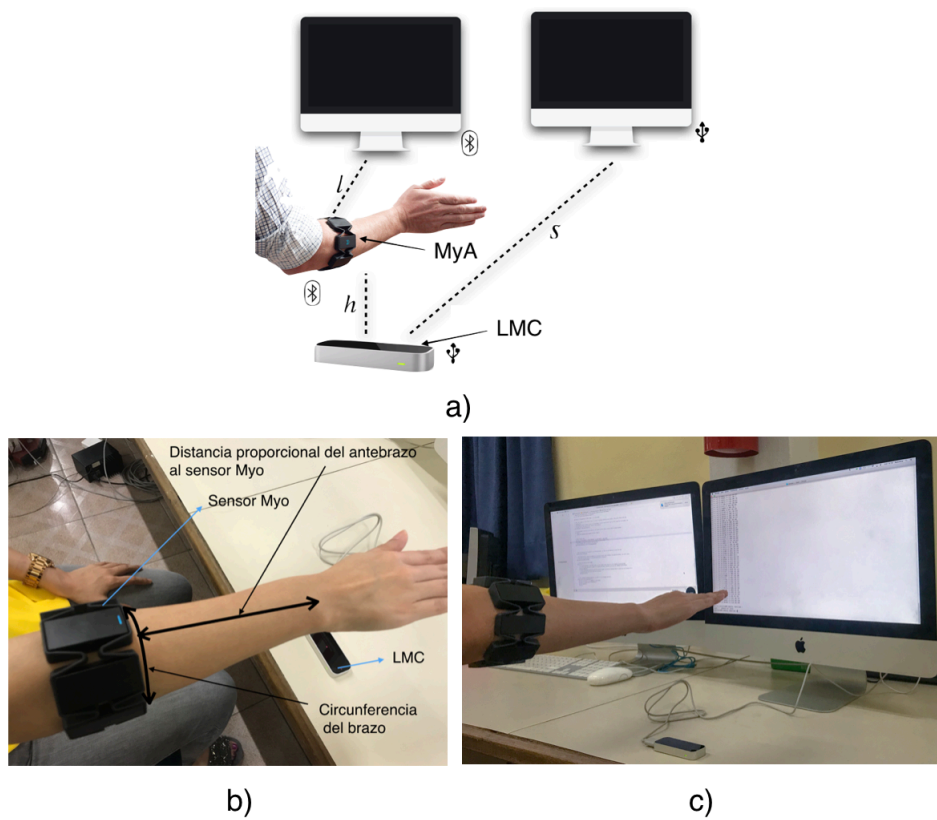
- Sensibilidad (Sensitivity):  $\frac{TP}{TP+FN}$
- Especificidad (Specificity):  $\frac{TN}{TN+FP}$
- Exactitud (Accuracy):  $\frac{TN+TP}{TN+FP+TP+FN}$

### 3.6 Diseño experimental

El equipo para la adquisición de registros fueron dos computadoras iMac modelo 2015, cada uno con un procesador Intel Core i5 de cuatro núcleos a 2.5 GHz. La Fig.3.9 ilustra la posición de la mano respecto al sensor LMC, se consideró a una distancia  $15\text{cm} < h < 30\text{cm}$ , se conecta a la computadora mediante USB a una distancia  $s$  (distancia del cable USB). El sensor Myo está colocado a una distancia del 70% de la muñeca al codo, además, se midió la circunferencia del antebrazo de cada usuario ( $26.65\text{cm} \pm 3.11\text{cm}$ ). Dado que Myo es un sensor de conectividad Bluetooth, la distancia de Myo a la computadora no fue mayor a  $1\text{m}$ . Para inicializar la adquisición de datos se realizó de manera manual en cada computadora.

Se registraron 13 usuarios (ocho hombres y cinco mujeres), con una edad promedio de  $28.23 \pm 3.66$  años. Cada usuario respondió el test de Edimburg (Apéndice A) que evalúa la lateralidad del usuario para determinar la mano dominante.

Cada movimiento tiene un tiempo de registro de dos segundos, se le pidió al usuario que por cada movimiento realizara cinco repeticiones, teniendo un total de 25 registros por usuario.



**Fig. 3.9.:** a) Diagrama general del desarrollo experimental. b) Posición del Myo a un 70% de distancia entre la muñeca y el codo, además se midió la circunferencia del antebrazo respecto a la posición del Myo. c) Diseño experimental montado.



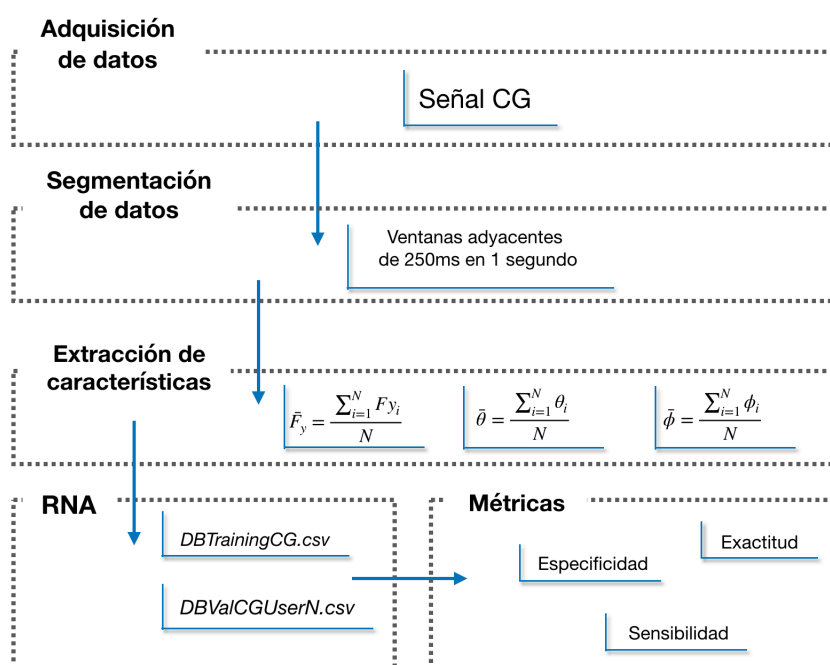
## Modalidad basada en características geométricas

” *El mundo es un problema de datos*

— Andrew McAfee  
(Ingeniero)

Este capítulo describe el proceso del tratamiento en la modalidad basada en características geométricas (CG). Muestra una descripción de las etapas de implementación en la investigación como la adquisición de los datos, segmentación de los datos, extracción de características, clasificación y resultados.

La Fig.4.1 muestra una descripción de las etapas de implementación para la modalidad de características geométricas.



**Fig. 4.1.:** Diagrama de las etapas de implementación para la modalidad de características geométricas (CG).

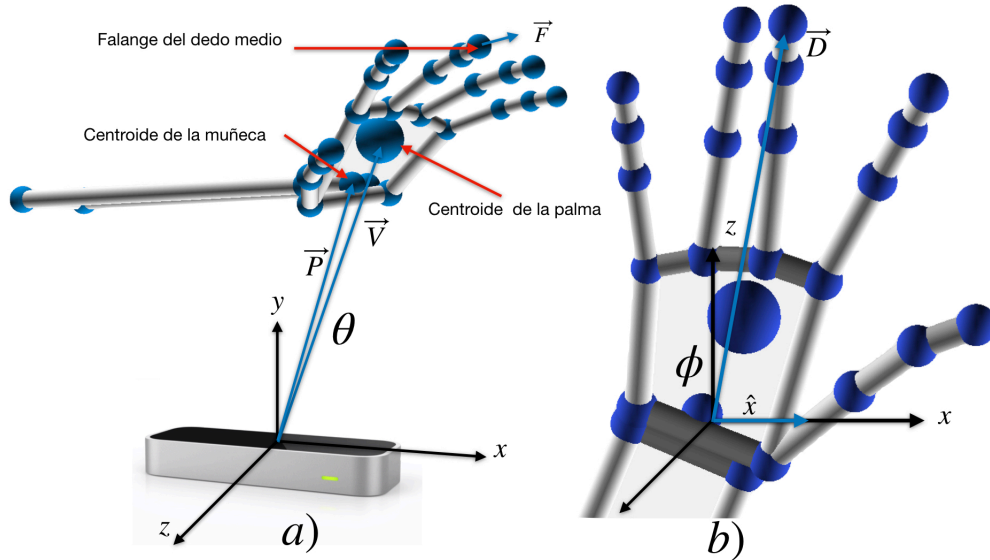
## 4.1 Adquisición

El sensor LMC es capaz de mapear el esqueleto del brazo a un sistema 3D a una tasa de muestreo de 400 FPS, además, permite localizar las falanges de la mano (articulaciones de la mano) como puntos en el espacio. Para el interés de la investigación, se enfocó en localizar los puntos del centroide de la palma ( $\vec{P}$ ), centroide de la muñeca ( $\vec{V}$ ) y la dirección de la mano en su componente ( $\vec{F}_y$ ). El objetivo es identificar qué características geométricas aportan información para la identificación de los gestos usados en rehabilitación para la investigación. Las siguientes condiciones muestran los parámetros para reconocer los movimientos mediante los vectores identificados:

1. Movimientos de extensión y flexión: Se calculó el ángulo que existe entre el vector posición de la muñeca  $\vec{P}$  y el vector posición de la palma  $\vec{V}$ . Se considera que el ángulo para una flexión total es  $80^\circ$ , mientras que para una extensión total es  $70^\circ$  [44]. Sin embargo, para una rehabilitación, los movimientos se realizan de manera gradual. Se consideró que para detectar cualquier gesto sea flexión o extensión, el ángulo  $\theta$  entre los dos vectores debe ser menor a  $12^\circ$ . Dada la condición, se asegura que, si el ángulo de los vectores es muy pequeño: entonces es posible que se esté realizando algún movimiento. Para determinar el tipo de movimiento, el vector dirección de la mano  $\vec{F}_y$  - vector resultante de la suma vectorial de la dirección de cada dedo -, determina si el movimiento es flexión o extensión, verificando el sentido del elemento  $F_y$ , esto es; si  $F_y > 0$  entonces, el movimiento es extensión, si  $F_y < 0$  entonces, el movimiento es flexión.
2. Movimientos radial y ulnar: Se realizó una transformación del sistema de referencia, colocando el origen en el centroide de la muñeca. Para identificar los gestos, se propuso un vector  $\vec{D}$  con dirección a la punta de la mano, además, se caracteriza el vector unitario  $\hat{x}$ . A partir de estos vectores, se considera que el ángulo ( $\phi$ ) para un movimiento radial debe ser menor a  $75^\circ$ , mientras que para un movimiento ulnar, el ángulo ( $\phi$ ) debe ser mayor a  $120^\circ$  de acuerdo con [44].
3. Movimiento neutro o reposo: Ninguna de las condiciones anteriores se debe cumplir. Es decir, no deberá de existir un rango de movimiento mayor al establecido por las condiciones.

La Fig.4.2 muestra los ángulos y vectores para la identificación de los movimientos respecto al sistema de referencia por el sensor LMC. La tabla 4.1 muestra las condiciones de las CG para la identificación de cada movimiento. Finalmente, para

adquirir estas señales se utilizó el SKD proporcionado por LMC, bajo el lenguaje de programación C++. El código para la adquisición de la señal CG se puede consultar en el apéndice B.



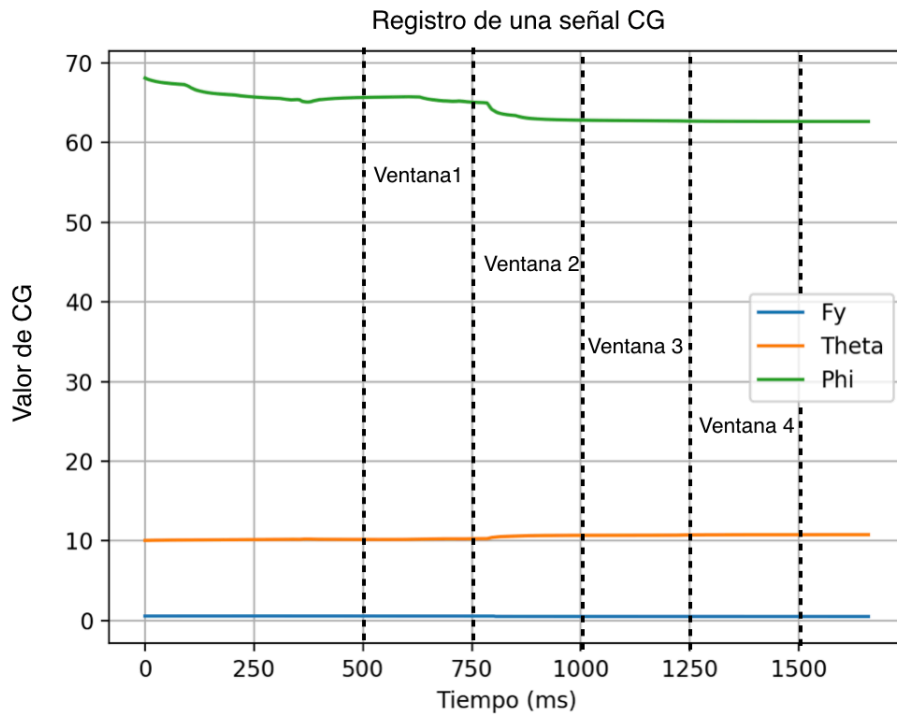
**Fig. 4.2.:** a) Identificación del ángulo  $\theta$  y el vector  $\vec{F}_y$  para el reconocimiento de los movimientos de extensión y flexión. b) Identificación del ángulo  $\phi$  para el reconocimiento de los movimientos radial y ulnar.

Movimiento	Características geométricas
Extensión	$\theta < 12^\circ \wedge F_y$
Flexión	$\theta < 12^\circ \wedge -F_y$
Ulnar	$\phi > 120^\circ$
Radial	$\phi < 75^\circ$
Neutro	$\theta > 12^\circ \wedge 75 < \phi < 120$

**Tab. 4.1.:** Características geométricas correspondientes a cada movimiento.

## 4.2 Segmentación de datos

Debido a que las señales fisiológicas se caracterizan por eventos o cambios dinámicos en función del tiempo, aplicamos segmentación de ventanas adyacentes en un intervalo de  $250ms$ . Consideramos un tiempo  $t = 1s$  para generar cuatro ventanas del mismo intervalo. La Fig.4.3 muestra un registro de las señales CG en un intervalo de tiempo, se considera el segundo entre los  $500ms - 1500ms$  para generar las ventanas y posteriormente extraer características del dominio del tiempo.



**Fig. 4.3.:** Registro de una señal CG segmentada mediante ventanas adyacentes de  $250ms$  en un intervalo entre  $500ms - 1500ms$ .

### 4.3 Extracción de características

Para cada una de las ventanas se calcula el promedio de cada valor de la señal CG, es decir, para cada ventana existe un único valor de cada componente de la señal.

Frames por ventana	$F_y$	$\theta$	$\theta$	Movimiento
1	0.713032275	9.524779804	95.81400784	extensión
2	0.29787618	6.2538462	107.88666	extensión
...	...	...	...	...
100	0.339184039	5.723782941	105.4636667	extensión
Promedio	0.413143869	6.93243003	103.5800738	extensión

**Tab. 4.2.:** Ejemplo de los valores de los componentes  $F_y$ ,  $\theta$  y  $\phi$  para una ventana de  $250ms$ .

La tabla 4.2 ejemplifica la extracción del promedio para una ventana de  $250ms$ . LMC publica a 400 FPS, por lo tanto, para cada ventana de  $250ms$  corresponden 100 Frames. En consecuencia, se obtiene un vector con tres componentes que corresponden a los valores  $\bar{F}_y$ ,  $\bar{\theta}$  y  $\bar{\phi}$  para cada ventana. La ecuación 4.1 expresa el promedio para las características de la señal CG, donde  $N$  representa el tamaño de la ventana e  $i$  el índice de la instancia de cada ventana.



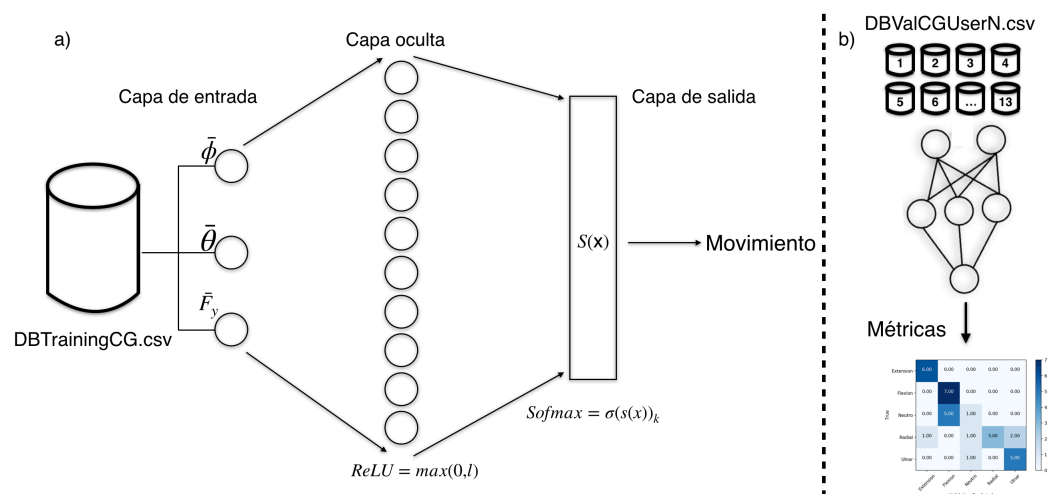
$$\bar{\theta} = \frac{1}{N} \sum_{i=1}^N \theta_i \quad \bar{F}_y = \frac{1}{N} \sum_{i=1}^N F_y^i \quad \bar{\phi} = \frac{1}{N} \sum_{i=1}^N \phi_i \quad (4.1)$$

Para un registro de un segundo, se generan cuatro vectores para una señal CG. Cada vector se etiqueta con el movimiento realizado. Finalmente, el archivo generado se exporta en formato *csv*. Cada archivo se guardó como *meanCGUserN.csv* el cual contiene los registros de cada movimiento y  $N$  representa el índice del usuario.

## 4.4 Clasificación

Cada registro de la señal CG contiene 100 instancias, además, los movimientos se encuentran balanceados (20 instancias para cada movimiento). De acuerdo con [14], una base de datos se debe dividir en 66% para entrenamiento y 33% para validación. Por lo tanto, cada archivo *meanCGUserN.csv* se divide bajo esos valores; El 66% se almacena en una base de datos llamada *DBTrainingCG.csv*, esta base de datos servirá para el entrenamiento de la RNA y el 33% es otra base de datos llamada *DBValCGUserN.csv* que servirá para la validación de la RNA, es decir, medir el desempeño de la RNA por cada usuario.

La Fig.4.4 describe la estructura de la RNA. Las entradas del clasificador serán los valores de la base de datos *DBTrainingCG.csv*. Una vez que los valores de los pesos estén optimizados, es decir, la RNA esté entrenada, se hará pasar cada uno de los archivos *DBValCGUserN.csv* para medir el desempeño de cada usuario mediante las métricas de especificidad, sensibilidad y exactitud. La tabla 4.3 muestra los parámetros de la RNA.



**Fig. 4.4.:** a) Estructura de la RNA para la clasificación de la señal CG. b) Mediante la RNA ya entrenada, se evalúan los registros para medir el desempeño de la RNA.

Capa de entrada	$\bar{F}_y, \bar{\theta}, \bar{\phi}$
Capa oculta	10 neuronas
Función de activación	ReLU
Capa de salida	Softmax
Aprendizaje	Gradiente descendiente
Función de pérdida	Entropía cruzada
Epoch	10000

**Tab. 4.3.:** Parámetros de la RNA para la clasificación de los registros de la señal CG.

## 4.5 Resultados

El sistema envía información del aprendizaje de la RNA cada 2000 epochs, además, identifica el número de instancias, número de atributos (8 electrodos) y el número de clases (cinco movimientos), para la base de entrenamiento y las bases de validación. La salida de consola para la RNA es la siguiente:

```

1
2 (816, 4) Base de entrenamiento
3 Index([u'Fy', u'Theta', u'Phi'], dtype='object')
4 Movimiento
5 ((33, 3), (33, 5)) Base de validación de un usuario
6
7 Loss at step 10000: 0.059049
8 Training accuracy: 99.0%
9 Validation accuracy User 1: 81.8%
10 Validation accuracy User 2: 93.9%
11 Validation accuracy User 3: 90.9%
12 Validation accuracy User 4:: 97.0%
13 Validation accuracy User 5: 81.8%
14 Validation accuracy User 6: 87.9%
15 Validation accuracy User 7: 90.9%
16 Validation accuracy User 8: 97.0%
17 Validation accuracy User 9: 87.9%
18 Validation accuracy User 10: 97.0%
19 Validation accuracy User 11: 93.9%
20 Validation accuracy User 12: 100.0%
21 Validation accuracy User 13: 100.0%
22 ('Mean of all users:', 92.30%)

```

El sistema calcula las métricas estudiadas para cada usuario, la siguiente salida representa los resultados de las métricas para el primer usuario:

```

1 Confusion matrix for user 1


```

```

2  a b c d e
3  6 0 0 0 0 a = extension
4  1 5 2 0 0 b = flexion
5  0 1 5 0 0 c = neutro
6  0 0 1 6 0 d = radial
7  0 0 0 1 6 e = ulnar
8  Metrics
9  [a b c d e]
10 Sensitivity for gesture
11 [1 0.86 1. 1 0.86]
12 Specificity for gesture
13 [1 1 0.96 0.96 1. ]
14 Acurracy for gesture
15 [1 0.97 0.97 0.97 0.97]

```

La Fig. 4.5 ilustra la matriz de confusión que proporciona el sistema para el cálculo de las métricas. Estos valores se exportan para aplicar pruebas estadísticas.




**Fig. 4.5.:** Matriz de confusión para el primer usuario en la modalidad CG.

El promedio de las métricas para cada movimiento, se ilustra en la tabla 4.4.

Movimiento	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.98	0.96	0.97	0.97
Flexión	0.98	0.80	0.94	0.90
Neutro	0.95	0.97	0.95	0.95
Radial	0.98	0.96	0.97	0.97
Ulnar	1	0.94	0.98	0.97
Promedio	0.97	0.92	0.96	0.95

**Tab. 4.4.:** Promedio de las métricas para los 13 registros.

La Fig.4.6 ilustra el promedio de los usuarios para cada métrica respecto a cada gesto. Basándonos en el promedio de las métricas, se puede mencionar de manera exploratoria que los movimientos de extensión, radial y ulnar obtuvieron el mejor resultado de clasificación (promedio:97%). En contraste, el movimiento de flexión reportó un promedio del 90%. La métrica con mejor desempeño fue especificidad, con un promedio por los cinco movimientos de 97.8%. Mientras que la métrica con menor desempeño fue sensibilidad con un promedio del 92%.



**Fig. 4.6.:** Promedio de los registros para cada una de las métricas, correspondiente en la modalidad de características geométricas. (CG).

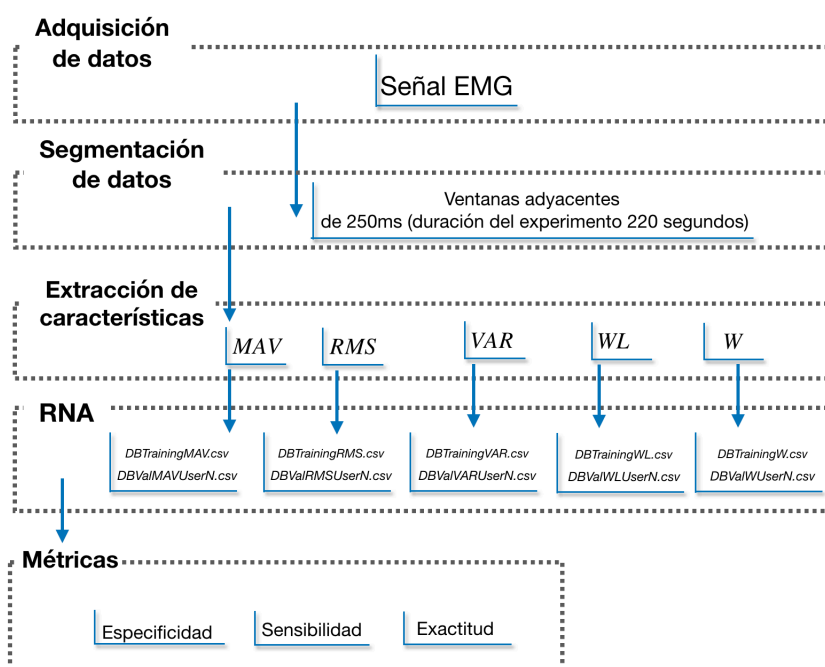
## Modalidad basada en señales electromiográficas

“ Las palabras y las ecuaciones están conectadas con el mundo real.

— Feynman  
(Físico)

Este capítulo describe el proceso del tratamiento de la modalidad basada en señales electromiográficas (EMG). Muestra una descripción de las etapas de implementación en la investigación como la adquisición de los datos, segmentación de los datos, extracción de características, clasificación y resultados.

La Fig.5.1 muestra una descripción de las etapas de implementación para las cuatro características de la modalidad EMG.



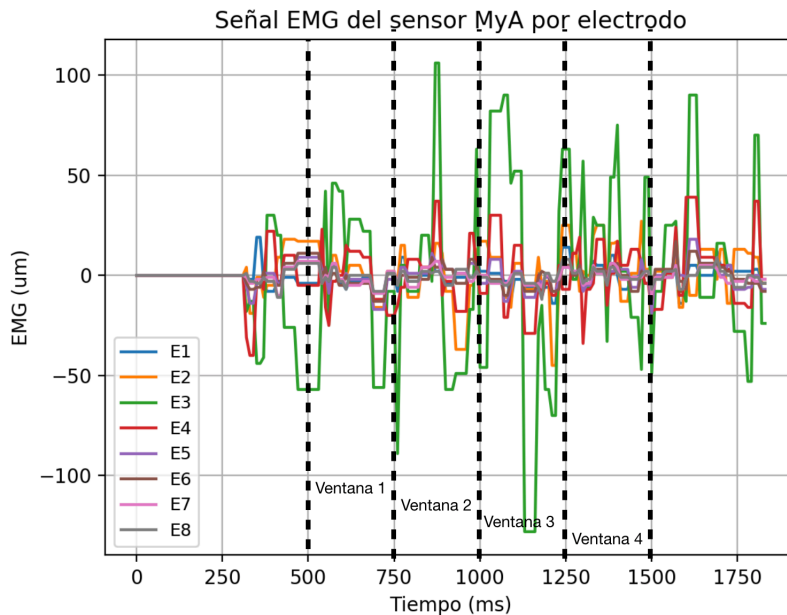
**Fig. 5.1.:** Diagrama de las etapas de implementación para las modalidades MAV, VAR, RMS y WL basada en señales electromiográficas.

## 5.1 Adquisición de la señal

El sensor Myo es capaz de detectar las señales EMG mediante sus ocho electrodos, sin embargo, una desventaja de Myo es su frecuencia de muestreo limitada de 200Hz, mientras que las señales EMG tienen una frecuencia de muestreo de 20Hz-400Hz. La adquisición de la señal para cada registro se llevó a cabo como lo indica el protocolo experimental explicado en la sección de *Diseño experimental* 3.6. Para cada usuario se guardó su registro en un archivo llamado *MovimientoUserNEMG.csv*. Por cada usuario se generaron un total de 25 registros,  $N$  representa el índice del usuario.

## 5.2 Segmentación de la señal

Debido a que las señales fisiológicas se caracterizan por eventos o cambios dinámicos en función del tiempo, aplicamos segmentación de ventanas adyacentes en un intervalo de  $250ms$ . Consideramos un tiempo  $t = 1sg$  para generar cuatro ventanas del mismo intervalo. Myo tiene una tasa de muestreo de 200 Hz aproximadamente, por lo tanto cada ventana adyacente contendrá un total de 50 instancias aproximadamente. La Fig.5.2 muestra un registro de una señal EMG en un intervalo de tiempo correspondiente a dos segundos, se considera el segundo entre los  $500ms - 1500ms$  para generar las ventanas y posteriormente extraer características del dominio del tiempo.



**Fig. 5.2.:** Registro de una señal EMG segmentada mediante ventanas adyacentes de  $250ms$  en un intervalo entre  $500ms - 1500ms$ .

## 5.3 Extracción de características

En esta investigación se utilizaron características del dominio de tiempo para señales EMG. Debido a su simplicidad computacional, este tipo de características son las más populares [14]. A continuación se presentan las características utilizadas en esta investigación:

- MAV - Mean Absolute Value: Devuelve la media de una señal para una clase  $k$ . Se calcula de la siguiente manera:

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_{i,k}| \quad (5.1)$$

- RMS - Root Mean Square: esta característica, también conocida como media cuadrática, está estrechamente relacionada con la desviación estándar, ya que ambas son iguales cuando la media de la señal es cero. Se calcula de la siguiente manera:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_{i,k}^2} \quad (5.2)$$

- WL - Wavelength: esta característica ofrece una forma simple de la señal de onda. Se calcula de la siguiente manera:

$$WL = \sum_{i=1}^N |x_{i,k} - x_{i-1,k}| \quad (5.3)$$

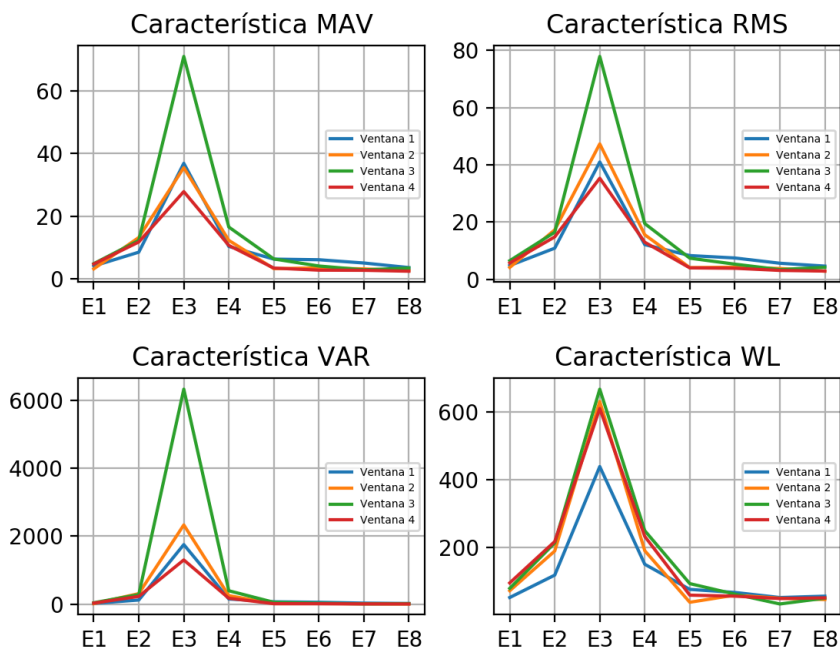
- VAR - Variance : Mide la variación de los datos respecto al valor medio. Se calcula de la siguiente manera:

$$VAR = \frac{1}{N-1} \sum_{i=1}^N (x_{i,k} - \bar{x})^2 \quad (5.4)$$

Donde  $N$  es el número total de instancias para una ventana,  $x_i$  valores de una instancia,  $\bar{x}$  promedio de un atributo y  $k$  el atributo clase. El código para la extracción de las características de la señal EMG se puede ver en el apéndice C:

Las características anteriores se aplican a cada una de las ventanas de  $250ms$ , es decir, por cada registro (1 segundo) se calculan un total de 16 características. La Fig.5.3 ilustra el resultado de aplicar las características a un registro, cada color re-

presenta una ventana. El eje vertical representa las unidades del sensor Myo, mientras que el eje horizontal corresponde a los electrodos del sensor.



**Fig. 5.3.:** Extracción de características para un registro de una señal EMG.

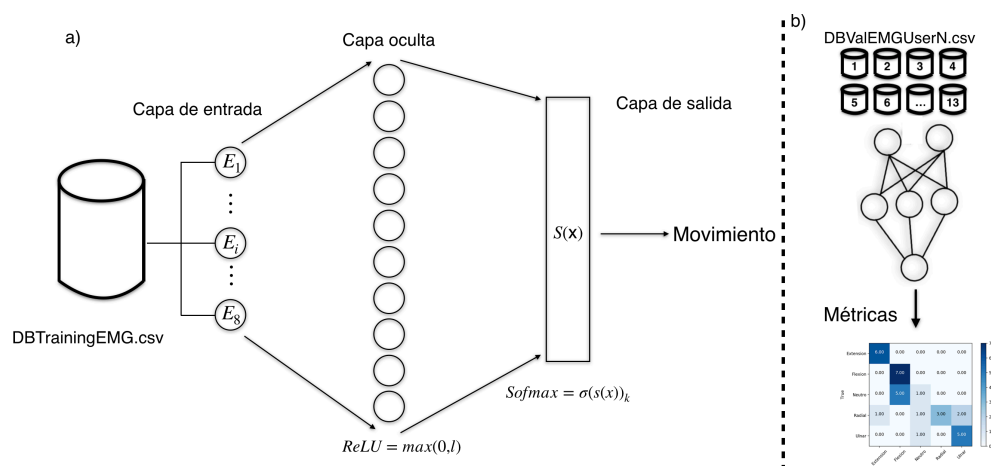
Cada una de las características representa un tratamiento a estudiar. Por lo tanto, los datos de las características se exportan a un archivo *csv*, que se guardan como *DataSetEMGUserN.csv*, *DataSetRMSUserN.csv*, *DataSetVARUserN.csv* y *DataSetWLUserN.csv*, los cuales contienen los registros de cada movimiento para cada usuario.

## 5.4 Clasificación

Cada registro de la señal EMG contiene 100 instancias, además, los movimientos se encuentran balanceados (20 instancias para cada movimiento). Cada base de datos se divide en 66 % para entrenamiento y 33 % para validación. Por lo tanto, cada base de datos se divide bajo esos valores; El 66 % se almacena en una base de datos llamada *DBTrainingEMG.csv*, esta base de datos servirá para el entrenamiento de la RNA; y el 33 % es otra base de datos llamada *DBValEMGUserN.csv* que servirá para la validación de la RNA, es decir, medir el desempeño de la RNA por cada usuario. En consecuencia, se obtendrán cuatro bases de entrenamiento correspondientes a las cuatro características. Cada una de ellas con sus bases de validación para cada usuario.



Se crearon cuatro RNAs con la finalidad de evaluar cada una de las características estudiadas (MAV,RMS,VAR y WL), la Fig.5.4 describe la estructura de las RNAs. La capa de entrada corresponde a las base de datos *DBTrainingEMG.csv*. Una vez que los valores de los pesos estén calibrados, es decir la RNA esté entrenada, se evalúan los registros correspondientes a cada usuario (*DBValFeatureEMGUserN.csv*) para medir el desempeño mediante las métricas descritas. La tabla 5.1 muestra los parámetros de las RNAs.



**Fig. 5.4.:** a) Estructura de la RNA para la clasificación de la señal EMG. b) Mediante la RNA ya entrenada, se evalúan los registros para medir el desempeño de la RNA.

Capa de entrada	8 electrodos
Capa oculta	10 neuronas
Función de activación	ReLU
Capa de salida	Softmax
Aprendizaje	Gradiente descendiente
Función de perdida	Entropía cruzada
Epoch	10000

**Tab. 5.1.:** Parámetros de las RNAs para la clasificación de los registros de la señal EMG. Para todas las modalidades la estructura es la misma.

## 5.5 Resultados

El sistema envía información del aprendizaje de la RNA cada 2000 epochs, además, identifica el número de instancias, número de atributos (8 electrodos) y el número de clases (cinco movimientos), para la base de entrenamiento y las bases de validación. La salida de consola para la RNA es la siguiente:

```

1 (816, 9) Base de entrenamiento
2 Index(['u'E1', 'u'E2', 'u'E3', 'u'E4', 'u'E5', 'u'E6', 'u'E7', 'u'E8
      '], dtype='object')
3 Movimiento

```

```

4 ((32, 8), (32, 5)) Base de validación
5
6 Loss at step 10000: 0.553829
7 Training accuracy: 78.9%
8 Validation accuracy User 1: 84.4%
9 Validation accuracy User 2: 78.1%
10 Validation accuracy User 3: 81.2%
11 Validation accuracy User 4:: 81.2%
12 Validation accuracy User 5: 78.1%
13 Validation accuracy User 6: 71.9%
14 Validation accuracy User 7: 84.4%
15 Validation accuracy User 8: 81.2%
16 Validation accuracy User 9: 78.1%
17 Validation accuracy User 10: 78.1%
18 Validation accuracy User 11: 78.1%
19 Validation accuracy User 12: 81.2%
20 Validation accuracy User 13: 81.2%
21 ('Mean of all users:', 79.80%)

```

El sistema calcula las métricas estudiadas para cada usuario. La siguiente salida representa los resultados de las métricas para el primer usuario en la modalidad MAV:

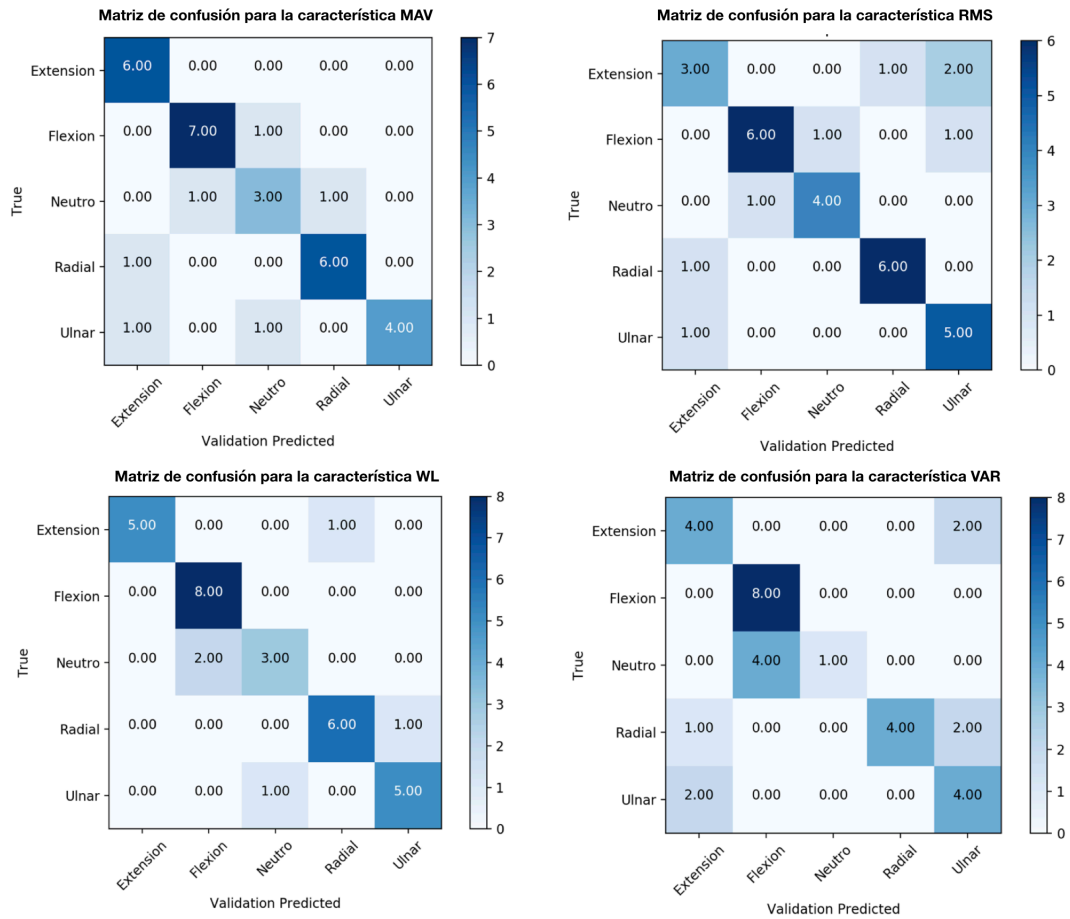
```

1 Confusion Matrix
2 6 0 0 0 0 a = extensión
3 0 7 1 0 0 b = flexión
4 0 1 4 0 0 c = neutro
5 1 0 0 5 1 d = radial
6 1 0 0 0 5 e = ulnar
7 Metrics
8 [a b c d e]
9 Sensitivity for gesture
10 [1 0.875 0.8 0.71 0.83]
11 Specificity for gesture
12 [0.92 0.95 0.96 1 0.96]
13 Accuracy for gesture
14 [0.95 0.93 0.93 0.93 0.93]

```

La Fig. 5.5 ilustra las matrices de confusión correspondientes a cada característica para el primer usuario. Estos valores se exportan para aplicar pruebas estadísticas.

El promedio de las métricas para cada característica, se ilustra en la tablas 5.2, 5.3, 5.4, 5.5.



**Fig. 5.5.:** Matrices de confusión para cada característica correspondientes al primer usuario.

MAV	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.94	0.95	0.95	0.94
Flexión	0.80	0.99	0.94	0.91
Neutro	1	0.97	0.98	0.98
Radial	0.86	0.99	0.96	0.93
Ulnar	0.96	0.96	0.96	0.96
Promedio	0.91	0.97	0.95	0.94

**Tab. 5.2.:** Promedio de las métricas para los 13 registros con la característica MAV.

VAR	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.94	0.87	0.88	0.89
Flexión	0.90	0.98	0.96	0.94
Neutro	0.83	0.98	0.95	0.92
Radial	0.86	0.95	0.93	0.91
Ulnar	0.64	1	0.93	0.85
Promedio	0.83	0.95	0.93	0.90

**Tab. 5.3.:** Promedio de las métricas para los 13 registros con la característica VAR.

RMS	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.94	0.93	0.95	0.94
Flexión	0.94	0.91	0.92	0.92
Neutro	0.69	0.96	0.93	0.86
Radial	0.86	0.98	0.96	0.93
Ulnar	0.96	1	0.99	0.98
Promedio	0.87	0.95	0.95	0.92

**Tab. 5.4.:** Promedio de las métricas para los 13 registros con la característica RMS.

WL	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.78	0.91	0.88	0.85
Flexión	0.91	0.95	0.93	0.93
Neutro	0.83	0.94	0.92	0.89
Radial	0.58	0.95	0.87	0.80
Ulnar	0.79	0.96	0.93	0.89
Promedio	0.77	0.94	0.90	0.87

**Tab. 5.5.:** Promedio de las métricas para los 13 registros con la característica WL.

La Fig.5.6 ilustra el promedio de los usuarios para cada característica respecto a cada métrica y movimiento. Basándonos en el promedio de las métricas para cada movimiento, se puede mencionar de manera exploratoria para la tabla 5.2 el movimiento neutro fue el que mejor clasificación mostró (promedio:98 %). Mientras que para la tabla 5.3 el movimiento con mayor clasificación fue flexión (promedio:94 %). La tabla 5.4 muestra que el movimiento de extensión tiene el mejor promedio de clasificación (promedio:94 %). Finalmente la tabla 5.5 mostró que el movimiento de flexión es el promedio más alto de clasificación (promedio: 93 %).

Promedio de los registros por movimiento para la modalidad EMG




Fig. 5.6.: Promedio de los registros para cada una de las métricas, correspondiente a las características de la modalidad EMG.



# Fusión de las modalidades basada en señales electromiográficas y características geométricas

” *Sin análisis de datos, estamos ciegos y sordos*

— **Geoffrey Moore**  
(Management)

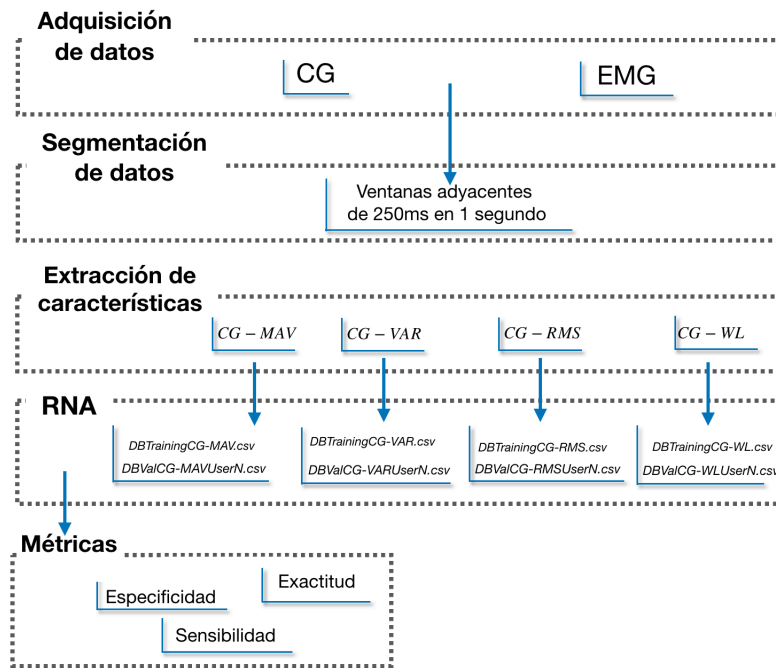
Este capítulo describe el proceso del tratamiento de la fusión de las modalidades basadas en señales electromiográficas (EMG) y características geométricas (CG). Se muestra una descripción de las etapas de implementación en la investigación como la adquisición de los datos, segmentación de los datos, extracción de características, clasificación y resultados.

La Fig.6.1 muestra una descripción de las etapas de implementación para la fusión de las modalidades.

## 6.1 Etapas equivalentes

Los capítulos 4 y 5 exponen el proceso de adquisición de los datos a partir de los sensores Myo y LMC. Es decir, los datos descritos en estos capítulos son los mismos que se emplearon para la fusión. De modo que, las etapas de adquisición, segmentación y extracción de características son equivalentes para este capítulo.

Para fusionar las características de ambas modalidades, es necesario que la segmentación de los datos (ventanas adyacentes) estén sincronizados. La frecuencia de muestreo permite observar el número de muestras por unidad de tiempo que se toman de una señal continua. En los capítulos de ambas modalidades, se especificó que la tasa de muestreo para LMC y Myo es de 400 FPS y 200Hz, respectivamente. A través de estos valores es posible sincronizar las ventanas para cualquier tiem-



**Fig. 6.1.:** Diagrama de las etapas de implementación para la fusión de las señales EMG Y CG).

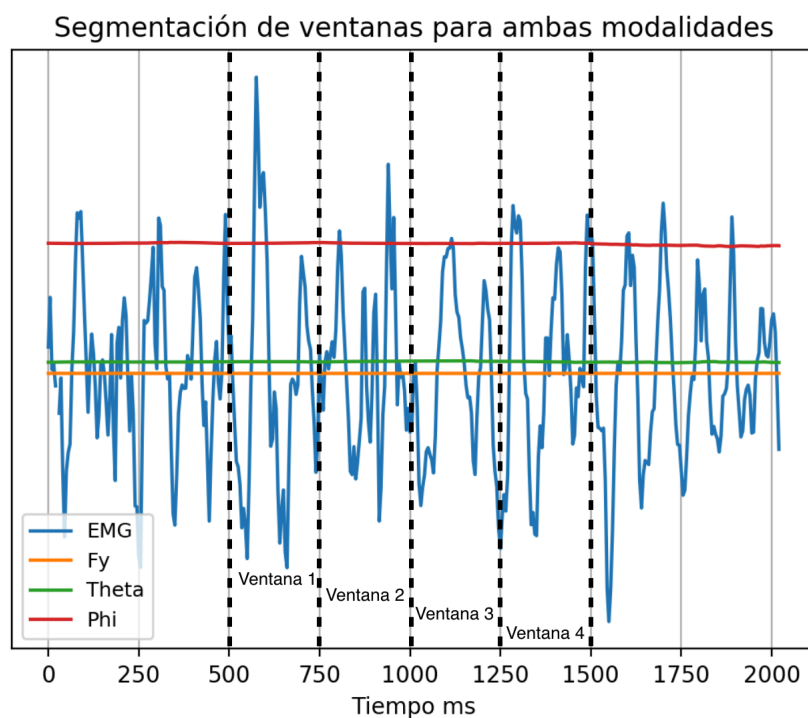
po  $t$ . La Fig.6.2 ilustra la segmentación de las ventanas sincronizadas para ambos sensores.

Cada ventana contiene la información de las señales EMG y CG, por lo tanto, los datos de ambas señales se exportan a un archivo *csv* por cada ventana (*DataSetMAV-CGUserN.csv*, *DataSetRMS-CGUserN.csv*, *DataSetVAR-CGUserN.csv* y *DataSetWL-CGUserN.csv*) el cual contiene los registros de cada movimiento para cada usuario.

## 6.2 Clasificación

Cada una de las bases de datos contiene 100 instancias, además, los movimientos se encuentran balanceados (20 instancias para cada movimiento). Cada base de datos se divide en 66 % para entrenamiento y 33 % para validación. Por lo tanto, cada archivo *DataSetFeature-CGUserN.csv* se divide bajo esos valores. El 66 % se almacena en una base de datos llamada *DBTrainingFeature-CGEMG.csv*, esta base de datos servirá para el entrenamiento de la RNA. El 33 % es otra base de datos llamada *DBValFeatureEMG-CGUserN.csv* que servirá para la validación de la RNA, es decir, para medir el desempeño de la RNA por cada usuario. En consecuencia, se obtendrán cuatro bases de entrenamiento correspondientes a las cuatro modalidades, cada una de ellas con sus bases de validación para cada usuario.






**Fig. 6.2.:** Segmentación de las señales EMG y CG en ventanas adyacentes de  $250ms$  para un tiempo  $t = 1s$ .

Se crearon cuatro RNAs con la finalidad de evaluar cada combinación de características de cada modalidad (CG-MAV, CG-RMS, CG-VAR y CG-WL). La Fig.6.3 describe la estructura de las RNAs. La capa de entrada corresponde a la base de datos *DBTrainingFeature-CG.csv*. Una vez que los valores de los pesos estén calibrados, es decir, la RNA esté entrenada, se evalúan los registros correspondientes a cada usuario (*DBValFeatureCG-UserN.csv*) para medir el desempeño mediante las métricas descritas. La tabla 6.1 muestra los parámetros de las RNAs.

Capa de entrada	11 (8 electrodos, $F_y, \theta, \phi$ )
Capa oculta	10 neuronas
Función de activación	ReLU
Capa de salida	Softmax
Aprendizaje	Gradiente descendiente
Función de pérdida	Entropía cruzada
Epoch	10000

**Tab. 6.1.:** Parámetros de las RNAs para la clasificación de los registros de las señales EMG y CG. Para todas las combinaciones de características la estructura es la misma.



**Fig. 6.3.:** a) Estructura de la RNA para la clasificación de la fusión de las señales EMG y CG. b) Mediante la RNA ya entrenada, se evalúan los registros *DBValFeatureCG-UserN.csv* para medir el desempeño de la RNA.

## 6.3 Resultados

El sistema envía información del aprendizaje de la RNA cada 2000 epochs, además, identifica el número de instancias, número de atributos (8 electrodos y 3 CG) y el número de clases (cinco movimientos), para la base de entrenamiento y las bases de validación. La salida en consola para la RNA es la siguiente:

```

1 (816, 12) Base de entrenamiento
2 Index(['Fy', 'Theta', 'Phi', 'E1', 'E2', 'E3', 'E4', 'E5',
3       'E6', 'E7', 'E8'],
4       dtype='object')
5 Movimiento
6 ((33, 11), (33, 5)) Base de validación
7
8 Loss at step 10000: 0.042054
9 Training accuracy: 99.1%
10 Validation accuracy User 1: 84.8%
11 Validation accuracy User 2: 90.9%
12 Validation accuracy User 3: 84.8%
13 Validation accuracy User 4: 90.9%
14 Validation accuracy User 5: 81.8%
15 Validation accuracy User 6: 87.9%
16 Validation accuracy User 7: 84.8%
17 Validation accuracy User 8: 90.9%
18 Validation accuracy User 9: 81.8%
19 Validation accuracy User 10: 90.9%
20 Validation accuracy User 11: 87.9%
```

```

21 Validation accuracy User 12: 93.9%
22 Validation accuracy User 13: 93.9%
23 ('Mean of all users:', 88.11%)

```

El sistema calcula las métricas para cada usuario. La siguiente salida representa los resultados de las métricas para el primer usuario en la combinación de las características CG-MAV:

```

1 Confusion Matrix
2 6 0 0 0 0 a = extensión
3 0 6 2 0 0 b = flexión
4 0 1 4 0 0 c = neutro
5 0 0 1 6 0 d = radial
6 1 0 0 0 6 e ulnar
7 Metrics
8 [a b c d e]
9 Sensitivity for user 1
10 [1 0.75 0.8 0.85 0.85]
11 Specificity for user 1
12 [0.96 0.96 0.89 1 1]
13 Accuracy for user 1
14 [0.96 0.90 0.87 0.96 0.96]

```

La Fig. 6.4 ilustra las matrices de confusión correspondientes cada combinación para el primer usuario. Estos valores se exportan para aplicar pruebas estadísticas.

El promedio de las métricas para cada combinación, se ilustra en las tablas 6.2, 6.3, 6.4, 6.5.

CG-MAV	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.98	0.96	0.97	0.97
Flexión	0.97	0.89	0.95	0.93
Neutro	0.98	0.92	0.97	0.95
Radial	0.98	0.96	0.97	0.97
Ulnar	1	0.93	0.98	0.97
Promedio	0.98	0.93	0.96	0.95

**Tab. 6.2.:** Promedio de las métricas para los 13 registros con la fusión de características CG-MAV.

La Fig.6.5 ilustra el promedio de los usuarios para cada fusión de características respecto a cada métrica y movimiento. Basándonos en el promedio de las métricas para cada movimiento, se puede mencionar de manera exploratoria para la tabla 6.2 los movimientos de radial, ulnar y extensión fueron los mejores clasificados con

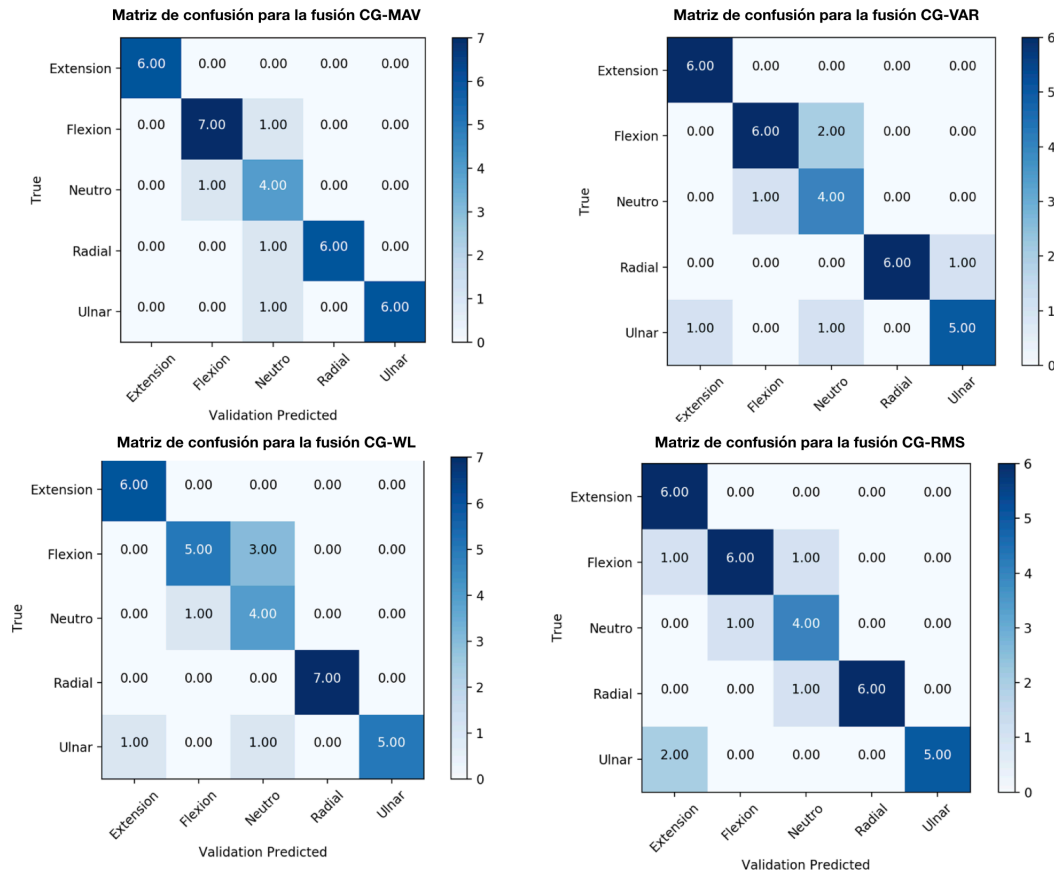


Fig. 6.4.: Matrices de confusión para cada modalidad correspondientes al primer usuario.

CG-VAR	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.98	0.96	0.94	0.96
Flexión	0.97	0.80	0.94	0.90
Neutro	0.98	0.92	0.96	0.95
Radial	0.98	0.96	0.97	0.97
Ulnar	1	0.78	0.92	0.90
Promedio	0.98	0.88	0.94	0.93

Tab. 6.3.: Promedio de las métricas para los 13 registros con la fusión de características CG-VAR.


CG-RMS	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.94	0.96	0.94	0.94
Flexión	0.96	0.89	0.95	0.93
Neutro	0.98	0.93	0.96	0.95
Radial	0.98	0.96	0.97	0.97
Ulnar	1	0.78	0.95	0.91
Promedio	0.97	0.90	0.95	0.94

Tab. 6.4.: Promedio de las métricas para los 13 registros con la fusión de características CG-RMS.

CG-WL	Especificidad	Sensibilidad	Exactitud	Promedio por movimiento
Extensión	0.94	0.96	0.94	0.94
Flexión	0.97	0.86	0.95	0.92
Neutro	0.98	0.94	0.96	0.96
Radial	0.98	0.96	0.97	0.97
Ulnar	1	0.78	0.95	0.91
Promedio	0.97	0.90	0.95	0.94

**Tab. 6.5.:** Promedio de las métricas para los 13 registros con la fusión de características CG-WL.

un promedio de 97%. Mientras que para la tabla 6.3 los movimientos radial y ulnar fueron los mejores clasificados con un promedio del 97% y 96% respectivamente. La tabla 6.4 mostró que los movimientos radial y neutro tienen un promedio del 96% y 97% respectivamente.



**Fig. 6.5.:** Promedio de los registros para cada una de las métricas, correspondiente a la fusión de las modalidades CG y EMG.



## Discusión de las modalidades

” *Ninguna investigación humana puede ser denominada ciencia si no pasa a través de pruebas matemáticas*

— **Leonardo Da Vinci**  
(Arquitecto)

Cuando se analizan datos medidos por una variable cuantitativa continua, las pruebas estadísticas paramétricas se basan en suponer que se ha obtenido de una muestra aleatoria de una distribución de probabilidad de tipo normal o gaussiana. Sin embargo, en muchas ocasiones esta suposición no resulta válida. Los datos se pueden transformar de tal manera que sigan una distribución normal, o bien se puede acudir a pruebas estadísticas que no se basan en ninguna suposición en cuanto a la distribución de probabilidad a partir de la que fueron obtenidos los datos, y por ello se denominan pruebas no paramétricas. Mientras que las pruebas que suponen una distribución de probabilidad determinada para los datos se denominan pruebas paramétricas [31].

El objetivo inicial de la investigación era identificar los movimientos de muñeca usados en rehabilitación a través de la fusión de señales EMG y CG, en consecuencia, medir el desempeño de las características por cada modalidad y la fusión entre ellas. Los capítulos 4,5 y 6 exponen los resultados de la clasificación de los movimientos por cada característica y su correspondiente modalidad, a lo cual responde a las tres primeras preguntas de investigación en este estudio, se confirma que es posible clasificar los movimientos de muñeca usados en rehabilitación a partir de la actividad muscular (señales EMG) y de postura (características geométricas). Sin embargo, aún no se discute sobre el desempeño de las modalidades, es decir, ¿Existen diferencias significativas entre las características y la fusión entre ellas?.

Para demostrar que nuestra hipótesis es válida, evaluamos la evidencia de los resultados de cada modalidad, verificando si existen diferencias significativas entre ellas. Para cada movimiento se aplica la prueba de normalidad *Shapiro Wilk*. Consideramos que la población está distribuida normalmente (hipótesis nula  $H_0$ ). El test obtiene el valor de  $W$  (estadístico de contraste), su distribución permite calcular el valor crítico del test que permite tomar una decisión sobre la normalidad de la

muestra. Además, obtiene su probabilidad crítica  $p_c$ , la cual se puede aceptar o rechazar  $H_0$ . Para nuestra investigación decidimos utilizar un  $\alpha=0.05$ . Por lo tanto, si  $p_c < 0.05$ , se rechazará la hipótesis nula con un nivel de significación del 5 %.

La herramienta computacional que se utilizó para analizar los datos fue R. La tabla 7.1 ilustra los resultados de cada modalidad para el movimiento de extensión con la métrica de sensibilidad. Para observar el resultado del resto de los movimientos por cada métrica véase el apéndice E.

Valor de la métrica sensibilidad para el movimiento de extensión									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	1	1	1	1	0.83	1	1	1	1
2	1	1	1	1	0.83	1	1	1	1
3	1	1	1	1	0.83	1	1	1	1
4	1	0.85	0.85	0.85	0.71	1	1	1	1
5	0.85	0.83	0.83	0.83	0.6	0.85	0.85	0.85	0.85
6	0.85	0.71	0.71	0.71	0.57	0.85	0.85	0.85	0.85
7	1	1	1	1	0.83	1	1	1	1
8	1	1	1	1	0.83	1	1	1	1
9	0.85	0.85	0.85	0.85	0.71	0.85	0.85	0.85	0.85
10	1	1	1	1	0.83	1	1	1	1
11	1	1	1	1	0.83	1	1	1	1
12	1	1	1	1	0.83	1	1	1	1
13	1	1	1	1	0.83	1	1	1	1

**Tab. 7.1.:** Resultado de la métrica sensibilidad para el movimiento de extensión.

La salida del test para la tabla 7.1 es la siguiente:

```

1 Shapiro-Wilk normality test
2 data: CG
3 W = 0.53324, p-value = 1.837e-05
4
5 data: MAV
6 W = 0.65986, p-value = 0.0002265
7
8 data: VAR
9 W = 0.65986, p-value = 0.0002265
10
11 data: RMS
12 W = 0.65986, p-value = 0.0002265
13
14 data: WL
15 W = 0.66191, p-value = 0.0002368
16
17 data: CG-MAV
18 W = 0.53324, p-value = 1.837e-05
19

```



```

20 data: CG-VAR
21 W = 0.53324, p-value = 1.837e-05
22
23 data: CG-RMS
24 W = 0.53324, p-value = 1.837e-05
25
26
27 data: CG-WL
28 W = 0.53324, p-value = 1.837e-05


```

Para cada modalidad y la fusión entre ellas, la prueba de *Shapiro Wilk* reportó como resultado un valor  $p < .05$ , lo que nos da evidencias suficientes para rechazar la hipótesis nula; por lo tanto, los datos no son normales (se corroboró para todos los tratamientos). En consecuencia, es necesario aplicar pruebas no paramétricas para evaluar las diferencias significativas entre las modalidades.

De acuerdo con [31], menciona que para datos con distribución no normal, es conveniente aplicar pruebas no paramétricas. En este estudio se empleó la prueba *Friedman*, ya que los datos cumplen con las condiciones establecidas para dicha prueba. Sin embargo, esta prueba no muestra entre qué pares de tratamientos existen diferencias significativas. Para ello se utilizó método de comparación *post-hoc* de *Nemenyi*, también llamada prueba de *Wilcoxon-Nemenyi-Donald-Thomson*.

## 7.1 Discusión para el movimiento de extensión

La Fig.7.1 ilustra el promedio de las métricas para los 13 registros con el movimiento de extensión.



**Fig. 7.1.:** Promedio de cada métrica para el movimiento de extensión.

Ahora se tiene que determinar si existen diferencias significativas entre las modalidades y la fusión entre ellas, para el movimiento de extensión en cada una de las métricas. La siguiente salida en consola, ilustra la prueba *post-hoc de Nemenyi* para cada métrica considerando el movimiento de extensión. Los tratamientos que tengan un valor  $p < 0.05$  son los que presentan diferencias significativas.

```

1      Pairwise comparisons using Nemenyi multiple comparison test with q approximation for unreplicated
2      blocked data
3
4      Sensibilidad
5      Friedman chi-squared = 81.778, df = 8, p-value = 2.143e-14
6
7      CG      MAV      VAR      RMS      WL      CG-MAV  CG-VAR  CG-RMS
8      MAV  0.99491  -        -        -        -        -        -        -
9      VAR  0.99491  1.00000  -        -        -        -        -        -
10     RMS  0.99491  1.00000  1.00000  -        -        -        -        -
11     WL  0.00022  0.00798  0.00798  0.00798  -        -        -        -
12     CG-MAV 1.00000  0.99491  0.99491  0.99491  0.00022  -        -        -
13     CG-VAR 1.00000  0.99491  0.99491  0.99491  0.00022  1.00000  -        -
14     CG-RMS 1.00000  0.99491  0.99491  0.99491  0.00022  1.00000  1.00000  -
15     CG-WL 1.00000  0.99491  0.99491  0.99491  0.00022  1.00000  1.00000  1.00000
16
17     Especificidad
18     Friedman chi-squared = 94.588, df = 8, p-value < 2.2e-16
19
20     CG      MAV      VAR      RMS      WL      CG-MAV  CG-VAR  CG-RMS
21     MAV  0.0534  -        -        -        -        -        -        -
22     VAR  1.3e-10  0.0035  -        -        -        -        -        -
23     RMS  0.0193  1.0000  0.0118  -        -        -        -        -
24     WL  6.4e-08  0.0803  0.9913  0.1806  -        -        -        -
25     CG-MAV 1.0000  0.0657  2.2e-10  0.0245  1.0e-07  -        -        -
26     CG-VAR 0.0171  1.0000  0.0134  1.0000  0.1958  0.0218  -        -
27     CG-RMS 0.0309  1.0000  0.0070  1.0000  0.1284  0.0386  1.0000  -
28     CG-WL 0.0171  1.0000  0.0134  1.0000  0.1958  0.0218  1.0000  1.0000
29
30     Exactitud
31     Friedman chi-squared = 92.237, df = 8, p-value < 2.2e-16
32
33     CG      MAV      VAR      RMS      WL      CG-MAV  CG-VAR  CG-RMS
34     MAV  0.0047  -        -        -        -        -        -        -
35     VAR  2.6e-09  0.1402  -        -        -        -        -        -
36     RMS  0.0047  1.0000  0.1402  -        -        -        -        -
37     WL  2.6e-09  0.1402  1.0000  0.1402  -        -        -        -
38     CG-MAV 1.0000  0.0047  2.6e-09  0.0047  2.6e-09  -        -        -
39     CG-VAR 0.0885  0.9933  0.0091  0.9933  0.0091  0.0885  -        -
40     CG-RMS 0.0885  0.9933  0.0091  0.9933  0.0091  0.0885  1.0000  -
41     CG-WL 0.0885  0.9933  0.0091  0.9933  0.0091  0.0885  1.0000  1.0000

```

La prueba Friedman reveló que existe diferencia significativa entre las características y su fusión, reportando un valor  $p = 2.143e-14$ . Para la métrica sensibilidad, las de características que reportaron diferencias significativas son: WL/CG, WL/MAV, WL/VAR, WL/RMS, WL/CG-MAV, WL/CG-VAR, WL/CG-RMS y WL/CG-WL. Estos pares reportaron un valor  $p < 0.22e-4$ . Por otra parte, para la métrica de especificidad, los pares que reportaron diferencias son: CG/VAR, CG/RMS, CG/WL, CG/CG-VAR, CG/CG-RMS, CG-WL, MAV/VAR, VAR/RMS, VAR/CG-MAV, VAR/CG-RMS, VAR/CG-VAR, VAR/CG-WL, RMS/CG-MAV, WL/CG-MAV, CG-MAV/CG-VAR, CG-RMS/CG-MAV y CG-WL/CG-MAV. Estos pares reportaron un valor  $p < 6.4e-08$ . Mientras que para la métrica exactitud, los pares de características que reportaron diferencias significativas son: CG/MAV, CG/VAR, CG/RMS, CG/WL, MAV/CG-MAV,

VAR/CG-MAV, VAR/CG-VAR, VAR/CG-RMS, VAR/CG-WL, RMS/CG-MAV, WL/CG-MAV, WL/CG-VAR y WL/CG-WL. Estos pares reportaron un valor  $p < 62.6e-09$ .


Modalidad	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
Promedio	97.624 %	95.009 %	90.326 %	94.474 %	86.26 %	97.621 %	95.339 %	95.431 %	95.339 %

**Tab. 7.2.:** Promedio de las métricas para el movimiento de extensión.

Consideremos el promedio de las tres métricas para poder evaluar cuál de ellas es la mejor para clasificar el movimiento de extensión (Tabla 7.2). Los promedios más altos son CG y CG-MAV. Entre ellos, tienen una diferencia del 0.003 %, pero no existe diferencias significativas. Esto confirma que las características CG y la fusión CG-MAV, presentan el mejor desempeño para la clasificación del movimiento de extensión. Por otra parte, si observamos los valores para la métrica exactitud en la fusión de las modalidades, todas presentan diferencias significativas respecto a las características VAR y WL. Únicamente la fusión CG-MAV si presenta diferencias significativas respecto a MAV, VAR, RMS y WL, para la métrica exactitud. Esto confirma que la fusión de las señales CG y MAV si presentan un mejor desempeño para la clasificación del movimiento de extensión.

## 7.2 Discusión para el movimiento de flexión

La Fig.7.2 ilustra el promedio de las métricas para los 13 registros con el movimiento de flexión.



**Fig. 7.2.:** Promedio de cada métrica para el movimiento de flexión.

Ahora se tiene que determinar si existen diferencias significativas entre las modalidades y la fusión entre ellas, para el movimiento de flexión en cada una de las métricas. La siguiente salida en consola ilustra la prueba *post-hoc de Nemenyi* para

cada métrica considerando el movimiento de flexión. Los tratamientos que tengan un valor  $p < 0.05$  son los que presentan diferencias significativas.

```

1      Pairwise comparisons using Nemenyi multiple comparison test
2      with q approximation for unreplicated blocked data
3
4      Sensibilidad
5      Friedman chi-squared = 49.069, df = 8, p-value = 6.167e-08
6
7      CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
8      MAV      1.0000      -        -        -        -        -        -        -
9      VAR      0.0431      0.0534.  -        -        -        -        -
10     RMS      0.0053      0.0070      0.9996  -        -        -        -
11     WL      0.0309      0.0386      1.0000      0.9999.  -        -        -
12     CG-MAV  0.1529      0.1806      0.9999      0.9779      0.9997  -        -
13     CG-VAR  1.0000      1.0000      0.0431      0.0053      0.0309      0.1529  -        -
14     CG-RMS  0.2286      0.2649      0.9993      0.9444      0.9980      1.0000      0.2286  -
15     CG-WL  0.7786      0.8184      0.8542      0.4645      0.7990      0.9822      0.7786      0.9949
16
17     Especificidad
18     Friedman chi-squared = 63.131, df = 8, p-value = 1.129e-10
19
20     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
21     MAV      0.9998      -        -        -        -        -        -        -
22     VAR      0.9997      0.9729  -        -        -        -        -
23     RMS      3.3e-05      1.9e-06      0.0005  -        -        -        -
24     WL      0.0386      0.0061      0.1806      0.7352  -        -        -
25     CG-MAV  0.9348      0.6647      0.9986      0.0091      0.6154.  -        -
26     CG-VAR  1.0000      0.9986      1.0000      8.0e-05      0.0657      0.9729  -        -
27     CG-RMS  0.7573      0.3924      0.9729      0.0346      0.8542      1.0000      0.8542  -
28     CG-WL  0.9348      0.6647      0.9986      0.0091      0.6154      1.0000      0.9729      1.0000
29
30     Exactitud
31     Friedman chi-squared = 23.619, df = 8, p-value = 0.002654
32
33     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
34     MAV      1.000      -        -        -        -        -        -        -
35     VAR      0.837      0.540  -        -        -        -        -
36     RMS      0.689      0.924      0.024  -        -        -        -
37     WL      0.924      0.995      0.097      1.000  -        -        -
38     CG-MAV  0.924      0.689      1.000      0.048      0.166  -        -
39     CG-VAR  1.000      1.000      0.837      0.689      0.924      0.924  -        -
40     CG-RMS  0.986      0.870      1.000      0.117      0.325      1.000      0.986  -
41     CG-WL  0.986      0.870      1.000      0.117      0.325      1.000      0.986      1.000

```

La prueba Friedman reveló que existen diferencias significativas entre las características, reportando un valor  $p = 6.167e-08$ . Para la métrica sensibilidad, las características que reportaron diferencias significativas son: CG/VAR, CG/RMS, CG/WL, MAV/RMS, MAV/WL, VAR/CG-VAR, RMS/CG-VAR y WL/CG-VAR. Estos pares reportaron un valor  $p < 1.9e-06$ . Por otra parte, para la métrica de especificidad, los pares que reportaron diferencias son: CG/RMS, CG/WL, MAV/RMS, MAV/WL, VAR/RMS, RMS/CG-MAV, RMS/CG-VAR, RMS/CG-RMS y RMS/CG-WL. Estos pares reportaron un valor  $p < 1.9e-06$ . Finalmente, la métrica exactitud únicamente reportó dos pares: RMS/CG-MAV y VAR/RMS. Estos pares reportaron un valor  $p < 0.024$ .

Modalidad	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
Promedio	91.040 %	91.644 %	95.294 %	92.780 %	93.694 %	94.342 %	91.036 %	94.013 %	93.189 %

**Tab. 7.3.:** Promedio de las métricas para el movimiento de flexión.

Consideremos el promedio de las tres métricas para poder evaluar cual de ellas es la mejor para clasificar el movimiento de flexión (Tabla 7.3). Los promedios más

altos son VAR y CG-MAV. Entre ellos, tienen una diferencia del 0.95 %, pero no existen diferencias significativas. Esto confirma que las características VAR y CG-MAV, presentan el mejor desempeño para la clasificación del movimiento flexión, sin importar que existe una diferencia en el promedio de las métricas.

### 7.3 Discusión para el movimiento neutro

La Fig.7.3 ilustra el promedio de las métricas para los 13 registros con el movimiento neutro.




Fig. 7.3.: Promedio de cada métrica para el movimiento neutro.

Ahora se tiene que determinar si existen diferencias significativas entre las modalidades y la fusión entre ellas, para el movimiento neutro en cada una de las métricas. La siguiente salida en consola ilustra la prueba *post-hoc de Nemenyi* para cada. Los tratamientos que tengan un valor  $p < 0.05$  son los que presentan diferencias significativas.

```

1      Pairwise comparisons using Nemenyi multiple comparison test
2      with q approximation for unreplicated blocked data
3
4      Sensibilidad
5      Friedman chi-squared = 79.142, df = 8, p-value = 7.276e-14
6
7      CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
8      MAV      1.00000      -        -        -        -        -        -        -
9      VAR      0.00910      0.00699      -        -        -        -        -
10     RMS      8.0e-05      5.6e-05      0.97294      -        -        -        -
11     WL      0.02177      0.01710      1.00000      0.91246      -        -        -
12     CG-MAV  0.99957      0.99903      0.06575      0.00127      0.12838      -        -
13     CG-VAR  0.99983      0.99957      0.05343      0.00094      0.10702      1.00000      -
14     CG-RMS  1.00000      1.00000      0.01931      0.00022      0.04312      0.99998      1.00000
15     CG-WL  1.00000      1.00000      0.00612      4.7e-05      0.01512      0.99859      0.99934      1.00000
16
17     Especificidad
18     Friedman chi-squared = 52.464, df = 8, p-value = 1.369e-08
19
20     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
21     MAV      0.5145      -        -        -        -        -        -
22     VAR      0.2463      1.0000      -        -        -        -        -
23     RMS      0.1663      0.9996      1.0000      -        -        -        -
24     WL      0.8996      0.0171      0.0035      0.0017      -        -        -

```

25	CG-MAV	0.2286	0.9999	1.0000	1.0000	0.0031	—	—	—
26	CG-VAR	0.2286	0.9999	1.0000	1.0000	0.0031	1.0000	—	—
27	CG-RMS	0.2286	0.9999	1.0000	1.0000	0.0031	1.0000	1.0000	—
28	CG-WL	0.2286	0.9999	1.0000	1.0000	0.0031	1.0000	1.0000	1.0000
29									
30									
31									
32									
33									
34									
35									
36									
37									
38									
39									
40									
41									

Exactitud  
Friedman chi-squared = 50.857, df = 8, p-value = 2.796e-0

	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS
MAV	0.77860	—	—	—	—	—	—	—
VAR	0.89960	0.05932	—	—	—	—	—	—
RMS	0.46455	0.00534	0.99859	—	—	—	—	—
WL	0.08033	0.00016	0.83686	0.99620	—	—	—	—
CG-MAV	0.91246	1.00000	0.12838	0.01512	0.00059	—	—	—
CG-VAR	0.98217	0.99957	0.26489	0.04312	0.00230	1.00000	—	—
CG-RMS	0.98217	0.99957	0.26489	0.04312	0.00230	1.00000	1.00000	—
CG-WL	0.98217	0.99957	0.26489	0.04312	0.00230	1.00000	1.00000	1.00000

La prueba Friedman reveló que existen diferencias significativas entre las características, reportando un valor  $p = 7.276e-14$ . Para la métrica sensibilidad, las características que reportaron diferencias significativas son: CG/VAR, CG/RMS, CG/WL, MAV/VAR, MAV/RMS, MAV/WL, VAR/CG-RMS, VAR/CG-WL, RMS/CG-MAV, RMS/CG-VAR, RMS/CG-RMS, RMS/CG-WL, WL/CG-RMS y RMS/CG-WL. Estos pares reportaron un valor  $p < 5.6e-05$ . Por otra parte, para la métrica de especificidad, los pares que reportaron diferencias son: CG/VAR, MAV/WL, VAR/WL, RMS/WL, CG-MAV/WL, CG-VAR/WL, CG-RMS/WL y CG-WL/WL. Estos pares reportaron un valor  $p < 0.0017$ . Finalmente, los pares reportados para la métrica exactitud son: MAV/RMS, MAV/WL, RMS/CG-MAV, RMS/CG-VAR, RMS/CG-RMS, RMS/CG-WL, WL/CG-MAV, WL/CG-VAR, WL/CG-RMS y WL/CG-WL. Estos pares reportaron un valor  $p < 0.00059$ .

Modalidad	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
Promedio	93.371 %	92.851 %	93.266 %	93.41 %	91.79 %	95.539 %	92.40 %	94.39 %	93.816 %

**Tab. 7.4.:** Promedio de las métricas para el movimiento neutro.

Consideremos el promedio de las tres métricas para poder evaluar cuál de ellas es la mejor para clasificar el movimiento neutro (Tabla 7.4). Los promedios más altos son CG-RMS y CG-MAV. Entre ellos, tienen una diferencia del 1.14 %, pero no existe diferencias significativas. Esto confirma que la fusión de características CG-RMS y CG-MAV, presentan el mejor desempeño para la clasificación del movimiento neutro, sin importar que existe una diferencia en el promedio de las métricas.

## 7.4 Discusión para el movimiento radial

La Fig.7.4 ilustra el promedio de las métricas para los 13 registros con el movimiento radial.




Fig. 7.4.: Promedio de cada métrica para el movimiento radial.

Ahora se tiene que determinar si existen diferencias significativas entre las modalidades y la fusión de ellas para el movimiento radial en cada una de las métricas. La siguiente salida en consola ilustra la prueba *post-hoc* de Nemenyi para cada métrica. Los tratamientos que tengan un valor  $p < 0.05$  son los que presentan diferencias significativas.

```

1      Pairwise comparisons using Nemenyi multiple comparison test
2      with q approximation for unreplicated blocked data
3
4      Sensibilidad
5      Friedman chi-squared = 86.698, df = 8, p-value = 2.173e-15
6
7      CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
8      MAV      0.11732  -        -        -        -        -        -        -
9      VAR      0.14022  1.00000  -        -        -        -        -        -
10     RMS      0.16632  1.00000  1.00000  -        -        -        -        -
11     WL      0.00011  0.64023  0.59024  0.53969  -        -        -        -
12     CG-MAV  0.99999  0.04312  0.05343  0.06575  1.9e-05  -        -        -
13     CG-VAR  0.99997  0.03457  0.04312  0.05343  1.3e-05  1.00000  -        -
14     CG-RMS  0.99990  0.02752  0.03457  0.04312  9.0e-06  1.00000  1.00000  -
15     CG-WL  0.99973  0.02177  0.02752  0.03457  6.1e-06  1.00000  1.00000  1.00000
16
17     Especificidad
18     Friedman chi-squared = 71.729, df = 8, p-value = 2.223e-12
19
20
21     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
22     MAV      0.99125  -        -        -        -        -        -        -
23     VAR      0.00699  0.00013  -        -        -        -        -        -
24     RMS      0.99994  0.99994  0.00109  -        -        -        -        -
25     WL      0.03457  0.00109  0.99994  0.00699  -        -        -        -
26     CG-MAV  1.00000  0.99903  0.00265  1.00000  0.01512  -        -        -
27     CG-VAR  1.00000  0.99903  0.00265  1.00000  0.01512  1.00000  -        -
28     CG-RMS  1.00000  0.99903  0.00265  1.00000  0.01512  1.00000  1.00000  -
29     CG-WL  1.00000  0.99903  0.00265  1.00000  0.01512  1.00000  1.00000  1.00000
30
31     Exactitud
32     Friedman chi-squared = 77.798, df = 8, p-value = 1.355e-13
33
34     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
35     MAV      0.71231  -        -        -        -        -        -        -
36     VAR      0.00069  0.22863  -        -        -        -        -        -
37     RMS      0.71231  1.00000  0.22863  -        -        -        -        -
38     WL      1.1e-05  0.02177  0.99491  0.02177  -        -        -        -
39     CG-MAV  1.00000  0.71231  0.00069  0.71231  1.1e-05  -        -        -
40     CG-VAR  1.00000  0.71231  0.00069  0.71231  1.1e-05  1.00000  -        -
41     CG-RMS  1.00000  0.71231  0.00069  0.71231  1.1e-05  1.00000  1.00000  -
42     CG-WL  1.00000  0.71231  0.00069  0.71231  1.1e-05  1.00000  1.00000  1.00000

```

La prueba Friedman reveló que existen diferencias significativas entre pares de características, reportando un valor  $p = 2.173e-15$ . Para la métrica sensibilidad, las características que reportaron diferencias significativas son: CG/WL, MAV/CG-MAV, MAV/CG-VAR, MAV/CG-RMS, MAV/CG-WL, VAR/CG-VAR, VAR/CG-RMS, VAR/CG-WL, RMS/CG-RMS, RMS/CG-WL, WL/CG-MAV, WL/CG-VAR, WL/CG-RMS y WL/CG-WL. Estos pares reportaron un valor  $p < 6.1e-06$ . Por otra parte, para la métrica de especificidad, los pares que reportaron diferencias son: CG/VAR, CG/WL, MAV/VAR, VAR/CG-MAV, VAR/CG-VAR, VAR/CG-RMS, VAR/CG-WL, RMS/WL, WL/CG-MAV, WL/CG-RMS, WL/CG-VAR y WL/CG-WL. Estos pares reportaron un valor  $p < 0.00013$ . Finalmente, los pares reportados para la métrica exactitud son: CG/VAR, CG/WL, MAV/WL, VAR/CG-MAV, VAR/CG-RMS, VAR/CG-VAR, VAR/CG-WL, RMS/WL, WL/CG-MAV, WL/CG-VAR, WL/CG-RMS y WL/CG-WL. Estos pares reportaron un valor  $p < 1.1e-05$ .


Modalidad	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
Promedio	94.606 %	94.196 %	94.17 %	94.207 %	91.118 %	96.139 %	94.261 %	95.623 %	95.255 %

**Tab. 7.5.:** Promedio de las métricas para el movimiento radial.

Consideremos el promedio de las tres métricas para poder evaluar cuál de ellas es la mejor para clasificar el movimiento radial (Tabla 7.5). Los promedios más altos son CG-RMS y CG-MAV. Entre ellos, tienen una diferencia del 0.5 %, pero no existe diferencias significativas. Esto confirma que la modalidad CG-MAV y CG-RMS tienen el mejor promedio de clasificación para el movimiento radial.

## 7.5 Discusión para el movimiento ulnar

La Fig.7.5 ilustra el promedio de las métricas para los 13 registros con el movimiento ulnar.



**Fig. 7.5.:** Promedio de cada métrica para el movimiento ulnar.



Ahora se tiene que determinar si existen diferencias significativas entre las modalidades y la fusión ente ellas para el movimiento ulnar en cada una de las métricas. La siguiente salida en consola ilustra la prueba *post-hoc de Nemenyi* para cada métrica. Los tratamientos que tengan un valor  $p < 0.05$  son los que presentan diferencias significativas.

```

1      Pairwise comparisons using Nemenyi multiple comparison test
2      with q approximation for unreplicated blocked data
3
4      data:  as.matrix(Ulnar)
5
6
7      Sensibilidad
8      Friedman chi-squared = 79.011, df = 8, p-value = 7.732e-14
9
10     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
11     MAV  1.00000  -        -        -        -        -        -        -
12     VAR  0.00013  3.9e-05  -        -        -        -        -        -
13     RMS  0.99998  1.00000  1.9e-05  -        -        -        -        -
14     WL   0.11732  0.05932  0.66474  0.03864  -        -        -        -
15     CG-MAV 1.00000  1.00000  4.7e-05  1.00000  0.06575  -        -        -
16     CG-VAR 0.08033  0.03864  0.75730  0.02449  1.00000  0.04312  -        -
17     CG-RMS 0.09743  0.04804  0.71231  0.03087  1.00000  0.05343  1.00000  -
18     CG-WL  0.11732  0.05932  0.66474  0.03864  1.00000  0.06575  1.00000  1.00000
19
20     Especificidad
21     Friedman chi-squared = 99.403, df = 8, p-value < 2.2e-16
22
23     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
24     MAV  0.00019  -        -        -        -        -        -        -
25     VAR  1.00000  0.00019  -        -        -        -        -        -
26     RMS  1.00000  0.00019  1.00000  -        -        -        -        -
27     WL   0.00080  1.00000  0.00080  0.00080  -        -        -        -
28     CG-MAV 1.00000  0.00019  1.00000  1.00000  0.00080  -        -        -
29     CG-VAR 0.01512  0.97792  0.01512  0.01512  0.99800  0.01512  -        -
30     CG-RMS 1.00000  0.00019  1.00000  1.00000  0.00080  1.00000  0.01512  -
31     CG-WL  1.00000  0.00019  1.00000  1.00000  0.00080  1.00000  0.01512  1.00000
32
33     Exactitud
34     Friedman chi-squared = 90.004, df = 8, p-value = 4.642e-16
35
36     CG      MAV      VAR      RMS      WL      CG-MAV      CG-VAR      CG-RMS
37     MAV  0.043  -        -        -        -        -        -        -
38     VAR  3.6e-07  0.196  -        -        -        -        -        -
39     RMS  1.000  0.028  1.5e-07  -        -        -        -        -
40     WL   3.4e-06  0.416  1.000  1.5e-06  -        -        -        -
41     CG-MAV 1.000  0.066  8.3e-07  1.000  7.4e-06  -        -        -
42     CG-VAR 3.3e-05  0.712  0.996  1.6e-05  1.000  6.7e-05  -        -
43     CG-RMS 0.304  0.997  0.022  0.229  0.073  0.392  0.212  -
44     CG-WL  0.304  0.997  0.022  0.229  0.073  0.392  0.212  1.000

```

La prueba Friedman reveló que existen diferencias significativas entre las modalidades, reportando un valor  $p = 7.732e-14$ . Para la métrica sensibilidad, las características que reportaron diferencias significativas son: CG/VAR, MAV/VAR, MAV/CG-VAR, MAV/CG-RMS, VAR/RMS, VAR/CG-MAV, RMS/WL, RMS/CG-VAR, RMS/CG-RMS, RMS/CG-WL y CG-MAV/CG-VAR. Estos pares reportaron un valor  $p < 1.9e-05$ . Por otra parte, para la métrica de especificidad, los pares de modalidades que reportaron diferencias son: CG/MAV, CG/WL, CG/VAR, MAV/VAR, MAV/RMS, MAV/CG-MAV, MAV/CG-RMS, MAV/CG-WL, VAR/WL, VAR/CG-VAR, RMS/WL, RMS/CG-VAR, WL/CG-MAV, WL/CG-WL, CG-MAV/CG-VAR, CG-RMS/CG-VAR y CG-WL/CG-VAR. Estos pares reportaron un valor  $p < 0.00080$ . Finalmente, los pares reportados para la métrica exactitud son: CG/MAV, CG/VAR, CG/WL, MAV/RMS, VAR/RMS, RM-

S/WL, WL/CG-MAV y CG-MAV/CG-VAR. Estos pares reportaron un valor  $p < 1.5e-07$ .


Modalidad	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
Promedio	97.793 %	96.325 %	85.832 %	98.660 %	89.868 %	97.505 %	88.946 %	91.212 %	91.212 %

**Tab. 7.6.:** Promedio de las métricas para el movimiento ulnar.

Consideremos el promedio de las tres métricas para poder evaluar cuál de ellas es la mejor para clasificar el movimiento ulnar (Tabla 7.6). Los promedios más altos son RMS y CG. Entre ellos, tienen una diferencia del 0.87 %, pero no existe diferencias significativas. Ahora, comparemos la fusión de características CG-MAV con RMS y CG, evidentemente la diferencia entre los tratamientos es mínima, sin embargo no existen diferencias significativas entre ellas. Esto confirma que las modalidades CG, RMS y CG-MAV, presentan los mejores resultados para la clasificación del movimiento ulnar, siendo la modalidad RMS con el mejor promedio de clasificación para dicho movimiento.

## 7.6 Discusión general

Finalmente, consideremos los promedios de las tablas 7.2, 7.3, 7.4, 7.5 y 7.6. Para determinar la mejor característica o fusión de características, considerando los promedios de las métricas y los movimientos. La Fig.7.6 ilustra el promedio general para cada modalidad.



**Fig. 7.6.:** Promedio general para cada característica y la fusión de ellas, considerando las métricas y los movimientos.

Los valores indican que la fusión de los datos mejoran el desempeño para la fusión de características CG-MAV, CG-VAR y CG-WL. El único par de fusión que no mejoró su resultado en la fusión fue RMS. Finalmente, la fusión CG-MAV muestra un mejor desempeño respecto al resto de las modalidades. Sin embargo, no mostró diferencias significativas respecto a la modalidad CG. Es decir, ambas características son confiables para la identificación de movimientos de muñeca usados en rehabilitación. No obstante, la fusión CG-MAV tiene la ventaja de ser tolerante a fallas en los sensores y además, la capacidad para monitorear la actividad muscular mediante el sensor Myo y la postura mediante el sensor LMC. En comparación con la modalidad CG que únicamente puede monitorear la postura.



## Conclusiones y trabajo futuro

” *Lo importante es no dejar de hacerse preguntas*

— **Albert Einstein**  
(Físico)

A lo largo de este trabajo se compararon características de las señales EMG y CG, para la clasificación de movimientos de muñeca usados en rehabilitación. Cumpliendo así el objetivo general de comparar el desempeño individual y la fusión de las modalidades de postura y actividad muscular. De modo que se identificaron los movimientos de rehabilitación mediante el sensor LMC con señales CG y el sensor Myo mediante señales EMG. Además, se evaluó la RNA para determinar cuáles características mostraban un mejor desempeño en función de las métricas. Se encontró que bajo la hipótesis planteada al comienzo del trabajo, y de acuerdo al esquema general que se presentó en el capítulo 7, los resultados del entrenamiento y la validación de la red neuronal para las nueve estructuras, fueron capaces de clasificar los movimientos de muñeca.

En particular, la combinación de características que más se adecua para la clasificación es CG-MAV con un promedio general de desempeño de 96.22 %. Adicionalmente, la característica CG muestra un promedio general de desempeño de 94.88 %, sin embargo, entre ambas características no existen diferencias significativas. La literatura menciona que la fusión de sensores da lugar a una cobertura espacial, es decir, la fusión CG-MAV cumple con esta condición, además, que en rehabilitación se evalúa la postura y la actividad muscular. Finalmente, se contribuye que las características basadas en la fusión de los datos (CG-MAV, CG-VAR y CG-WL) mostraron un mejor desempeño que los valores basados en el sensor Myo.

Aunque el desempeño general de la señal EMG es del 89.75 %, para realizar un tratamiento más fino en EMG, hizo falta diseñar un filtro para eliminar las frecuencias de paso bajo, además agregar una característica de potencia, la cual permite obtener información de la energía de la señal.

Los sistemas en tiempo real con múltiples sensores tienden a tener problemas en la sincronización de los datos, debido a que cada sensor tiene su propia frecuencia

de muestreo y conectividad. Este problema se debe de mejorar diseñando una arquitectura que permita sincronizar ambos sensores para una aplicación en tiempo real. Sin embargo, se requiere de un aumento en la capacidad de procesamiento de datos.

# Test de Edimburgo

## EDINBURGH HANDEDNESS INVENTORY

(Oldfield, 1971; Bryden, 1977)

Nombre: \_\_\_\_\_ Varón [ ] Mujer [ ]  
 Fecha: \_\_\_\_\_ F. nacimiento: \_\_\_\_\_ Edad: \_\_\_\_\_  
 Estudios/Profesión: \_\_\_\_\_ Observaciones: \_\_\_\_\_

**INSTRUCCIONES:** Marque la casilla correspondiente con  
 + una cruz, si es la mano que utiliza de modo preferente.  
 ++ dos cruces, si es la mano que utiliza de modo muy preferente y además le resultaría imposible o muy difícil hacerlo con la otra mano.  
 + una cruz, en las dos casillas cuando pueda hacerlo tan bien tanto con una mano como con la otra.

¿QUÉ MANO UTILIZA PARA?	DERECHA	IZQUIERDA	Puntos
1. Escribir			1-2-3-4-5
2. Dibujar			1-2-3-4-5
3. Lanzar un objeto			1-2-3-4-5
4. Limpiarse los dientes			1-2-3-4-5
5. Utilizar un cuchillo (sin tenedor)			1-2-3-4-5
6. Cortar con tijeras			1-2-3-4-5
7. Comer con la cuchara			1-2-3-4-5
8. La mano que coloca en la parte superior de la escoba para barrer			1-2-3-4-5
9. Rascar una cerilla			1-2-3-4-5
10. Levantar la tapa de una caja			1-2-3-4-5

Puntos: 5 si ++ sólo en mano izquierda  
 4 si + sólo en mano izquierda  
 3 si + en manos izquierda y derecha  
 2 si + sólo en mano derecha  
 1 si ++ sólo en mano derecha

Consistentemente zurdo/a: 50 ptos (Máximo)  
 Consistentemente diestro/a: 10 ptos (Mínimo)

Fig. A.1.: Test de Edimburgo para determinar la lateralidad del usuario





## Código para adquirir las características geométricas del sensor LMC

```
1  /*
2   Universidad veracruzana
3   Research Center Artificial Intelligence
4   Master Artificial Intelligence
5   Irving Herrera Luna
6   Summary: This code presents the acquisition of gestures by Leap
7           sensor
8   Version: 1.0
9   */
10 ... Initialize LMC sensor ...
11
12 // I can get the palm position and if the hand is left or right
13 HandList hands = frame.hands();
14
15 for (HandList::const_iterator hl = hands.begin(); hl != hands.end();
16     ++hl) {
17     // Get the first hand
18     const Hand hand = *hl;
19
20     // I can get de wrist position
21     Hand hand = frame.hands().frontmost();
22     Arm arm = hand.arm();
23     // Vector wrist = arm.wristPosition();
24
25     // Calculation of the angle between the wrist and position palm for
26     // measurement flexion or extension
27     float angleInRadians = hand.palmPosition().angleTo(arm.
28         wristPosition());
29     float angleInRadians2 = angleInRadians*57.2958; // obtein angle
30     // in dregees
31     Pointable pointable = frame.pointables().frontmost();
32     Vector direction = pointable.direction(); // I get
33     // direction fingers
34
35     std::cout << " " << direction[1]; // 3 colum Fingers direction
36     std::cout << ", " << angleInRadians2; // 4 colum Latitud angle
37 }
```

```

34  /* Measurements of radian and urnal gestures
35
36  The frame of reference of the hand can be defined in a useful way
    by
37  hand basis () and palmPosition (). The base orients the x-axis
    laterally
38  through the hand, the z axis pointing forward and the axis and
    parallel to the
39  normal of the palm. The origin of the transform is the
    palmPosition (). */
40
41
42  Matrix handTransform = hand.basis();
43  handTransform.origin = hand.palmPosition(); // new reference frame
44  handTransform = handTransform.rigidInverse();
45
46  Finger finger = hand.fingers()[2]; // you work with the ring finger
47
48  /* Vectors that obtain the new position and direction of the
    fingers
49  regarding the position of the palm */
50
51  Vector transformedPosition = handTransform.transformPoint(finger.
    tipPosition());
52
53  // Is necessary multiply the vector transformedPosition for -1,
    because the vectormdirection is negative
54  // this new vector is called "correct"
55  Vector correct = Vector(-transformedPosition[0],-
    transformedPosition[1],-    transformedPosition[2]);
56
57  /* To calculate the angle to determine what gesture is? I create
    a unit vector (x) inside the new reference frame xAcisVecotor
    =(1,0,0) */
58
59
60
61  Vector xAxisVector = Vector::xAxis();
62  Vector newXAxisVector = handTransform.transformDirection(
    xAxisVector);
63  float angleUrnal = newXAxisVector.angleTo(correct);
64  float angleUrnal2 = angleUlnar*57.2958; // Angle in degrees
65  std::cout << "," << angleUlnar2 << std::endl; // 5 colum Azimut
    angle
66
67  //These series of conditions I can determine what kind of gestures is
    , knowing the parameters described above
68
69  // Flexion: Verify that the angle is less than .20 radians and
    that the direction of the fingertips is negative
70  if (angleInRadians < 0.20 && direction[1] < 0.0){

```

```

71     std::cout << "Flexion,";
72     }
73     // Extension: Verify that the angle is less than .20 radians
       and that the direction of the fingertips is positive
74     if (angleInRadians < 0.20 && direction[1] > 0.0){
75         std::cout << "Extension,";
76     }
77     // Ulnar: Verify that the angle "angleUrnal2" is greater
       than 120 degrees
78     if (angleUrnal2 > 120){
79         std::cout << "ULnar,";
80     }
81     // Radial: Verify that the angle "angleUrnal2" is less than
       75 degrees
82     if (angleUrnal2 < 75){
83         std::cout << "Radial,";
84     }
85     //movements neutro
86     if (angleUrnal2 > 75 && angleUrnal2 < 120 && angleInRadians >
       .20 ){
87         std::cout << "Neutro,";
88     }
89 }

```



## Código para extracción de características de la señal EMG

```
1 '''
2     Universidad veracruzana
3     Research Center Artificial Intelligence
4     Master Artificial Intelligence
5     Irving Herrera Luna
6     Summary: Code for the extraction of features in EMG signals
7     Version: 1.0
8 '''
9 import numpy as np
10 import pandas as pd
11 import matplotlib.pyplot as plt
12 import scipy as sp
13 import csv
14
15 ... Lectura de la base de datos y visualizador ...
16
17 # Creó las ventanas adyacentes del data frame
18 window1 = data[0:24]
19 window2 = data[25:50]
20 window3 = data[51:75]
21 window4 = data[76:100]
22
23 ##### Cálculo MAV por ventana
24 MVWindow1 = np.sum(windowN[['E1', 'E2', 'E3', 'E4', 'E5', 'E6', 'E7', 'E8'
25     ]].abs())/len(windowN)
26
27 ##### Cálculo RMS por ventana
28 RMSWindowN = np.sqrt(np.sum(windowN[['E1', 'E2', 'E3', 'E4', 'E5', 'E6', '
29     E7', 'E8']]**2)/len(windowN))
30
31 ### Cálculo VAR por ventana
32 VARwindowN = (np.sum(windowN[['E1', 'E2', 'E3', 'E4', 'E5', 'E6', 'E7', 'E8'
33     ]]- windowN.mean())**2) * 1/(len(windowN)-1))
34
35 ##### Cálculo Wavelength por ventana
36
37 WLWindowN = np.sum(np.absolute(windowN[['E1', 'E2', 'E3', 'E4', 'E5', 'E6'
38     ], 'E7', 'E8']].diff()))
39
40 ... Se exporta la base de datos correspondiente a cada ventana ...
```



## Código de RNA en Tensorflow

```
1  '''
2  Universidad veracruzana
3  Research Center Artificial Intelligence
4  Master Artificial Intelligence
5  Irving Herrera Luna
6  Summary: RNA
7  Version: 1.0
8  '''
9  import numpy as np
10 import pandas as pd
11 import itertools
12 import matplotlib.pyplot as plt
13 from IPython.display import display, Image
14 import os
15 os.environ['TF_CPP_MIN_LOG_LEVEL'] = '2'
16 import tensorflow as tf
17 import random
18 from IPython.display import display, Image
19 from pandas import get_dummies
20 from sklearn.model_selection import train_test_split
21
22
23
24 ... Import data base and Data distribution ...
25
26 # The training data is order referent to gesture. Its necessary
27   generate a clutter of the data
28 indices = data_norm.index.tolist() # Returns a copy of the data as a
29   list
30 indices = np.array(indices)        # Create a new array with new
31   index
32 np.random.shuffle(indices)        # Apply shuffle at array.
33
34
35 # Create a sets for labels and features of data training
36 X = data_norm.reindex(indices)[features]
37 y = data_norm.reindex(indices)[label]
38
39 # One Hot Encode as a data frame (data training)
40 y = get_dummies(y)
41 yNames = y.columns
42 yNames.tolist()
```

```

41 # Generate Training and Validation Sets
42 X_train, X_test, y_train, y_test = train_test_split(X,y, test_size
    =0.1)
43
44 # Convert to np arrays so that we can use with TensorFlow (data
    training)
45 X_train = np.array(X_train).astype(np.float32)
46 X_test  = np.array(X_test).astype(np.float32)
47 y_train = np.array(y_train).astype(np.float32)
48 y_test  = np.array(y_test).astype(np.float32)
49
50 # Convert to np arrays so that we can use with TensorFlow (data
    validation for each user)
51
52 training_size = X_train.shape[1]
53 test_size    = X_test.shape[1]
54
55 # Estructure of data base training and validation
56 NumFeatures = 8 # 3 CG and 11 for fusion (CG-EMG)
57 NumLabels   = 5
58
59 # Number of hidden neurons
60 NumHidden   = 10
61
62 graph = tf.Graph()
63 plt.show()
64 with graph.as_default():
65     tf_train_set    = tf.constant(X_train)
66     tf_train_labels = tf.constant(y_train)
67     tfValidSetUser1 = tf.constant(XTestUserN)
68
69 ListTfValid = [tfValidSetUserN]
70 YTestUserN  = [YTestUserN]
71
72 print(tf_train_set)
73 print(tf_train_labels)
74
75
76 # Note, since there is only 1 layer there are actually no hidden
    layers... but if there were
77 # there would be NumHidden
78 weights1 = tf.Variable(tf.truncated_normal([NumFeatures,
    NumHidden]))
79 weights2 = tf.Variable(tf.truncated_normal([NumHidden, NumLabels
    ]))
80
81 ## tf.zeros Automaticaly adjusts rows to input data batch size
82 bias1 = tf.Variable(tf.zeros([NumHidden]))
83 bias2 = tf.Variable(tf.zeros([NumLabels]))
84
85

```



```

86     logits1 = tf.matmul(tf_train_set , weights1) + bias1
87     relu1 = tf.nn.relu(logits1)
88     logits2 = tf.matmul(relu1, weights2) + bias2
89
90     loss = tf.reduce_mean(tf.nn.softmax_cross_entropy_with_logits_v2(
91         logits=logits2, labels=tf_train_labels))
92     optimizer = tf.train.GradientDescentOptimizer(.005).minimize(loss
93         )
94
95     # Training prediction
96     predictTrain = tf.nn.softmax(logits2)
97
98     # Validation prediction
99     for i in range(len(ListTfValid)):
100
101         logits1Val = tf.matmul(ListTfValid[i], weights1) + bias1
102         relu1Val = tf.nn.relu(logits1Val)
103         logits2Val = tf.matmul(relu1Val, weights2) + bias2
104         predictValid = tf.nn.softmax(logits2Val)
105
106     def accuracy(predictions, labels):
107         return (100.0 * np.sum(np.argmax(predictions, 1) == np.
108             argmax(labels, 1)) / predictions.shape[0])
109
110     NumSteps = 10001
111     accuracyValid = []
112     accuracyTrain = []
113     error=[]
114
115     with tf.Session(graph = graph) as session:
116         tf.global_variables_initializer().run()
117         print(loss.eval())
118         for step in range(NumSteps):
119             _,l, predictions = session.run([optimizer, loss, predictTrain
120                 ])
121             error.append(l)
122
123             accuracyTrain.append(accuracy(predictions, y_train[:, :]))
124             accuracyValid.append(accuracy(predictValid.eval(), YTestUser1
125                 ))
126
127             if (step % 2000 == 0):
128
129                 print('Loss at step %d: %f' % (step, l))
130                 print('Training accuracy: %.1f%%' % accuracy(
131                     predictions, y_train[:, :]))
132                 print('Validation accuracy User N: %.1f%%' % accuracy(
133                     predictValid.eval(), YTestUser1))

```

```

129 # In this part we calculate the sensitivity, Specificity and accuracy
    each user gesture
130
131 ConfMatrix = tf.confusion_matrix(labels=tf.argmax(y_test,1),
    predictions= tf.argmax(predictValid,1))
132
133 FP = ConfMatrix.eval().sum(axis=0) - ConfMatrix.eval().astype('
    float')
134 FN = ConfMatrix.eval().sum(axis=1) - ConfMatrix.eval().astype('
    float')
135 TP = ConfMatrix.eval().astype('float')
136 TN = ConfMatrix.eval().sum() - (FP + FN + TP)
137
138 Sensitivity = TP/(TP+FN)
139 Specificity = TN/(TN+FP)
140 Accuracy = ((TP+TN)/(TP+FP+FN+TN))

```

## Resultados de las métricas para cada usuario

Valor de la métrica sensibilidad para el movimiento de extensión									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	1	1	1	1	0.83333333	1	1	1	1
2	1	1	1	1	0.83333333	1	1	1	1
3	1	1	1	1	0.83333333	1	1	1	1
4	1	0.85714286	0.85714286	0.85714286	0.71428571	1	1	1	1
5	0.85714286	0.83333333	0.83333333	0.83333333	0.66666667	0.85714286	0.85714286	0.85714286	0.85714286
6	0.85714286	0.71428571	0.71428571	0.71428571	0.57142857	0.85714286	0.85714286	0.85714286	0.85714286
7	1	1	1	1	0.83333333	1	1	1	1
8	1	1	1	1	0.83333333	1	1	1	1
9	0.85714286	0.85714286	0.85714286	0.85714286	0.71428571	0.85714286	0.85714286	0.85714286	0.85714286
10	1	1	1	1	0.83333333	1	1	1	1
11	1	1	1	1	0.83333333	1	1	1	1
12	1	1	1	1	0.83333333	1	1	1	1
13	1	1	1	1	0.83333333	1	1	1	1

**Tab. E.1.:** Resultado de la métrica sensibilidad para el movimiento de extensión.

Valor de la métrica sensibilidad para el movimiento de flexión									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.625	0.75	0.875	1	0.875	0.75	0.625	0.75	0.75
2	0.85714286	0.75	0.875	0.875	0.875	1	0.85714286	1	1
3	0.75	0.75	0.875	1	0.875	0.75	0.75	0.75	0.75
4	0.85714286	0.71428571	0.85714286	1	0.85714286	1	0.85714286	1	1
5	0.71428571	0.85714286	0.85714286	0.85714286	0.85714286	0.85714286	0.71428571	0.85714286	0.85714286
6	0.66666667	0.83333333	0.83333333	0.83333333	0.83333333	0.83333333	0.66666667	0.83333333	0.83333333
7	0.66666667	0.75	0.875	1	0.875	0.77777778	0.66666667	0.77777778	0.77777778
8	0.85714286	0.85714286	1	1	1	1	0.85714286	1	1
9	0.71428571	1	1	1	1	0.85714286	0.71428571	0.85714286	0.85714286
10	0.85714286	0.75	0.875	0.875	0.875	1	0.85714286	1	0.85714286
11	0.85714286	0.75	0.875	0.875	1	0.85714286	0.85714286	0.83333333	0.85714286
12	1	0.85714286	1	1	1	1	1	1	0.85714286
13	1	0.85714286	1	1	1	1	1	1	0.85714286

**Tab. E.2.:** Resultado de la métrica sensibilidad para el movimiento de flexión

Valor de la métrica sensibilidad para el movimiento neutro									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.8	1	0.8	0.8	0.8	0.8	0.8	0.8	0.8
2	1	1	1	0.6	0.8	1	1	1	1
3	1	1	0.8	0.8	0.8	0.83333333	0.83333333	0.83333333	0.83333333
4	1	1	0.8	0.8	0.8	1	1	1	1
5	1	1	0.83333333	0.66666667	0.83333333	1	1	1	1
6	0.85714286	1	0.83333333	0.66666667	0.83333333	0.85714286	0.85714286	0.85714286	0.85714286
7	1	1	0.8	0.8	0.8	1	1	1	1
8	1	1	0.83333333	0.66666667	0.83333333	1	1	1	1
9	1	1	0.83333333	0.66666667	0.83333333	1	1	1	1
10	1	1	0.8	0.6	0.8	1	1	1	1
11	1	1	0.8	0.6	1	0.83333333	0.83333333	1	0.83333333
12	1	1	0.83333333	0.66666667	0.83333333	0.85714286	0.85714286	0.85714286	1
13	1	1	0.83333333	0.66666667	0.83333333	0.85714286	0.85714286	0.85714286	1

**Tab. E.3.:** Resultado de la métrica sensibilidad para el movimiento neutro

Valor de la métrica sensibilidad para el movimiento radial									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.85714286	0.85714286	0.85714286	0.85714286	0.57142857	0.85714286	0.85714286	0.85714286	0.85714286
2	1	1	1	1	0.66666667	1	1	1	1
3	1	0.83333333	0.83333333	0.83333333	0.5	1	1	1	1
4	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1
5	0.83333333	0.83333333	0.83333333	0.83333333	0.66666667	0.83333333	0.83333333	0.83333333	0.83333333
6	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1
7	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1
8	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1
9	0.875	0.85714286	0.85714286	0.85714286	0.57142857	0.875	0.875	0.875	0.875
10	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1
11	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1
12	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1
13	1	0.85714286	0.85714286	0.85714286	0.57142857	1	1	1	1

**Tab. E.4.:** Resultado de la métrica sensibilidad para el movimiento de radial

Valor de la métrica sensibilidad para el movimiento ulnar									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.85714286	1	0.66666667	1	0.83333333	0.85714286	0.71428571	0.71428571	0.71428571
2	0.85714286	0.85714286	0.57142857	0.85714286	0.71428571	0.85714286	0.71428571	0.71428571	0.71428571
3	1	0.85714286	0.57142857	0.85714286	0.71428571	0.85714286	0.71428571	0.71428571	0.71428571
4	1	1	0.66666667	1	0.83333333	1	0.83333333	0.83333333	0.83333333
5	0.75	0.85714286	0.57142857	0.85714286	0.85714286	0.75	0.625	0.625	0.625
6	1	1	0.66666667	1	0.83333333	1	0.83333333	0.83333333	0.83333333
7	1	1	0.66666667	1	0.83333333	1	0.83333333	0.83333333	0.83333333
8	1	1	0.66666667	1	0.83333333	1	0.83333333	0.83333333	0.83333333
9	1	1	0.66666667	1	0.83333333	1	0.83333333	0.83333333	0.83333333
10	1	1	0.66666667	1	0.83333333	1	0.83333333	0.83333333	0.83333333
11	0.85714286	1	0.66666667	1	0.83333333	0.85714286	0.71428571	0.71428571	0.71428571
12	1	1	0.66666667	1	0.83333333	1	0.83333333	0.83333333	0.83333333
13	1	1	0.66666667	1	0.57142857	1	0.83333333	0.83333333	0.83333333

**Tab. E.5.:** Resultado de la métrica sensibilidad para el movimiento de ulnar

Valor de la métrica especificidad para el movimiento extensión									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.96296296	0.96153846	0.88461538	0.96153846	0.92307692	0.96296296	0.92592593	0.92592593	0.92592593
2	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
3	0.96296296	0.96153846	0.88461538	0.96153846	0.92307692	0.96296296	0.92592593	0.92592593	0.92592593
4	1	0.96	0.88	0.96	0.92	1	0.96153846	0.96153846	0.96153846
5	0.96296296	0.92307692	0.84615385	0.71428571	0.88461538	0.96153846	0.92307692	0.92307692	0.92307692
6	0.96153846	0.92	0.84	0.92	0.88	0.96153846	0.92307692	0.92307692	0.92307692
7	0.96296296	0.96153846	0.88461538	0.96153846	0.92307692	0.96296296	0.92592593	0.96153846	0.92592593
8	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
9	0.96153846	0.96	0.88	0.96	0.92	0.96153846	0.92307692	0.92307692	0.92307692
10	1	0.96153846	0.88	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
11	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
12	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
13	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846

**Tab. E.6.:** Resultado de la métrica especificidad para el movimiento de extensión

Valor de la métrica especificidad para el movimiento de flexión									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.96296296	0.96153846	0.88461538	0.96153846	0.92307692	0.96296296	0.92592593	0.92592593	0.92592593
2	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
3	0.96296296	0.96153846	0.88461538	0.96153846	0.92307692	0.96296296	0.92592593	0.92592593	0.92592593
4	1	0.96	0.88	0.96	0.92	1	0.96153846	0.96153846	0.96153846
5	0.96296296	0.92307692	0.84615385	0.71428571	0.88461538	0.96153846	0.92307692	0.92307692	0.92307692
6	0.96153846	0.92	0.84	0.92	0.88	0.96153846	0.92307692	0.92307692	0.92307692
7	0.96296296	0.96153846	0.88461538	0.96153846	0.92307692	0.96296296	0.92592593	0.96153846	0.92592593
8	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
9	0.96153846	0.96	0.88	0.96	0.92	0.96153846	0.92307692	0.92307692	0.92307692
10	1	0.96153846	0.88	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
11	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
12	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846
13	1	0.96153846	0.88461538	0.96153846	0.92307692	1	0.96153846	0.96153846	0.96153846

**Tab. E.7.:** Resultado de la métrica especificidad para el movimiento de flexión

Valor de la métrica especificidad para el movimiento neutro									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.89285714	0.96153846	0.96296296	1	0.92592593	0.92857143	0.92857143	0.92857143	0.92857143
2	0.96296296	0.96296296	1	0.96296296	0.92592593	1	1	1	1
3	0.96296296	0.96296296	0.96296296	1	0.92592593	0.96296296	0.96296296	0.96296296	0.96296296
4	0.96296296	0.96296296	0.96296296	1	0.92592593	1	1	1	1
5	0.92857143	1	1	0.66666667	0.96153846	0.96428571	0.96428571	0.96428571	0.96428571
6	0.96296296	1	1	1	0.96153846	1	1	1	1
7	0.92857143	0.96153846	0.96296296	1	0.92592593	0.96428571	0.96428571	0.96428571	0.96428571
8	0.96296296	1	1	1	0.96153846	1	1	1	1
9	0.92857143	1	1	1	0.96153846	0.96428571	0.96428571	0.96428571	0.96428571
10	0.96296296	0.96296296	0.96296296	0.96296296	0.92592593	1	1	1	1
11	0.96296296	0.96296296	0.96296296	0.96296296	0.96296296	0.96296296	0.96296296	0.96296296	0.96296296
12	1	1	1	1	0.96	1	1	1	1
13	1	1	1	1	0.96	1	1	1	1

**Tab. E.8.:** Resultado de la métrica especificidad para el movimiento de neutro

Valor de la métrica especificidad para el movimiento radial									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.96153846	0.96296296	0.96	1	0.96	0.96153846	0.96153846	0.96153846	0.96153846
2	0.96153846	1	0.96153846	1	0.96153846	0.96296296	0.96296296	0.96296296	0.96296296
3	0.96296296	0.96153846	0.92307692	0.96153846	0.92307692	0.96296296	0.96296296	0.96296296	0.96296296
4	1	1	0.96	1	0.96	1	1	1	1
5	0.92592593	0.96153846	0.92307692	0.85714286	0.96153846	0.92592593	0.92592593	0.92592593	0.92592593
6	1	1	0.96	1	0.96	1	1	1	1
7	1	1	0.96	1	0.96	1	1	1	1
8	1	1	0.96	1	0.96	1	1	1	1
9	1	1	0.96	1	0.96	1	1	1	1
10	1	1	0.96	1	0.96	1	1	1	1
11	0.96296296	1	0.96	1	0.96	0.96296296	0.96296296	0.96296296	0.96296296
12	1	1	0.96	1	0.96	1	1	1	1
13	1	1	0.96	1	0.96	1	1	1	1

**Tab. E.9.:** Resultado de la métrica especificidad para el movimiento radial

Valor de la métrica especificidad para el movimiento ulnar									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	1	0.96153846	1	1	0.96153846	1	0.96153846	1	1
2	1	0.96	1	1	0.96	1	0.96153846	1	1
3	1	0.96	1	1	0.96	1	0.96153846	1	1
4	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1
5	1	0.96	1	1	1	1	0.96	1	1
6	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1
7	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1
8	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1
9	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1
10	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1
11	1	0.96153846	1	1	0.96153846	1	0.96153846	1	1
12	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1
13	1	0.96153846	1	1	0.96153846	1	0.96296296	1	1

**Tab. E.10.:** Resultado de la métrica especificidad para el movimiento ulnar

Valor de la métrica exactitud para el movimiento de extensión									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.96969697	0.96875	0.90625	0.96875	0.96969697	0.939393939	0.939393939	0.939393939	93.93939394
2	1	0.96875	0.90625	0.96875	1	0.96969697	0.96969697	0.96969697	96.96969697
3	0.96969697	0.96875	0.90625	0.96875	0.96969697	0.939393939	0.939393939	0.939393939	93.93939394
4	1	0.9375	0.875	0.9375	1	0.96969697	0.96969697	0.96969697	96.96969697
5	0.939393939	0.90625	0.84375	0.90625	0.939393939	0.909090909	0.909090909	0.909090909	90.90909091
6	0.939393939	0.875	0.8125	0.875	0.939393939	0.909090909	0.909090909	0.909090909	90.90909091
7	0.96969697	0.96875	0.90625	0.96875	0.96969697	0.939393939	0.939393939	0.939393939	93.93939394
8	1	0.96875	0.90625	0.96875	1	0.96969697	0.96969697	0.96969697	96.96969697
9	0.939393939	0.9375	0.875	0.9375	0.939393939	0.909090909	0.909090909	0.909090909	90.90909091
10	1	0.96875	0.90625	0.96875	1	0.96969697	0.96969697	0.96969697	96.96969697
11	1	0.96875	0.90625	0.96875	1	0.96969697	0.96969697	0.96969697	96.96969697
12	1	0.96875	0.90625	0.96875	1	0.96969697	0.96969697	0.96969697	96.96969697
13	1	0.96875	0.90625	0.96875	1	0.96969697	0.96969697	0.96969697	96.96969697

**Tab. E.11.:** Resultado de la métrica exactitud para el movimiento de extensión

Valor de la métrica exactitud para el movimiento de flexión									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.878787879	0.9375	0.96875	0.96875	0.9375	0.909090909	0.878787879	0.909090909	0.909090909
2	0.969696967	0.9375	0.96875	0.90625	0.9375	1	0.969696967	1	1
3	0.939393939	0.9375	0.96875	0.96875	0.9375	0.939393939	0.939393939	0.909090909	0.909090909
4	0.969696967	0.90625	0.9375	0.9375	0.90625	1	0.969696967	1	1
5	0.909090909	0.96875	0.9375	0.875	0.90625	0.939393939	0.909090909	0.939393939	0.939393939
6	0.878787879	0.9375	0.90625	0.84375	0.875	0.909090909	0.878787879	0.909090909	0.909090909
7	0.909090909	0.9375	0.96875	0.96875	0.9375	0.939393939	0.909090909	0.939393939	0.939393939
8	0.969696967	0.96875	1	0.9375	0.96875	1	0.969696967	1	1
9	0.909090909	1	0.96875	0.90625	0.9375	0.939393939	0.909090909	0.939393939	0.939393939
10	0.969696967	0.9375	0.96875	0.90625	0.9375	1	0.969696967	1	1
11	0.969696967	0.9375	0.96875	0.90625	1	0.939393939	0.969696967	0.939393939	0.939393939
12	1	0.96875	1	0.9375	0.96875	0.969696967	1	0.969696967	0.969696967
13	1	0.96875	1	0.9375	0.96875	0.969696967	1	0.969696967	0.969696967

**Tab. E.12.:** Resultado de la métrica exactitud para el movimiento de flexión

Valor de la métrica exactitud para el movimiento neutro									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.878787879	0.96875	0.9375	0.96875	0.90625	0.909090909	0.909090909	0.909090909	0.909090909
2	0.969696967	0.96875	1	0.90625	0.90625	1	1	1	1
3	0.969696967	0.96875	0.9375	0.96875	0.90625	0.969696967	0.939393939	0.939393939	0.939393939
4	0.969696967	0.96875	0.9375	0.96875	0.90625	1	1	1	1
5	0.939393939	1	0.96875	0.9375	0.9375	0.969696967	0.969696967	0.969696967	0.969696967
6	0.939393939	1	0.96875	0.9375	0.9375	0.969696967	0.969696967	0.969696967	0.969696967
7	0.939393939	0.96875	0.9375	0.96875	0.90625	0.969696967	0.969696967	0.969696967	0.969696967
8	0.969696967	1	0.96875	0.9375	0.9375	1	1	1	1
9	0.939393939	1	0.96875	0.9375	0.9375	0.969696967	0.969696967	0.969696967	0.969696967
10	0.969696967	0.96875	0.9375	0.90625	0.90625	1	1	1	1
11	0.969696967	0.96875	0.9375	0.90625	0.96875	0.939393939	0.939393939	0.939393939	0.939393939
12	1	1	0.96875	0.9375	0.9375	0.969696967	0.969696967	0.969696967	0.969696967
13	1	1	0.96875	0.9375	0.9375	0.969696967	0.969696967	0.969696967	0.969696967

**Tab. E.13.:** Resultado de la métrica exactitud para el movimiento neutro

Valor de la métrica exactitud para el movimiento radial									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.939393939	0.96875	0.9375	0.96875	0.875	0.939393939	0.939393939	0.939393939	0.939393939
2	0.969696967	1	0.96875	1	0.90625	0.969696967	0.969696967	0.969696967	0.969696967
3	0.969696967	0.9375	0.90625	0.9375	0.84375	0.969696967	0.969696967	0.969696967	0.969696967
4	1	0.96875	0.9375	0.96875	0.875	1	1	1	1
5	0.909090909	0.9375	0.90625	0.9375	0.90625	0.909090909	0.909090909	0.909090909	0.909090909
6	1	0.96875	0.9375	0.96875	0.875	1	1	1	1
7	1	0.96875	0.9375	0.96875	0.875	1	1	1	1
8	1	0.96875	0.9375	0.96875	0.875	1	1	1	1
9	0.969696967	0.96875	0.9375	0.96875	0.875	0.969696967	0.969696967	0.969696967	0.969696967
10	1	0.96875	0.9375	0.96875	0.875	1	1	1	1
11	0.969696967	0.96875	0.9375	0.96875	0.875	0.969696967	0.969696967	0.969696967	0.969696967
12	1	0.96875	0.9375	0.96875	0.875	1	1	1	1
13	1	0.96875	0.9375	0.96875	0.875	1	1	1	1

**Tab. E.14.:** Resultado de la métrica exactitud para el movimiento radial

Valor de la métrica exactitud para el movimiento ulnar									
Registro	CG	MAV	VAR	RMS	WL	CG-MAV	CG-VAR	CG-RMS	CG-WL
1	0.969696967	0.96875	0.9375	1	0.9375	0.969696967	0.909090909	0.939393939	0.939393939
2	0.969696967	0.9375	0.90625	0.96875	0.90625	0.969696967	0.909090909	0.939393939	0.939393939
3	0.969696967	0.9375	0.90625	0.96875	0.90625	1	0.909090909	0.939393939	0.939393939
4	1	0.96875	0.9375	1	0.9375	0.939393939	0.939393939	0.969696967	0.969696967
5	0.939393939	0.9375	0.90625	0.96875	0.96875	1	0.878787879	0.909090909	0.909090909
6	1	0.96875	0.9375	1	0.9375	1	0.939393939	0.969696967	0.969696967
7	1	0.96875	0.9375	1	0.9375	1	0.939393939	0.969696967	0.969696967
8	1	0.96875	0.9375	1	0.9375	1	0.939393939	0.969696967	0.969696967
9	1	0.96875	0.9375	1	0.9375	1	0.939393939	0.969696967	0.969696967
10	1	0.96875	0.9375	1	0.9375	0.969696967	0.939393939	0.969696967	0.969696967
11	0.969696967	0.96875	0.9375	1	0.9375	1	0.909090909	0.939393939	0.939393939
12	1	0.96875	0.9375	1	0.9375	1	0.939393939	0.969696967	0.969696967
13	1	0.96875	0.9375	1	0.9375	1	0.939393939	0.969696967	0.969696967

**Tab. E.15.:** Resultado de la métrica exactitud para el movimiento ulnar

# Bibliografía

- [1] Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., & Kudlur, M. (2016). Tensorflow: A system for large-scale machine learning. In *12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16)* (pp. 265-283).
- [2] Adamovich, S. V., Merians, A. S., Boian, R., Lewis, J. A., Tremaine, M., Burdea, G. S., & Poizner, H. (2005). A virtual reality—based exercise system for hand rehabilitation post-stroke. *Presence: Teleoperators & Virtual Environments*, *14*(2), 161-174.
- [3] Adewuyi, A. A., Hargrove, L. J., & Kuiken, T. A. (2017). Resolving the effect of wrist position on myoelectric pattern recognition control. *Journal of neuroengineering and rehabilitation*, *14*(1), 39.
- [4] Berlin, E., Liu, J., Van Laerhoven, K., & Schiele, B. (2010, January). Coming to grips with the objects we grasp: detecting interactions with efficient wrist-worn sensors. In *Proceedings of the fourth international conference on Tangible, embedded, and embodied interaction* (pp. 57-64). ACM.
- [5] Bonato, P. (2005). Advances in wearable technology and applications in physical medicine and rehabilitation.
- [6] Castanedo, F. (2013). A review of data fusion techniques. *The Scientific World Journal*, 2013.
- [7] Castellini, C., & Koiva, R. (2012, June). Using surface electromyography to predict single finger forces. In *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)* (pp. 1266-1272). IEEE.
- [8] Connan, M., Ruiz Ramírez, E., Vodermayr, B., & Castellini, C. (2016). Assessment of a wearable force-and electromyography device and comparison of the related signals for myocontrol. *Frontiers in neurorobotics*, *10*, 17.
- [9] Covarrubias, M., Bordegoni, M., Rosini, M., Guanziroli, E., Cugini, U., & Molteni, F. (2015, November). VR system for rehabilitation based on hand gestural and olfactory interaction. In *Proceedings of the 21st ACM Symposium on Virtual Reality Software and Technology* (pp. 117-120). ACM.
- [10] Dementyev, A., & Paradiso, J. A. (2014, October). WristFlex: low-power gesture input with wrist-worn pressure sensors. In *Proceedings of the 27th annual ACM symposium on User interface software and technology* (pp. 161-166). ACM.
- [11] Elmenreich, W. (2002). An introduction to sensor fusion. *Vienna University of Technology, Austria*, 502.
- [12] Fougner, A., Scheme, E., Chan, A. D., Englehart, K., & Stavdahl. (2011). Resolving the limb position effect in myoelectric pattern recognition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *19*(6), 644-651.

- [13] Fukui, R., Watanabe, M., Gyota, T., Shimosaka, M., & Sato, T. (2011, September). Hand shape classification with a wrist contour sensor: development of a prototype device. In *Proceedings of the 13th international conference on Ubiquitous computing* (pp. 311-314). ACM.
- [14] Géron, A. (2017). Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems. "O'Reilly Media, Inc."
- [15] Gobee, S., Durairajah, V., & Mohammadullah, N. (2017, September). Portable soft-exoskeleton for finger rehabilitation. In *Proceedings of the 2017 International Conference on Biomedical Engineering and Bioinformatics* (pp. 65-70). ACM.
- [16] Herrera-Luna, I., Rechy-Ramirez, E. J., Rios-Figueroa, H. V., & Marin-Hernandez, A. (2019). Sensor Fusion Used in Applications for Hand Rehabilitation: A Systematic Review. *IEEE Sensors Journal*, 19(10), 3581-3592.
- [17] Herrmann, S., & Buchenrieder, K. (2010, July). Fusion of myoelectric and near-infrared signals for prostheses control. In *Proceedings of the 4th International Convention on Rehabilitation Engineering & Assistive Technology* (p. 54). Singapore Therapeutic, Assistive & Rehabilitative Technologies (START) Centre.
- [18] Huang, M. C., Chen, E., Xu, W., & Sarrafzadeh, M. (2011, October). Gaming for upper extremities rehabilitation. In *Proceedings of the 2nd Conference on Wireless Health* (p. 27). ACM.
- [19] Jack, D., Boian, R., Merians, A. S., Tremaine, M., Burdea, G. C., Adamovich, S. V., & Poizner, H. (2001). Virtual reality-enhanced stroke rehabilitation. *IEEE transactions on neural systems and rehabilitation engineering*, 9(3), 308-318.
- [20] Kmet, L. M., Cook, L. S., & Lee, R. C. (2004). Standard quality assessment criteria for evaluating primary research papers from a variety of fields.
- [21] Kozlovsky, M., Bogdanov, P., Karóckai, K., Garaguly, G., & Kronreif, G. (2018, May). IMU based human movement tracking. In *2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)* (pp. 0240-0244). IEEE.
- [22] Landgraf, M., Yoo, I. S., Sessner, J., Mooser, M., Kaufmann, D., Mattejat, D., & Franke, J. (2018, August). Gesture recognition with sensor data fusion of two complementary sensing methods. In *2018 7th IEEE International Conference on Biomedical Robotics and Biomechatronics (Biorob)* (pp. 795-800). IEEE.
- [23] LeCun, Y. A., Bottou, L., Orr, G. B., & Müller, K. R. (2012). Efficient backprop. In *Neural networks: Tricks of the trade* (pp. 9-48). Springer, Berlin, Heidelberg.
- [24] Lee, B. J., Williams, A., & Ben-Tzvi, P. (2018). Intelligent object grasping with sensor fusion for rehabilitation and assistive applications. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(8), 1556-1565.
- [25] Lin, B. S., Lee, I., Yang, S. Y., Lo, Y. C., Lee, J., & Chen, J. L. (2018). Design of an inertial-sensor-based data glove for hand function evaluation. *Sensors*, 18(5), 1545.
- [26] Lipovský, R., & Ferreira, H. A. (2015, October). Self hand-rehabilitation system based on wearable technology. In *Proceedings of the 3rd 2015 Workshop on ICTs for improving Patients Rehabilitation Research Techniques* (pp. 93-95). ACM.
- [27] Luo, R. C., Yih, C. C., & Su, K. L. (2002). Multisensor fusion and integration: approaches, applications, and future research directions. *IEEE Sensors journal*, 2(2), 107-119.



- [28] Ma, X., Tu, X., Huang, J., & He, J. (2011, December). A cyber-physical system based framework for motor rehabilitation after stroke. In *Proceedings of the 1st International Conference on Wireless Technologies for Humanitarian Relief* (pp. 285-290). ACM.
- [29] Markovic, M., Dosen, S., Popovic, D., Graimann, B., & Farina, D. (2015). Sensor fusion and computer vision for context-aware control of a multi degree-of-freedom prosthesis. *Journal of neural engineering*, 12(6), 066022.
- [30] Mowrer, H. T., & Congalton, R. G. (Eds.). (2003). Quantifying spatial uncertainty in natural resources: theory and applications for GIS and Remote Sensing. CRC Press.
- [31] Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. G. (2009). Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *Annals of internal medicine*, 151(4), 264-269.
- [32] Moital, A. R., Dogramadzi, S., & Ferreira, H. A. (2015, October). Development of an EMG controlled hand exoskeleton for post-stroke rehabilitation. In *Proceedings of the 3rd 2015 Workshop on ICTs for improving Patients Rehabilitation Research Techniques* (pp. 66-72). ACM.
- [33] Moore, A. J., & Newell, D. W. (Eds.). (2010). *Tumor Neurosurgery: Principles and Practice*. Springer Science & Business Media.
- [34] Moschetti, A., Fiorini, L., Esposito, D., Dario, P., & Cavallo, F. (2016). Recognition of daily gestures with wearable inertial rings and bracelets. *Sensors*, 16(8), 1341.
- [35] Mukhopadhyay, S. C. (2014). Wearable sensors for human activity monitoring: A review. *IEEE sensors journal*, 15(3), 1321-1330.
- [36] Anindya Nag, Subhas Chandra M. & Jürgen K. Wearable flexible sensors: A review. *IEEE Sensors Journal* 17.13 (2017), págs. 3949-3960.
- [37] Arne Passon, Thomas Schauer & Thomas Seel. Hybrid Inertial-Robotic Motion Tracking for Posture Biofeedback in Upper Limb Rehabilitation“. (2018) 7th IEEE International Conference on Biomedical Robotics and Biomechatronics (Biorob). IEEE. 2018, págs. 1163-1168.
- [38] Patil, Y., Sarris, M., Gunter, M., & Averette, L. (2016, October). Planet 10: A space odyssey. In *Proceedings of the 2016 Annual Symposium on Computer-Human Interaction in Play Companion Extended Abstracts* (pp. 67-70). ACM.
- [39] Penelle, B., & Debeir, O. (2014, April). Multi-sensor data fusion for hand tracking using Kinect and Leap Motion. In *Proceedings of the 2014 Virtual Reality International Conference* (p. 22). ACM.
- [40] Qingyun, M., Qiaoling, M., Hongliu, Y., Wujing, C., & Ming, Z. (2016, December). A real-time force-displacement detection and evaluation system for wearable hand exoskeleton based on multi-sensors. In *2016 8th International Conference on Information Technology in Medicine and Education (ITME)* (pp. 39-43). IEEE.
- [41] Rechy-Ramirez, E. J., Marin-Hernandez, A., & Rios-Figueroa, H. V. (2018). Impact of commercial sensors in human computer interaction: a review. *Journal of Ambient Intelligence and Humanized Computing*, 9(5), 1479-1496.
- [42] Schomaker, L., Nijtmans, J., Camurri, A., Lavagetto, F., Morasso, P., Benoît, C., ... & Defée, I. (1995). A taxonomy of multimodal interaction in the human information processing system. *Report of the ESPRIT project*, 8579.

- [43] Standring, S. (Ed.). (2015). *Gray's anatomy e-book: the anatomical basis of clinical practice*. Elsevier Health Sciences.
- [44] Strohmeier, P., Vertegaal, R., & Girouard, A. (2012, February). With a flick of the wrist: stretch sensors as lightweight input for mobile devices. In *Proceedings of the Sixth International Conference on Tangible, Embedded and Embodied Interaction*(pp. 307-308). ACM.
- [45] Tong, R. K., Leung, W. W., Hu, X. L., & Song, R. (2009, April). Interactive robot-assisted training system using continuous EMG signals for stroke rehabilitation. In *Proceedings of the 3rd International Convention on Rehabilitation Engineering & Assistive Technology* (p. 20). ACM.
- [46] White, F. E. (1991). *Data fusion lexicon*. Joint Directors of Labs Washington DC.
- [47] Wilson, S., & Vaidyanathan, R. (2017, July). Upper-limb prosthetic control using wearable multichannel mechanomyography. In *2017 International Conference on Rehabilitation Robotics (ICORR)* (pp. 1293-1298). IEEE.
- [48] Xiao, N., Xu, H., Gao, B., Guo, S., Ma, H., & Zhou, F. (2017, August). Characteristics evaluation of a rehabilitation robot for upper limbs. In *2017 IEEE International Conference on Mechatronics and Automation (ICMA)* (pp. 990-994). IEEE.
- [49] Yu, N., Xu, C., Li, H., Wang, K., Wang, L., & Liu, J. (2016). Fusion of haptic and gesture sensors for rehabilitation of bimanual coordination and dexterous manipulation. *Sensors*, 16(3), 395.
- [50] Zhang, X., Wang, Y., & Cheng, Z. (2007, November). An EEG based approach for pattern recognition of precise hand activities with data fusion technology. In *IECON 2007-33rd Annual Conference of the IEEE Industrial Electronics Society* (pp. 2423-2428). IEEE.
- [51] Michael Zyda. (2005). From visual simulation to virtual reality to games. *En: Computer* 38.9, págs. 25-32.

# Índice de figuras

2.1	Secuencia del protocolo PRISMA. . . . .	8
2.2	Parámetros de estudio para los artículos de búsqueda. . . . .	9
2.3	Número de publicaciones por año en las tres categorías. . . . .	10
2.4	Porcentaje obtenido del QualSyst, incluyendo el porcentaje mayor, el menor y la media para cada categoría. . . . .	10
2.5	Movimientos para rehabilitación en manos reportados por la literatura. Imagen tomada de [16]. . . . .	11
2.6	Frecuencia de estudios por movimiento de mano. . . . .	11
2.7	Beneficios de la fusión de sensores . . . . .	13
2.8	Etapa de fusión de sensores basado en los niveles de abstracción de los datos y sensores fusionados. (M) mediciones, (E) extracción de características y (C) decisión / clasificación. . . . .	14
2.9	Porcentaje de niveles de fusión por cada categoría. . . . .	15
3.1	Sistema de coordenadas del sensor Leap motion para describir las posiciones de las manos en el espacio. . . . .	18
3.2	Sensor Myo armband con sus electrodos categorizados. . . . .	18
3.3	Diagrama del flujo datos de una red neuronal en TensorFlow. . . . .	19
3.4	Movimientos de manos usados en rehabilitación en esta investigación. . . . .	19
3.5	Modalidades implementadas en la investigación. . . . .	20
3.6	Registro de una señal EMG, segmentada en ventanas adyacentes y superpuestas. . . . .	22
3.7	Estructura general de la red neuronal. . . . .	23
3.8	Función ReLu y función Softmax . . . . .	24
3.9	a) Diagrama general del desarrollo experimental. b) Posición del Myo a un 70 % de distancia entre la muñeca y el codo, además se midió la circunferencia del antebrazo respecto a la posición del Myo. c) Diseño experimental montado. . . . .	27
4.1	Diagrama de las etapas de implementación para la modalidad de características geométricas (CG). . . . .	29
4.2	a) Identificación del ángulo $\theta$ y el vector $\vec{F}_y$ para el reconocimiento de los movimientos de extensión y flexión. b) Identificación del ángulo $\phi$ para el reconocimiento de los movimientos radial y ulnar. . . . .	31

4.3	Registro de una señal CG segmentada mediante ventanas adyacentes de $250ms$ en un intervalo entre $500ms - 1500ms$ . . . . .	32
4.4	a) Estructura de la RNA para la clasificación de la señal CG. b) Mediante la RNA ya entrenada, se evalúan los registros para medir el desempeño de la RNA. . . . .	33
4.5	Matriz de confusión para el primer usuario en la modalidad CG. . . . .	35
4.6	Promedio de los registros para cada una de las métricas, correspondiente en la modalidad de características geométricas. (CG). . . . .	36
5.1	Diagrama de las etapas de implementación para las modalidades MAV, VAR, RMS y WL basada en señales electromiográficas. . . . .	37
5.2	Registro de una señal EMG segmentada mediante ventanas adyacentes de $250ms$ en un intervalo entre $500ms - 1500ms$ . . . . .	38
5.3	Extracción de características para un registro de una señal EMG. . . . .	40
5.4	a) Estructura de la RNA para la clasificación de la señal EMG. b) Mediante la RNA ya entrenada, se evalúan los registros para medir el desempeño de la RNA. . . . .	41
5.5	Matrices de confusión para cada característica correspondientes al primer usuario. . . . .	43
5.6	Promedio de los registros para cada una de las métricas, correspondiente a las características de la modalidad EMG. . . . .	45
6.1	Diagrama de las etapas de implementación para la fusión de las señales EMG Y CG). . . . .	48
6.2	Segmentación de las señales EMG y CG en ventanas adyacentes de $250ms$ para un tiempo $t = 1s$ . . . . .	49
6.3	a) Estructura de la RNA para la clasificación de la fusión de las señales EMG y CG. b) Mediante la RNA ya entrenada, se evalúan los registros <i>DBValFeatureCG-UserN.csv</i> para medir el desempeño de la RNA. . . . .	50
6.4	Matrices de confusión para cada modalidad correspondientes al primer usuario. . . . .	52
6.5	Promedio de los registros para cada una de las métricas, correspondiente a la fusión de las modalidades CG y EMG. . . . .	53
7.1	Promedio de cada métrica para el movimiento de extensión. . . . .	57
7.2	Promedio de cada métrica para el movimiento de flexión. . . . .	59
7.3	Promedio de cada métrica para el movimiento neutro. . . . .	61
7.4	Promedio de cada métrica para el movimiento radial. . . . .	63
7.5	Promedio de cada métrica para el movimiento ulnar. . . . .	64
7.6	Promedio general para cada característica y la fusión de ellas, considerando las métricas y los movimientos. . . . .	66
A.1	Test de Edimburgo para determinar la lateralidad del usuario . . . . .	71

# Índice de cuadros

4.1	Características geométricas correspondientes a cada movimiento. . . .	31
4.2	Ejemplo de los valores de los componentes $F_y, \theta$ y $\phi$ para una ventana de 250ms. . . . .	32
4.3	Parámetros de la RNA para la clasificación de los registros de la señal CG. . . . .	34
4.4	Promedio de las métricas para los 13 registros. . . . .	36
5.1	Parámetros de las RNAs para la clasificación de los registros de la señal EMG. Para todas las modalidades la estructura es la misma. . . . .	41
5.2	Promedio de las métricas para los 13 registros con la característica MAV. . . . .	43
5.3	Promedio de las métricas para los 13 registros con la característica VAR. . . . .	43
5.4	Promedio de las métricas para los 13 registros con la característica RMS. . . . .	44
5.5	Promedio de las métricas para los 13 registros con la característica WL. . . . .	44
6.1	Parámetros de las RNAs para la clasificación de los registros de las señales EMG y CG. Para todas las combinaciones de características la estructura es la misma. . . . .	49
6.2	Promedio de las métricas para los 13 registros con la fusión de características CG-MAV. . . . .	51
6.3	Promedio de las métricas para los 13 registros con la fusión de características CG-VAR. . . . .	52
6.4	Promedio de las métricas para los 13 registros con la fusión de características CG-RMS. . . . .	52
6.5	Promedio de las métricas para los 13 registros con la fusión de características CG-WL. . . . .	53
7.1	Resultado de la métrica sensibilidad para el movimiento de extensión. . . . .	56
7.2	Promedio de las métricas para el movimiento de extensión. . . . .	59
7.3	Promedio de las métricas para el movimiento de flexión. . . . .	60
7.4	Promedio de las métricas para el movimiento neutro. . . . .	62
7.5	Promedio de las métricas para el movimiento radial. . . . .	64
7.6	Promedio de las métricas para el movimiento ulnar. . . . .	66
E.1	Resultado de la métrica sensibilidad para el movimiento de extensión. . . . .	83
E.2	Resultado de la métrica sensibilidad para el movimiento de flexión . . . . .	83

E.3	Resultado de la métrica sensibilidad para el movimiento neutro . . . .	83
E.4	Resultado de la métrica sensibilidad para el movimiento de radial . . .	84
E.5	Resultado de la métrica sensibilidad para el movimiento de ulnar . . .	84
E.6	Resultado de la métrica especificidad para el movimiento de extensión	84
E.7	Resultado de la métrica especificidad para el movimiento de flexión . .	84
E.8	Resultado de la métrica especificidad para el movimiento de neutro . .	85
E.9	Resultado de la métrica especificidad para el movimiento radial . . . .	85
E.10	Resultado de la métrica especificidad para el movimiento ulnar . . . .	85
E.11	Resultado de la métrica exactitud para el movimiento de extensión . .	85
E.12	Resultado de la métrica exactitud para el movimiento de flexión . . . .	86
E.13	Resultado de la métrica exactitud para el movimiento neutro . . . . .	86
E.14	Resultado de la métrica exactitud para el movimiento radial . . . . .	86
E.15	Resultado de la métrica exactitud para el movimiento ulnar . . . . .	86