UNIVERSIDAD POLITÉCNICA DE MADRID

ESCUELA TÉCNICA SUPERIOR
DE INGENIEROS DE TELECOMUNICACIÓN

GRADO EN INGENIERÍA BIOMÉDICA

TRABAJO FIN DE GRADO

# DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE ANÁLISIS AUTOMÁTICO DE LA CINEMÁTICA DE LA MANO EN PACIENTES CON ICTUS

LAURA PASCUAL HEBRERO

2022

UNIVERSIDAD POLITÉCNICA DE MADRID

ESCUELA TÉCNICA SUPERIOR
DE INGENIEROS DE TELECOMUNICACIÓN

GRADO EN INGENIERÍA BIOMÉDICA

TRABAJO FIN DE GRADO

# DISEÑO E IMPLEMENTACIÓN DE UN SISTEMA DE ANÁLISIS AUTOMÁTICO DE LA CINEMÁTICA DE LA MANO EN PACIENTES CON ICTUS

Autora
LAURA PASCUAL HEBRERO

Tutores

MARÍA ALONSO DE LECIÑANA CASES
ÁLVARO GUTIÉRREZ MARTÍN

2022

## Resumen

La medición objetiva de los déficits causados en personas que han sufrido un ictus es fundamental para optimizar los tratamientos de rehabilitación, monitorizar la respuesta a los mismos y así contribuir a maximizar la recuperación funcional de los pacientes.

Este Trabajo de Fin de Grado propone un sistema de medición de variables cinemáticas del movimiento de la mano. Para ello, se graba con un móvil la repetición de cuatro ejercicios o movimientos básicos de la mano: extensión de la muñeca, pinza de los dedos índice y pulgar, separación lateral de los dedos y apertura y cierre del puño. Para poder grabar los vídeos desde la vista superior, se diseña y construye una estructura con la que grabarlos a una distancia constante. Posteriormente, se graban los ejercicios propuestos con voluntarios. Con estos vídeos se entrenan redes neuronales artificiales en DeepLabCut, herramienta basada en aprendizaje profundo. Con las redes entrenadas se analizan nuevos vídeos, obteniendo una estimación de la posición de las partes de la mano designadas en la red.

A partir de la estimación de la posición, tras filtrar las trayectorias se calculan parámetros cinemáticos comunes en el estudio del miembro superior en pacientes de ictus: distancias, ángulos, velocidades y tiempos de realización del movimiento. Finalmente, se analiza la calidad de las variables obtenidas mediante el estudio de los valores medios, desviación estándar así como la comparativa entre las medidas cinemáticas de la mano derecha e izquierda de cada voluntario.



**Palabras clave:** Ictus, DeepLabCut, medición objetiva, cinemática, mano

## Abstract

An objective measurement of impairments caused due to stroke disease is a key point, in order to optimize the rehabilitation's plans, assess its follow-up and maximize functional recovery in those patients.

This Final Degree Project proposes a system that measures hand's kinematic metrics. To do this, a mobile phone is used to record the repetition of four basic hand exercises or movements: extension of the wrist, grip of the index finger and thumb, lateral separation of the fingers and opening and closing of the fist. In order to record the videos from the top view, a structure is designed and built to record them at a constant distance. Subsequently, the proposed exercises are recorded with volunteers. These videos are used to train artificial neural networks in DeepLabCut, a deep learning based tool. The trained networks are used to analyse new videos, obtaining an estimate of the position of the parts of the hand designated in the network.

From the pose estimation, after filtering the trajectories, kinematic parameters common in the study of the upper limb in stroke patients are calculated: distances, angles, velocities and movement times. Finally, the quality of the variables obtained is analysed by studying the mean values, standard deviation and the comparison between the kinematic measurements of the right and left hand of each volunteer.



**Keywords:** Stroke, DeepLabCut, objective measurement, kinematics, hand

## Agradecimientos

En primer lugar, me gustaría agradecer a mis tutores María Alonso y Álvaro Gutiérrez que me dieran la oportunidad de formar parte de este proyecto, ha sido una experiencia muy enriquecedora e ilusionante. Gracias por vuestra ayuda y guía durante estos meses.

También me gustaría agradecer a Miguel Gómez de Robolabo, Ana Fuster del servicio de Rehabilitación y David López del HULP, su ayuda también ha hecho posible este trabajo.

Asimismo quisiera mencionar y agradecer a mi familia, en especial a mis padres, por ser mi ejemplo a seguir e inculcarme el aprender como un privilegio que disfrutar y aprovechar. A mis amigos, por escuchar mis preocupaciones cuando lo he necesitado, es un placer poder compartir tanto las celebraciones como las preocupaciones con vosotros.

Finalmente, me gustaría expresar mi agradecimiento a todos los voluntarios que cedieron parte de su tiempo a este proyecto, gracias a ellos es posible.

# Índice general

**Resumen** v

**Abstract** vii

**Agradecimientos** ix

**Índice General** xi

**Índice de Figuras** xiii

**Índice de Tablas** xv

**Lista de Acrónimos** xvii

**1. Introducción** 1
- 1.1. Ictus . . . 1
  - 1.1.1. Secuelas tras un ictus y Rehabilitación . . . 2
  - 1.1.2. Evaluación del Déficit . . . 3
- 1.2. Objetivos . . . 5
- 1.3. Organización del documento . . . 5

**2. Estado del arte** 7
- 2.1. Captura del Movimiento . . . 7
- 2.2. Redes Neuronales y Aprendizaje Profundo . . . 8
- 2.3. Estimación de la Posición con Captura Óptica y Redes Neuronales . . . 9

**3. Metodología** 11
- 3.1. Captura del Movimiento . . . 12
  - 3.1.1. Selección de ejercicios a realizar para la captura del movimiento 12
  - 3.1.2. Creación de la estructura . . . 14
  - 3.1.3. Recogida de vídeos y datos clínicos y demográficos de los sujetos participantes . . . 17
- 3.2. DeepLabCut . . . 18
  - 3.2.1. Preprocesado y Etiquetado . . . 19
  - 3.2.2. Entrenamiento y Refinamiento . . . 21
  - 3.2.3. Evaluación y Análisis de vídeos . . . 22
- 3.3. Análisis cinemático . . . 24
  - 3.3.1. Filtrado . . . 24

3.3.2. Extracción de variables . . . . . 26
3.3.2.1. Ejercicio 1 . . . . . 27
3.3.2.2. Ejercicio 2 . . . . . 27
3.3.2.3. Ejercicio 3 . . . . . 28
3.3.2.4. Ejercicio 4 . . . . . 28

**4. Resultados** **31**
4.1. Evaluación de las redes . . . . . 31
4.2. Variables cinemáticas . . . . . 33
4.2.1. Media de las variables cinemáticas . . . . . 36
4.2.1.1. Ejercicio 1 . . . . . 36
4.2.1.2. Ejercicio 2 . . . . . 37
4.2.1.3. Ejercicio 3 . . . . . 38
4.2.1.4. Ejercicio 4 . . . . . 40
4.2.2. Evaluación de las variables cinemáticas . . . . . 40
4.2.3. Distancias normalizadas . . . . . 42
4.3. Vídeos de pacientes . . . . . 44

**5. Conclusiones** **45**
5.1. Conclusiones . . . . . 45
5.2. Líneas futuras . . . . . 45

**Bibliografía** **47**

**A. Aspectos éticos, económicos, sociales y ambientales** **53**
A.1. Impactos y aspectos del trabajo . . . . . 53
A.2. Conclusiones . . . . . 54

**B. Presupuesto económico** **55**

**C. Datos recogidos en REDCap** **59**

**D. Tablas de *likelihood*** **63**

# Índice de figuras

1.1. Tipos de ECV . . . . . 2

2.1. Tecnologías de captura del movimiento . . . . . 8
2.2. Comparación de flujos de trabajo con y sin vídeos. . . . . 9

3.1. Flujo de trabajo (metodología). . . . . 12
3.2. Ejercicio 1. *(a)* Mínima extensión y *(b)* máxima extensión. . . . . 13
3.3. Ejercicio 2. *(a)* Apertura y *(b)* cierre de la pinza. . . . . 13
3.4. Ejercicio 3. *(a)* Unión y *(b)* separación de los dedos. . . . . 13
3.5. Ejercicio 4. *(a)* Apertura y *(b)* cierre del puño. . . . . 14
3.6. Diseño de la estructura de soporte (vistas). . . . . 15
3.7. Diseño de la funda para el móvil (vistas). . . . . 15
3.8. Embellecedor. *(a)* Modelo 3D y *(b)* piezas impresas. . . . . 16
3.9. Estructura de soporte para la grabación. . . . . 16
3.10. Soporte para brazos. *(a)* Modelo 3D y *(b)* pieza impresa. . . . . 17
3.11. Flujo de trabajo en DeepLabCut. . . . . 18
3.12. Flujo de trabajo de preprocesado y etiquetado de vídeos. . . . . 19
3.13. Proceso de rotación y recorte de vídeos. . . . . 19
3.14. Representación de las etiquetas. . . . . 20
3.15. Interfaz para el etiquetado. . . . . 21
3.16. Convergencia de la pérdida o *loss*. . . . . 22
3.17. Gráficos del análisis de vídeos con DeepLabCut. . . . . 23
3.18. *Likelihood* para la etiqueta *pinky* del voluntario DC30 . . . . . 24
3.19. Ejercicio 4 realizado por el voluntario DC30: etiquetas no visibles. . . . 25
3.20. Posición de *index* (eje x) en el tiempo. . . . . 25
3.21. Franjas de tiempo (etiqueta *index*) del ejercicio 2, voluntario DC30. . . 26

4.1. Errores de entrenamiento y evaluación de las redes . . . . . 32
4.2. Predicciones de DeepLabCut y etiquetas manuales . . . . . 32
4.3. Valor medio de los ángulos del ejercicio 1 . . . . . 36
4.4. Valor medio de las distancias del ejercicio 1 . . . . . 36
4.5. Valor medio de los tiempos del ejercicio 1 . . . . . 37
4.6. Valor medio de las velocidades del ejercicio 1 . . . . . 37
4.7. Valor medio de los ángulos del ejercicio 2 . . . . . 37
4.8. Valor medio de las distancias del ejercicio 2 . . . . . 38
4.9. Valor medio de los tiempos del ejercicio 2 . . . . . 38
4.10. Valor medio de las velocidades del ejercicio 2 . . . . . 38

4.11. Valor medio de los ángulos del ejercicio 3 . . . . . 39
4.12. Valor medio de las distancias del ejercicio 3 . . . . . 39
4.13. Valor medio de los tiempos del ejercicio 3 . . . . . 39
4.14. Valor medio de las velocidades del ejercicio 3 . . . . . 39
4.15. Valor medio de los ángulos del ejercicio 4 . . . . . 40
4.16. Valor medio de las distancias del ejercicio 4 . . . . . 40
4.17. Aperturas máximas y mínimas del ejercicio 3, DC33 y DC8 . . . . . 42
4.18. Ángulo FN_A_t_mMCP_p del ejercicio 3 . . . . . 43
4.19. Distancia FN_D_m_p y distancia normalizada . . . . . 43
4.20. Gráficas comparativas de manos sintomática y asintomática. . . . . 44

# Índice de tablas

1.1. Secuelas y complicaciones más frecuentes. . . . . 3

3.1. Materiales para la estructura. . . . . 14
3.2. Etiquetas empleadas . . . . . 20
3.3. Variables y etiquetas empleadas (ejercicio 1) . . . . . 27
3.4. Variables y etiquetas empleadas (ejercicio 2) . . . . . 28
3.5. Variables y etiquetas empleadas (ejercicio 3) . . . . . 28
3.6. Variables y etiquetas empleadas (ejercicio 4) . . . . . 29

4.1. Media de los valores de los controles en las variables del ejercicio 1. . . 33
4.2. Media de los valores de los controles en las variables del ejercicio 2. . . 34
4.3. Media de los valores de los controles en las variables del ejercicio 3. . . 35
4.4. Media de los valores de los controles en las variables del ejercicio 4. . . 35
4.5. Ratios derecha-izquierda de las variables cinemáticas . . . . . 41

B.1. Costes de personal. . . . . 55
B.2. Costes de recursos materiales. . . . . 56
B.3. Costes totales. . . . . 57

C.1. Cuestionario de datos demográficos. . . . . 59
C.2. Cuestionario de datos clínicos. . . . . 60
C.3. Cuestionario de datos de la exploración. . . . . 61

D.1. *Likelihood* media por ejercicio y etiqueta . . . . . 63

# Lista de Acrónimos

**AIT:** Ataque Isquémico Transitorio

**AVD:** Actividades de la Vida Diaria

**CNN:** Redes Neuronales Convolucionales (del inglés *Convolutional Neural Networks*)

**DLC:** DeepLabCut™

**ECV:** Enfermedades Cerebrovasculares

**GPU:** Unidad de Procesamiento Gráfico (del inglés *Graphics Processing Unit*)

**HULP:** Hospital Universitario La Paz

**NIHSS:** *National Institute of Health Stroke Scale*

**TFG:** Trabajo Fin de Grado

# Capítulo 1

# Introducción

## 1.1. Ictus

Las enfermedades cerebrovasculares (ECV) o ictus, hacen referencia al conjunto de patologías originadas por la alteración de la circulación sanguínea en el encéfalo. Su nombre, proveniente del latín, hace referencia a su naturaleza brusca o repentina. En estas enfermedades, el tiempo es un factor clave puesto que cada minuto que transcurre sin tratar el ictus, se pierden alrededor de 1,9 millones de neuronas [1].

Las enfermedades cerebrovasculares son la segunda causa de muerte en España y la primera causa de discapacidad adquirida en el adulto [2]. Además, el envejecimiento de la población alerta sobre la previsible subida de la incidencia del ictus [3]. El coste anual en España asociado a los nuevos casos de ictus asciende a 1.989 millones de euros [3].

Atendiendo a la naturaleza de la lesión, podemos clasificar estas enfermedades en dos grupos. Ictus isquémico, cuando el aporte circulatorio se ve comprometido, ya sea cualitativa o cuantitativamente. Los ictus isquémicos son los más frecuentes y representan aproximadamente el 80-85 % de los ictus. Ictus hemorrágico, si se produce la extravasación de la sangre en la cavidad craneal. Los ictus hemorrágicos suponen el 15-20 % de los ictus [4].

El ictus, engloba un rango heterogéneo de manifestaciones clínicas así como una etiología u origen de la enfermedad variado [5]. En la Figura 1.1, se muestran los tipos de ictus.

Dentro de los ictus isquémicos, podemos diferenciar el Ataque Isquémico Transitorio (AIT) como un episodio de disfunción neurológica transitoria cuyas manifestaciones duran menos de 24 horas y en el que no se produce la lesión irreversible (necrosis) del tejido por la isquemia. El infarto cerebral se produce cuando la pérdida del flujo sanguíneo cerebral regional produce la necrosis del tejido y esta un déficit neurológico persistente. Según la causa, distinguiremos seis tipos de ictus isquémico: aterotrombótico, cardioembólico, lacunar, de causa inhabitual, rara y de origen indeterminado por coexistencia de causas o criptogénico cuando tras un estudio exhaustivo no se encuentra ninguna causa [4].

Por otro lado, en el caso del ictus hemorrágico distinguiremos hemorragias subaracnoideas si la sangre se vierte al espacio subaracnoideo y hemorragias intra-

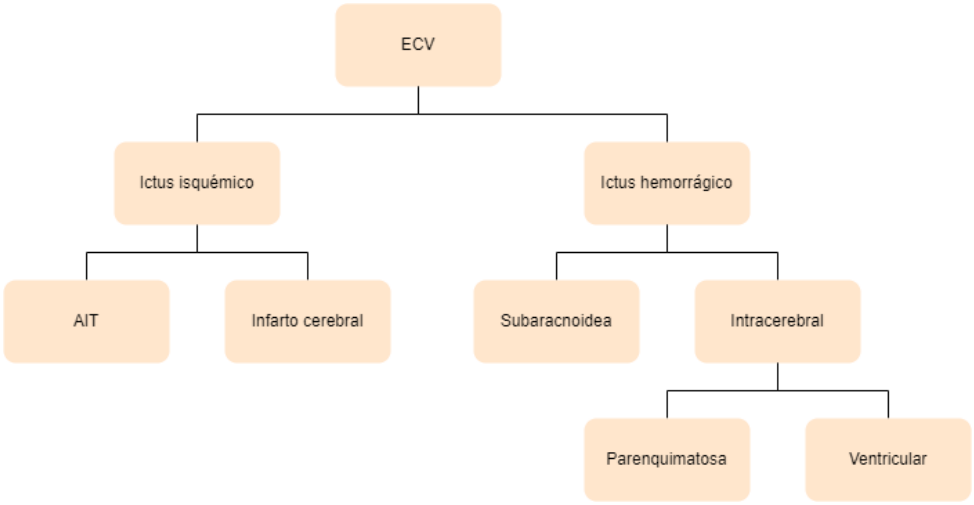


Figura 1.1: Tipos de ECV. Adaptado de [4, 6]

cerebrales si el fluido se acumula en el parénquima cerebral. En este segundo caso, clasificaremos la hemorragia en ventricular si la sangre se confina entre las paredes ventriculares o parenquimatosa, en cuyo caso diferenciaremos entre parenquimatosa lobular, profunda, troncoencefálica o cerebelosa según la localización. Los signos y síntomas variarán según la región afectada y el volumen de la hemorragia [4].

El tratamiento dependerá del tipo de ictus. La etiología determinará las medidas preventivas a tomar a posteriori [4].

### 1.1.1. Secuelas tras un ictus y Rehabilitación

De forma global, el 44 % de los pacientes que sufren un ictus presentan alguna secuela que les ocasiona diverso grado de dependencia funcional [7]. Los déficits neurológicos se engloban en seis áreas distintas: motora, sensitiva, visual, de lenguaje o comunicación, cognitiva o intelectual y emocional según la AHA-SOC (American Heart Association-Stroke Outcome Classification) [8].

Para reducir al máximo las secuelas, una vez se alcanza una etapa estable tras la fase aguda, se debe iniciar, lo antes posible, la rehabilitación [10]. En la fase subaguda, la rehabilitación puede tener lugar en los ámbitos hospitalario, ambulatorio, de atención domiciliaria o en centros o residencias de larga estancia [5]. En cualquier caso, la recuperación debe ser evaluada periódicamente para poder ajustar el tratamiento según los objetivos funcionales establecidos [5].

El mayor grado de recuperación tiene lugar en las primeras 6 semanas [11] y se debe a procesos endógenos de reparación y plasticidad neuronal. Pero la mejoría funcional se puede extender, hasta los 6 meses después del ictus, cuando la curva de recuperación alcanza una zona de meseta [10, 11]. Una vez pasado dicho periodo, los déficits se establecen y hablaremos de secuelas [10]. Las secuelas y complicaciones más frecuentes se detallan en la Tabla 1.1. Cabe señalar, que los déficits motores son los que tienen una mayor prevalencia y así como un mayor impacto negativo en la calidad de vida tras un ictus [8].

| Tipo | Secuelas |
|---|---|
| Físicas | Déficits motores totales o parciales |
| | Alteraciones sensitivas |
| | Alteraciones del lenguaje |
| | Fatiga |
| | Osteoporosis |
| | Dolor de hombro |
| | Caídas / fracturas |
| | Espasticidad |
| | Incontinencia urinaria |
| | Contracturas |
| | Subluxación del hombro hemipléjico |
| | Disfunción sexual |
| Anímicas | Depresión |
| | Ansiedad |
| Cognitivas | Demencia |
| | Déficits de atención |
| | Alteración de la memoria |
| Actividades diarias | Subir escaleras |
| | Vestirse |
| | Ir al baño |
| | Asearse |
| | Alimentarse |
| | Pasear |

Tabla 1.1: Secuelas y complicaciones más frecuentes. Adaptado de [9].

En particular, en un 60 % de los casos, se produce la afectación del miembro superior [12], siendo esta una de las discapacidades más frecuentes en esta población [13]. El déficit en el miembro superior y en particular en la mano, impacta notoriamente en la calidad de vida de las personas que lo sufren [14] y es por ello que se debe prestar atención a su estudio y cuantificación de forma sensible, sencilla y objetiva.

### 1.1.2. Evaluación del Déficit

Las escalas de valoración clínica permiten expresar los resultados de la exploración clínica de manera objetiva y cuantificable [10]. La evaluación de los pacientes con escalas clínicas validadas, tanto en la fase aguda de la enfermedad como en etapas posteriores permite graduar la gravedad del déficit, así como monitorizar la evolución y la eficacia de la rehabilitación [12, 13].

Existe un elevado número de escalas empleadas en el estudio del déficit neurológico. Se aconseja emplear una escala de déficit neurológico global junto a una escala de valoración de Actividades de la Vida Diaria (AVD). Para el déficit neurológico en

pacientes con ictus, la escala más utilizada es la *National Institute of Health Stroke Scale* (NIHSS). Consta de 11 apartados que evalúan distintos aspectos de la función neurológica. La puntuación global oscila entre 0 (sin sintomatología) y 42 puntos. No necesita equipamiento específico y su aplicación es rápida (alrededor de 6 minutos) [15]. Además, posee carácter predictivo [16, 17]. Ha sido demostrada su fiabilidad entre observadores, pudiendo ser estos tanto personal cualificado en neurología como no especializados (previo entrenamiento, para que la concordancia interobservador sea alta y la puntuación obtenida fiable) [15]. Las escalas de valoración de las AVD como el Índice de Barthel (dirigido a tareas o actividades específicas) o la Escala de Rankin modificada (valoración de la adaptación física y mental, a la vida cotidiana del paciente, teniendo en cuenta su estado previo al ictus) [18] nos dan una medida del nivel de independencia del paciente [10, 14, 15].

Sin embargo, pese a su utilidad contrastada, la escala NIHSS, así como otras escalas globales, no aporta información detallada sobre las distinas áreas funcionales. En particular, no es capaz de discriminar de forma precisa el déficit de la mano, especialmente cuando estos déficit son leves a moderados [10, 13, 15, 19], pudiendo incluso existir limitaciones funcionales en la mano en pacientes que obtienen una puntuación de 0 en la escala NIHSS [13, 19].

Para la exploración del déficit de regiones o áreas funcionales concretas se usan escalas más complejas como la escala Fugl Meyer, que engloba la función motora, equilibrio, sensibilidad, rango de movimiento y dolor articular en 113 apartados. Sin embargo, su aplicación global es lenta y compleja, por lo que se puede dividir por áreas de interés, empleando por ejemplo la sección para la extremidad superior y la sección específica de la mano [10, 20, 21]. Sin embargo estas escalas tampoco son suficientemente precisas para la cuantificación del déficit y están sujetas a la subjetividad del explorador.

También se recomienda la valoración de la espasticidad (aumento del tono muscular normal [22]), puesto que esta repercute en la función motora y la coordinación [10]. Para su valoración, la escala más utilizada es la escala modificada de Ashworth [22, 23]. El grado de deformidad de la mano y la muñeca, debido a la espasticidad, se puede clasificar con la clasificación de Zancolli [10, 24]. Además de la espasticidad, la pérdida de sensibilidad debe ser tenida en cuenta en la terapia de rehabilitación [10].

El estudio de la funcionalidad de la mano es, por tanto, complejo y se debe evaluar desde diferentes perspectivas. Esta evaluación puede considerar uno o más de los siguientes aspectos, aunque de manera óptima se deberían considerar todos ellos: valoración funcional global, destreza o coordinación, fuerza muscular de presión y pinzas manuales, rango de movimiento o amplitud articular y evaluación de la función sensorial. Además, algunos estudios apoyan la valoración de la percepción de autoeficacia [25, 26].

Se hace necesario, por tanto, investigar y generar sistemas de evaluación objetiva del movimiento basados en la cinemática [12, 27]. El uso de herramientas de captura óptica en combinación con redes neuronales artificiales e inteligencia artificial en general, nos ofrece una nueva manera de estudiar la funcionalidad de la mano, incluso permitiendo detectar pequeños cambios no perceptibles por las escalas clínicas tradicionales [28].

Si bien, los primeros sistemas desarrollados para la estimación de la posición requerían de herramientas específicas así como un lugar dedicado a la grabación del movimiento de los sujetos con marcadores físicos en los puntos de interés (lo que conllevaba un elevado coste así como podía influir en los resultados), los avances en los algoritmos de aprendizaje profundo o *deep learning* han permitido generar herramientas de estimación basadas en vídeo sin necesidad de marcadores [29, 30].

Con todo lo expuesto, este Trabajo de Fin de Grado (TFG) surge con la motivación de avanzar en el abordaje y diseño de la solución a dicha problemática, gracias a la colaboración del Laboratorio de Robótica y Control (Robolabo) de la Escuela Técnica Superior de Ingenieros de Telecomunicación de la Universidad Politécnica de Madrid y el Servicio de Neurología del Hospital Universitario La Paz.

## 1.2. Objetivos

El objetivo general de este TFG es generar un sistema para el análisis de la cinemática de la mano en pacientes que han sufrido un ictus, mediante herramientas de captura óptica y redes neuronales artificiales. De este modo, pacientes, neurólogos y rehabilitadores podrán obtener una evaluación objetiva del déficit y de los cambios evolutivos en el proceso de rehabilitación. Para cumplir con este objetivo general, se plantean los siguientes objetivos específicos:

1. Diseño e implementación de una estructura de soporte que permita la grabación del movimiento de ambas manos.
2. Toma de vídeos y registro de datos clínicos y demográficos en pacientes y sujetos control.
3. Extracción de la posición de la mano mediante redes neuronales artificiales.
4. Procesamiento de los datos para la obtención de variables cinemáticas.
5. Extracción de parámetros estadísticos de las variables cinemáticas y estudio de la viabilidad de la herramienta de captura óptica para la evaluación del déficit funcional.

## 1.3. Organización del documento

El **Capítulo 1** introduce las enfermedades cerebrovasculares, especialmente su impacto en el miembro superior así como la manera de evaluarlo. Además, se exponen los objetivos de este TFG.

En el **Capítulo 2** se revisan las tecnologías disponibles para la captura del movimiento, el aprendizaje profundo, así como el estado del arte de la estimación de la posición con redes neuronales.

El **Capítulo 3** recoge la metodología seguida, comenzando con el diseño y creación del soporte para la grabación de vídeos, continuando con el proceso de grabación de

vídeos y toma de datos de los voluntarios, el flujo de trabajo en DeepLabCut para la estimación de la posición de las manos y por último, el filtrado y la extracción de variables cinemáticas a partir de las estimaciones anteriores.

En el **Capítulo 4** se exponen los resultados obtenidos. Se incluyen los parámetros estadísticos de las variables cinemáticas calculadas para los voluntarios sanos.

Finalmente, el **Capítulo 5** incluye las conclusiones del trabajo así como las propuestas de líneas futuras de investigación.

# Capítulo 2

# Estado del arte

## 2.1. Captura del Movimiento

Existen varias tecnologías para la captura del movimiento de la mano (ver Figura 2.1). Wheatland et al. [31] resumen las principales propuestas:

- **Captura óptica basada en el uso de marcadores**. Debido al elevado número de grados de libertad de la mano, esta tecnología requiere la colocación de numerosos marcadores. Destaca por su elevada precisión espacial pero requiere un posprocesado exhaustivo, así como los marcadores no visibles en ciertos instantes de tiempo son una fuente de error. Es una tecnología cara que además requiere un tiempo de preparación elevado para la colocación de los sensores.

- **Captura de movimiento con guantes**. Existen diferentes diseños de colocación de sensores sobre el guante según la aplicación. Evita los errores debidos a zonas no visibles, presentes en otras tecnologías, pero existen problemas de acoplamiento entre sensores. Además, su uso requiere de una calibración precisa para cada individuo. En esta tecnología, también encontramos guantes con sensores inerciales.

- **Captura con imágenes**. Uso de vídeos para la identificación de la mano. Inicialmente, con guantes (sin sensores) con colores según la zona de la mano. Actualmente la captura se realiza sin guantes y en combinación con redes neuronales artificiales. Es una herramienta barata pero susceptible a errores derivados de las zonas no visibles en la imagen, así como inexacta en la dimensión de profundidad.

- **Sensores de profundidad**. Tecnologías con sensores de profundidad únicamente (controlador Leap Motion [32]) o en combinación con captura de colores (como el sistema Kinect de Microsoft [33, 34]). Es una tecnología barata pero susceptible a errores por las partes ocultas al sensor.

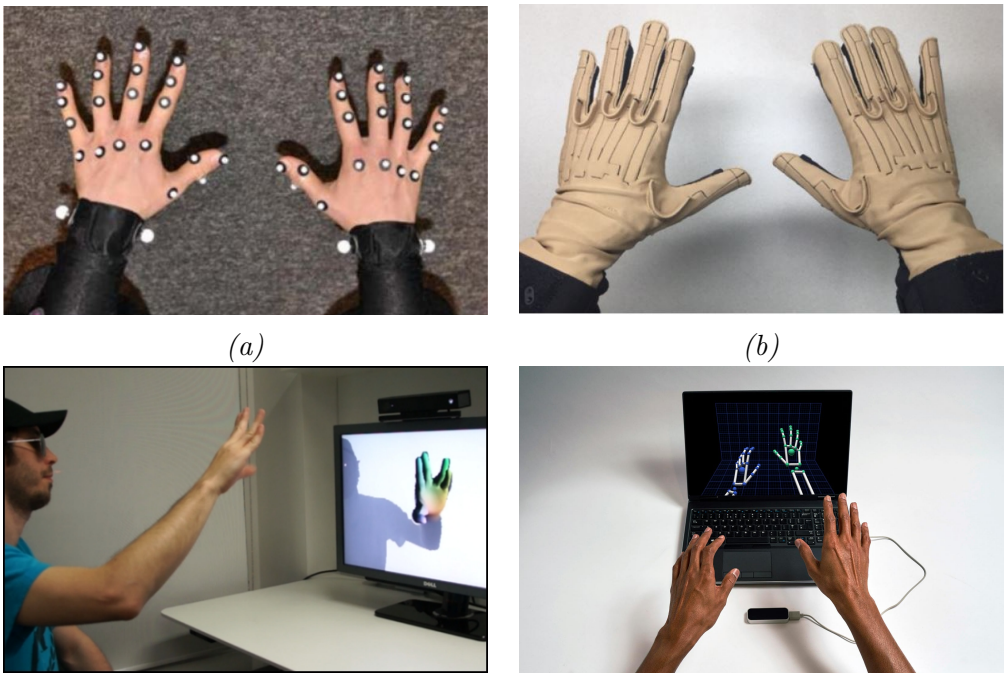

*(a)* *(b)*

*(c)* *(d)*

Figura 2.1: Tecnologías de captura del movimiento. *(a)* Marcadores [31], *(b)* guantes CyberGloves [31], *(c)* Kinect [33] y *(d)* Leap Motion [35].

## 2.2. Redes Neuronales y Aprendizaje Profundo

Las redes neuronales artificiales tienen su origen o inspiración en cómo funciona el sistema nervioso humano. Es un proceso inspirado en el que una neurona recibe varias entradas o *inputs* y las combina para generar una salida o *output* [36]. Entre estas entradas y salidas encontramos nodos o neuronas que modifican sus pesos (parámetros numéricos que determinan la influencia de las conexiones entre neuronas en la red) de modo que se minimice el error de la salida, realizando la tarea de "aprendizaje" [36, 37]. Destacan dos tipos de aprendizaje: supervisado y no supervisado. El aprendizaje supervisado necesita datos etiquetados previamente y cuya correcta detección será el objetivo del algoritmo [37, 38]. El aprendizaje no supervisado emplea conjuntos de datos no etiquetados, de los que el modelo debe aprender los patrones comunes [37, 38]. Existen otros dos tipos de aprendizaje adicionales: semisupervisado y aprendizaje reforzado [38, 39].

Si bien, el estudio de redes neuronales con capas ocultas ya era popular en 1980 [36], en el siglo XXI ha llegado a su máxima expansión. La publicación en 2006 de Geoffrey Hinton et al. [40], introduciendo un algoritmo de aprendizaje profundo rápido y preciso marcó el comienzo de una nueva etapa en el desarrollo de estas tecnologías [38]. El reciente avance del aprendizaje profundo se debe al aumento en la capacidad de cómputo [36], con la introducción de potentes unidades de procesamiento gráfico (GPU) así como la disponibilidad de grandes conjuntos de datos con los que entrenar los algoritmos [36].

De entre los tipos de redes neuronales artificiales, las redes neuronales convolucionales (CNN) están especialmente orientadas a tareas de reconocimiento de patrones en imágenes. Para ello, la estructura de sus capas está especialmente desarrollada para tratar este tipo de datos (entradas de 3 dimensiones) [37], conviertiéndose en la principal técnica en la visión artificial o *computer vision* [36]. Normalmente el aprendizaje es de tipo supervisado en el caso de imágenes [37], con aplicación de retropropagación o *backpropagation* de características compartidas disminuyendo así la carga computacional asociada a esta técnica [37, 41].

Las capas que componen las CNN serán de tipo convolucional, de *pooling* o agrupación y multicapa o *fully-connected* [37].

## 2.3. Estimación de la Posición con Captura Óptica y Redes Neuronales

Los laboratorios de captura óptica del movimiento son el *gold standard* para identificar movimientos patológicos y así poder planear terapias en enfermedades neurológicas y musculoesqueléticas [42]. Pese a aportar datos de gran valor, su coste así como la duración del estudio impiden la colección de estos datos con una mayor frecuencia así como que el análisis del movimiento tenga lugar en entornos cotidianos de la vida diaria del paciente [42].

El uso extendido de móviles junto con el desarrollo computacional del aprendizaje profundo o *deep learning* ha permitido el desarrollo de alternativas (ver Fig. 2.2) de estudio del movimiento mediante vídeos y algoritmos de estimación de la posición [42].

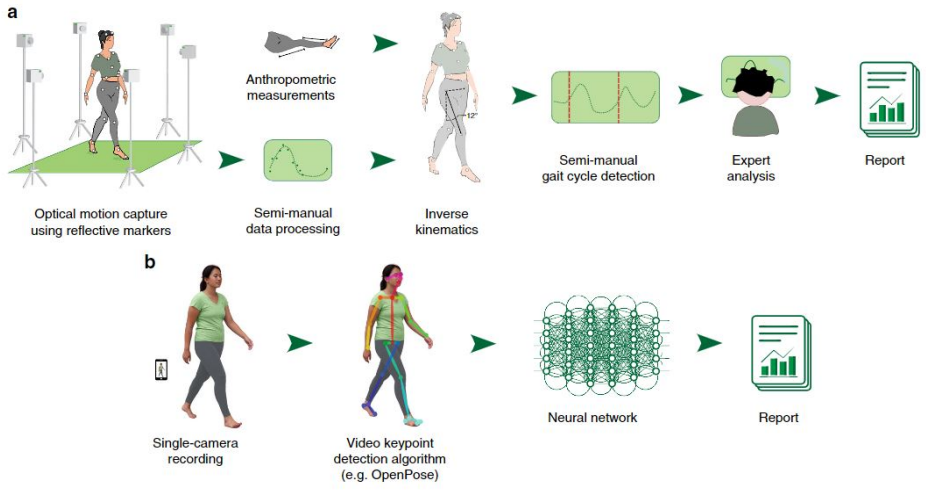


Figura 2.2: Comparación de flujos de trabajo con *(b)* y sin *(a)* vídeos [42].

Actualmente encontramos diversas propuestas de algoritmos de estimación de la posición mediante captura óptica con vídeos:

- **LEAP** [43]. Ofrece su propia arquitectura de red, que permite entrenar la red

desde cero con el conjunto de datos de interés.

- **DeepPoseKit** [44]. Emplea redes de tipo Stacked DenseNet para una estimación de la pose más rápida que los otros modelos.
- **OpenPose** [45]. Detección a tiempo real de la pose en humanos.
- **DeepLabCut** [46]. Estimación de la posición mediante el uso de redes neuronales convolucionales de tipo residual preentrenadas, ya que, para obtener gran precisión con pocos datos, utiliza técnicas de *transfer learning*.

Los algoritmos de extracción de la posición con vídeos han sido utilizados con anterioridad con pacientes. Chen et al. proponen el seguimiento de pacientes en ámbitos hospitalarios como unidades de monitorización de epilepsia o unidades de cuidados intensivos [47], Ossmy et al. realiza un estudio de la locomoción en bebés [48], así como otras aplicaciones de la estimación de la pose en el campo de la salud son recopiladas por Stenum et al. [49]. En personas con ictus, Lonini et al. emplea estos algoritmos en el estudio de la marcha [29]. Por otro lado, la estimación de la posición de la mano ha sido estudiada en numerosos estudios tanto en personas sanas [50] como en pacientes del área de neurología [51].

Estos estudios se apoyan en el cálculo de variables cinemáticas. Las variables utilizadas para evaluar el miembro superior de pacientes que han sufrido un ictus incluyen tiempos en realizar tareas o movimientos, ratio de longitud de la trayectoria, rango de velocidad, número de picos de velocidad máxima, ángulos de flexión y extensión, velocidad máxima, velocidad media, etc. [12].

Según estos antecedentes, en el siguiente capítulo se muestra la metodología propuesta, para introducir las tecnologías de captura óptica y redes neuronales en el estudio del movimiento de la mano en pacientes que han sufrido un ictus.

# Capítulo 3

# Metodología

En este capítulo se detalla la metodología seguida para la extracción de la posición de la mano así como las variables cinemáticas asociadas.

En la Figura 3.1 se resume el procedimiento llevado a cabo. En primer lugar, se grabaron los vídeos de las manos y se recogieron los datos de los voluntarios en la plataforma REDCap. A continuación, se realizó una copia de los vídeos, volteándolos horizonalmente con Python. Los vídeos se dividieron en dos grupos: uno destinado a entrenar y evaluar las redes neuronales artificiales y otro para utilizarlo posteriormente en el análisis cinemático.

En morado se recogen las secciones del flujo de trabajo que se realizan con la herramienta DeepLabCut. En primer lugar, se crean los proyectos con los vídeos destinados a entrenar las redes. El proceso de entrenamiento se detalla en la Sección 3.2 (ver Figura 3.11). Una vez entrenadas las redes, se estima la posición de las manos de los vídeos reservados para el análisis cinemático.

Finalmente, con distintas librerías de Python, se realiza el preprocesamiento de las posiciones extraídas con DeepLabCut, para a continuación extraer las variables cinemáticas de las trayectorias filtradas. Por último, se asocian los datos clínicos y demográficos anteriormente almacenados en REDCap, con las variables cinemáticas calculadas.

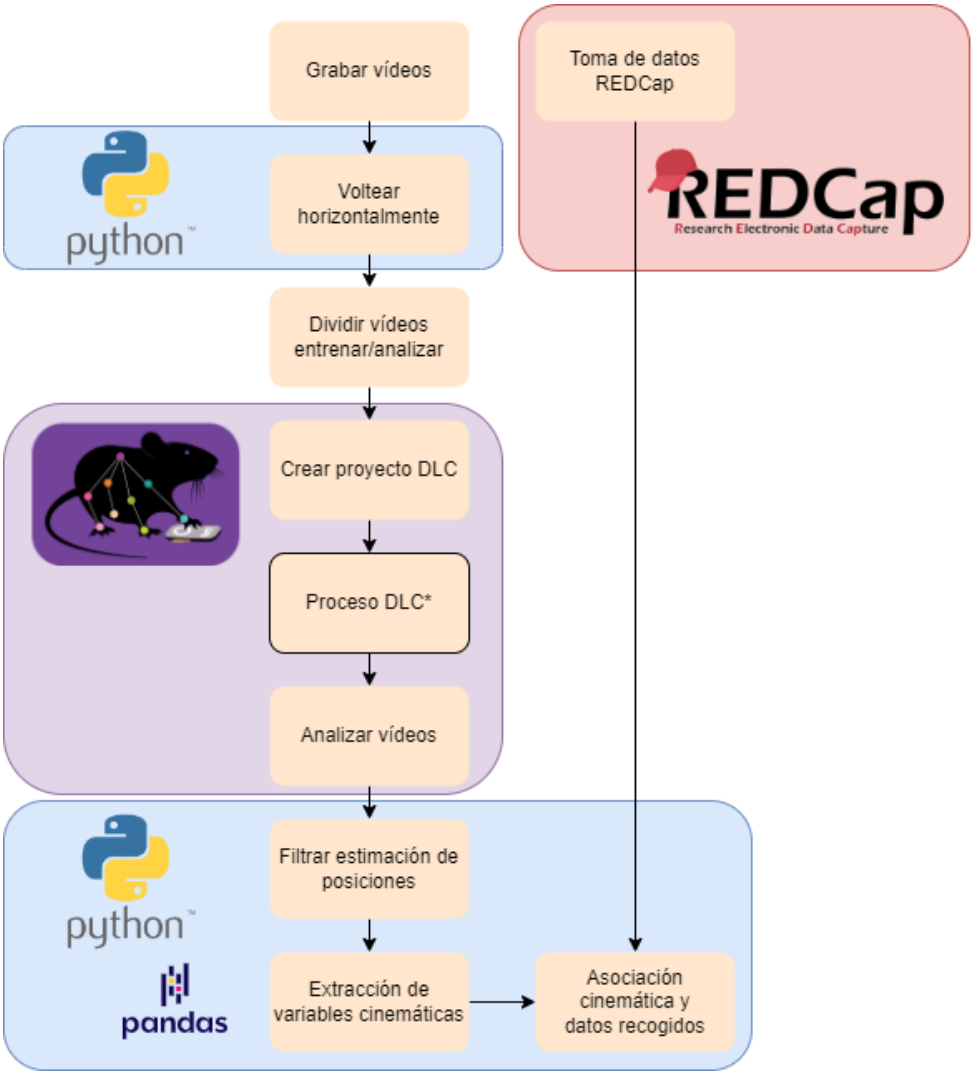


Figura 3.1: Flujo de trabajo. Elaboración propia.

## 3.1. Captura del Movimiento

### 3.1.1. Selección de ejercicios a realizar para la captura del movimiento

De acuerdo con los neurólogos participantes en el estudio, se seleccionan cuatro movimientos básicos de las manos que incluyen movimientos habituales en las tareas cotidianas y que a su vez se pueden grabar en un único plano. Cada ejercicio se repite durante 10 segundos aproximadamente.

Estos ejercicios son:

**EJERCICIO 1 - Extensión de muñeca.** Alternando entre una posición horizontal y la mayor extensión, elevando la parte distal de la mano, maximizando así el ángulo entre la horizontal, la muñeca y la punta de los dedos.

*(a)* *(b)*

Figura 3.2: Ejercicio 1. *(a)* Mínima extensión y *(b)* máxima extensión.

**EJERCICIO 2 - Pinza dígito-digital.** Movimiento de prensión con los dedos índice y pulgar, repitiendo este movimiento entre la máxima extensión o apertura de los dedos y el cierre de la pinza.

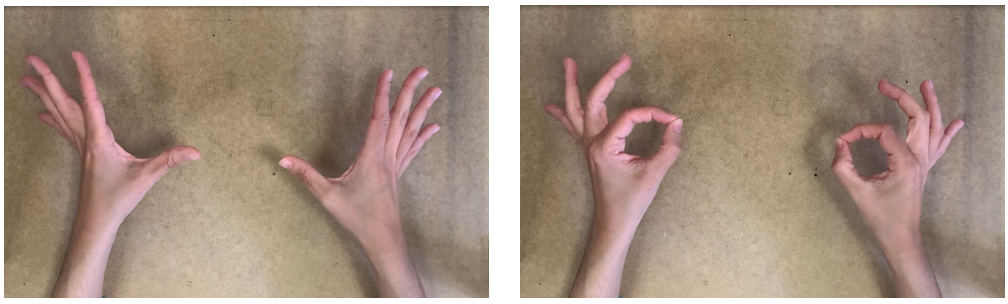

*(a)* *(b)*

Figura 3.3: Ejercicio 2. *(a)* Apertura y *(b)* cierre de la pinza.

**EJERCICIO 3 - Abducción y aducción de los dedos.** Manteniendo la mano en el plano horizontal, se separan y se vuelven a juntar los dedos de la mano lateralmente.

*(a)* *(b)*

Figura 3.4: Ejercicio 3. *(a)* Unión y *(b)* separación de los dedos.

**EJERCICIO 4 - Flexión y extensión de los dedos.** Se realizan los movimientos de cierre y apertura de la mano, haciendo y deshaciendo el puño.

*(a)* *(b)*

Figura 3.5: Ejercicio 4. *(a)* Apertura y *(b)* cierre del puño.

### 3.1.2. Creación de la estructura

Para todos los ejercicios, el participante deberá sostener los brazos estirados con las palmas de la mano hacia abajo, manteniendo una posición constante a una distancia suficiente de la cámara, de modo que se vean las dos manos en un mismo vídeo. Por ello, se diseña una estructura que soporte la cámara y un apoyo para los brazos.

La estructura a diseñar debía satisfacer los siguientes requisitos:

1. Los vídeos se pueden grabar desde el plano cenital o vista superior.
2. El movimiento de ambas manos se puede capturar simultáneamente.
3. Se pueden realizar los ejercicios descritos en la sección 3.1.1, sin que la estructura interfiera en su correcta realización.
4. El móvil utilizado para grabar está sujeto y puede cargarse estando en la estructura, en el caso que fuera necesario.

Se realizó un diseño de las estructura con el software Autodesk Inventor® de Autodesk, Inc. En la Figura 3.6, se incluyen las vistas del diseño con las dimensiones en milímetros.

Los materiales empleados se detallan en la Tabla 3.1:

| Material | Dimensiones (mm) | Unidades |
|---|---|---|
| Perfiles de Aluminio | 500×30×30 | 5 |
| | 360×30×30 | 2 |
| | 300×30×30 | 2 |
| Escuadras | 40×40×40 | 14 |
| Tablero de aglomerado | 600×400×15 | 1 |
| Tuercas | M8 | 24 |
| Arandelas | M8 | 18 |
| Tornillos | M8 | 28 |

Tabla 3.1: Materiales para la estructura.

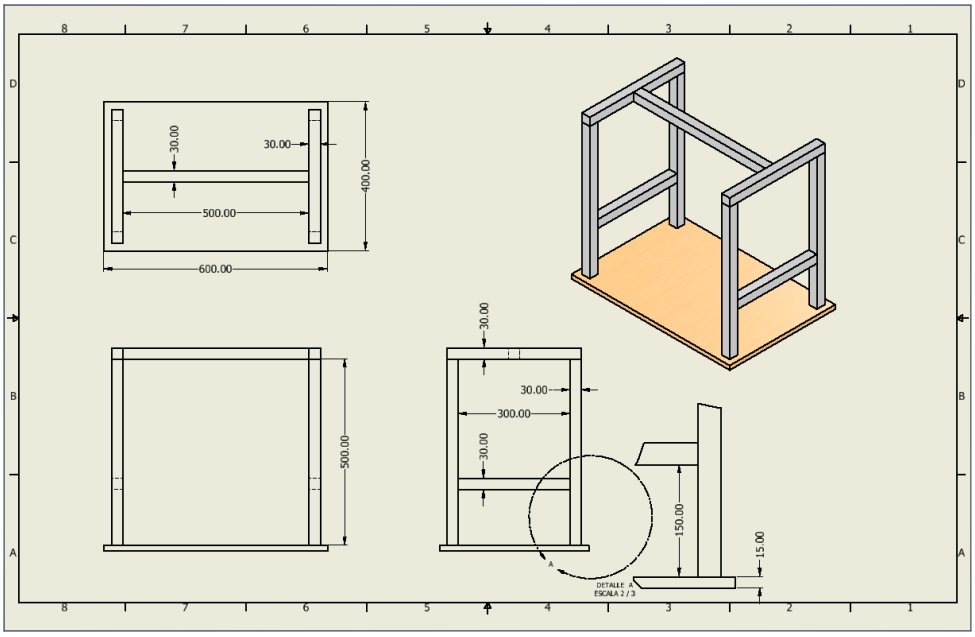


Figura 3.6: Diseño de la estructura de soporte (vistas).

Para satisfacer el requisito número 4, se diseñó una funda acorde a las dimensiones del móvil a emplear y con la que se pudiera desbloquear el móvil mientras este se encontrara en el soporte. El diseño en 3D de nuevo se hizo con Autodesk Inventor® (ver Figura 3.7, dimensiones en en mm) y se imprimió con impresoras Original Prusa i3 MK3.

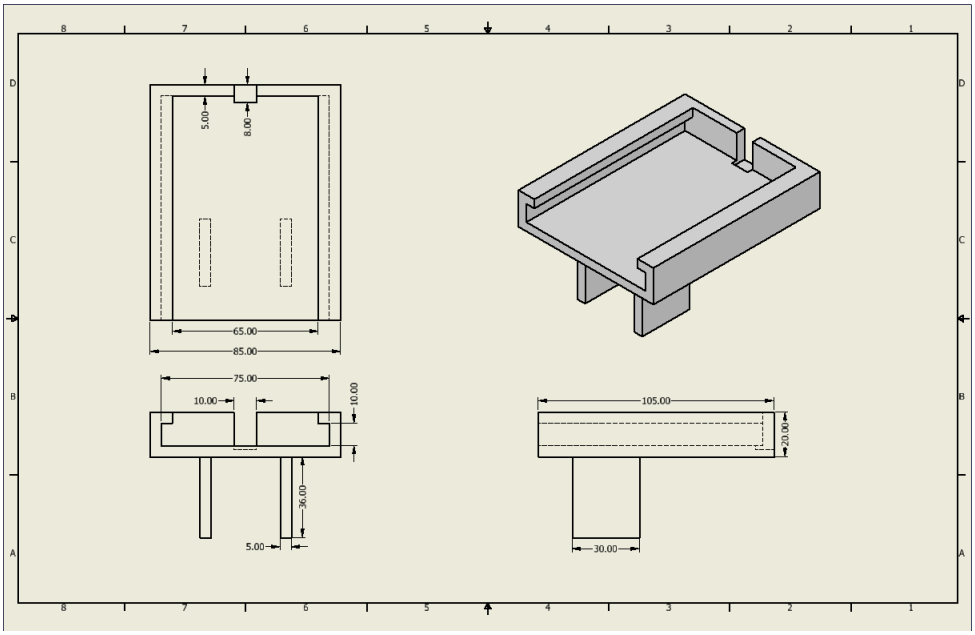


Figura 3.7: Diseño de la funda para el móvil (vistas).

Además se diseñaron unos protectores o embellecedores para ocultar los bordes de los perfiles que estaban expuestos y que habían sido cortados para evitar posibles roces o cortes (ver Fig. 3.8).

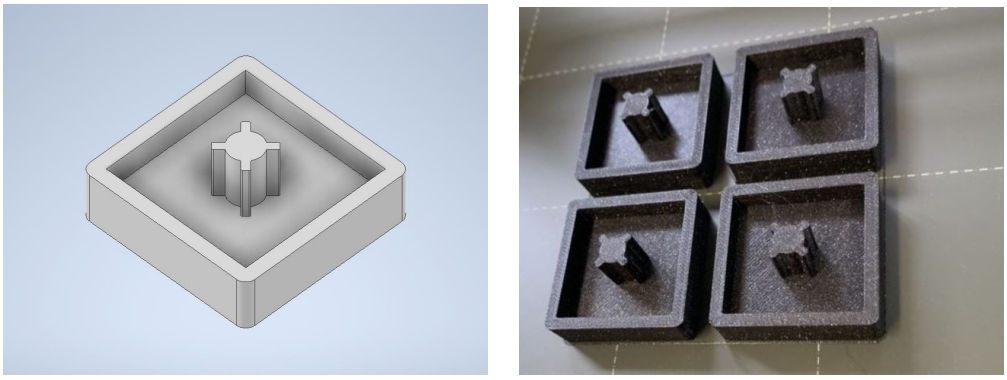

*(a)* *(b)*

Figura 3.8: Embellecedor. *(a)* Modelo 3D y *(b)* piezas impresas.

La Figura 3.9 muestra la estructura final en el HULP.

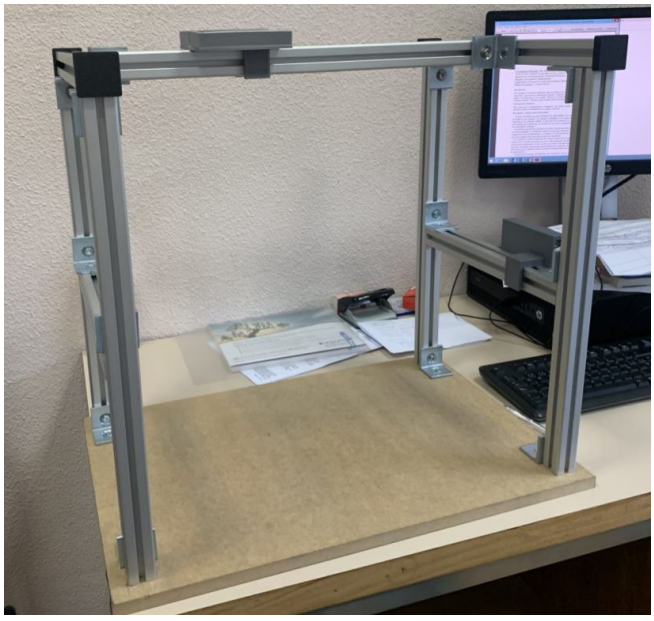

Figura 3.9: Estructura de soporte para la grabación.

Por otro lado, se imprimieron dos soportes independientes para que pudieran apoyar los brazos aquellos pacientes con dificultad para mantenerlos en el aire ligeramente elevados (ver Fig. 3.10).

*(a)* *(b)*

Figura 3.10: Soporte para brazos. *(a)* Modelo 3D y *(b)* pieza impresa.

### 3.1.3. Recogida de vídeos y datos clínicos y demográficos de los sujetos participantes

La recogida de datos se realizó en el Servicio de Neurología del Hospital Universitario La Paz. El estudio fue autorizado por el Comité de Ética e Investigación del HULP. Todos los sujetos participantes otorgaron su consentimiento informado.

En el estudio se incluyeron:

- **Sujetos sanos**, a los que se les asigna un código DCxx.
- **Pacientes con ictus**, identificados como DPxx.
- **Pacientes procedentes del Servicio de Rehabilitación** con otras patologías o dificultades motoras en la mano, con el fin de aumentar la variabilidad de los movimientos en los ejercicios y mejorar la detección de los pacientes. Se les identifica mediante un código del tipo DMxx.

Para la grabación de todos los vídeos se utilizó un iPhone XS con resolución de 1920×1080 píxeles y 29.97 fps.

Junto con los vídeos, se recogieron datos de tipo demográfico así como datos clínicos, mediante formularios almacenados con la plataforma web REDCap (Research Electronic Data Capture) [52, 53] del Instituto de Investigación Hospital Universitario La Paz (IDIPaz). Las variables recogidas se adjuntan en el Anexo C.

## 3.2. DeepLabCut

DeepLabCut (DLC) es un *software* que permite mediante el uso de redes neuronales convolucionales de tipo residual [46], la estimación de la posición en vídeos. El uso de *transfer learning* permite obtener resultados del nivel de precisión humano, con un número pequeño de imágenes etiquetadas [46].

En esta sección se detallan las fases del flujo de trabajo de la Figura 3.11. En primer lugar, se debe crear el proyecto de DeepLabCut y configurar los parámetros deseados. Tras incluir los vídeos a utilizar en el proyecto, se extraen los *frames* que posteriormente serán etiquetados. Después de comprobar la correcta posición de las etiquetas manualmente anotadas, se crea el conjunto de datos con el que entrenar la red neuronal. Una vez entrenada, se evaluará la red, pudiendo añadir más vídeos nuevos, realizar más iteraciones o incluso refinar la red si el resultado no es el deseado. Si por el contrario, los resultados de la evaluación son satisfactorios, se realizará la estimación de la posición de los vídeos a utilizar en el análisis cinemático.

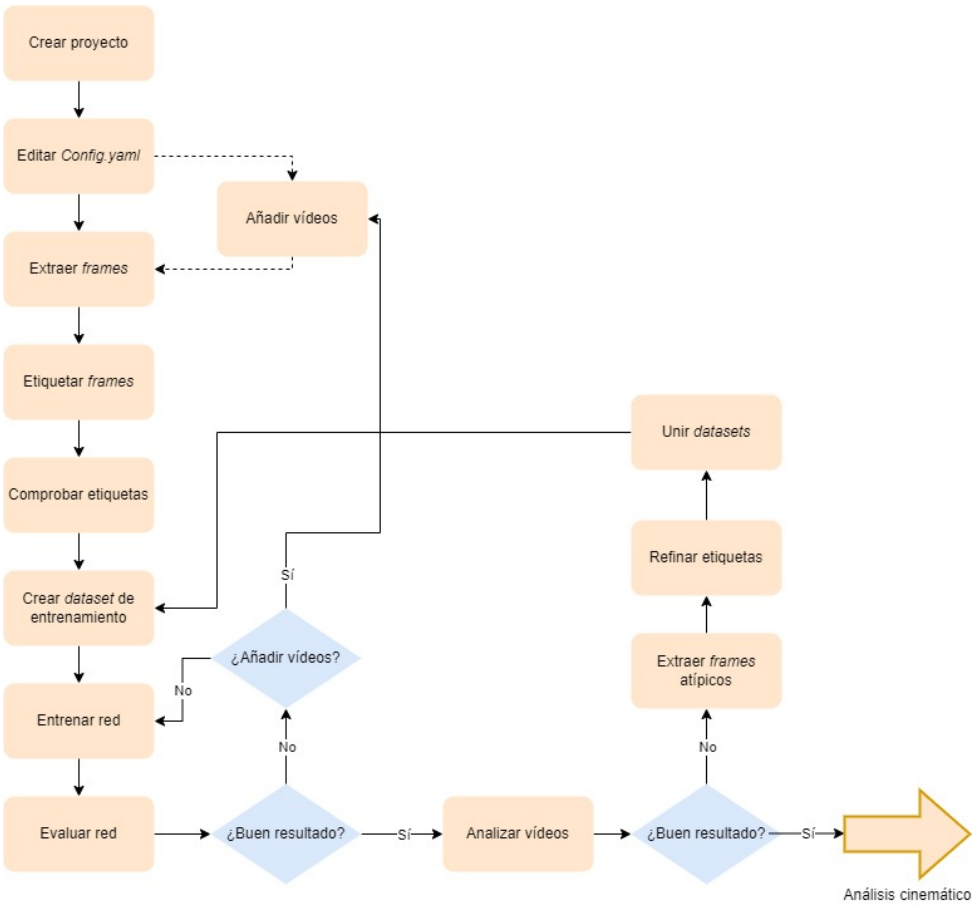


Figura 3.11: Flujo de trabajo en DeepLabCut. Adaptado de [46].

### 3.2.1. Preprocesado y Etiquetado

Figura 3.12: Flujo de trabajo de preprocesado y etiquetado de vídeos. Elaboración propia.

Para el entrenamiento de las redes, se seleccionaron 19 voluntarios de los cuales 5 eran pacientes de rehabilitación con alguna patología en la mano de tipo traumática para así poder entrenar con un mayor número de patrones de movimiento y facilitar la estimación del movimiento de manos con déficit, y sujetos sanos los 14 restantes. 10 eran mujeres y 9 hombres. La edad media alrededor de 46 $\pm$ 19 años con valores mínimos y máximos de 21 y 74 años respectivamente.

Para aumentar el número de vídeos destinados a entrenar y para facilitar su procesado, con la librería `MoviePy` de Python se giraron horizontalmente todos los vídeos en modo espejo de modo que por cada vídeo inicial se tuvieran dos vídeos (añadiendo "-flip" al final del identificador en los vídeos volteados). Gracias a esto, se pudieron introducir y etiquetar todos los vídeos como "manos derechas" tras ser recortados al introducirse en DLC. Al emplear más *frames* de entrada y de menores dimensiones, mejoramos el rendimiento del algoritmo [46]. Los vídeos se recortan especificando las coordenadas $x_1 = 900$, $x_2 = 1920$, $y_1 = 80$ e $y_2 = 1080$ en el parámetro `crop` del fichero `config.yaml`, teniendo en cuenta que el origen de coordenadas $(0, 0)$ se encuentra en la esquina superior izquierda.

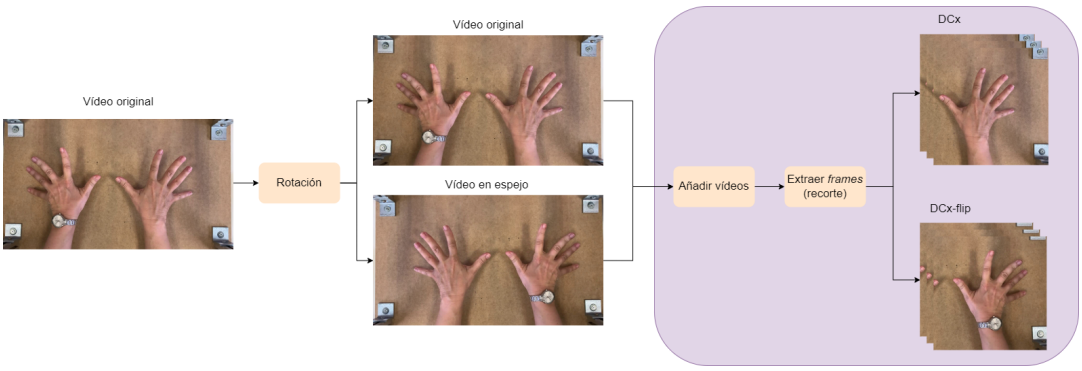


Figura 3.13: Proceso de rotación y recorte de vídeos.

Para la extracción de los *frames*, se empleó el algoritmo *kmeans* para la selección automática de los instantes más significativos. Este algoritmo emplea técnicas de *clustering* o agrupamiento sobre la apariencia de los *frames* [46]. Pese a que los

movimientos son periódicos, la velocidad no se mantiene constante en todas las fases y por ello es preferible la extracción con este algoritmo frente a una extración uniforme.

De cada vídeo se extrajeron 10 *frames* (parámetro `numframes2pick` del fichero `config.yaml`), obteniendo 380 *frames* por ejercicio, que fueron etiquetados manualmente con las 21 etiquetas que se indican en la Tabla 3.2:

| **Muñeca** | **Pulgar** | **Índice** | **Medio** | **Anular** | **Meñique** |
|---|---|---|---|---|---|
| wristInner | thumb | index | middle | ring | pinky |
| wristOuter | thumbIP | indexDIP | middleDIP | ringDIP | pinkyDIP |
| | thumbMCP | indexPIP | middlePIP | ringPIP | pinkyPIP |
| | | indexMCP | middleMCP | ringMCP | pinkyMCP |

Tabla 3.2: Etiquetas empleadas

La Figura 3.14 muestra los puntos a los que hacen referencia las etiquetas de la Tabla 3.2. Se asignan dos etiquetas a los laterales de la muñeca (*wristInner* y *wristOuter*), una etiqueta a la punta o extremo distal de cada dedo (*thumb*, *index*, *middle*, *ring* y *pinky*), dos etiquetas destinadas para las articulaciones interfalángica y metacarpofalángica del pulgar (*thumbIP* y *thumbMCP* respectivamente) y tres etiquetas para las articulaciones distal interfalángica (*xxxxxDIP*), proximal interfalángica (*xxxxxPIP*) y metacarpofalángica (*xxxxxMCP*) de cada uno de los dedos restantes (índice, medio, anular y meñique).

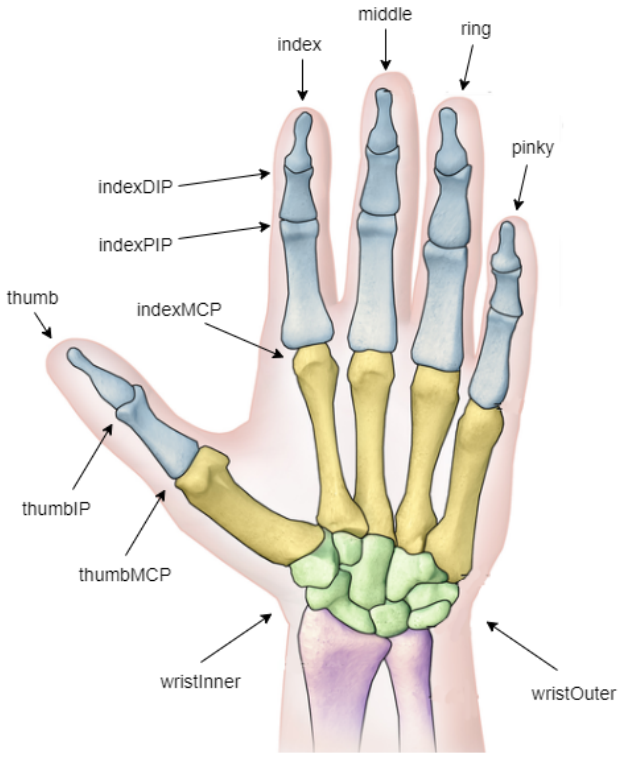


Figura 3.14: Representación de las etiquetas. Adaptado de [54].

Tanto para la creación del proyecto como la fase de etiquetado, se empleó la versión 2.2.0.3 de DeepLabCut. En la Figura 3.15 se muestra la interfaz gráfica de usuario (GUI) utilizada durante la fase de etiquetado.

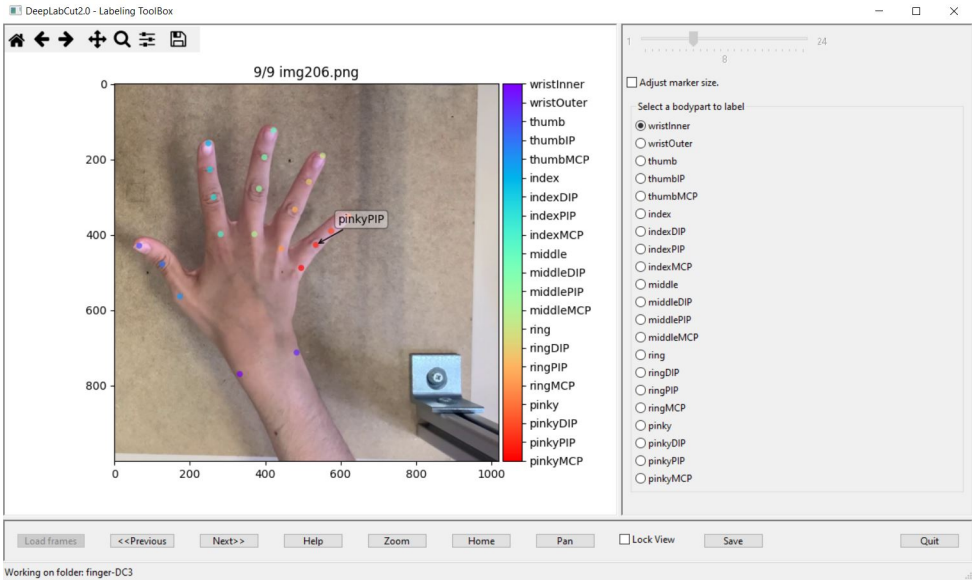


Figura 3.15: GUI de etiquetado.

Se crearon 4 redes de entrenamiento, una para cada ejercicio.

### 3.2.2. Entrenamiento y Refinamiento

Para el entrenamiento, se genera un *dataset* de entrenamiento para cada red. Este junta todos los *frames* etiquetados manualmente y los divide en dos subconjuntos de entrenamiento y evaluación [46]. Con el parámetro `TrainingFraction` del archivo `config.yaml` destinamos un 95 % de las imágenes etiquetadas a entrenar la red y un 5 % para su evaluación.

Como ya se mencionó previamente, DeepLabCut emplea técnicas de *transfer learning* por lo que se cargarán los pesos de la red preentranda elegida. Aunque la red por defecto (ResNet-50) puede ser suficiente, se entrenó con la red ResNet-101 que pese a aumentar el tiempo y la carga computacional, disminuye el error [55, 56].

Se entrenó con una GPU NVIDIA GeForce RTX 2080 Ti, limitando el entrenamiento a 300.000 iteraciones para asegurar la convergencia (ver Fig. 3.16). El tiempo de entrenamiento fue próximo a 11 horas cada red. En este caso, la versión de DeepLabCut empleada fue la versión 2.2.0.2.

En el caso del ejercicio 1, tras evaluar la red y analizar algunos vídeos, se decidió refinar la red para mejorar las estimaciones observadas. Se extrajeron 5 frames en 6 de los vídeos analizados. Con el parámetro `comparisonbodyparts` se definieron las etiquetas de interés sobre las que identificar los *outliers*, para así extraer *frames* de interés en los que corregir las etiquetas predichas. Las etiquetas del parámetro

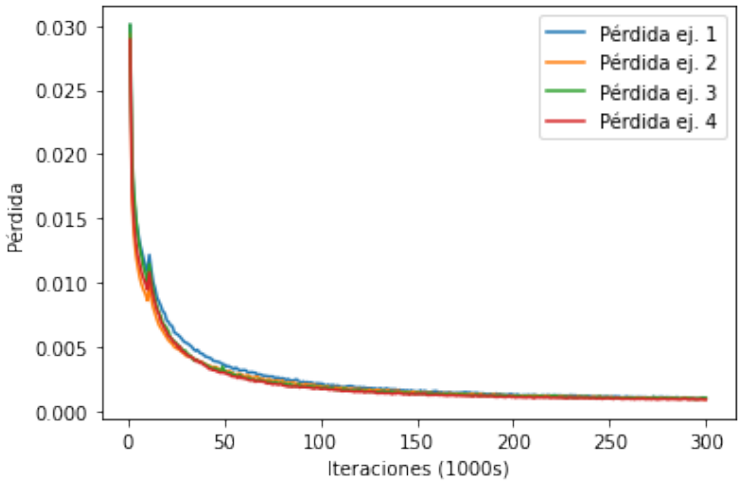


Figura 3.16: Convergencia de la pérdida o *loss*.

`comparisonbodyparts` fueron: `wristInner`, `wristOuter`, `thumb` e `index`. El algoritmo de extracción de *frames* atípicos seleccionó aquellos en los que la variación de la posición de dichas etiquetas entre dos instantes de tiempo era mayor. Se continuó el entrenamiento desde la última copia en la iteración 300.000 de la red, hasta las 400.000 iteraciones.

### 3.2.3. Evaluación y Análisis de vídeos

Una vez finalizado el entrenamiento, se evalúan las redes con el 5 % de los frames totales que se reservaron para ello. DLC genera una nueva carpeta llamada `evaluation_results`, que contiene un archivo `.csv` con los errores obtenidos y un archivo `.h5` con las coordenadas predichas en la evaluación.

Para obtener la estimación de la posición en nuevos vídeos, los vídeos (originales y rotados como se mencionó en la Sección 3.2.1) que no han sido utilizados en la fase de entrenamiento, se analizan con las redes neuronales entrenadas. El análisis se realiza con la *snapshot* o copia instantánea de la red que obtuvo menor error en la evaluación. Del análisis obtenemos los siguientes archivos por cada vídeo analizado:

- Fichero `.h5` con las estimaciones de todas las etiquetas (columnas), en cada uno de los *frames* del vídeo (filas). Opcionalmente se puede obtener el mismo contenido en un archivo `.csv`.
- Gráfico de tipo histograma de las diferencias de las coordenadas x e y entre *frames* consecutivos (ver Fig. 3.17 (a)).
- Gráfico de la trayectoria de las etiquetas (coordenadas x frente a coordenadas y) (ver Fig. 3.17 (b)).
- Gráfico de la estimación de certeza de la predicción (*likelihood*) para las etiquetas a través del tiempo (ver Fig. 3.17 (c)).

- Gráfico de la posición (coordenada x y coordenada y) para cada etiqueta a lo largo del tiempo (ver Fig. 3.17 (d)).

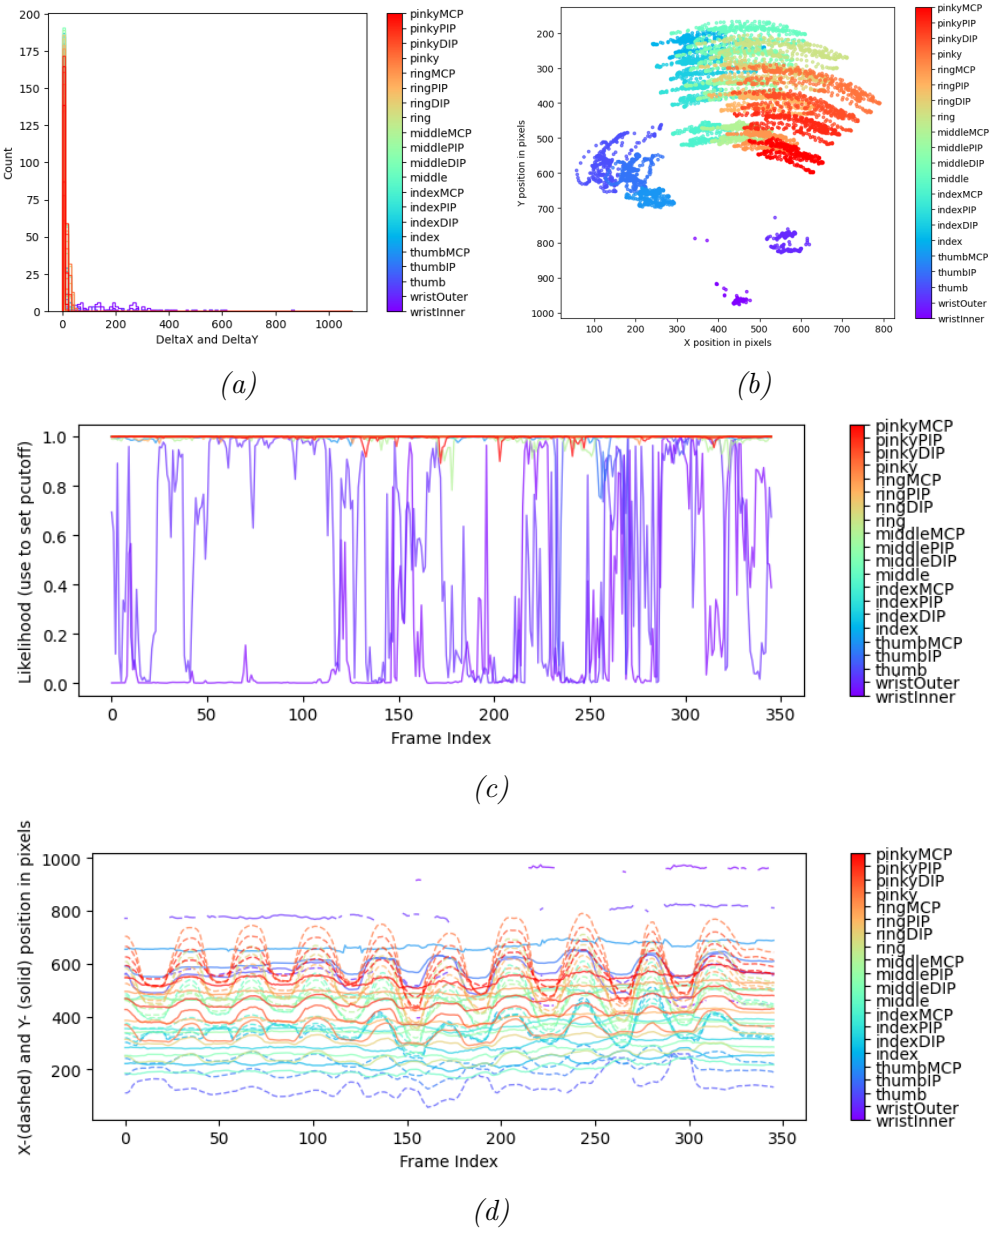


*(a)* *(b)*

*(c)*

*(d)*

Figura 3.17: Gráficos del análisis de vídeos con DeepLabCut. Gráficos del ejercicio 3 del control DC15: *(a)* histograma, *(b)* trayectoria, *(c) likelihood* y *(d)* posición en el tiempo.

## 3.3. Análisis cinemático

Partiendo de los ficheros con extensión `.h5` generados por cada vídeo analizado con las redes entrenadas, se propone un análisis cinemático a partir de las estimaciones de las posiciones. Cada fichero contiene una estimación de la posición (coordenadas x e y) de cada una de las etiquetas para cada imagen o *frame* del vídeo, así como una estimación de la probabilidad o *likelihood* de la predicción en cada instante.

Los valores medios de esta probabilidad para cada etiqueta, en los cuatro ejercicios de los vídeos analizados, se recogen en el Anexo D.

Para el siguiente análisis, se han utilizado las librerías `NumPy`, `Pandas`, `SciPy`, `math` y `statistics` del lenguaje de programación Python.

### 3.3.1. Filtrado

Teniendo en cuenta los valores de *likelihood*, se realizó un posprocesado de las posiciones estimadas.

Una de las limitaciones de DLC, es la no predicción de las partes ocultas [46]. Sin embargo el valor de certeza *likelihood* nos puede ayudar a identificar los periodos en los que una parte etiquetada no se muestra en la imagen [55]. Para valores con probabilidad menor a 0.2, se consideró que eran etiquetas no visibles en la imagen. Esto se puede ver fácilmente en el ejercicio 4 (ver Fig. 3.5) de apertura y cierre del puño:

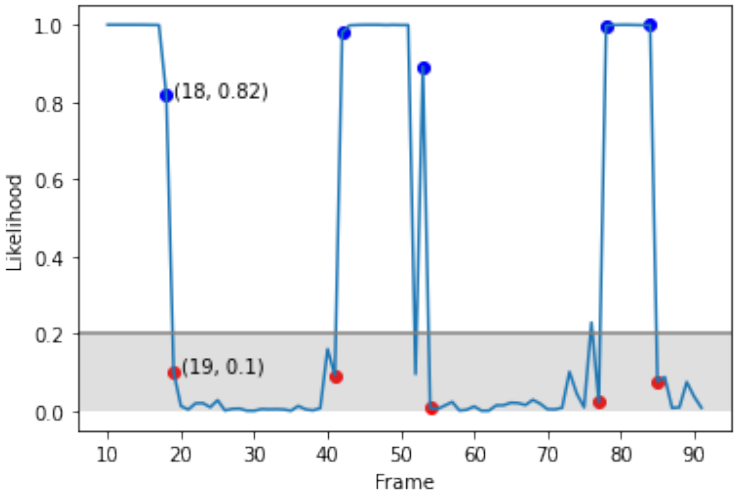


Figura 3.18: *Likelihood* para la etiqueta *pinky* del voluntario DC30

Para homogeneizar la longitud de todas las series así como para no incluir el principio y el final del movimiento, teniendo en cuenta la longitud de los vídeos, para todos los cálculos se acotó la señal a los valores desde el *frame* 10 al 220. De este modo obtenemos series temporales de 7 segundos.

*(a)* *(b)*

Figura 3.19: Voluntario DC30 haciendo el ejercicio 4 (mano dcha.). Frames *(a)* 18 y *(b)* 19.

Con el objetivo de suavizar las señales de posición a lo largo del tiempo y reducir el ruido debido a predicciones erróneas, las series temporales de las etiquetas empleadas se procesaron del siguiente modo. En primer lugar, para valores con *likelihood* inferior a 0.4 pero superior a 0.2, se realizó la media de los valores alrededor de este (desde $i-2$ hasta $i+2$, ambos inclusive, donde $i$ es el número de *frame*) y se asignó esta como su nuevo valor.

A la serie obtenida, se le aplicó un filtro de mediana móvil, con una ventana igual a 5. A la señal de salida finalmente se le aplicó el filtro de Savitzky–Golay [57] con una ventana igual a 3 y orden del polinomio igual a 1 (ver Figura 3.20).

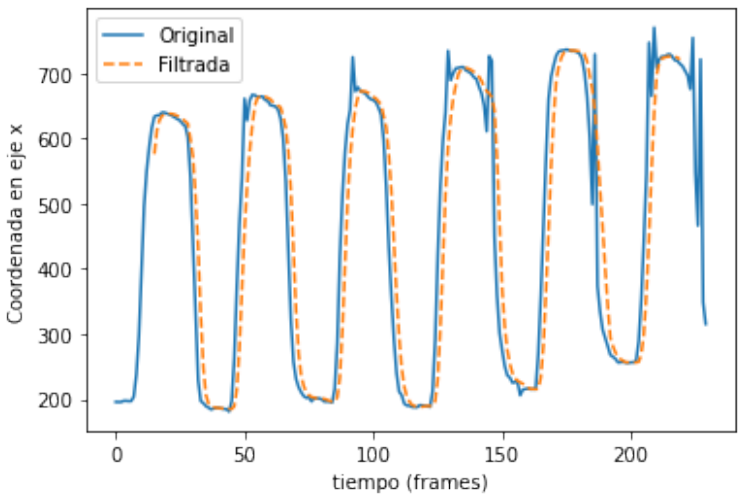


Figura 3.20: Posición de *index* (eje x) en el tiempo. Voluntario DC25, ejercicio 2.

### 3.3.2. Extracción de variables

Teniendo en cuenta los valores de certeza que proporciona DeepLabCut (incluidos en el Anexo D), con los límites que estos marcan, se extraen variables cinemáticas para cada ejercicio.

Las variables a calcular serán distancias, ángulos, tiempos de cada fase del movimiento, y velocidades. Se calculan para cada vídeo, así como sus valores estadísticos de media, desviación estándar, mínimo y máximo.

Las distancias se obtienen mediante la Ecuación 3.1, donde $e_1$ y $e_2$ hacen referencia a las etiquetas 1 y 2 de las distancias a calcular.

$$d = \sqrt{(x_{e2} - x_{e1})^2 + (y_{e2} - y_{e1})^2} \tag{3.1}$$

Los ángulos se calculan con la Ecuación 3.2, siendo $\vec{d_{12}}$ y $\vec{d_{32}}$ los vectores que unen las etiquetas 1 y 2 y 2 y 3 respectivamente.

$$\theta = \arccos \frac{\vec{d_{12}} \cdot \vec{d_{32}}}{\|\vec{d_{12}}\| \|\vec{d_{32}}\|} \tag{3.2}$$

El cálculo de los tiempos se cuantifica como el tiempo trascurrido entre los máximos y los mínimos locales de la trayectoria para la etiqueta y coordenada elegida en cada ejercicio. La Figura 3.21 muestra un ejemplo de las franjas de tiempos que se obtienen con la trayectoria del dedo índice en el ejercicio 2, para la persona control DC30.

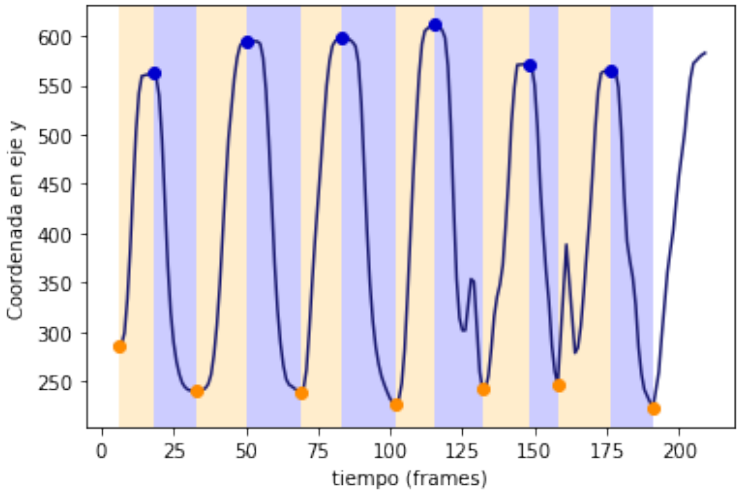


Figura 3.21: Franjas de tiempo (etiqueta *index*). Voluntario DC30, ejercicio 2.

Para las velocidades, de nuevo se utiliza el filtro de Savitzky–Golay con una ventana igual a 3 y orden del polinomio igual a 1, con orden 1 de derivada para calcular la velocidad a partir de las trayectorias.

Además, se calculan las distancias "normalizadas". Es decir, para poder hacer un mejor análisis, se dividen las distancias calculadas por un valor patrón (distancia

máxima entre dos etiquetas con *likelihood* > 0,8) de modo que las distancias sean valores relativos y su valor pueda compararse independientemente del tamaño de la mano de cada individuo así como de su distancia a la cámara.

#### 3.3.2.1. Ejercicio 1

En este ejercicio, se calculan las variables indicadas en la Tabla 3.3. Así como las distancias normalizadas a partir de la distancia entre las etiquetas *index* e *indexMCP*.

| Métrica | Etiqueta 1 | Etiqueta 2 | Etiqueta 3 |
|---|---|---|---|
| Distancia | thumb | pinky | - |
| Distancia | middle | middleMCP | - |
| Ángulo | thumb | middle | pinky |
| Ángulo | middle | middleMCP | - |
| Velocidad | index | - | - |
| Velocidad | middle | - | - |
| Tiempos | index (eje y) | - | - |
| Tiempos | middle (eje y) | - | - |

Tabla 3.3: Variables y etiquetas empleadas.

Para poder calcular el ángulo de extensión de la muñeca, debido a que se disponía únicamente de la vista superior de la mano, se ha aproximado su valor con el arcoseno. Teniendo en cuenta que los puntos de la muñeca tenían una predicción de baja calidad (*likelihood* baja) y por lo tanto poco fiable, se calcula con la variación de distancia entre el dedo corazón (*middle*) y su articulación metacarpofalángica (*middleMCP*).

$$\theta_i = \arcsin(\frac{distancia_i}{longitud_{dedo}}) \tag{3.3}$$

Donde $longitud_{dedo}$ es la longitud del dedo en píxeles, distancia máxima alcanzada teóricamente cuando la mano se encuentra horizontal. Esta longitud se calcula como la media de las distancias máximas *middle-middleMCP* cuya *likelihood* media supere 0.8, valor medio entre el umbral o *p-cutoff* definido en DLC (0.6) y el valor máximo de *likelihood* (1).

El ángulo obtenido será por tanto el ángulo que forme la muñeca con la vertical, obteniendo un valor de 90° cuando la mano se encuentre paralela a la horizontal.

#### 3.3.2.2. Ejercicio 2

En este ejercicio, se calculan las variables indicadas en la Tabla 3.4. Así como las distancias normalizadas a partir de la distancia entre las etiquetas *index* e *indexMCP*.

| Métrica | Etiqueta 1 | Etiqueta 2 | Etiqueta 3 |
|---|---|---|---|
| Distancia | thumb | index | - |
| Distancia | thumbMCP | indexMCP | - |
| Distancia | index | middle | - |
| Ángulo | index | indexDIP | indexMCP |
| Ángulo | thumb | thumbIP | thumbMCP |
| Velocidad | index | - | - |
| Velocidad | thumb | - | - |
| Tiempos | index (eje y) | - | - |
| Tiempos | thumb (eje y) | - | - |

Tabla 3.4: Variables y etiquetas empleadas.

#### 3.3.2.3. Ejercicio 3

En este ejercicio, se calculan las variables indicadas en la Tabla 3.5. Así como las distancias normalizadas a partir de la distancia entre las etiquetas *index* e *indexMCP*.

| Métrica | Etiqueta 1 | Etiqueta 2 | Etiqueta 3 |
|---|---|---|---|
| Distancia | thumbIP | pinkyPIP | - |
| Distancia | middleDIP | ringDIP | - |
| Distancia | thumb | index | - |
| Distancia | thumb | middle | - |
| Distancia | middle | pinky | - |
| Ángulo | thumb | middleMCP | pinky |
| Velocidad | thumb | - | - |
| Velocidad | index | - | - |
| Velocidad | middle | - | - |
| Velocidad | ring | - | - |
| Velocidad | pinky | - | - |
| Tiempos | thumb (eje x) | - | - |
| Tiempos | index (eje x) | - | - |
| Tiempos | ring (eje x) | - | - |
| Tiempos | pinky (eje x) | - | - |

Tabla 3.5: Variables y etiquetas empleadas.

#### 3.3.2.4. Ejercicio 4

En este ejercicio, se calculan las variables indicadas en la Tabla 3.6. Así como las distancias normalizadas a partir de la distancia entre las etiquetas *index* e *indexMCP*.

| Métrica | Etiqueta 1 | Etiqueta 2 | Etiqueta 3 |
|---|---|---|---|
| Distancia | indexMCP | pinkyMCP | - |
| Distancia | thumbMCP | pinkyMCP | - |
| Ángulo | thumbIP | thumbMCP | indexMCP |
| Ángulo | thumbIP | thumbMCP | pinkyMCP |

Tabla 3.6: Variables y etiquetas empleadas.

# Capítulo 4

# Resultados

## 4.1. Evaluación de las redes

Para evaluar la calidad de las redes entrenadas, se obtienen cuatro tipos de errores para cada red. Estos errores se calculan como la media de la distancia euclídea (Ecuación 4.1), promediando el valor de la distancia en todas las etiquetas para todos los *frames* (MAE: *Mean Average Euclidean error*).

$$d = \sqrt{(x_{DLC} - x_{Humano})^2 + (y_{DLC} - y_{Humano})^2} \tag{4.1}$$

Los errores mencionados son:

- **Error de entrenamiento**: media de las distancias entre las etiquetas de las imágenes de entrenamiento y las etiquetas manuales.
- **Error de evaluación**: media de las distancias entre las posiciones de las etiquetas de las imágenes reservadas para evaluar y las de las etiquetas manuales.
- **Error de entrenamiento (`p-cutoff` = 0.6)**: el error de entrenamiento se calcula únicamente para aquellas etiquetas cuyo valor de *likelihood* supere el umbral designado por el parámetro `p-cutoff`, en 0,6.
- **Error de evaluación (`p-cutoff` = 0.6)**: error de evaluación calculado para las etiquetas cuya *likelihood* sea mayor a 0.6.

La Figura 4.1 muestra dichos errores (errores de entrenamiento en naranja y errores de evaluación en azul) para cada una de las redes, correspondientes a los cuatro ejercicios entrenados.

Establecer un umbral, permite comparar los errores sin incluir las métricas de etiquetas ocultas [46]. En el tercer ejercicio (Figura 4.1 (c)) la diferencia entre el error global y el error con predicciones con *likelihood* $> 0.6$ es mínima, como era de esperar puesto que en general todos las etiquetas son visibles en todo momento en dicho ejercicio.

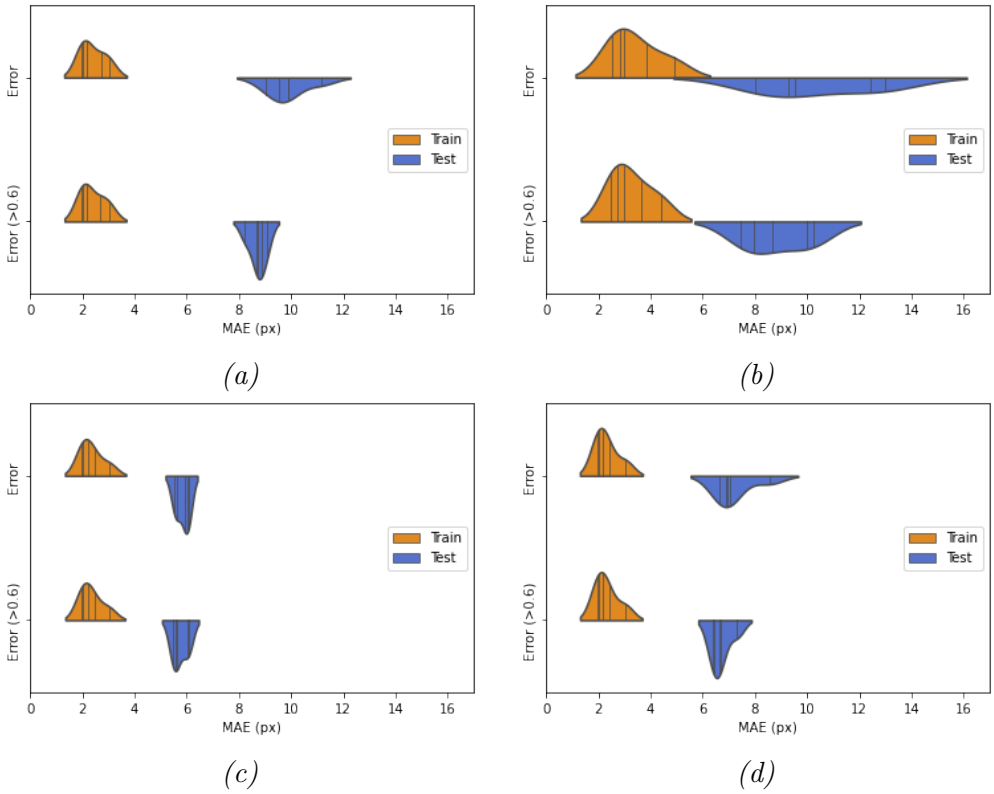


Figura 4.1: Errores de entrenamiento y evaluación de las redes. Ejercicios 1 *(a)*, 2 *(b)*, 3 *(c)* y 4 *(d)*.

Destacar que el error de la evaluación puede ser mayor al de entrenamiento, debido a la variabilidad en el etiquetado manual [55]. En ningún caso los errores obtenidos suponen una distancia mayor al 2 % de las dimensiones totales de los *frames*.

La Figura 4.2 muestra un *frame* con las etiquetas de evaluación. Las etiquetas manuales se representan con el símbolo +, las etiquetas con *likelihood* $\leq 0.6$ con $\times$ (en su mayoría, etiquetas correspondientes a partes ocultas) y las etiquetas con *likelihood* $> 0.6$ con el símbolo $\bullet$ [46].

Figura 4.2: Predicciones de DeepLabCut y etiquetas manuales (detalle).

## 4.2. Variables cinemáticas

En esta sección se incluyen los resultados de las variables cinemáticas. La nomenclatura empleada distingue los ejercicios 1, 2, 3 y 4 con las letras WR (*wrist*), PI (*pinch*), FN (*finger*) y FS (*fist*) respectivamente. Respecto al tipo de variable: A se refiere a ángulo, D a distancia, DN a distancia normalizada, V a velocidad y T a tiempo. Las letras t, i, m, r, p representan las etiquetas *thumb*, *index*, *middle*, *ring* y *pinky* respectivamente, así como IP, DIP, PIP y MCP las articulaciones etiquetadas.

Se calculó la media, desviación estándar, el valor mínimo y el valor máximo de cada variable para los sujetos control, para obtener intuitiva y resumidamente la magnitud y dispersión de las variables cinemáticas obtenidas para cada ejercicio. Las distancias se expresan en píxeles (a excepción de las distancias normalizadas, que son adimensionales), los ángulos en grados, la velocidad en píxeles/segundo, los tiempos en número de *frames* (todos los vídeos fueron grabados con la misma tasa de fotogramas).

Las Tablas 4.1, 4.2, 4.3 y 4.4 muestran la media de los parámetros estadísticos calculados en los controles para cada ejercicio.

Los parámetros de los ejercicios 1, 3 y 4 fueron calculados con las estimaciones de 42 vídeos (21 personas control), con una edad media de 35 $\pm$ 18 años. 13 eran mujeres y 8 hombres. En el ejercicio 2, debido a que se refinó su red neuronal, el cálculo de las variables se realizó con 36 vídeos de 18 personas (11 mujeres y 7 hombres de edad promedio 34 $\pm$ 18 años). Cabe destacar que los valores de distancias normalizadas solo incluyen aquellos cuya *likelihood* fuera suficiente ($>$ 0,8) para calcular la distancia patrón con la que normalizar, en ambas manos.

| | Media | Desv. Estándar | Mínimo | Máximo |
|---|---|---|---|---|
| WR_D_t_p | 461.20 | 84.19 | 248.23 | 594.34 |
| WR_D_m_MCP | 289.09 | 85.03 | 90.96 | 434.23 |
| WR_A_t_m_p | 98.42 | 30.79 | 48.17 | 168.07 |
| WR_A_m_MCP | 55.42 | 16.58 | 19.99 | 90.00 |
| WR_V_i | 24.85 | 26.78 | 0.17 | 113.95 |
| WR_V_m | 26.75 | 28.26 | 0.18 | 120.29 |
| WR_T_i1 | 23.25 | 10.37 | 11.45 | 36.26 |
| WR_T_i2 | 26.04 | 12.45 | 11.86 | 40.60 |
| WR_T_m1 | 24.10 | 10.31 | 12.05 | 36.24 |
| WR_T_m2 | 26.71 | 12.71 | 12.98 | 42.43 |
| WR_DN_t_p | 1.33 | 0.23 | 0.76 | 1.71 |
| WR_DN_m_MCP | 0.83 | 0.24 | 0.27 | 1.21 |

Tabla 4.1: Media de los valores de los controles en las variables del ejercicio 1.

| | Media | Desv. Estándar | Mínimo | Máximo |
|---|---|---|---|---|
| PI_D_t_i | 251.13 | 189.74 | 18.86 | 552.36 |
| PI_D_tMCP_iMCP | 237.33 | 61.26 | 96.18 | 380.27 |
| PI_D_i_m | 199.05 | 102.66 | 26.80 | 387.24 |
| PI_A_i_DIP_MCP | 140.17 | 30.91 | 58.41 | 179.55 |
| PI_A_t_IP_MCP | 137.70 | 23.82 | 75.07 | 178.16 |
| PI_V_t | 8.77 | 10.11 | 0.07 | 49.08 |
| PI_V_i | 23.83 | 25.31 | 0.08 | 107.85 |
| PI_T_t1 | 23.61 | 9.94 | 12.64 | 35.67 |
| PI_T_t2 | 25.83 | 9.94 | 14.19 | 37.44 |
| PI_T_i1 | 22.00 | 9.97 | 11.33 | 34.72 |
| PI_T_i2 | 21.96 | 9.21 | 10.92 | 32.61 |
| PI_DN_t_i | 0.81 | 0.59 | 0.06 | 1.66 |
| PI_DN_tMCP_iMCP | 0.71 | 0.14 | 0.37 | 1.03 |
| PI_DN_i_m | 0.57 | 0.30 | 0.09 | 1.08 |

Tabla 4.2: Media de los valores de los controles en las variables del ejercicio 2.

| | Media | Desv. Estándar | Mínimo | Máximo |
|---|---|---|---|---|
| FN_D_tIP_pPIP | 405.27 | 88.13 | 257.01 | 522.85 |
| FN_D_mDIP_rDIP | 98.86 | 31.60 | 50.31 | 151.44 |
| FN_D_t_i | 317.27 | 98.79 | 151.76 | 481.64 |
| FN_D_t_m | 421.40 | 124.90 | 215.63 | 614.24 |
| FN_D_m_p | 245.18 | 68.05 | 144.71 | 350.23 |
| FN_A_t_mMCP_p | 126.88 | 31.66 | 69.05 | 171.57 |
| FN_V_t | 13.50 | 16.54 | 0.12 | 75.61 |
| FN_V_i | 6.19 | 6.76 | 0.10 | 34.05 |
| FN_V_m | 8.90 | 8.34 | 0.11 | 36.79 |
| FN_V_r | 12.40 | 12.54 | 0.10 | 56.31 |
| FN_V_p | 14.34 | 14.52 | 0.11 | 61.49 |
| FN_T_t1 | 20.53 | 8.19 | 11.36 | 30.12 |
| FN_T_t2 | 25.00 | 10.14 | 13.60 | 37.40 |
| FN_T_i1 | 20.98 | 8.15 | 11.52 | 31.67 |
| FN_T_i2 | 21.66 | 7.75 | 12.69 | 31.19 |
| FN_T_r1 | 24.97 | 8.18 | 15.98 | 34.14 |
| FN_T_r2 | 23.24 | 8.12 | 14.33 | 32.07 |
| FN_T_p1 | 24.93 | 7.21 | 17.17 | 33.52 |
| FN_T_p2 | 23.06 | 6.30 | 15.24 | 29.62 |
| FN_DN_tIP_pPIP | 1.26 | 0.27 | 0.80 | 1.62 |
| FN_DN_mDIP_rDIP | 0.30 | 0.09 | 0.15 | 0.46 |
| FN_DN_t_i | 0.99 | 0.29 | 0.49 | 1.47 |
| FN_DN_t_m | 1.32 | 0.38 | 0.69 | 1.89 |
| FN_DN_m_p | 0.77 | 0.21 | 0.45 | 1.08 |

Tabla 4.3: Media de los valores de los controles en las variables del ejercicio 3.

| | Media | Desv. Estándar | Mínimo | Máximo |
|---|---|---|---|---|
| FS_D_iMCP_pMCP | 219.63 | 20.72 | 173.47 | 275.18 |
| FS_D_tMCP_pMCP | 350.58 | 27.80 | 280.70 | 400.76 |
| FS_A_tIP_tMCP_iMCP | 67.13 | 16.22 | 33.61 | 114.29 |
| FS_A_tIP_tMCP_pMCP | 94.01 | 18.18 | 57.42 | 137.25 |
| FS_DN_iMCP_pMCP | 0.67 | 0.06 | 0.54 | 0.83 |
| FS_DN_tMCP_pMCP | 1.09 | 0.08 | 0.90 | 1.24 |

Tabla 4.4: Media de los valores de los controles en las variables del ejercicio 4.

### 4.2.1. Media de las variables cinemáticas

Con el objetivo de estudiar en mayor detalle las variables, en esta sección se incluyen los diagramas de cajas de la media de las variables cinemáticas. Estos diagramas muestran de manera visual la dispersión, simetría y tendencia central de los datos, así como la presencia de valores atípicos.

#### 4.2.1.1. Ejercicio 1

La Figura 4.3 incluye la distribución de la media de los ángulos en los controles. El valor medio del ángulo de extensión de la muñeca (WR_A_m_MCP), como estaba previsto, se encuentra comprendido entre 0° (mano vertical) y 90° (mano horizontal), siendo su tendencia central más próxima a la horizontal. El ángulo WR_A_t_m_p que une los dedos pulgar, medio y meñique, tiene una mayor dispersión ya que es más dependiente de la morfología de la mano y de si el ejercicio se realizó con los dedos más o menos separados. Los valores de las distancias se incluyen en la Figura 4.4.

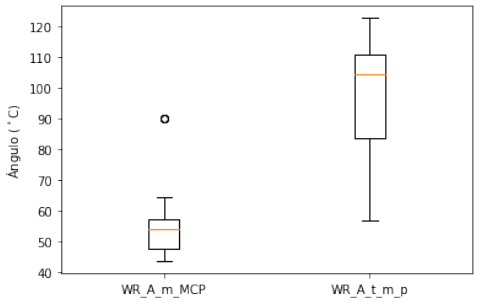


Figura 4.3: Valor medio de los ángulos

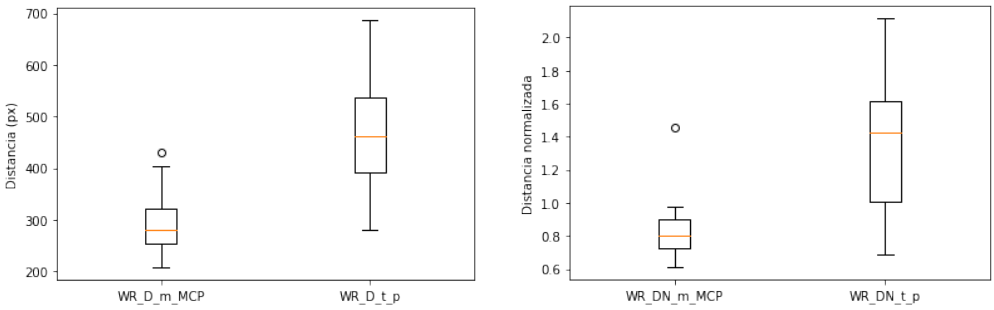


*(a)* *(b)*

Figura 4.4: Valor medio de las distancias. Distancias *(a)* y distancias normalizadas *(b)*.

Respecto a los tiempos, la Figura 4.5 señala que los tiempos de subida (WR_T_*2)

y bajada (WR_T_*1) del índice y el dedo medio son similares, como era de esperar al mover la mano "en bloque", siendo el tiempo de bajada más variable. Las velocidades (ver Fig. 4.6) presentan unas distribución similar, siendo la velocidad del dedo índice menor, como cabía esperar puesto que su recorrido es menor.

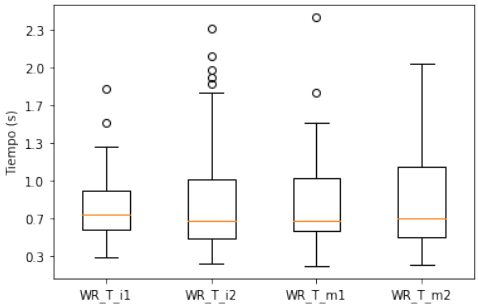


Figura 4.5: Valor medio de los tiempos

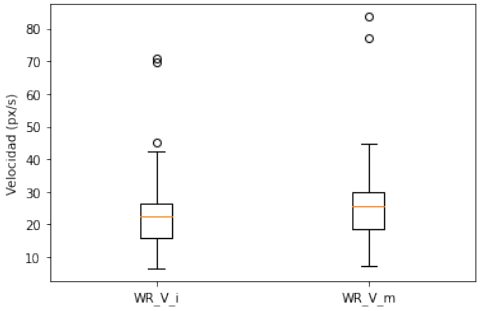


Figura 4.6: Valor medio de las velocidades

#### 4.2.1.2. Ejercicio 2

La Figura 4.7 incluye los ángulos del ejercicio 2. En el movimiento de pinza, el ángulo del índice se encuentra en media más próximo a la posición del dedo extendido (180°) que en ángulo recto (90°). Del mismo modo que el ángulo del dedo pulgar (PI_A_t_IP_MCP), siendo su media más variable a través de las personas control.

Las distancias se incluyen en la Figura 4.8. Los tiempos medios del pulgar y el índice son similares, con distribuciones asimétricas positivas, siendo la mediana del tiempo de apertura (PI_T_*1) mayor (ver Fig. 4.9). Las velocidades medias del dedo índice son mayores que las del dedo pulgar (ver Fig. 4.10), como era de esperar puesto que su recorrido es mayor.

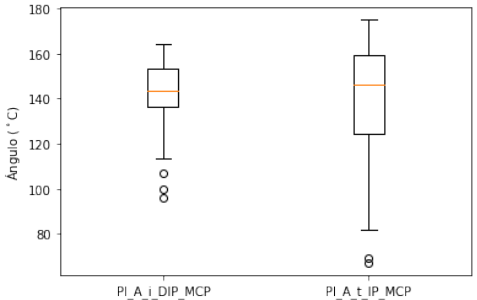


Figura 4.7: Valor medio de los ángulos

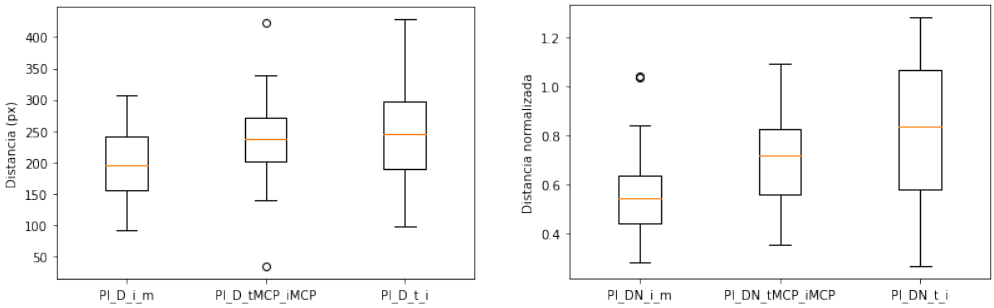


*(a)* *(b)*

Figura 4.8: Valor medio de las distancias. Distancias *(a)* y distancias normalizadas *(b)*.

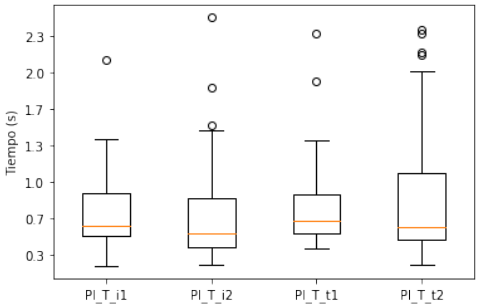


Figura 4.9: Valor medio de los tiempos

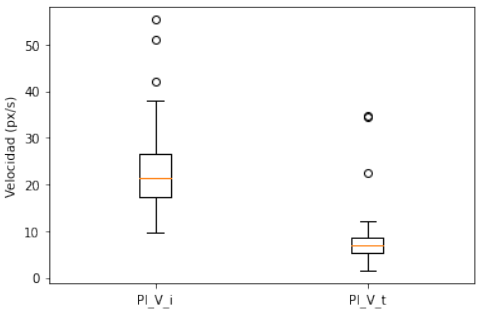


Figura 4.10: Valor medio de las velocidades

#### 4.2.1.3. Ejercicio 3

Los ángulos, distancias, tiempos y velocidades del ejercicio 3 se muestran en las Figuras 4.11, 4.12, 4.13 y 4.14 respectivamente. La Figura 4.12 ilustra que la distancia entre el pulgar y el dedo medio es mayor que entre el dedo medio y el dedo meñique. De nuevo, los dedos con velocidad promedio mayor son aquellos cuyo rango de movimiento es mayor: el pulgar y el meñique (ver Fig. 4.14).

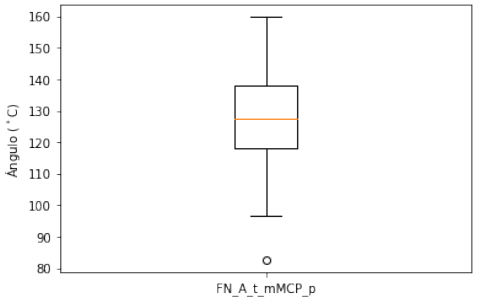


Figura 4.11: Valor medio de los ángulos

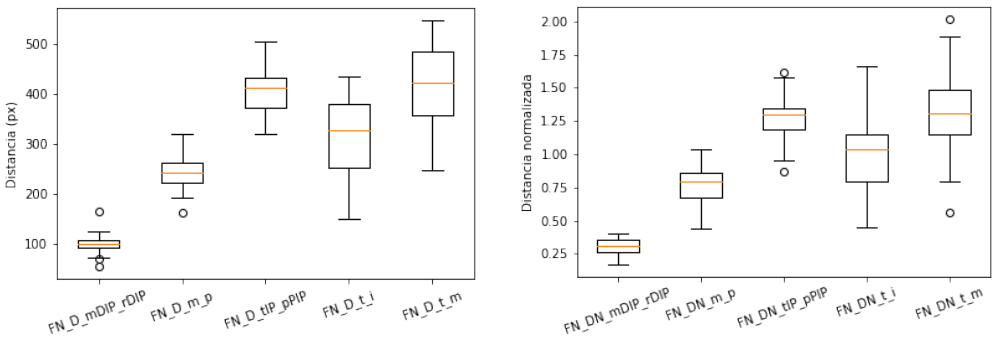


*(a)* *(b)*

Figura 4.12: Valor medio de las distancias. Distancias *(a)* y distancias normalizadas *(b)*.

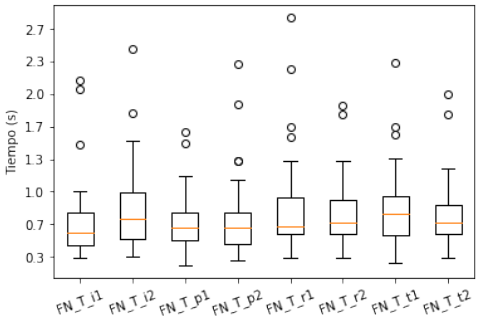


Figura 4.13: Valor medio de los tiempos

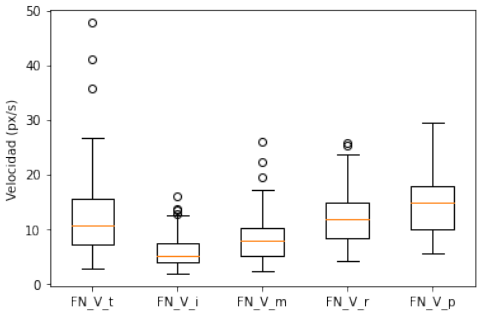


Figura 4.14: Valor medio de las velocidades

#### 4.2.1.4. Ejercicio 4

La Figura 4.15 incluye los diagramas de cajas para los ángulos del cuarto ejercicio (apertura y cierre del puño). Así como la Figura 4.16 muestra las distancias. Dado que en este ejercicio, la mayoría de las etiquetas se encontraban ocultas en los vídeos durante parte del movimiento, su utilidad se ve limitada al grabarse desde la vista superior.

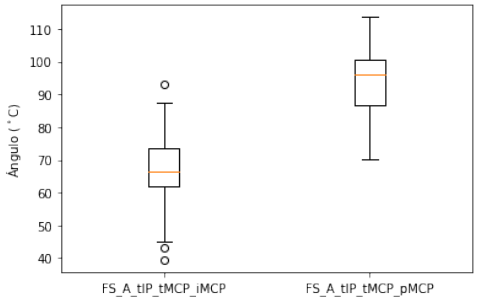


Figura 4.15: Valor medio de los ángulos

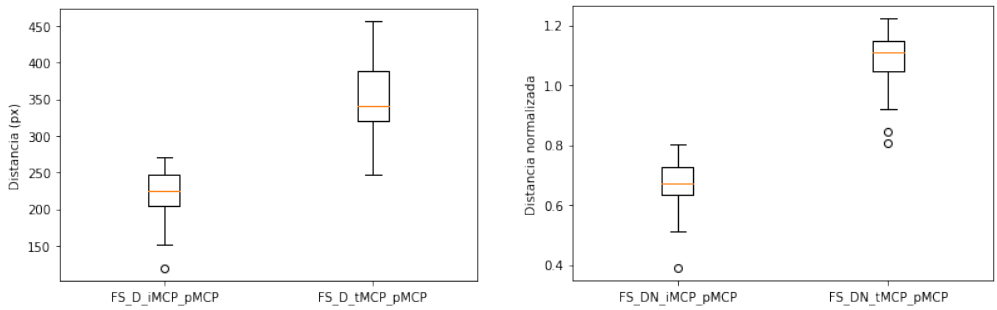


*(a)* *(b)*

Figura 4.16: Valor medio de las distancias. Distancias *(a)* y distancias normalizadas *(b)*.

### 4.2.2. Evaluación de las variables cinemáticas

Para encontrar aquellas variables cuyo cálculo es más preciso, partimos de la hipótesis que, para los voluntarios sanos, los valores de la mano derecha deben ser muy similares a los de la mano izquierda.

Siguiendo esta hipótesis, calculamos el ratio entre los valores de la mano derecha e izquierda de todos los sujetos control, con la Ecuación 4.2 (donde j es el número identificador de cada control e i el número de *frame*). Este cálculo se lleva a cabo para los valores medios de todas las variables.

$$ratio_{DCj} = \frac{(\frac{1}{210}\sum_{i=1}^{210} variable_{i,DCj})_{izq}}{(\frac{1}{210}\sum_{i=1}^{210} variable_{i,DCj})_{der}} \tag{4.2}$$

Las variables que obtuvieron un ratio, de mediana igual a 1 ± 0,1, primer quartil $Q_1 > 0{,}8$ y cuartil 3 $Q_3 < 1{,}2$ se muestran en la Tabla 4.5, donde de nuevo, A se refiere a ángulo, D a distancia, DN a distancia normalizada, V a velocidad y T a tiempo (en número de *frames*). Las letras t, i, m, r, p representan las etiquetas *thumb*, *index*, *middle*, *ring* y *pinky* respectivamente. En la Tabla 4.5 se incluyen dichas variables junto a la mediana y el rango intercuartil ($IQR = Q_3 - Q_1$) de los ratios.

| Ejercicio | Variable | Mediana del ratio | IQR del ratio |
|---|---|---|---|
| 1 | WR_A_m_MCP | 0.96 | 0.1 |
| | WR_A_t_m_p | 1.03 | 0.16 |
| | WR_D_m_MCP | 0.99 | 0.1 |
| | WR_D_t_p | 1.08 | 0.11 |
| | WR_DN_m_MCP | 1.0 | 0.15 |
| | WR_DN_t_p | 1.06 | 0.2 |
| | WR_T_i1 | 0.94 | 0.34 |
| 2 | PI_A_i_DIP_MCP | 1.05 | 0.07 |
| | PI_A_t_IP_MCP | 0.99 | 0.05 |
| | PI_D_tMCP_iMCP | 1.0 | 0.15 |
| | PI_D_t_i | 1.05 | 0.12 |
| | PI_DN_tMCP_iMCP | 0.98 | 0.09 |
| | PI_DN_t_i | 0.99 | 0.2 |
| | PI_V_i | 1.07 | 0.13 |
| | PI_V_t | 0.9 | 0.08 |
| 3 | FN_A_t_mMCP_p | 1.06 | 0.12 |
| | FN_D_mDIP_rDIP | 1.0 | 0.18 |
| | FN_D_m_p | 0.99 | 0.17 |
| | FN_D_tIP_pPIP | 1.02 | 0.04 |
| | FN_DN_mDIP_rDIP | 1.0 | 0.33 |
| | FN_DN_m_p | 1.01 | 0.21 |
| | FN_DN_tIP_pPIP | 1.01 | 0.08 |
| | FN_T_i1 | 0.99 | 0.15 |
| | FN_T_r2 | 0.96 | 0.25 |
| 4 | FS_A_tIP_tMCP_iMCP | 0.99 | 0.16 |
| | FS_A_tIP_tMCP_pMCP | 1.02 | 0.07 |
| | FS_D_iMCP_pMCP | 1.04 | 0.14 |
| | FS_D_tMCP_pMCP | 1.03 | 0.06 |
| | FS_DN_iMCP_pMCP | 1.02 | 0.14 |
| | FS_DN_tMCP_pMCP | 1.02 | 0.1 |

Tabla 4.5: Ratios derecha-izquierda de las variables cinemáticas

### 4.2.3. Distancias normalizadas

En la Figura 4.17 se ilustra un ejemplo de la utilidad de la distancia normalizada. Durante la realización del ejercicio 3, los voluntarios DC8 y DC33 se encuentran a distinta separación de la cámara. Si bien, la distancia en píxeles puede ser similar (ver Figura 4.19 (a)), alrededor de 180 px, la apertura de la mano no es igual en ambos casos (ver Figura 4.18). Con la distancia normalizada (ver Figura 4.19 (b)) podemos distinguir como, proporcionalmente a las dimensiones de la mano, DC33 realiza una apertura mayor, aproximadamente el doble de la apertura de DC8.

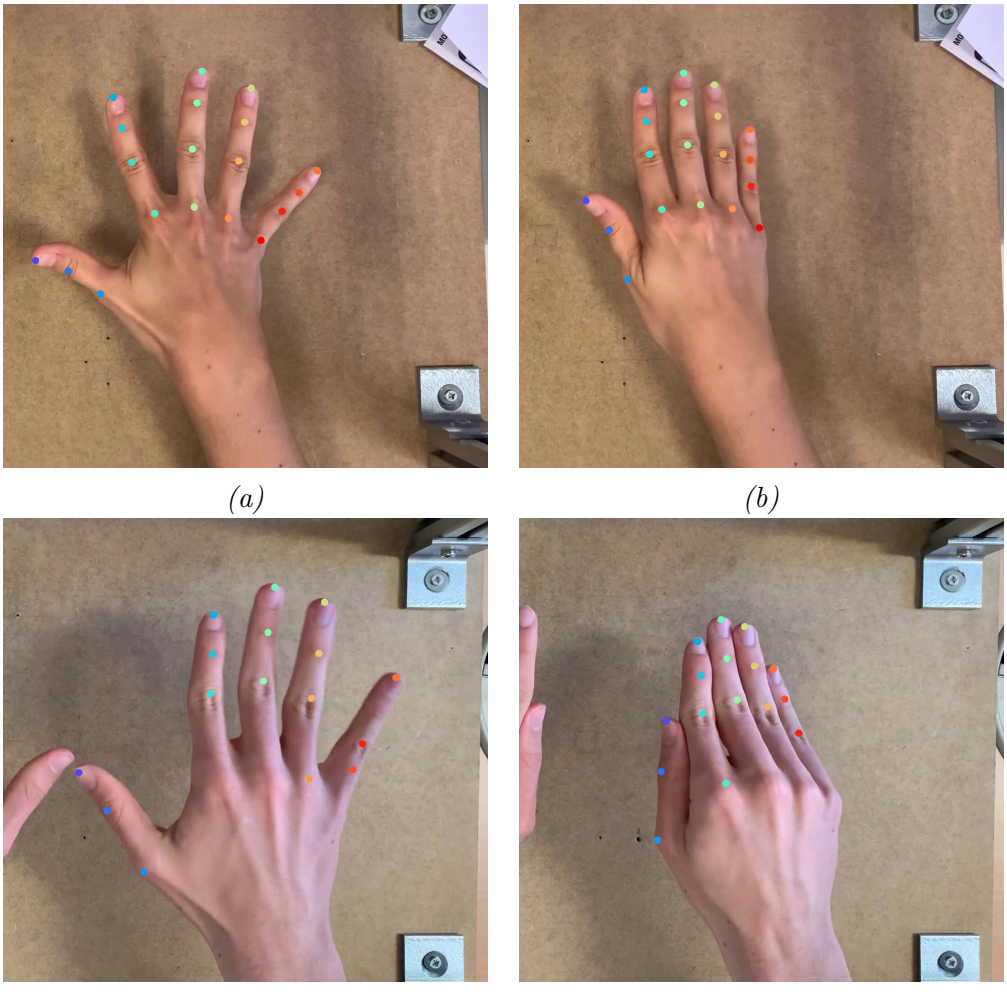

*(a)* *(b)*

*(c)* *(d)*

Figura 4.17: Aperturas mínimas y máximas del ejercicio 3. Voluntarios DC33 *(a)* y *(b)* y DC8 *(c)* y *(d)*.

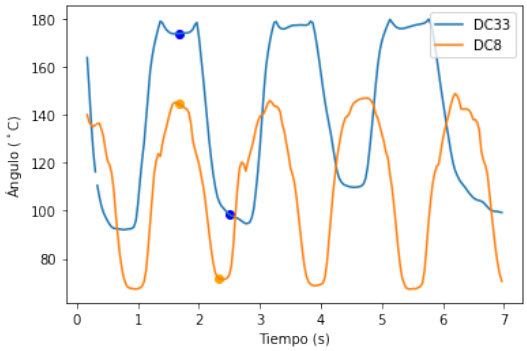


Figura 4.18: Ángulo FN_A_t_mMCP_p, controles DC33 y DC8.

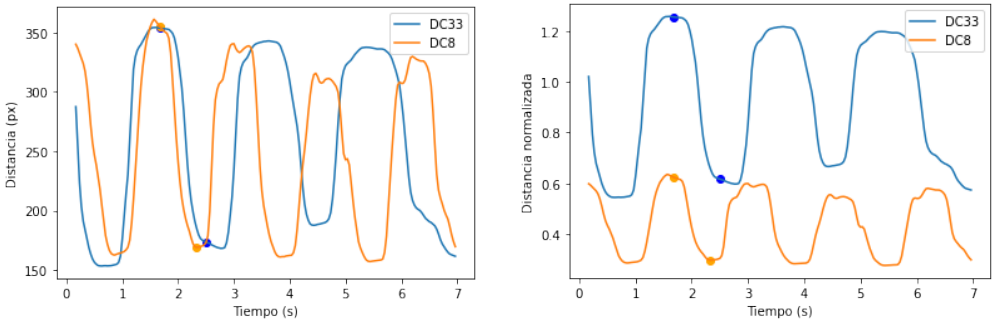


*(a)* *(b)*

Figura 4.19: Distancia FN_D_m_p *(a)* y distancia normalizada FN_DN_m_p *(b)*.

## 4.3. Vídeos de pacientes

Pese a que el número de pacientes de ictus incluidos en el estudio (cinco personas), no son suficientes para formar una muestra estadísticamente relevante, sus vídeos se analizaron con las redes entrenadas. En general, se detectaron las posiciones de las manos satisfactoriamente, pudiendo incluso observar diferencias en las variables cinemáticas para los vídeos de las manos sintomáticas y asintomáticas (en la Figura 4.20 se incluyen dos gráficas con las distancias PI_D_t_i y FN_D_tIP_pPIP para el paciente DP4, estas gráficas muestran una mayor amplitud de la pinza a lo largo del tiempo así como mayor rango de movimiento en la separación lateral de los dedos en la mano asintomática).

Estos resultados, ofrecen futuras líneas de investigación, como realizar el estudio de las variables cinemáticas que mantengan una mayor correlación con la exploración clínica, así como en general, la viabilidad de este sistema en la evaluación del déficit de la mano de pacientes con ictus.

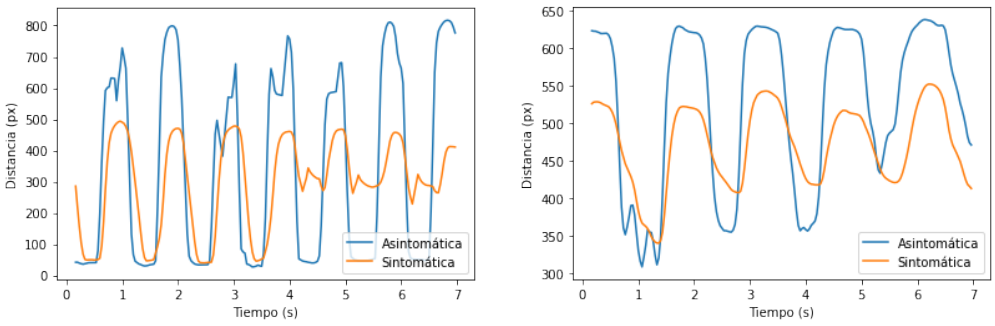


*(a)* *(b)*

Figura 4.20: Gráficas comparativas de manos sintomática y asintomática. Paciente DP4: distancia PI_D_t_i *(a)* y distancia FN_D_tIP_pPIP *(b)*.

# Capítulo 5

# Conclusiones

## 5.1. Conclusiones

Tras exponer el desarrollo y los resultados de este Trabajo de Fin de Grado, se recogen las siguientes conclusiones:

1. Atendiendo a los objetivos marcados, se ha podido diseñar y construir una estructura de soporte con la que grabar los vídeos de ambas manos satisfactoriamente. El mantenimiento de una posición constante de los brazos es necesario para que el cálculo de las variables cinemáticas sea correcto, por lo que se propone extender el uso del soporte de brazos a todos los sujetos.

2. La captura óptica con un único dispositivo móvil, es una vía accesible y eficaz para la extracción de la pose de la mano mediante redes neuronales artificiales. Sin embargo, el ejercicio de apertura y cierre del puño, en el que parte de la mano no se encontraba visible para la cámara, es menos útil puesto que DeepLabCut no es un *software* capaz de predecir la posición de dichas partes y el cálculo de variables se ve limitado.

3. El etiquetado de *frames* es un proceso crítico que sin embargo requiere de un gran volumen de datos y tiempo. El uso de DeepLabCut, permite obtener buenos resultados de estimación de la posición, minimizando los recursos de vídeos y tiempo necesarios.

4. Se ha podido extraer variables cinemáticas representativas del movimiento de la mano. Destacando las distancias, por su sencillez de interpretación y menor error asociado a su cálculo. La correlación de las variables obtenidas con este sistema con los parámetros clínicos, aún no ha podido ser estudiada dado el escaso número de pacientes del estudio, pero se plantea como futura línea de investigación.

## 5.2. Líneas futuras

Debido a la complejidad del movimiento de la mano, se considera de interés continuar con el estudio de la estimación del movimiento de la mano con una muestra

poblacional más variada así como incluyendo distintas vistas del movimiento.

Por otro lado, pese a que las variables extraídas son comunes a otros estudios clinimétricos, se considera de interés la validación de estas medidas con pacientes y controles, realizando un estudio de la correlación de estas medidas cinemáticas con parámetros clínicos y escalas clínicas validadas.

Además, se propone el estudio de la estimación de la posición con diferentes dispositivos móviles y cámaras de distinta calidad y resolución así como el uso de cámaras de alta definición espacial y temporal para el cálculo de nuevas variables como la aceleración y el *jerk*, para la medida de la fluidez o suavidad del movimiento.

# Referencias

## Referencias


[1] Jeffrey L. Saver. Time is brain - Quantified, 1 2006.

[2] N Ruiz-Giménez, P González Ruano, and C Suárez. Abordaje del accidente cerebrovascular. *Información Terapéutica del Sistema Nacional de Salud*, 26(4), 2002.

[3] Patricia Simal Hernández, Jorge Matías Guiu-Guia, Teresa Hernández Meléndez, Pilar Aparicio Azcárraga, and Comité Institucional de la Estrategia en ICTUS del SNS. Logros y retos en la atención del ictus en españa: desde la estrategia del sistema nacional de salud al plan de acción europeo 2018-2030. *Revista Española de Salud Pública*, 10 2021.

[4] Exuperio. Diez Tejedor. *Guia para el diagnostico y tratamiento del ictus*. Prous Science, 2006.

[5] Estrategia en Ictus del Sistema Nacional de Salud. Ministerio de Sanidad y Política Social, 2009.

[6] E. Díez Tejedor and R. Soler. Concepto y clasificación de las enfermedades cerebrovasculares. In *Manual de enfermedades vasculares cerebrales*. 1999.

[7] María Angeles Durán Heras. Informe sobre el impacto social de los enfermos dependientes por ictus. informe isedic, 2004.

[8] Panel Margaret Kelly-Hayes, James T. Robertson, Joseph P. Broderick, Pamela W. Duncan, Linda A. Hershey, Elliot J. Roth, William H. Thies, and Catherine A. Trombly. The american heart association stroke outcome classification. *Stroke*, 29(6):1274–1280, 1998.

[9] Grupo de Trabajo de la Guía de Práctica Clínica para el Manejo de Pacientes con Ictus en Atención Primaria. *Guía de Práctica Clínica para el Manejo de Pacientes con Ictus en Atención Primaria*. Agencia Laín Entralgo, Comunidad de Madrid, 2009.

[10] Ángel Arias Cuadrado. Rehabilitación del acv: evaluación, pronóstico y tratamiento, 2009.

[11] Henrik S Jcrgensen, Hirofumi Nakayama, Hans O Raaschou, Jcrgen Vive-Larsen, Mogens St¢ier, Tom S Olsen, and Henrik Stig Jcrgensen. Outcome and time course of recovery in stroke. part ii: Time course of recovery. the copenhagen stroke study, 1995.

[12] Anne Schwarz, Christoph M. Kanzler, Olivier Lambercy, Andreas R. Luft, and Janne M. Veerbeek. Systematic review on kinematic assessments of upper limb movements after stroke, 3 2019.

[13] Brittany Hand, Stephen J. Page, and Susan White. Stroke survivors scoring zero on the NIH stroke scale score still exhibit significant motor impairment and functional limitation. *Stroke Research and Treatment*, 2014.

[14] R De Haan, ; J Horn, ; M Limburg, ; J Van Der Meulen, and ; P Bossuyt. A comparison of five stroke scales with measures of disability, handicap, and quality of life. *Stroke*, 24:1178–1181, 1993.

[15] Jennifer K. Harrison, Katherine S. McArthur, and Terence J. Quinn. Assessment scales in stroke: Clinimetric and clinical considerations, 2 2013.

[16] Scott E Kasner. Clinical interpretation and use of stroke scales. *The Lancet Neurology*, 5(7):603–612, July 2006.

[17] M. Maria Glymour, Lisa F. Berkman, Karen A. Ertel, Martha E. Fay, Thomas A. Glass, and Karen L. Furie. Lesion characteristics, nih stroke scale, and functional recovery after stroke, 9 2007.

[18] J C Van Swieten, P J Koudstaal, M C Visser, H J A Schouten, and J Van Gijn. Interobserver agreement for the assessment of handicap in stroke patients. *Stroke*, 19:604–607, 1988.

[19] Antonio Siniscalchi, Piergiorgio Lochner, Paolo Perrotta, Stefano Rizzuto, Giovambattista De Sarro, and Luca Gallelli. Isolated hand palsy in national institutes of health stroke scale (nihss): Is it useful?, 5 2018.

[20] Axel R. Fugl-Meyer, Lisbeth Jääskö, Leyman Ingegerd, Sigyn Olsson, and Solveig Steglind. The post-stroke hemiplegic patient. *Scandinavian Journal of Rehabilitation Medicine*, pages 13–31, 1975.

[21] Fátima Pérez-Robledo, Rocío Llamas-Ramos, Inés Llamas-Ramos, Beatriz M. Bermejo-Gil, Juan L. Sánchez-González, and Ana M. Martín-Nogueras. Adaptation and feasibility of the online version of the fugl meyer scale for the assessment of patients following cerebrovascular accidents. *Revista de Neurologia*, 74:156–162, 1 2022.

[22] Erica Zurawski, Kirsten Behm, Charlotte Dunlap, James Koo, Farooq Ismail, Chris Boulias, Shannon Reid, and Chetan P. Phadke. Interrater reliability of the modified ashworth scale with standardized movement speeds: A pilot study. *Physiotherapy Canada*, 71:348–354, 9 2019.

[23] María Pilar Sáinz Pelayo, Sergiu Albu, Narda Murillo, and Jesús Benito Penalva. Espasticidad en la patología neurológica. actualización sobre mecanismos fisiopatológicos, avances en el diagnóstico y tratamiento. *Revista de Neurología*, 70(12):453, 2020.

[24] E. A. Zancolli and E. R. Zancolli. Surgical management of the hemiplegic spastic hand in cerebral palsy. *Surgical Clinics of North America*, 61:395–406, 1981.

[25] José Manuel Pérez Mármol. Valoración funcional de la mano. In *Terapia de mano basada en el razonamiento y la práctica clínica*, chapter 2, pages 31–41. 2020.

[26] Sergio Rodríguez Menéndez. Evaluación y exploración de la mano neurológica. In *Terapia de mano basada en el razonamiento y la práctica clínica*, chapter 18, pages 227–239. 2020.

[27] Rieko Osu, Kazuko Ota, Toshiyuki Fujiwara, Yohei Otaka, Mitsuo Kawato, and Meigen Liu. Quantifying the quality of hand movement in stroke patients through three-dimensional curvature. *Journal of NeuroEngineering and Rehabilitation*, 8, 2011.

[28] Margit Alt Murphy, Steve Murphy, Hanna C. Persson, Ulla Britt Bergström, and Katharina Stibrant Sunnerhagen. Kinematic analysis using 3d motion capture of drinking task in people with and without upper-extremity impairments. *Journal of Visualized Experiments*, 2018, 3 2018.

[29] Luca Lonini, Yaejin Moon, Kyle Embry, R. James Cotton, Kelly McKenzie, Sophia Jenz, and Arun Jayaraman. Video-based pose estimation for gait analysis in stroke survivors during clinical assessments: A proof-of-concept study. *Digital Biomarkers*, pages 9–18, 2022.

[30] Ryan North, Rachele Wurr, Ryan Macon, Christopher Mannion, John Hyde, Abel Torres-Espin, Ephron S. Rosenzweig, Adam R. Ferguson, Mark H. Tuszynski, Michael S. Beattie, Jacqueline C. Bresnahan, and Wilsaan M. Joiner. Quantifying the kinematic features of dexterous finger movements in nonhuman primates with markerless tracking. In *2021 43rd Annual International Conference of the IEEE Engineering in Medicine &amp Biology Society (EMBC)*. IEEE, November 2021.

[31] Nkenge Wheatland, Yingying Wang, Huaguang Song, Michael Neff, Victor Zordan, and Sophie Jörg. State of the art in hand and finger modeling and animation. volume 34, pages 735–760. Blackwell Publishing Ltd, 5 2015.

[32] Youchen Du, Shenglan Liu, Lin Feng, Menghui Chen, and Jie Wu. Hand gesture recognition with leap motion. 11 2017.

[33] Toby Sharp, Cem Keskin, Duncan Robertson, Jonathan Taylor, Jamie Shotton, David Kim, Christoph Rhemann, Ido Leichter, Alon Vinnikov, Yichen Wei, Daniel Freedman, Pushmeet Kohli, Eyal Krupka, Andrew Fitzgibbon, and Shahram Izadi. Accurate, robust, and flexible realtime hand tracking. volume 2015-April, pages 3633–3642. Association for Computing Machinery, 4 2015.

[34] Jungong Han, Ling Shao, Dong Xu, and Jamie Shotton. Enhanced computer vision with microsoft kinect sensor: A review. *IEEE Transactions on Cybernetics*, 43:1318–1334, 10 2013.

[35] Ultraleap. Leap motion controller. [Online; consultado 16 junio 2022].

[36] Nikolaus Kriegeskorte and Tal Golan. Neural network models and deep learning, 4 2019.

[37] Keiron O'Shea and Ryan Nash. An introduction to convolutional neural networks. 11 2015.

[38] Aurelien Geron. *Hands-on machine learning with scikit-learn, keras, and TensorFlow*. O'Reilly Media, Sebastopol, CA, 2 edition, October 2019.

[39] Deekshith Shetty*, Harshavardhan C.A, M Jayanth Varma, Shrishail Navi, and Mohammed Riyaz Ahmed. Diving deep into deep learning: History, evolution, types and applications. *International Journal of Innovative Technology and Exploring Engineering*, 9:2835–2846, 1 2020.

[40] Geoffrey E Hinton and Simon Osindero. A Fast Learning Algorithm for Deep Belief Nets, 2006.

[41] Jordan J Bird and Diego R Faria. A study on cnn transfer learning for image classification, 2018.

[42] Łukasz Kidziński, Bryan Yang, Jennifer L. Hicks, Apoorva Rajagopal, Scott L. Delp, and Michael H. Schwartz. Deep neural networks enable quantitative movement analysis using single-camera videos. *Nature Communications*, 11, 12 2020.

[43] Talmo D. Pereira, Diego E. Aldarondo, Lindsay Willmore, Mikhail Kislin, Samuel S.H. Wang, Mala Murthy, and Joshua W. Shaevitz. Fast animal pose estimation using deep neural networks. *Nature Methods*, 16:117–125, 1 2019.

[44] Jacob M. Graving, Daniel Chae, Hemal Naik, Liang Li, Benjamin Koger, Blair R. Costelloe, and Iain D. Couzin. Deepposekit, a software toolkit for fast and robust animal pose estimation using deep learning. *eLife*, 8, 10 2019.

[45] Zhe Cao, Gines Hidalgo, Tomas Simon, Shih-En Wei, and Yaser Sheikh. Openpose: Realtime multi-person 2d pose estimation using part affinity fields. 12 2018.

[46] Tanmay Nath, Alexander Mathis, An Chi Chen, Amir Patel, Matthias Bethge, and Mackenzie Weygandt Mathis. Using DeepLabCut for 3d markerless pose estimation across species and behaviors. *Nature Protocols*, 14(7):2152–2176, June 2019.

[47] Kenny Chen, Paolo Gabriel, Abdulwahab Alasfour, Chenghao Gong, Werner K. Doyle, Orrin Devinsky, Daniel Friedman, Patricia Dugan, Lucia Melloni, Thomas

Thesen, David Gonda, Shifteh Sattar, Sonya Wang, and Vikash Gilja. Patient-specific pose estimation in clinical environments. *IEEE Journal of Translational Engineering in Health and Medicine*, 6, 2018.

[48] Ori Ossmy and Karen E. Adolph. Real-time assembly of coordination patterns in human infants. *Current Biology*, 30(23):4553–4562.e4, December 2020.

[49] Jan Stenum, Kendra M. Cherry-Allen, Connor O. Pyles, Rachel D. Reetzke, Michael F. Vignos, and Ryan T. Roemmich. Applications of pose estimation in human health and performance across the lifespan, 11 2021.

[50] Tomas Simon, Hanbyul Joo, Iain Matthews, and Yaser Sheikh. Hand keypoint detection in single images using multiview bootstrapping. 4 2017.

[51] Zhibin Zhao, Hui Fang, Stefan Williams, Samuel D. Relton, Jane Alty, Alex J. Casson, and David C. Wong. Time series clustering to examine presence of decrement in parkinson's finger-tapping bradykinesia. volume 2020-July, pages 780–783. Institute of Electrical and Electronics Engineers Inc., 7 2020.

[52] Paul A. Harris, Robert Taylor, Robert Thielke, Jonathon Payne, Nathaniel Gonzalez, and Jose G. Conde. Research electronic data capture (REDCap)—a metadata-driven methodology and workflow process for providing translational research informatics support. *Journal of Biomedical Informatics*, 42(2):377–381, April 2009.

[53] Paul A. Harris, Robert Taylor, Brenda L. Minor, Veida Elliott, Michelle Fernandez, Lindsay O'Neal, Laura McLeod, Giovanni Delacqua, Francesco Delacqua, Jacqueline Kirby, and Stephany N. Duda. The REDCap consortium: Building an international community of software platform partners. *Journal of Biomedical Informatics*, 95:103208, July 2019.

[54] Medical gallery of blausen medical 2014. *WikiJournal of Medicine*, 1(2), 2014.

[55] Alexander Mathis, Pranav Mamidanna, Kevin M. Cury, Taiga Abe, Venkatesh N. Murthy, Mackenzie Weygandt Mathis, and Matthias Bethge. Deeplabcut: markerless pose estimation of user-defined body parts with deep learning. *Nature Neuroscience*, 21:1281–1289, 9 2018.

[56] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep residual learning for image recognition. 12 2015.

[57] Neal Gallagher. Savitzky-golay smoothing and differentiation filter, 2020.

# Apéndice A

# Aspectos éticos, económicos, sociales y ambientales

Este TFG tiene como objetivo final proporcionar una herramienta de evaluación de la motricidad de la mano en aquellos pacientes que han sufrido un ictus. No obstante, la consecución de dicho objetivo debe ser alcanzada de forma ética, considerando el impacto de este trabajo a nivel económico, social y ambiental.

## A.1. Impactos y aspectos del trabajo

- **Aspectos éticos**: El desarrollo de este proyecto ha sido aprobado por el Comité de Ética de la Investigación del HULP. La recogida de datos se llevó a cabo siguiendo el Reglamento General de Protección de Datos (GDPR) de la Unión Europea, de modo que los datos de los voluntarios fueron recogidos bajo un identificador anonimizado.

- **Impacto económico**: El coste del desarrollo de este proyecto se detalla en el Anexo B. A nivel global, una correcta evaluación del déficit motor, constituye un elemento clave para maximizar su recuperación, reduciendo así el coste asociado a la dependencia adquirida a causa del ictus.

- **Impacto social**: La prevalencia de las enfermedades cerebrovasculares, hace que el avance en su estudio pueda generar un gran impacto a nivel social. Este trabajo introduce una herramienta para el personal sanitario y pacientes, pudiendo ayudar a alcanzar una mayor recuperación funcional de la motricidad de la mano con apoyo de esta, ya que medir adecuadamente el déficit puede permitir la optimización del tratamiento de rehabilitación y ello a su vez mejorar la recuperación de los pacientes, lo cual impactará positivamente en su funcionalidad y calidad de vida contribuyendo a reducir el coste sanitario y social. Se genera así un impacto positivo en la calidad de vida del paciente así como en su entorno.

  Además, el desarrollo de este TFG mediante herramientas de *software* libre, así como la estimación de la posición con vídeos de móviles, democratiza el acceso a los avances que de este estudio se puedan obtener.

- **Impacto medioambiental**: los materiales empleados en la estructura pueden ser extraídos y reutilizados en otros proyectos una vez finalice este. Además, el uso de un móvil, dispositivo común en la actualidad, para la captura del movimiento, evita la necesidad de adquirir dispositivos específicos únicamente empleados para ello, generando así el mínimo número de residuos posibles.

  Sin embargo, el almacenamiento de los vídeos y datos generados, debe hacerse en formatos que optimicen su almacenamiento, debido al gran volumen que puede suponer el uso de esta herramienta a gran escala. La carga computacional requerida para el uso de las redes neuronales artificiales conlleva un elevado consumo de energía, que debe optimizarse.

## A.2. Conclusiones

Si bien, este trabajo trata el problema en cuestión de forma ética, su impacto medioambiental debe ser considerado en el futuro para un almacenamiento y cómputo eficiente y sostenible. Este TFG tiene un potencial impacto económico y social positivo para la sociedad.

# Apéndice B

# Presupuesto económico

Este anexo resume el coste estimado para la realización de este TFG. Para su cálculo, consideramos dos tipos de gasto: coste de personal y coste de recursos materiales. Los costes se detallan en las Tablas B.1 (recursos humanos), B.2 (recursos materiales) y B.3 (coste total).

- **Personal**: El desarrollo de este proyecto ha requerido la implicación de 4 personas: dos directores del trabajo (para las tareas técnicas y clínicas respectivamente), un técnica de laboratorio para la supervisión del montaje de la estructura e impresión 3D y un estudiante de ingeniería biomédica (ver Tabla B.1).

| | **Coste horario (€)** | **Horas** | **Total (€)** |
|---|---|---|---|
| **Director del trabajo 1** | 60 | 30 | 1800 |
| **Director del trabajo 2** | 60 | 30 | 1800 |
| **Estudiante de ingeniería** | 15 | 300 | 4500 |
| **Técnico de laboratorio** | 50 | 20 | 1000 |
| **TOTAL** | | | **9100** |

Tabla B.1: Costes de personal.

- **Costes de recursos materiales**: Como se mencionó en el Capítulo 3, para el desarrollo de este trabajo ha sido necesaria la construcción de una estructura o soporte para la grabación. A continuación se detallan los gastos de la estructura así como los gastos correspondientes a la impresora 3D (Prusa i3 MK3S), el ordenador personal empleado (Lenovo IdeaPad Flex 5 14IIL05), el móvil utilizado para la grabación de los vídeos (iPhone XS) y la GPU (NVIDIA GeForce RTX 2080 Ti) para el entrenamiento de las redes neuronales artificiales. Puesto que el *software* empleado es de código abierto, no requiere de licencia y su coste asociado es nulo (DeepLabCut y otras dependencias de Python), a excepción del programa Autodesk Inventor® (ver Tabla B.2).

| | Tiempo de vida (años) | Uds. | Coste (€) | Amortización (€/mes) | Uso (meses) | Total (€) |
|---|---|---|---|---|---|---|
| **Ordenador** | 5 | 1 | 900 | 15 | 9 | 135 |
| **iPhone XS** | 5 | 1 | 500 | 8,33 | 7 | 58,31 |
| **Autodesk Inventor** | 1 | 1 | 2400 | 200 | 2 | 400 |
| **Python** | - | - | 0 | - | 9 | 0 |
| **Impresora 3D** | 5 | 1 | 800 | 13,33 | 1 | 13,33 |
| **NVIDIA GPU** | 5 | 1 | 700 | 11,67 | 4 | 46,68 |
| **Filamento PLA** | - | 1 | 20 | - | - | 20 |
| **Perfiles de aluminio** | - | 2 | 60 | - | - | 120 |
| **Escuadras** | - | 14 | 1 | - | - | 14 |
| **Tornillos** | - | 28 | 0.05 | - | - | 1,4 |
| **Arandelas** | - | 18 | 0.05 | - | - | 0,9 |
| **Tuercas** | - | 24 | 0.05 | - | - | 1,2 |
| **Tablón de madera** | - | 1 | 15 | - | - | 15 |
| **TOTAL** | | | | | | **825,82** |

Tabla B.2: Costes de recursos materiales.

Aplicando un IVA (Impuesto sobre el Valor Añadido) del 21 % a los costes materiales y combinando ambos tipos de costes, estimamos un gasto total de 10099,24€ asociado al desarrollo de este trabajo.

| | **Coste** |
|---|---|
| **Costes de personal** | 9100€ |
| **Costes de material** | 825,82€ |
| **Subtotal** | 9925,82€ |
| **IVA** | 173,42€ |
| **Total** | 10099,24€ |

Tabla B.3: Costes totales.

# Apéndice C

# Datos recogidos en REDCap

| Campo | Opciones |
|---|---|
| ID | texto |
| Tipo de voluntario | Paciente<br>Control |
| Fecha del estudio | dd/mm/aaaa |
| Edad | texto |
| Sexo | Mujer<br>Hombre |
| Mano Dominante | Izquierda<br>Derecha<br>Ambidiestro |
| Tabaquismo | No<br>Sí<br>Exfumador |
| Alcohol | No<br>Moderado<br>>100mL/día |
| Hipertensión Arterial | Sí / No |
| Diabetes Mellitus | Sí / No |
| Dislipidemia | Sí / No |
| Fibrilación Auricular | Sí / No |
| Antecedentes de Ictus | Sí / No |
| Otras patologías | texto |
| Cuestionario EUROQol-5D* | - |

Tabla C.1: Cuestionario de datos demográficos.

El cuestionario EUROQoL-5D solo se realizó a aquellos voluntarios que eran pacientes de ictus. Del mismo modo, los cuestionarios de las tablas C.2 y C.3 solo se aplican a pacientes de ictus.

| **Campo** | **Opciones** |
|---|---|
| Fecha de inicio de los síntomas | dd/mm/aaaa |
| Diagnóstico | AIT<br>Infarto Cerebral Territorial<br>Infarto Cerebral Lacunar<br>Hemorragia Cerebral<br>Otros (texto) |
| Localización de la lesión | Sin lesión<br>Arteria CA<br>Arteria CM<br>Arteria CP<br>Ganglios de la base<br>Cerebelo<br>Tronco |
| Lateralidad de la lesión | Izquierda<br>Derecha<br>Indeterminado |
| Lado sintomático | Izquierdo<br>Derecho<br>Bilateral<br>Ninguno |

Tabla C.2: Cuestionario de datos clínicos.

| Campo | Opciones |
|---|---|
| Rankin Basal | Número entero |
| NIHSS | Número entero |
| Fugl Meyer (miembro superior) | Número entero |
| Balance muscular muñeca (m. sintomática) | 0<br>1<br>2<br>3<br>4 |
| Balance muscular pinza (m. sintomática) | 0<br>1<br>2<br>3<br>4 |
| Balance muscular sep. dedos (m. sintomática) | 0<br>1<br>2<br>3<br>4 |
| Balance muscular puño (m. sintomática) | 0<br>1<br>2<br>3<br>4 |
| Balance muscular muñeca (m. asintomática) | idem |
| Balance muscular pinza (m. asintomática) | idem |
| Balance muscular sep. dedos (m. asintomática) | idem |
| Balance muscular puño (m. asintomática) | idem |

Tabla C.3: Cuestionario de datos de la exploración.

# Apéndice D

# Tablas de *likelihood*

Tabla D.1: *Likelihood* media por ejercicio y etiqueta

| | | Ej. 1 | Ej. 2 | Ej. 3 | Ej. 4 |
|---|---|---|---|---|---|
| wristInner | median | 0.254881 | 0.054955 | 0.352743 | 0.359723 |
| | q1 | 0.102999 | 0.009129 | 0.192267 | 0.204200 |
| | q3 | 0.446819 | 0.175009 | 0.540024 | 0.475378 |
| wristOuter | median | 0.491994 | 0.203714 | 0.384853 | 0.378698 |
| | q1 | 0.286994 | 0.050365 | 0.227557 | 0.304923 |
| | q3 | 0.730300 | 0.356899 | 0.529205 | 0.530092 |
| thumb | median | 0.863388 | 0.967277 | 0.815442 | 0.803113 |
| | q1 | 0.602935 | 0.854220 | 0.785077 | 0.462054 |
| | q3 | 0.968960 | 0.999209 | 0.962858 | 0.896747 |
| thumbIP | median | 0.827263 | 0.845311 | 0.955533 | 0.859715 |
| | q1 | 0.546880 | 0.779802 | 0.908450 | 0.684142 |
| | q3 | 0.969343 | 0.882442 | 0.972167 | 0.878489 |
| thumbMCP | median | 0.814378 | 0.433895 | 0.849943 | 0.896295 |
| | q1 | 0.545450 | 0.311352 | 0.618869 | 0.804151 |
| | q3 | 0.943104 | 0.648023 | 0.970128 | 0.954383 |
| index | median | 0.992996 | 0.981671 | 0.978493 | 0.567638 |
| | q1 | 0.896056 | 0.877888 | 0.930571 | 0.203167 |
| | q3 | 0.998690 | 0.999485 | 0.998745 | 0.930681 |
| indexDIP | median | 0.990727 | 0.870678 | 0.987560 | 0.799726 |
| | q1 | 0.626703 | 0.710132 | 0.951587 | 0.333736 |
| | q3 | 0.999269 | 0.966454 | 0.997792 | 0.996497 |
| indexPIP | median | 0.960972 | 0.795479 | 0.998601 | 0.955916 |
| | q1 | 0.656760 | 0.640879 | 0.987404 | 0.903543 |
| | q3 | 0.999499 | 0.940205 | 0.999711 | 0.976470 |
| indexMCP | median | 0.771971 | 0.756991 | 0.904837 | 0.932172 |
| | q1 | 0.560666 | 0.532922 | 0.821063 | 0.794252 |
| | q3 | 0.859676 | 0.836586 | 0.988488 | 0.955371 |

Continúa en la siguiente página

Tabla D.1: *Likelihood* media por ejercicio y etiqueta

| | | Ej. 1 | Ej. 2 | Ej. 3 | Ej. 4 |
|---|---|---|---|---|---|
| middle | median | 0.994220 | 0.927153 | 0.999325 | 0.302056 |
| | q1 | 0.914733 | 0.858005 | 0.992914 | 0.076805 |
| | q3 | 0.999520 | 0.986942 | 0.999805 | 0.874999 |
| middleDIP | median | 0.982191 | 0.936079 | 0.982431 | 0.613453 |
| | q1 | 0.695462 | 0.732843 | 0.938684 | 0.095177 |
| | q3 | 0.999603 | 0.990488 | 0.997254 | 0.960327 |
| middlePIP | median | 0.960729 | 0.877097 | 0.999644 | 0.906913 |
| | q1 | 0.573324 | 0.570881 | 0.998500 | 0.764135 |
| | q3 | 0.999610 | 0.976385 | 0.999884 | 0.996150 |
| middleMCP | median | 0.833969 | 0.556973 | 0.914205 | 0.896717 |
| | q1 | 0.623857 | 0.306844 | 0.817303 | 0.775616 |
| | q3 | 0.925040 | 0.753188 | 0.966334 | 0.976369 |
| ring | median | 0.997365 | 0.820617 | 0.998653 | 0.270436 |
| | q1 | 0.935106 | 0.574703 | 0.988127 | 0.027919 |
| | q3 | 0.999707 | 0.949937 | 0.999838 | 0.850829 |
| ringDIP | median | 0.965956 | 0.726068 | 0.988682 | 0.399946 |
| | q1 | 0.742150 | 0.520290 | 0.948803 | 0.024804 |
| | q3 | 0.997941 | 0.953959 | 0.999210 | 0.867856 |
| ringPIP | median | 0.944549 | 0.521274 | 0.998280 | 0.852040 |
| | q1 | 0.657870 | 0.319571 | 0.981865 | 0.617476 |
| | q3 | 0.962133 | 0.740576 | 0.999831 | 0.992375 |
| ringMCP | median | 0.831873 | 0.177706 | 0.938749 | 0.970557 |
| | q1 | 0.568089 | 0.083396 | 0.774707 | 0.865212 |
| | q3 | 0.945184 | 0.344556 | 0.995057 | 0.997455 |
| pinky | median | 0.998716 | 0.475550 | 0.992086 | 0.313448 |
| | q1 | 0.952843 | 0.333191 | 0.964860 | 0.043749 |
| | q3 | 0.999775 | 0.714613 | 0.999114 | 0.954617 |
| pinkyDIP | median | 0.968144 | 0.330990 | 0.988094 | 0.384447 |
| | q1 | 0.730268 | 0.218397 | 0.948628 | 0.055731 |
| | q3 | 0.998621 | 0.424958 | 0.997678 | 0.981343 |
| pinkyPIP | median | 0.969719 | 0.313591 | 0.999008 | 0.915038 |
| | q1 | 0.695647 | 0.193268 | 0.995688 | 0.484259 |
| | q3 | 0.995451 | 0.505212 | 0.999689 | 0.998833 |
| pinkyMCP | median | 0.852152 | 0.267264 | 0.967267 | 0.954728 |
| | q1 | 0.513947 | 0.178615 | 0.863044 | 0.900439 |
| | q3 | 0.954753 | 0.370995 | 0.998465 | 0.995081 |