



UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA

FACULTAD DE INGENIERÍA

PROYECTO DE INVESTIGACIÓN

**ENTRENAMIENTO DE UNA RED NEURONAL CONVOLUCIONAL PARA LA PRUEBA
SIT TO STAND EN REHABILITACIÓN**

**PREVIO A LA OBTENCIÓN DEL TÍTULO:
DE INGENIERO EN BIOMÉDICA**

PRESENTADO POR:

21911023 EDGARDO ISAÍ ARÉVALO LÓPEZ

ASESOR: KARLA REYES

SAN PEDRO SULA, CORTES, HONDURAS, C.A.

ABRIL 2024

Dedicatoria

Quisiera dedicarle este logro primeramente a Dios, ya que siempre me dio las fuerzas necesarias para poder seguir adelante y no decaer, seguidamente a mis padres Williams Arévalo y Mariela López, que siempre tuvieron fe de que lograría mi meta y por último a todas esas personas que me brindaron ayuda y apoyaron en todo momento.

Agradecimientos

Primeramente, agradecido con Dios por brindarme todo lo requerido en mi vida para llegar hasta donde estoy y que me acompañe hasta donde estaré en un futuro, a mis padres Mariela López y Williams Arévalo que me brindaron su gran apoyo incondicionalmente porque de no ser por su esfuerzo, enseñanzas y fe que tenían en mí no lo hubiese logrado, a mi familia López Arévalo que siempre me aconsejaban para seguir adelante, sin ellos y sin Dios jamás me hubiese convertido en lo que soy ahora y seré en un futuro. En ustedes recae mi adoración y pasión

Agradezco a Larissa Martínez que me acompañó en esos momentos en los cuales quería que todo se acabara, me ayudo a darme cuenta de lo que soy y lo que valgo siendo el hombro que necesitaba para descansar y desahogarme, apoyándome en todos mis desvelos brindándome consuelo y palabras de aliento. En ti recae mi más sincero amor y gratitud

La universidad no hubiese sido divertida sin amigos, esas personas por las cuales me gustaba ir a recibir clases, para ustedes: Arlin Mejía, Brianna Morales, Claudia Villalobos, Diego Irula, Fernando Pavón, Isis Martínez, Katherine Alberto, Moisés Gómez, Luis Reynaldo, Marvin Padilla y muchos otros más, a ustedes les agradezco por hacerme sentir como una familia ya que siempre estaban cuando más los necesitaba y siempre recordare la universidad como una época de estrés, felicidad y muchas risas, sobre ustedes recae mi amistad y cariño.

Agradecer a la Ing. Karla Reyes reconociéndola como una de las docentes más dedicada, amable, atenta, talentosa y estricta que sin la ayuda de su capacidad no hubiese obtenido este logro, sobre usted recae mi mayor respeto y admiración.

EPÍGRAFE

“PORQUE NINGUNA COSA ES IMPOSIBLE PARA DIOS”

LUCAS 1:37

RESUMEN EJECUTIVO

El método tradicional para rastrear el movimiento del cuerpo humano fue el uso de sistemas de captura de movimiento basado en marcadores infrarrojos, una tecnología ampliamente utilizada para medir el rango de movimiento (ROM). Este sistema se consideró el "estándar de oro" ya que ofrecía alta precisión y fiabilidad, sin embargo, era requerida una alta inversión monetaria para poder emplear este tipo de sistema. La captura de movimiento sin marcadores se presentó como una alternativa a la captura de movimiento basada en marcadores. Esta técnica resultó más asequible y fácil de usar, pero también demostró tener el potencial de ser más precisa. Con el concepto más claro se presentó la idea de cómo este tipo de sistemas de captura de movimiento pueden impulsar a mejorar el diagnóstico médico en rehabilitación brindando asistencia de manera remota. Para hacer funcionar este proyecto fue requerida la creación de una base de datos la cual contenía una serie de videos de las personas ejecutando un ejercicio de rehabilitación llamado Sit To Stand (STS) la cual requiere que el paciente se levante y se siente de una silla sin apoyabrazos durante 30 segundos haciendo la mayor cantidad de repeticiones posibles, siendo una prueba bastante esencial para lograr medir la capacidad física que tiene la persona. Uno de los objetivos para este estudio fue la aplicación de una red neural convolucional (CNN siglas en inglés) capaz de detectar las veces en las que una persona se levanta y se sienta durante la ejecución de la prueba STS, apoyando fuertemente el área de telemedicina debido a que será de gran utilidad para los centros de rehabilitación y sobre todo se logra hacer consentimiento referente a las personas discapacitadas ya sea por alguna enfermedad o genética facilitando para ellos asistir a su rehabilitación porque gracias a esta CNN tiene la oportunidad de recibir atención del personal médico sin la necesidad de salir de la comodidad de su hogar.

Palabras Clave— Computer Vision, Convolutional Neuronal Network, Deep Learning, Kinovea, Sit To Stand.

ABSTRACT

The traditional method for tracking human body movement involved the use of infrared marker-based motion capture systems, a widely used technology for measuring Range of Motion (ROM). This system was considered the "gold standard" as it offered high precision and reliability, but it required a significant monetary investment to employ. Markerless motion capture emerged as an alternative to marker-based motion capture. This technique proved to be more affordable and user-friendly, while also demonstrating the potential to be more accurate. With a clearer concept, the idea was presented as to how such motion capture systems could enhance medical diagnosis in rehabilitation by providing remote assistance. To operationalize this project, the creation of a database was required, containing a series of videos of individuals performing a rehabilitation exercise called 30 seconds Sit to Stand (STS), which requires the patient to stand up and sit down from a chair without armrests for 30 seconds, aiming to complete as many repetitions as possible. This test is essential for measuring the physical capacity of the individual. One of the objectives of this study was the Application of a Convolutional Neural Network (CNN) capable of detecting the times a person stands up and sits down during the execution of the STS test, strongly supporting the field of telemedicine as it will be of great use for rehabilitation centers, and most importantly, it allows consent for disabled individuals, whether due to illness or genetics, to attend their rehabilitation more easily because thanks to this CNN, they have the opportunity to receive medical attention without the need to leave the comfort of their homes.

Keywords: Computer Vision, Convolutional Neuronal Network, Deep Learning, Kinovea, Sit to Stand.

LISTA DE SIGLAS

ROM	Range of Movement
DL	Deep Learning
CV	Computer Vision
STS	Sit to Stand
PMMC	Passive Movement Motion Capture
CNN	Convolutional Neuronal Network
MoCap	Motion Capture

GLOSARIO

Las definiciones contenidas en este glosario son extraídas y sustentadas del diccionario de la Real Academia Española (RAE). Así mismo, se presentan conceptos de otras fuentes de respaldo.

Red neuronal convolucional: es un modelo computacional inspirado en el funcionamiento del cerebro humano (Salas, 2004)

Rehabilitación: Acción de reponer a alguien en la posesión de lo que le había sido desposeído (ASALE & RAE, 2014)

Sistemas de captura de movimiento: el cual permite observar, grabar y analizar de manera objetiva las variaciones propias de la marcha humana (Camargo C. et al., 2012)

Kinovea: Es un programa gratuito de edición de videos diseñado para analizar las imágenes y estudiar videos deportivos con el fin de encontrar fallas, mejorar la técnica y ayudar a entrenarse (Runco & Lanzarini, 2017)

Rango de movimiento: es el ángulo máximo descrito entre dos segmentos del cuerpo con un plano de referencia, el cual es realizado por medio de articulaciones (Peña Ayala et al., 2018)

ÍNDICE DE CONTENIDO

I.	INTRODUCCIÓN	1
II.	ESTADO DEL ARTE	3
	2.2. ANTECEDENTES	3
	2.3. PROBLEMÁTICA	6
	2.4. IMAGEN INTEGRADORA.....	8
	2.5. TABLA DE LIMITACIONES	9
	Tabla 1.- Limitantes de estudios previos	9
III.	OBJETIVOS	14
	3.1. OBJETIVOS GENERAL.....	14
	3.2. OBJETIVOS ESPECÍFICOS.....	14
IV.	METODOLOGÍA.....	15
	4.1. ENFOQUE.....	15
	4.2. METODOLOGIA DE ESTUDIO	15
	4.2.1. CREACIÓN DE LA BASE DE DATOS.....	16
	4.3. VARIABLES DE INVESTIGACIÓN	16
	4.3.1. VARIABLE DEPENDIENTE.....	16
	4.3.2. VARIABLE INDEPENDIENTE	16
	4.4. TÉCNICAS E INSTRUMENTACIÓN	17
	4.4.1. KINOVEA.....	17
	4.4.2. PYCHARM.....	18
	4.4.3. TENSORFLOW/KERAS.....	18
	4.4.4. PRUEBA STS	19
	4.5. MATERIALES.....	19
	4.5.1. CÁMARAS DE TELÉFONO INTELIGENTE	19
	4.5.2. MARCADORES	20
	4.5.3. SILLA SIN APOYABRAZOS	20
	4.6. POBLACIÓN Y MUESTRA.....	20
	4.7. METODOLOGÍA DE VALIDACIÓN	20
	4.8. CRONOGRAMA DE ACTIVIDADES.....	21
	Tabla 2.- Cronograma de actividades.....	21
V.	RESULTADOS	22
	5.1. PARTICIPANTES.....	22
	5.2. DATOS RECOLECTADOS	25

5.2.1.	MARKERLESS	25
5.2.2.	MARKER-BASED.....	26
5.3.	ANÁLISIS DE VARIABLES.....	27
5.4.	PROGRAMACIÓN DEL CÓDIGO	29
5.4.1.	ENTRENAMIENTO DEL MODELO	29
	Tabla 4: Características del modelo	31
VI.	DISCUSIÓN.....	33
VII.	LIMITACIONES.....	35
VIII.	CONCLUSIONES.....	36
IX.	RECOMENDACIONES.....	37
X.	ANEXOS	38
XI.	REFERENCIAS.....	41

ÍNDICE DE TABLAS

TABLA 1.-	LIMITANTES DE ESTUDIOS PREVIOS	9
TABLA 2.-	CRONOGRAMA DE ACTIVIDADES.....	21
TABLA 3.-	PARTICIPANTES QUE FORMARON PARTE DE ESTA INVESTIGACIÓN.....	22
TABLA 4:	CARACTERÍSTICAS DEL MODELO.....	31
TABLA 5:	PRUEBAS EN TIEMPO REAL CON LA CNN	32

ÍNDICE DE ILUSTRACIONES

ILUSTRACIÓN 1:	FUNCIONAMIENTO DEL SOFTWARE TENSORFLOW	5
ILUSTRACIÓN 2:	IMAGEN INTEGRADORA.....	8
ILUSTRACIÓN 3:	VARIABLES DE INVESTIGACIÓN	17
ILUSTRACIÓN 4:	PROMEDIO DE LA EDAD EN PARTICIPANTES QUE FORMARON PARTE DE ESTA INVESTIGACIÓN	23
ILUSTRACIÓN 5:	PROMEDIO DE REPETICIONES DE PARTICIPANTES QUE FORMARON PARTE DE ESTA INVESTIGACIÓN	24
ILUSTRACIÓN 6:	ALTURA PROMEDIO DE PARTICIPANTES QUE FORMARON PARTE DE ESTA INVESTIGACIÓN	24
ILUSTRACIÓN 7:	MARCADORES VIRTUALES MEDIANTE EL SOFTWARE KINOVEA	25
ILUSTRACIÓN 8:	COLOCACIÓN MARCADORES DE BAJO COSTO	26

ILUSTRACIÓN 9: EJECUCIÓN DE LA PRUEBA STS CAPTANDO LOS ÁNGULOS REQUERIDOS.....	26
ILUSTRACIÓN 10: SUJETO #11, PARÁMETROS DE LA CADERA MIENTRAS SE ESTÁ EN LA POSICIÓN DE SENTADO.....	27
ILUSTRACIÓN 11: SUJETO #11, PARÁMETROS DE LA CADERA MIENTRAS SE ESTÁ EN LA POSICIÓN DE PIE	27
ILUSTRACIÓN 12: SUJETO #11, PARÁMETROS DE LA RODILLA MIENTRAS SE ESTÁ EN LA POSICIÓN DE SENTADO.....	28
ILUSTRACIÓN 13: SUJETO #11, PARÁMETROS DE LA CADERA MIENTRAS SE ESTÁ EN LA POSICIÓN DE PIE.....	28
ILUSTRACIÓN 14: INTERFAZ DEL CÓDIGO CON LA CÁMARA WEB INDICANDO QUE ESTÁ SENTADO	30
ILUSTRACIÓN 15: INTERFAZ DEL CÓDIGO CON LA CÁMARA WEB INDICANDO QUE ESTÁ DE PIE.....	30
ILUSTRACIÓN 17: DIAGRAMA DE FUNCIONAMIENTO DE LA CNN	32

ÍNDICE DE ANEXOS

ANEXO 1. CREACIÓN DE LA BASE DE DATOS REALIZANDO LA PRUEBA STS	38
ANEXO 2. GRAFICAS OBTENIDAS DE LA PARTICIPANTE #16.....	38
ANEXO 3. MATERIALES IMPLEMENTADOS EN LA INVESTIGACIÓN.....	39
ANEXO 4. ARQUITECTURA DE UNA CNN.....	40
ANEXO 5. CÁLCULO DE PRECISIONES DE LA CNN	40

I. INTRODUCCIÓN

La rehabilitación ha sido crucial para ayudar a las personas a recuperarse física, emocional y socialmente, optimizando así sus capacidades y mejorando su calidad de vida. Más de mil millones de personas viven con algún tipo de discapacidad, lo que representa aproximadamente el 15% de la población mundial (*Informe mundial sobre la discapacidad*, 2011). La rehabilitación es importante para ayudar a las personas al facilitar la recuperación física, emocional y social para optimizar sus capacidades, mejorando así su calidad de vida.

En respuesta a desafíos como la pandemia y el envejecimiento poblacional, se implementaron nuevas técnicas de rehabilitación para hacer el proceso más rentable, fácil de usar y confiable. Una de estas innovaciones es la tele rehabilitación o rehabilitación remota, que se beneficia enormemente del avance de la tecnología basada en visión artificial, como la visión por computadora (Hellsten et al., 2021). La tele rehabilitación se define como la entrega de servicios de rehabilitación con intervenciones en cualquier ámbito de la fisioterapia, llevada a cabo de manera remota o fuera de una sesión convencional, a cargo de un terapeuta que está distante del paciente y que emplea tecnologías de visión por computadora (Seron et al., 2021).

Para ello se apoyan de los sistemas de captura de movimiento con marcadores pasivos (PMMC) han sido efectivos en la evaluación del movimiento humano, pero tienen limitaciones, como la necesidad de equipos costosos y la colocación de marcadores que consume tiempo (Takeda et al., 2021). Este método requiere equipos costosos, operadores formados y la colocación de los marcadores podía llevar mucho tiempo.

En segundo lugar, los PMMC convencionales no podían analizar el movimiento natural de los pacientes en entornos reales, como las salas de rehabilitación o los hogares (Van Hooren et al., 2023) (Song et al., 2023). Los enfoques basados en vídeo sin marcadores tenían una serie de ventajas sobre los enfoques tradicionales basados en marcadores. Eran menos costosos, ya que no requerían la compra de marcadores especiales.

No eran engorrosos, ya que no requerían que los sujetos llevaran marcadores en el cuerpo, y no afectaban a la naturalidad del movimiento debido a que los sujetos

podían moverse libremente sin restricciones estas ventajas hacen que los enfoques basados en vídeo sin marcadores sean ideales para estudiar el movimiento humano en un entorno natural.

Con este proyecto de investigación, se busca integrar la visión informática para entrenar un algoritmo que sea capaz de realizar el conteo de repeticiones que fueron ejecutadas durante la prueba de rehabilitación Sit to Stand (STS), de manera automática.

Para ello se entrenará una CNN que brinda la información requerida, esta automatización, llega a beneficiar específicamente las sesiones de terapia de rehabilitación física en diversas patologías. El desafío principal es establecer los parámetros de entrenamiento del algoritmo y establecer y etiquetar la base de datos que reconozca el movimiento.

II. ESTADO DEL ARTE

En esta sección se muestra la revisión hecha de los estudios más relevantes que fueron encontrados, demostrando antecedentes y limitaciones.

2.2. ANTECEDENTES

El análisis del movimiento tiene como objetivo comprender las causas de los cambios en los patrones de movimiento, extrayendo información de imágenes secuenciales. Esto se hace para ayudar en la prevención, identificación y rehabilitación de diversas enfermedades, discapacidades y lesiones. (Colyer et al., 2018). Lamentablemente, esas medidas solían ser subjetivas y propensas a errores, ya que se basaban en la interpretación de cada persona.

Los errores asociados a los marcadores se deben, en parte, a la suposición de que las marcas en la piel representaban ubicaciones esqueléticas, sin embargo, esa suposición podía dar lugar a errores en los artefactos de tejido blando, ya que el músculo, la grasa y la piel debajo de los marcadores podían hacer que se movieran independientemente del hueso (Wade et al., 2022). Los avances recientes en el ámbito de la inteligencia artificial, específicamente en visión por computadora, presentan posibles soluciones para afrontar los desafíos relacionados con la realización de pruebas funcionales (Cronin et al., 2023). Una opción viable para este tipo de análisis de movimiento exhaustivo son los sistemas de captura de movimiento sin marcadores (Klöpfer-Krämer et al., 2020).

Esta novedosa técnica utiliza visión por computadora y aprendizaje automático para detectar directamente puntos de referencia del cuerpo humano a partir de imágenes digitales, en lugar de depender de cámaras especializadas para rastrear marcadores físicos (Song et al., 2023) (Lam et al., 2023). En rehabilitación, se prueban estas técnicas de visión por computadora para monitorear el progreso de los pacientes. La prueba STS se utilizaba ampliamente en la investigación y la práctica clínica para evaluar la fragilidad física y el rendimiento motor (Park et al., 2021). El movimiento de levantarse y sentarse es crucial para cambiar la postura de sentado a estar de pie, siendo una práctica bastante común en la vida diaria (Tanaka et al., 2019).

Siendo una forma rápida y sencilla de evaluar la función física. La disminución de esta actividad estaba relacionada con las caídas, siendo una de las principales causas de lesiones en las personas mayores de edad (Atrsaei et al., 2022). Analizar la biomecánica de esta técnica se llevó a cabo durante varios años atrás, centrándose en varios factores y combinando ajustes, como el uso de los brazos para impulsarse o la utilización de una silla más grande, para observar las variaciones en las mediciones (Bennett et al., 2022).

Existen numerosos enfoques de captura de movimiento sin marcadores (2D o 3D) de libre disponibilidad, como OpenPose o Kinovea. OpenPose, en particular, fue una de las tecnologías de estimación de postura de código abierto más ampliamente utilizadas y se consideró accesible para los investigadores en biomecánica. (Nakano et al., 2020). Kinovea fue una herramienta fácil de usar, portátil y gratuita que se pudo utilizar en situaciones reales en el campo (Puig-Diví et al., 2019).

Es un software que permitía a los deportistas, entrenadores y médicos analizar sus movimientos y técnicas a través de la captura de videos (Tracy-María et al., 2023). Los usuarios podían subir videos a la plataforma y el software utilizaba algoritmos de visión por computadora para rastrear los puntos clave de las articulaciones de la cadera, rodilla y tobillo durante la fase de contacto inicial al ejecutar la acción. Siendo una herramienta útil para la prueba de rehabilitación STS. Podía utilizarse para monitorear el progreso de los pacientes, proporcionar retroalimentación y personalizar el tratamiento (Fernández-González et al., 2020).

Lo que se buscaba obtener de este estudio era que, al realizar la prueba STS, se pudiera hacer un conteo de las veces en el que el sujeto logra ejecutar el ejercicio correctamente durante la prueba de rehabilitación, mediante la digitalización y análisis de las imágenes a través del software de Kinovea. (Augustine et al., 2022). Creando una base de datos y entrenando un modelo capaz de realizar este proceso. Existen diversos modelos que ayudan a la detección de objetos como lo es también YOLOV8, utilizada para clasificación y detección.

En este estudio se optó por crear un modelo utilizando la biblioteca de softwares Tensorflow siendo de las más populares para el desarrollo de modelos de aprendizaje profundo, también se decidió usar la interfaz de programación de aplicaciones (API siglas en inglés) keras muy popular por su manera rápida y sencilla de entrenar redes

neuronales convolucionales. Tensorflow funciona de la siguiente manera: en la parte codificadora los datos de entrada se comprimen y pasan al espacio latente el cual luego prosigue a ser decodificada reconstruyendo los datos de entradas originales a partir de la representación comprimida.




Ilustración 1: Funcionamiento del software Tensorflow

Fuente: Elaboración propia

2.3. PROBLEMÁTICA

La rehabilitación es un proceso que ayuda a las personas a recuperar su capacidad de funcionar en la vida diaria después de una enfermedad, lesión o discapacidad. La necesidad de servicios de rehabilitación de bajo costo, fáciles de acceder y que puedan ser igualmente implementados para la población ha llevado a la búsqueda de nuevas formas de llevarlos a cabo (Hellsten et al., 2021). En 2020, la pandemia COVID-19 apareció, impidiendo que las personas salieran de sus casas.

Gracias a los avances en las ciencias de la computación, como el aprendizaje profundo, y en el desarrollo de hardware, como la miniaturización de sensores, se desarrollaron algoritmos de reconocimiento de actividad humana (HAR, siglas en inglés) que podían extraer características de los datos de forma automática. (Reyes Leiva et al., 2021) La forma y el movimiento del cuerpo humano fueron temas de investigación activos en biomecánica, visión por computadora y gráficos por computadora.

Los avances en estas áreas tienen el potencial de mejorar las interacciones humano-máquina, la atención médica asistida, los diagnósticos clínicos y la animación por computadora (Ghorbani et al., 2021). El aprendizaje profundo (DL, siglas en inglés) es una técnica de aprendizaje automático que demostró ser muy eficaz para el HAR. Los modelos de aprendizaje profundo aprenden a partir de datos no etiquetados, lo que los hacía más versátiles que los métodos tradicionales de reconocimiento de actividades humanas.

Además, los modelos de DL extraen características de datos sin procesar, lo que les permitía ser más precisos que los métodos tradicionales, que solían depender de características predefinidas (Jaén-Vargas et al., 2022). El método tradicional para rastrear el movimiento del cuerpo humano son los sistemas de captura de movimiento basados en marcadores infrarrojos, una tecnología ampliamente utilizada para medir el rango de movimiento (ROM).

Estos sistemas se consideran el "estándar de oro" para este tipo de mediciones, ya que ofrecen una alta precisión y fiabilidad (Moro et al., 2022). Se utilizan cámaras de video para rastrear la ubicación de marcadores colocados en el cuerpo humano. Estos marcadores se colocan en puntos específicos del cuerpo, como las articulaciones, para que las cámaras puedan rastrear su movimiento. A partir de la posición de los

marcadores, se puede calcular el movimiento de los segmentos corporales y sus movimientos relativos en las articulaciones (Hume et al., 2018).

Pese a ser el “estándar de oro” existen limitaciones a tomar en cuenta que el Análisis de movimiento basado en marcadores no es fácilmente adaptable en la mayoría de los entornos clínicos porque requiere un costo enorme, tiempo, espacio y personal altamente capacitado (Jo et al., 2022) (Takeda et al., 2021). Debido al envejecimiento poblacional el uso de marcadores en el cuerpo dificultaría la ejecución de ejercicios de evaluación como lo es el STS ocasionando posibles caídas al paciente.

Otra limitante fue que no existía una base de datos con videos de la prueba STS que pudiese usarse para delimitar mejor esta investigación. Para lograr detectar, clasificar y etiquetar la biomecánica implementada en las sesiones de rehabilitación durante la prueba STS. Existen los sistemas de captura de movimiento sin marcadores, Esta técnica es más asequible, fácil de usar, y también tiene el potencial de ser más precisa (Van Hooren et al., 2023). Este tipo de sistemas utilizan cámaras monoculares para capturar el movimiento humano. A partir de estos videos, pueden extraer automáticamente la posición de cada articulación.

Estos datos cinemáticos son ampliamente utilizados para analizar a biomecánica humana (Onitsuka et al., 2023). Los sistemas de captura de movimiento sin marcadores permiten una evaluación precisa de los ejercicios en una variedad de campos relacionados con el movimiento humano, como los deportes y la rehabilitación (Mennella et al., 2023). Gracias a esta tecnología se puede integrar la visión por computadora para entrenar un algoritmo capaz de realizar este proceso de manera automática en base a los videos etiquetados de personas realizando el ejercicio de rehabilitación (Kalbhorr et al., 2023). Para analizar la prueba STS es necesario hacer un conteo de las veces en que la persona sentó y se levantó de la silla, y al utilizar una inteligencia artificial que ha estudiado con la base de datos creada se logra hacer este proceso de manera automática solucionando de esa forma problemas en movilizar al paciente en cualquier ámbito apoyando y beneficiándolo al mismo tiempo.

2.4. IMAGEN INTEGRADORA



Ilustración 2: imagen integradora

Fuente: Elaboración propia

La representación gráfica (ilustración 2) muestra el paso a paso de cómo se llevó a cabo el proceso para adquirir información, procesarla, y en base a esa información entrenar un modelo de visión por computadora.

2.5. TABLA DE LIMITACIONES

Durante la revisión de la literatura fueron descubiertas ciertas limitaciones. Se presentan a continuación (Tabla 1).

Tabla 1.- Limitantes de estudios previos

Autores	Pais de estudio	Enfoque de estudio	Tipo de limitación	Detalle de la limitación
(Colyer et al., 2018)	UK (United Kingdom)	La visión por computadora se utiliza cada vez más para analizar el movimiento humano. Los sistemas sin marcadores son más cómodos y fáciles de usar que los sistemas con marcadores	Dificultad para evaluar movimientos rápidos	se destaca que la validación de los sistemas sin marcadores se ha centrado principalmente en movimientos lentos, lo que limita la comprensión de su aplicabilidad en movimientos más rápidos, como los que se encuentran en aplicaciones deportivas
(Tanaka et al., 2019)	Japan	El enfoque de este estudio es evaluar la precisión de la medición del centro de gravedad (COG) durante el movimiento de sentarse a pararse utilizando un sistema de captura de movimiento sin marcadores.	Posibles limitaciones del tamaño de la muestra, la validez externa de los resultados y la generalización de los hallazgos a poblaciones más amplias	El tamaño de la muestra es un factor importante a tener en cuenta al evaluar la validez de los resultados de un estudio. Un tamaño de muestra pequeño puede limitar la capacidad del estudio para detectar diferencias significativas entre los grupos.

Autores	Pais de estudio	Enfoque de estudio	Tipo de limitación	Detalle de la limitación
(Fernández-González et al., 2020)	Spain	evalúa la fiabilidad del software Kinovea® para el análisis de la marcha en sujetos sanos.	Una limitación del estudio fue que se enfocó únicamente en una fase específica de la marcha y en un solo plano de movimiento	se analizó únicamente una fase específica de la marcha, lo que limita la capacidad de extrapolar los resultados a otras fases del ciclo de la marcha. Además, al centrarse en un solo plano de movimiento, en este caso el plano sagital, la generalización de los hallazgos a movimientos en otros planos, como el plano frontal.
(Klöpfer-Krämer et al., 2020)	Germany, Austria	El enfoque de este estudio es proporcionar una visión general de las tecnologías de medición utilizadas en el análisis del movimiento, así como sus campos de aplicación y parámetros medibles.	Las limitaciones del estudio incluyen la necesidad de encontrar un equilibrio entre la precisión y la facilidad de uso de los sistemas de medición, así como la consideración de los costos financieros y de recursos humanos.	Se destaca que la instrumentación para el análisis del movimiento siempre debe considerarse como una faceta de una estrategia de tratamiento integral, manteniendo en mente la individualidad del paciente a pesar del esfuerzo de evaluación de datos y objetivación.

Autores	Pais de estudio	Enfoque de estudio	Tipo de limitación	Detalle de la limitación
(Park et al., 2021)	United States	El estudio se enfoca en utilizar tecnologías basadas en sensores para identificar la fragilidad física y tres fenotipos de fragilidad en adultos mayores.	Las limitaciones del estudio incluyen posibles errores en la predicción de la fragilidad física y los fenotipos de fragilidad, así como la posible falta de generalización del modelo de fragilidad.	Se especula que los posibles errores en la predicción podrían deberse a las diferencias entre el método utilizado en el estudio y otros métodos de evaluación de la fragilidad.
(Wade et al., 2022)	UK (United Kingdom)	El artículo se enfoca en revisar la tecnología de captura de movimiento sin marcadores y su aplicabilidad en la biomecánica clínica.	Las limitaciones identificadas en el artículo incluyen la falta de precisión en la localización de los centros articulares y ángulos articulares, lo que limita su aplicabilidad clínica.	Se señala que los algoritmos de estimación de pose utilizados en la tecnología sin marcadores no fueron originalmente diseñados para aplicaciones biomecánicas, lo que puede afectar su precisión.

Autores	Pais de estudio	Enfoque de estudio	Tipo de limitación	Detalle de la limitación
(Cronin et al., 2023)	UK (United Kingdom)	El enfoque de este estudio fue evaluar la precisión y validez concurrente de un sistema de visión por computadora para estimar medidas biomecánicas relevantes del cuerpo.	Las limitaciones de este estudio incluyen la necesidad de sostener un tablero de calibración antes de cada prueba	la incapacidad de estimar ciertos parámetros de la misma manera que lo hace el fisioterapeuta, y la variabilidad Inter prueba que puede haber afectado los resultados. Además, el enfoque de visión por computadora no puede capturar con precisión el ángulo de rotación cervical debido a la configuración de la cámara, lo que limita su aplicabilidad en ciertas pruebas.
(Song et al., 2023)	United States, Brazil	El enfoque principal de este artículo es comparar la cinemática y la cinética de las extremidades inferiores estimadas a través de la captura de movimiento basada en marcadores y sin marcadores durante ocho movimientos comunes de la vida diaria y el ejercicio.	Las limitaciones del estudio incluyen diferencias en los modelos biomecánicos utilizados por los sistemas de captura de movimiento basados en marcadores y sin marcadores, lo que puede influir en la comparabilidad de los resultados.	señala que las diferencias entre los sistemas pueden ser más pronunciadas durante movimientos rápidos, lo que sugiere limitaciones en la precisión de ambos sistemas en estas condiciones.

Autores	Pais de estudio	Enfoque de estudio	Tipo de limitación	Detalle de la limitación
(Lam et al., 2023)	China	El enfoque de este estudio fue investigar el uso de sistemas de medición de movimiento (MMC) en pacientes con condiciones sintomáticas	se excluyeron estudios que se centraban únicamente en la calibración de los sistemas MMC, así como aquellos que aplicaban la tecnología MMC solo en el entrenamiento de rehabilitación.	solo se incluyeron estudios publicados en inglés, lo que podría haber excluido información relevante en otros idiomas.
(Van Hooren et al., 2023)	The Netherlands	El estudio se centra en evaluar la precisión de las técnicas de captura de movimiento sin marcadores, como DeepLabCut y OpenPose, para medir la cinemática de la cadera, rodilla y tobillo durante la carrera a diferentes velocidades.	El método estándar de captura de movimiento con marcadores puede tener errores debido a la colocación incorrecta de los marcadores,	La precisión de las técnicas sin marcadores depende de la precisión con la que se identifican manualmente los puntos de referencia utilizados para el aprendizaje del modelo.

Fuente: Elaboración propia

III. OBJETIVOS

En este apartado se mostrarán los objetivos que fueron planteados para esta investigación.

3.1. OBJETIVOS GENERAL

Entrenar un modelo de aprendizaje automático de visión por computadora entrenado para contar las repeticiones realizadas en la prueba STS.

3.2. OBJETIVOS ESPECÍFICOS

- Adquirir información grabando videos y tomando fotografías para la creación de una base de datos
- Desarrollar una base de datos en base a los videos e imágenes obtenidos para luego etiquetarlos con un software de captura de movimiento
- Entrenar una red neuronal convolucional con la base de datos etiquetada que brinda información del conteo total de repeticiones del ejercicio STS.
- Refinar el modelo entrenado para obtener mayor porcentaje en la precisión del conteo.

IV. METODOLOGÍA

En esta sección, se detallará la metodología que fue implementada durante esta investigación, mostrando las herramientas utilizadas, cual es el enfoque de la investigación, las variables encontradas y el tipo de muestra.

4.1. ENFOQUE

El estudio abordó un enfoque cuantitativo al orientarse en el análisis cinemático dentro del entorno médico en rehabilitación, para obtener información precisa del ROM. La investigación se define como un tipo de estudio descriptivo y exploratorio al recopilar datos de los participantes mientras realizaban la prueba de levantarse y sentarse durante sesiones de rehabilitación.

4.2. METODOLOGÍA DE ESTUDIO

El objetivo principal de esta investigación fue el entrenamiento de una CNN que sea capaz de contar automáticamente la cantidad de veces en las cuales una persona realiza la prueba STS. Para entrenar el modelo correctamente, se estudiaron y analizaron detalladamente ciertas variables que eran vitales para el análisis del movimiento humano. En rehabilitación, analizar la biomecánica fue esencial para comprender y mejorar esa función en personas que habían experimentado lesiones o que nacían con alguna limitación física.

Para lograr la obtención de esos parámetros se emplearon técnicas de recolección de datos, como lo es Kinovea, un software de análisis de video desarrollado para ayudar en la evaluación y mejora del rendimiento físico y deportivo. Utilizando la prueba STS, se obtuvo información de la capacidad física que tenían las personas dependiendo de la edad y el género. Se le solicitó a cada uno de los participantes que cruzaran sus brazos tocando sus hombros y luego procedieran a sentarse y levantarse repetidas veces durante un lapso de 30 segundos para evaluar el total de repeticiones que eran capaces de hacer. Todo esto fue grabado con la cámara de un teléfono inteligente para luego procesarlos en el software de análisis de video.

Para la prueba se estableció un sistema de puntaje de 0 – 13 siendo 0 para las personas que no ejecutaron el ejercicio debido alguna discapacidad o falla motora de 8 - 10 siendo repeticiones de una persona que no se ejercita frecuentemente y 11 – 13 para las personas que si realizan actividades físicas permitiendo ejecutar con mayor facilidad el ejercicio.

4.2.1. CREACIÓN DE LA BASE DE DATOS

La obtención de estos datos fue esencial para poder identificar cuál de los parámetros proporcionaba la información necesaria para que el asesor de rehabilitación pudiese dar un dictamen de la condición física actual del paciente. El proceso de la creación de la base de datos fue algo laborioso debido a que el tipo de muestra era no probabilística, no se estimó a personas en específico para participar en el desarrollo de esta investigación por ende al momento de buscar la ayuda de alumnos de la universidad la mayoría presentaba alguna excusa, ya sea por pena, incomodidad, no disponibilidad o el simple hecho de no querer colaborar, estos factores provocaron que crear una base de datos fuese aún más tardío tomando en cuenta que en un inicio solo se tenía en cuenta la participación de 15 alumnos, pero el entrenar una red neuronal mientras más información haya mucho mejor serán los resultados es por eso que se decidió grabar un total de 30 personas con videos de aproximadamente 30-31 segundos con la intención de fragmentar estos videos y utilizar las imágenes para poder entrenar la red neuronal y que tengo un porcentaje de precisión bastante elevado. Se utilizó el software Kinovea, una herramienta para analizar videos y Pycharm como plataforma de programación para entrenar el algoritmo.

4.3. VARIABLES DE INVESTIGACIÓN

Al momento de realizar esta investigación, se consideraron ciertas variables de investigación que eran fundamentales para establecer los límites y los objetivos de la investigación. Las variables de investigación eran las características, propiedades o condiciones que determinaban cuál era el enfoque del estudio.

4.3.1. VARIABLE DEPENDIENTE

La precisión del modelo entrenado, lo más importante en una red neuronal es saber que tan precisa es, sin embargo, esta llega a variar dependiendo de la cantidad de información que adquiera y sea procesada para entrenarse.

4.3.2. VARIABLE INDEPENDIENTE

El proyecto consta de entrenar un modelo de visión artificial que detecte la cantidad de veces que la personas realiza la actividad de levantarse y sentarse siendo el

modelo capaz de captarlo de manera precisa. Variables que afectarían la precisión de este modelo serían:

- *Tamaño del lote*: El tamaño del lote mejora la precisión del entrenamiento, utilizar un lote pequeño el modelo extraería menos información por ende no tendría exactitud en el conteo.
- *Épocas*: Realizar la mayoría de las repeticiones es un factor en el cual el modelo se logra entrenar mejor, de no hacer muchas no lleva un seguimiento existiendo la posibilidad de proveer información no precisa

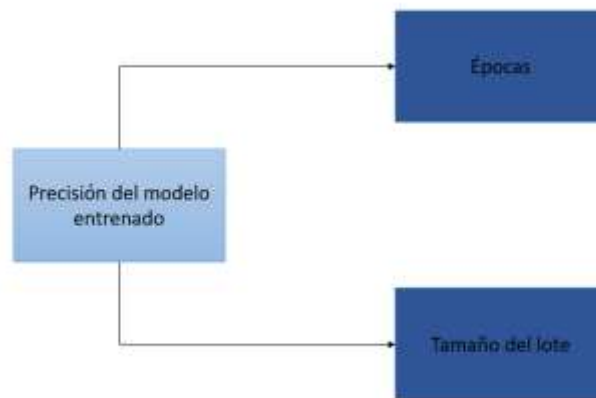


Ilustración 3: Variables de investigación

Fuente: Elaboración propia

4.4. TÉCNICAS E INSTRUMENTACIÓN

A continuación, se describen las técnicas e instrumentación utilizada que fueron empleada para la realización de esta investigación, tomando en cuenta que tipo de softwares y plataformas se usan para la detección de parámetros y clasificación de articulaciones de la biomecánica humana y las técnicas que brindan más información de dichos parámetros.

4.4.1. KINOVEA

Kinovea es un software de análisis de video desarrollado para ayudar en la evaluación y mejora del rendimiento físico y deportivo. Una de las ventajas que tenía Kinovea en comparación con otras herramientas era la capacidad de reproducir los videos a cámara lenta o cuadro por cuadro, lo que permitía a los entrenadores analizar

con detalle aspectos clave del movimiento y la técnica, ya sea en el deporte o para el uso médico en rehabilitación durante la ejecución de algún ejercicio. Kinovea ofreció una amplia gama de herramientas de análisis que permitieron dibujar líneas, formas y ángulos en el video para medir y evaluar diferentes parámetros.

Kinovea es una herramienta gratuita lo que lo convirtió en una opción asequible para entrenadores y usuarios. Otra característica destacada de Kinovea fue su simplicidad de manejo. A pesar de ser una herramienta avanzada, se creó con la idea de ser accesible y fácil de utilizar. La interfaz de usuario se diseñó de manera clara y ordenada, lo que simplificó la exploración y la utilización de las funciones de análisis. Kinovea fue una herramienta poderosa que pudo utilizarse para una variedad de propósitos. Fue una alternativa más precisa, rápida y fácil de usar para el análisis del movimiento humano.

4.4.2. PYCHARM

PyCharm, un Entorno Desarrollo Integrado (IDE) destacado en el mundo de Python, ofrece una variedad de características y funcionalidades que hacen que el desarrollo de software sea más eficiente y fluido. Su editor de código inteligente facilita la escritura de código de calidad, con colores distintivos que mejoran la legibilidad y la detección de errores. La navegación ágil por el código y las herramientas de refactorización permiten a los desarrolladores realizar cambios sin esfuerzo, manteniendo la integridad del código.

PyCharm proporciona un entorno propicio para el desarrollo web, con compatibilidad para tecnologías como HTML, CSS, JavaScript, AngularJS y NodeJS. Ofrece una integración perfecta con bibliotecas científicas como Matplotlib, NumPy y Anaconda.

4.4.3. TENSORFLOW/KERAS

Existen muchas librerías en el campo del DL, sin embargo, la más dominante en este rubro es TensorFlow siendo una de las más populares, se ha convertido en un pilar fundamental para aplicaciones de aprendizaje automático y redes neuronales profundas. Por otro lado, keras ofrece una interfaz de alto nivel para la construcción de modelos de aprendizaje, facilitando la creación de redes neuronales con una sintaxis uniforme y una interfaz modular. Al trabajar en conjunto se logra crear una combinación poderosa de potencia, facilidad de uso, y velocidad de ejecución.

4.4.4. PRUEBA STS

La prueba STS se empleó con frecuencia en ámbitos de rehabilitación y medicina física. Esta prueba implicaba valorar la habilidad de una persona para ponerse de pie desde una silla o una superficie baja, mantenerse en posición vertical durante un pequeño lapso y posteriormente regresar a la posición sentada. El procedimiento de la prueba fue relativamente sencillo; se le pedía al sujeto que se sentara en una silla sin apoyabrazos con los pies apoyados en el suelo.

Luego se le indicaba que se pusiera de pie completamente, teniendo sus brazos en forma de cruz tocando los hombros. Después de estar de pie por unos segundos, se le indicaba que volviera a sentarse, repitiendo este proceso durante 30 segundos y observando cuántas eran las repeticiones que podía realizar en este periodo de tiempo. Se contaba como repetición cuando se ponía de pie, luego se sentaba y se volvía a poner de pie.

El sujeto tenía la opción de descansar en cualquier momento; sin embargo, el tiempo seguía corriendo hasta completar los 30 segundos. La prueba de STS se empleó con el propósito de evaluar la fuerza muscular, la estabilidad y la funcionalidad de las extremidades inferiores. Ofrecía datos acerca de la aptitud de una persona para llevar a cabo actividades cotidianas esenciales, tales como ponerse de pie desde una silla, caminar o ascender escaleras.

Esta prueba fue particularmente relevante en el ámbito de la rehabilitación, ayudando a ver si el tratamiento mejoraba la fuerza y función de las piernas. También servía para conocer el riesgo de caídas, especialmente en gente mayor o aquellos con problemas de movilidad por temas médicos.

4.5. MATERIALES.

En esta sección se detallan los materiales utilizados para la investigación

4.5.1. CÁMARAS DE TELÉFONO INTELIGENTE

Los videos fueron grabados por medio de un teléfono inteligente de la marca iPhone era uno de los modelos más recientes siendo este el 14 pro que consta con 12 MP, 0.5x: 13 mm, fotografía macro, lente de 6 elementos y 100% de enfoque de píxeles.

4.5.2. MARCADORES

Los marcadores son puntos ubicados estratégicamente para facilitar el seguimiento del movimiento humano, fueron necesarios para analizar con precisión para que la inteligencia artificial pueda brindar información más exacta sin desviar mucho sus parámetros. Estos marcadores fueron hechos de cartulina para poder utilizarse al momento de que el sujeto este realizando la prueba.

4.5.3. SILLA SIN APOYABRAZOS

Es una silla común, con la peculiaridad que es sin apoyabrazos debido a que el sentido de realizar la prueba STS es solo utilizando la fuerza de las piernas.

4.6. POBLACIÓN Y MUESTRA

Para la realización de esta investigación se obtuvo la ayuda de estudiantes de la UNITEC, se trabajó con un total de 30 personas, eran 17 hombres y 13 mujeres con una edad alrededor de los 19-22 años con el fin de poder evaluar la biomecánica que es efectuada al momento de realizar la prueba STS, cada una de ellas acepto colaborar en la elaboración de estos videos.

Se había previsto también utilizar personas adultas mayores, para lograr obtener también una comparación en como la edad afecta la ejecución del ejercicio, sin embargo, no se obtuvo consentimiento alguno centros que permitiesen grabar y realizar esta prueba con los adultos mayores.

4.7. METODOLOGÍA DE VALIDACIÓN

Para validar que la metodología fue empleada exitosamente, los resultados debían ser precisos. Al medir el rango de movimiento, se adquiría información crucial para conocer la condición física en la que el cuerpo se encontraba. La razón por la cual se realizaba análisis biomecánico ayudaba a mejorar el rendimiento del cuerpo humano, ya sea por causa de alguna enfermedad o discapacidad.

La validación de los datos recopilados fue esencial para asegurar la coherencia de los resultados, y para llevar a cabo este proceso, se designó un asesor temático encargado de validar los resultados obtenidos. Este asesor desempeñó un papel fundamental como respaldo, fortaleciendo la integridad de la investigación. Dando oportunidad a que las técnicas de visión por computadora fueran más vistas en sesiones de rehabilitación para un diagnóstico más seguro y menos tardío.

4.8. CRONOGRAMA DE ACTIVIDADES

A continuación, se mostrará el registro de las actividades realizadas a lo largo de la investigación

Tabla 2.- Cronograma de actividades

Actividades	1 semana	2 semana	3 semana	4 semana	5 semana	6 semana	7 semana	8 semana	9 semana	10 semana
Revisión de artículos bibliográficos, relacionados a la prueba STS										
Utilización del software Kinovea, aprender a usarlo.										
Obtención de sujetos de prueba para realizar la toma de videos										
Definición de temarios y tiempo de ejecución										
Realización de grabaciones respecto a la prueba STS										
Procesar los videos utilizando la herramienta Kinovea										
Modificación y validación de datos adquiridos										
Creación de base de datos en base a videos obtenidos										
Mostrar resultados, calificación evaluación a los sujetos de prueba										
Entrenamiento de una red neuronal convolucional.										

V. RESULTADOS

A continuación, se presentarán los resultados obtenidos a partir de la recolección de datos que fue realizada. Fueron recopilados videos de estudiantes de la universidad ejecutando un famoso ejercicio de rehabilitación empleado mayormente en personas de mayor edad llamado prueba STS para poder analizar su ROM. Los resultados obtenidos serán un apoyo para los centros de rehabilitación brindando información importante de sus pacientes sin necesidad de hacerles ir al centro médico.

5.1. PARTICIPANTES

En un inicio se estimó que se obtendrían grabación de solo unas 15 personas, sin embargo, el hecho de no contar con una base de datos ya hecha se optó por crear una. Se determinó un total de 30 estudiantes siendo 17 hombres y 13 mujeres los que colaboraron en este estudio en un rango de entre los 19 – 22 años. Asimismo, se tomó en cuenta la altura, porque era un paso importante para lograr calibrar el software.

Tabla 3.- Participantes que formaron parte de esta investigación

Sujetos	Genero	Edad	Altura	Repeticiones
Sujeto 1	Hombre	22	172 cm	13
Sujeto 2	Hombre	21	181 cm	10
Sujeto 3	Mujer	20	165 cm	9
Sujeto 4	Mujer	19	167 cm	9
Sujeto 5	Hombre	19	177 cm	8
Sujeto 6	Hombre	19	172 cm	10
Sujeto 7	Hombre	20	178 cm	9
Sujeto 8	Hombre	22	179 cm	12
Sujeto 9	Mujer	21	162 cm	10
Sujeto 10	Mujer	21	153 cm	9
Sujeto 11	Hombre	22	168 cm	10
Sujeto 12	Mujer	19	150 cm	11
Sujeto 13	Hombre	19	184 cm	9
Sujeto 14	Mujer	19	151 cm	11
Sujeto 15	Hombre	21	186 cm	8
Sujeto 16	Mujer	20	152 cm	12
Sujeto 17	Hombre	21	178 cm	9
Sujeto 18	Hombre	19	178 cm	10
Sujeto 19	Hombre	21	179 cm	13

Continuación tabla 3

Sujetos	Genero	Edad	Altura	Repeticiones
Sujeto 21	Mujer	21	165 cm	9
Sujeto 22	Mujer	20	163 cm	9
Sujeto 23	Mujer	19	165 cm	11
Sujeto 24	Hombre	22	176 cm	13
Sujeto 25	Hombre	20	180 cm	8
Sujeto 26	Mujer	20	167 cm	10
Sujeto 27	Hombre	20	178 cm	10
Sujeto 28	Mujer	21	180 cm	9
Sujeto 29	Hombre	19	177 cm	9
Sujeto 30	Hombre	22	176 cm	13

Fuente: Elaboración propia



Ilustración 4: Promedio de la edad en participantes que formaron parte de esta investigación

Fuente: Elaboración propia

Según la gráfica (ilustración 4) se puede observar hubo más interés de participación en el género masculino que por parte del género femenino



Ilustración 5: Promedio de repeticiones de participantes que formaron parte de esta investigación

Fuente: Elaboración propia

En base a la gráfica (ilustración 5) se puede observar que la media de repeticiones entre hombres y mujeres es similar y se especula que es debido a que ambos géneros participaron personas jóvenes y no personas de la tercera edad como lo es usual en este ejercicio de rehabilitación.

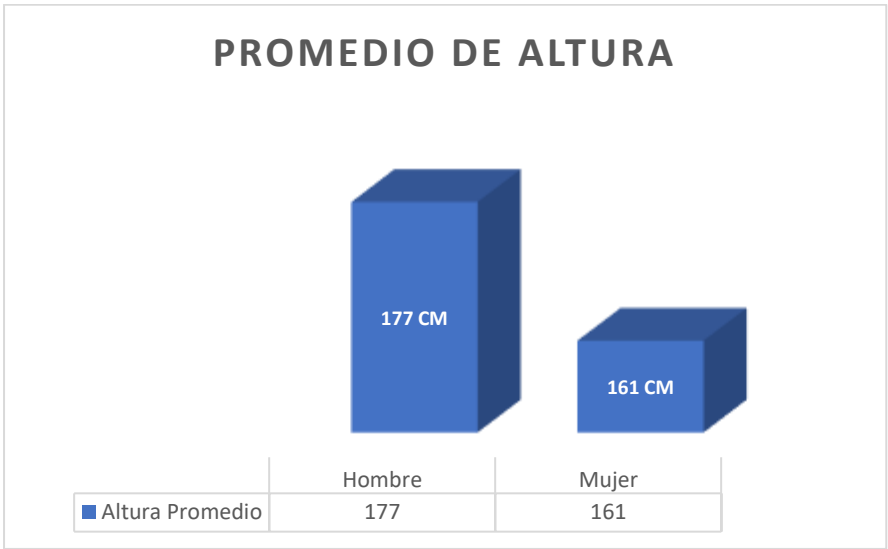


Ilustración 6: Altura promedio de participantes que formaron parte de esta investigación

Fuente: Elaboración propia

En la ilustración 6 se detalla el promedio de la altura de los participantes Masculinos y Femeninos.

5.2. DATOS RECOLECTADOS

Para recolectar los datos de este estudio, se capturaron las trayectorias de movimiento de los estudiantes al momento de realizar el ejercicio de rehabilitación. Utilizando una cámara y unos marcadores, se pudo registrar la posición de los marcadores que fueron colocados en lugares específicos, como la cadera para medir el ángulo que generaba el tronco y la rodilla para obtener el ángulo reflejado al momento de flexionarla.

Los datos obtenidos fueron analizados mediante el software de Kinovea para registrar el ángulo que se generaba en las extremidades mencionadas durante la ejecución del ejercicio. Se debe tener en cuenta que, para garantizar la mayor precisión en estos datos, se debían colocar los marcadores con la mayor exactitud posible para que se lograra generar la trayectoria. Sin embargo, en caso de no contar con recursos a disposición para los marcadores, siempre se podían obtener datos precisos debido a que el propio software permitía establecer marcadores virtuales que permitían el seguimiento en tiempo real.

5.2.1. MARKERLESS

El software de kinovea permite la utilización de marcadores virtuales los cuales eran pequeñas cruces que permitían el seguimiento de las trayectorias. Sin embargo, de haber movimientos bruscos, estos marcadores podían desplazarse y no captar las mediciones correctamente, lo que requería mucho más trabajo para posicionar el marcador en su lugar cada vez que se desplazaba de lugar.



Ilustración 7: Marcadores virtuales mediante el software Kinovea

5.2.2. MARKER-BASED

El hecho de contar con la ayuda de los marcadores hizo que el trabajo disminuyera, ya que siempre se podía desfasar la trayectoria, pero el desplazamiento era menor y mejor controlado. Existen marcadores de alto precio que se utilizan para para analizar el movimiento humano, pero en este caso se optó por utilizar marcadores de bajo costo que fueran bastante visibles para que el software pudiera cumplir su función y facilitar la obtención de estos parámetros.



Ilustración 8: Colocación marcadores de bajo costo

Fuente: Elaboración propia



Ilustración 9: Ejecución de la prueba STS captando los ángulos requeridos

Fuente: Elaboración propia

5.3. ANÁLISIS DE VARIABLES

Para analizar las variables obtenidas, se emplearon métodos estadísticos como Microsoft Excel para Microsoft 365 MSO (versión 2401 compilación 16.0.17231.20236) de 64 bits para obtener los datos proporcionados por las gráficas generadas por el software de Kinovea. Durante el ejercicio, se calculó el ángulo que generaba la cadera y el tobillo, mostrando los valores de dichas articulaciones durante los 30 segundos en que se ejecutó el ejercicio. Estos datos se utilizaron para la elaboración de un código que se utilizará para entrenar un modelo. En las ilustraciones 5 – 8, se pueden observar los datos obtenidos tanto de la cadera como de la rodilla durante la realización del ejercicio.

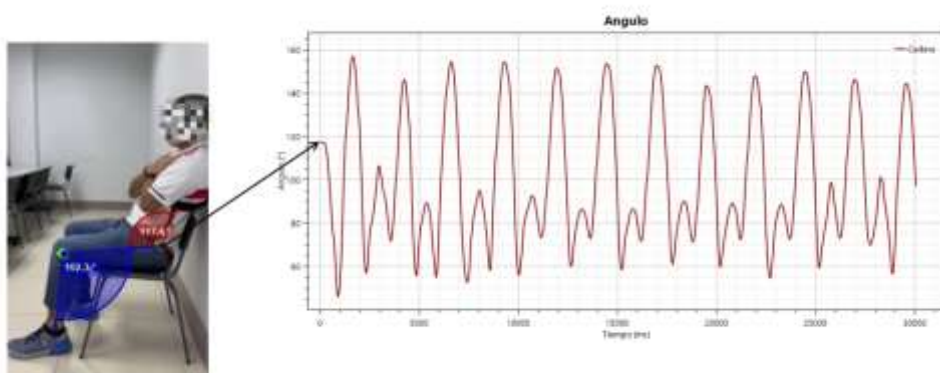


Ilustración 10: Sujeto #11, parámetros de la cadera mientras se está en la posición de sentado

Fuente: Elaboración propia

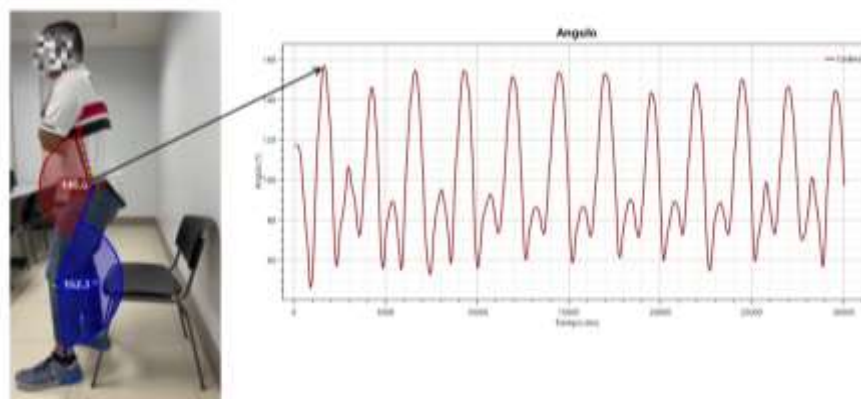


Ilustración 11: Sujeto #11, parámetros de la cadera mientras se está en la posición de pie

Fuente: Elaboración propia




Ilustración 12: Sujeto #11, parámetros de la rodilla mientras se está en la posición de sentado.

Fuente: Elaboración propia

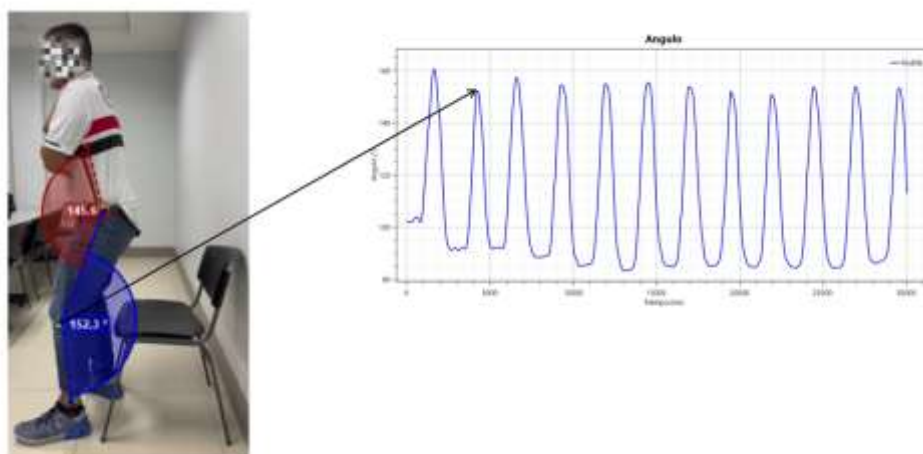


Ilustración 13: Sujeto #11, parámetros de la cadera mientras se está en la posición de pie.

Fuente: Elaboración propia

5.4. PROGRAMACIÓN DEL CÓDIGO

Para programar el código, se utilizó la plataforma de PyCharm que ejecuta código Python. En este código, se realizaron operaciones relacionadas con el procesamiento de videos y la detección, en este caso, el conteo de las veces en las que la persona se levantó y se sentó de la silla en el lapso de 30 segundos. Las repeticiones registraron momentos claves durante la realización del ejercicio y el código automatizó la extracción de estas repeticiones, proporcionando un resumen del total ejecutadas y ofreciendo información importante que evaluó el rendimiento físico de la persona durante la sesión de rehabilitación.

5.4.1. ENTRENAMIENTO DEL MODELO

Para lograr entrenar un CNN que fuese capaz de realizar el conteo de repeticiones de las veces en las que la persona se levanta y se sienta de la silla durante 30 segundos, fueron utilizadas técnicas de procesamiento de imágenes como conversión de escala de grises, umbralización, normalización, redimensionamiento para cambiar el tamaño de la imagen, ajuste de brillo y contraste y transformaciones geométricas.

Un punto clave para este entrenamiento fue el hecho de fragmentar los videos en imágenes para que la Inteligencia Artificial (IA) pudiese ser más precisa. Se entrenó, con diferentes tamaños de lote, primero con 10 video fragmentados, luego 20 y por último 30 pues a mayor información obtenida, mayor es su precisión. También se entrenó con distintas épocas, primero se entrenó con 10 épocas y mostro resultados bastante interesantes con un índice de precisión del 75%, luego con 30 épocas; su índice mejoró hasta alcanzar a un 85.40% y por último se entrenó con 75 épocas dando un índice de precisión de 93.5%, dando una media de precisión del 84.63%

El modelo entrenado mostró resultados prometedores indicando el conteo de la prueba de STS, aunque, el resultado viene a ser un conteo general, esto depende de la cantidad de videos que sean analizados al momento. Se agregó un apartado al código en el cual se puede utilizar, ya sea la cámara de la laptop o conectar por bluetooth una cámara alternativa para brindar la información del conteo de las repeticiones en tiempo real, la interfaz del video emitido indica cuando la persona está sentada y cuando está de pie y al final muestra un conteo de cuantas repeticiones fue capaz de realizar.



Ilustración 14: Interfaz del código con la cámara web indicando que está sentado

Fuente: Elaboración propia



Ilustración 15: Interfaz del código con la cámara web indicando que está de pie

Fuente: Elaboración propia

Tabla 4: Características del modelo

Model Characteristics		
Parameters	CNN+tensorflow/keras	
Layers with neurons	3 Dense Layer (512 neurons, 256 neurons, 1 neuron)	
	4 Convolutional layers (16 filter, 3x3 kernel, elu activation, 32 filters, 3x3 kernel, elu activation, 64 filters, 5x5 kernel, elu activation, 64 filters, 5x5 kernel, elu activation)	
Dropout Rate	0.5	
Activation Function	3 Dense Layers: ELU (Exponential Linear Unit)	
Optimizer	AdamW	
Loss Function	Binary_cross-entropy	
Batch Size	Test 1	1500
	Test 2	3000
	Test 3	4500
Epoch	Test 1	10
	Test 2	30
	Test 3	75

Fuente: Elaboración propia

En la tabla 4 se muestra en que consiste la red neuronal convolucional creada, y detalla la cantidad de épocas y tamaños de lote con los que se entrenó.

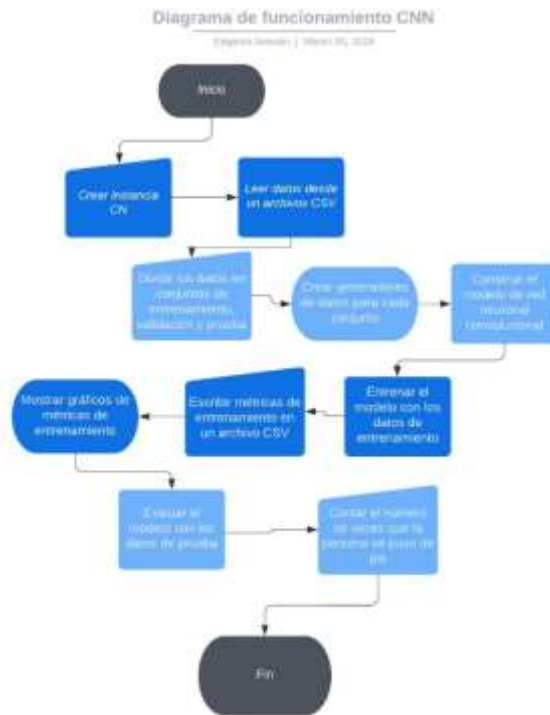


Ilustración 17: Diagrama de funcionamiento de la CNN

Fuente: Elaboración propia

En la ilustración 17 se puede observar cómo es el funcionamiento de la CNN paso a paso desde el momento que se programa para aprender a base de videos, hasta el final que logra mostrar un conteo de repeticiones.

Tabla 5: Pruebas en tiempo real con la CNN

Prueba STS			
<i>No.</i>	<i>Total ejecutadas</i>	<i>Captadas por la CNN</i>	<i>Precision</i>
Test numero 1	9	17	52.94%
Test numero 2	11	14	78.57%
Test numero 3	10	12	83.33%
Media	de	precisión	71.61%

Fuente: Elaboración propia

VI. DISCUSIÓN

La prueba STS fue realizada a los estudiantes de la universidad con el fin de extraer información de la biomecánica que es aplicada durante la realización de este ejercicio, en esta investigación participaron 30 estudiantes 17 hombres y 13 mujeres. La prueba STS es muy conocida en el ámbito de la rehabilitación en este caso se buscaba conocer la capacidad física que tienen las personas en base a la cantidad de repeticiones realizadas, ya que la realización de esta prueba proporciona información valiosa sobre la función de las extremidades inferiores. El uso de métodos de captura de movimiento con marcadores y sin marcadores no muestran cambios relevantes, siempre ocurren errores de precisión al colocar marcadores a la piel o colocarlos de manera virtual, porque de no haber una referencia clara que demuestre que los sistemas sin marcadores son mejores, queda desconocida la precisión que puede brindar. (Wade et al., 2022)

La creación de un modelo que sea capaz de detectar movimiento humano no fue una tarea sencilla, sin embargo, haber entrenado una CNN mejorara la forma de brindar asistencia médica de manera remota. Se logro porque se entrenó con diferentes cantidades de lotes y varias épocas, debido a que de no hacerse así no habría precisión o diferencia alguna al analizar los videos. (Tanaka et al., 2019) por ahora la CNN cuenta con una precisión del 73%, esta precisión es referente al momento en el que se hace el conteo de las repeticiones en tiempo real, por otra parte, la red neuronal tiene una precisión del 93.50% al momento de cargar los videos de las personas ejecutando el ejercicio, pese a que este conteo viene a ser un conteo general en base a la cantidad de videos analizados.

Añadido a esto, pese a que Kinovea es muy útil y fácil de usar, se necesita más herramientas para poder analizar un video correctamente, modelos como YOLOV8 y OpenPose son otra alternativa para continuar esta investigación ya que estas son mayormente compatibles con la mayoría de los modelos que han sido entrenados previamente.

Según (Rizk & Bayad, 2023) Utilizar YOLOV8, modelo de detección de objetos, aumentaría la precisión de la detección de la actividad humana en un 95% y OpenPose

siendo mayormente utilizado para detectar puntos clave humanos y detección en tiempo real de las posturas como sentarse, levantarse, caminar, recostarse y caerse (Jiang et al., 2023) viene siendo de gran ayuda para elaborar una CNN más precisa.

El grabar los videos en un área iluminada adecuadamente permitió a la CNN entrenar mucho mejor ya que se debe tomar en cuenta la calidad de los datos con los que se entrena la red neuronal, en esta ocasión se trabajó con videos fragmentados y de haber pixeles anormales la CNN se vería afectada en su precisión (Kavzoglu, 2009) La estructura de la red lograra ser más precisa si tomamos en cuenta que tan profunda o amplia es porque según (Zhang et al., 2019) al reducir el tamaño de una red se aumenta el índice de precisión.

VII. LIMITACIONES

Durante la elaboración de esta investigación se presentaron estas limitaciones: El hecho de no contar con una base de datos abierta al público dificultó las cosas porque se vio la necesidad de crear una base de datos de videos de STS, durante la creación de esa base de datos utilizar marcadores de bajo costo atrasó el proceso debido a que los marcadores se movía porque no se adherían a la ropa de los participantes y el software perdía el seguimiento en muchas ocasiones.

El uso de un software de análisis de video que fuese compatible con una red neuronal fue otro factor que impidió obtener mejores resultados, pese a que Kinovea analiza videos fue un trabajo más laborioso en comparación a otros softwares que son altamente compatibles con las redes neuronales

VIII. CONCLUSIONES

1. Se entrenó una red neuronal convolucional que tiene la capacidad de hacer el conteo de repeticiones de las veces en que la persona se sienta y se levanta durante la ejecución del ejercicio STS.
2. Se adquirió la información en base a los videos grabados para lograr hacer una base de datos de personas realizando la prueba.
3. Se aprovecho la base de datos creada y se entrenó una red neuronal capaz de brindar un conteo de las repeticiones ejecutadas por los participantes durante la prueba STS.
4. Se mejoro la precisión del modelo utilizando un mayor tamaño de lote y aumentando las épocas con las que era entrenado

IX.RECOMENDACIONES

Se recomienda utilizar un software diferente a Kinovea, si bien Kinovea es un software libre, gratuito y fácil de usar que puede otorgar información útil, al momento de utilizarse para crear una red neuronal, existen softwares especiales para análisis de video y captura de movimiento como lo es OpenPose o YOLOV8 que usualmente las redes neuronales se acoplan bastante bien a ellos.

Hacer ajustes en el código para lograr calibrar la cámara web de la laptop para obtener mejores resultados y utilizar una cámara que tenga mejor calidad para garantizar una mayor precisión.

La iluminación es un factor clave que se debe tener en cuenta debido a que la red se entrenó con un nivel de iluminación adecuado para que los videos fuesen claros y de esa forma la red neuronal logre detectar correctamente el movimiento del participante.

Utilizar una red reentrenada mejorara el proceso de aprendizaje de la red neuronal brindando una mejora en la precisión de esta red.

X. ANEXOS


Anexo 1. Creación de la base de datos realizando la prueba STS

Participante #16 De pie y sentada



Anexo 2. Graficas obtenidas de la participante #16

Grafica azul muestra la cadera y grafica roja muestra la rodilla




Anexo 3. Materiales implementados en la investigación

Marcadores, silla sin apoyabrazos, teléfono inteligente



Anexo 4. Arquitectura de una CNN

El paso a paso de cómo trabaja una CNN



Anexo 5. Cálculo de precisiones de la CNN

Precisiones obtenidas según tamaño de lote y épocas

Tamaño de lote	Épocas	Precision
10 videos	10 épocas	75%
20 videos	30 épocas	86%
30 videos	75 épocas	94%

XI.REFERENCIAS

1. Salas, R. (2004). *Redes Neuronales Artificiales*.
2. ASALE, R.-, & RAE. (2014). *Rehabilitación | Diccionario de la lengua española*.
«Diccionario de la lengua española» - Edición del Tricentenario.
<https://dle.rae.es/rehabilitación>
3. Camargo C., E., Garzón G., Y., & Camacho P, V. A. (2012). Sistema portátil de captura de movimiento para el análisis cinemático de la marcha humana. *Tecnura*, 16(34), 67-83.
4. Runco, A., & Lanzarini, L. (2017). *10025 HERRAMIENTAS DE SOFTWARE APLICADAS A LA EDUCACIÓN FÍSICA. OBJETO DE APRENDIZAJE KINOVEA*.
5. Peña Ayala, L. E., Gómez Bull, K. G., Vargas Salgado, M. M., Ibarra Mejía, G., Máynez Guaderrama, A. I., Peña Ayala, L. E., Gómez Bull, K. G., Vargas Salgado, M. M., Ibarra Mejía, G., & Máynez Guaderrama, A. I. (2018). Determinación de rangos de movimiento del miembro superior en una muestra de estudiantes universitarios mexicanos. *Revista Ciencias de la Salud*, 16(SPE), 64-74.
<https://doi.org/10.12804/revistas.urosario.edu.co/revsalud/a.6845>
6. *Informe mundial sobre la discapacidad*. (2011).
<https://www.who.int/es/publications/i/item/9789241564182>
7. Hellsten, T., Karlsson, J., Shamsuzzaman, M., & Pulkkis, G. (2021). The Potential of Computer Vision-Based Marker-Less Human Motion Analysis for Rehabilitation. *Rehabilitation Process and Outcome*, 10, 11795727211022330.
<https://doi.org/10.1177/11795727211022330>
8. Seron, P., Oliveros, M.-J., Gutierrez-Arias, R., Fuentes-Aspe, R., Torres-Castro, R. C., Merino-Osorio, C., Nahuelhual, P., Inostroza, J., Jalil, Y., Solano, R., Marzuca-Nassr, G. N., Aguilera-Eguía, R., Lavados-Romo, P., Soto-Rodríguez, F. J., Sabelle, C., Villarroel-Silva, G., Gomolán, P., Huaiquilaf, S., & Sanchez, P. (2021). Effectiveness of

- Telerehabilitation in Physical Therapy: A Rapid Overview. *Physical Therapy*, 101(6), pzab053. <https://doi.org/10.1093/ptj/pzab053>
9. Takeda, I., Yamada, A., & Onodera, H. (2021). Artificial Intelligence-Assisted motion capture for medical applications: A comparative study between markerless and passive marker motion capture. *Computer Methods in Biomechanics and Biomedical Engineering*, 24(8), 864-873. <https://doi.org/10.1080/10255842.2020.1856372>
 10. Van Hooren, B., Pecasse, N., Meijer, K., & Essers, J. M. N. (2023). The accuracy of markerless motion capture combined with computer vision techniques for measuring running kinematics. *Scandinavian Journal of Medicine & Science in Sports*, 33(6), 966-978. <https://doi.org/10.1111/sms.14319>
 11. Song, K., Hullfish, T. J., Scattone Silva, R., Silbernagel, K. G., & Baxter, J. R. (2023). Markerless motion capture estimates of lower extremity kinematics and kinetics are comparable to marker-based across 8 movements. *Journal of Biomechanics*, 157, 111751. <https://doi.org/10.1016/j.jbiomech.2023.111751>
 12. Colyer, S. L., Evans, M., Cosker, D. P., & Salo, A. I. T. (2018). A Review of the Evolution of Vision-Based Motion Analysis and the Integration of Advanced Computer Vision Methods Towards Developing a Markerless System. *Sports Medicine - Open*, 4(1), 24. <https://doi.org/10.1186/s40798-018-0139-y>
 13. Wade, L., Needham, L., McGuigan, P., & Bilzon, J. (2022). Applications and limitations of current markerless motion capture methods for clinical gait biomechanics. *PeerJ*, 10, e12995. <https://doi.org/10.7717/peerj.12995>
 14. Cronin, N. J., Mansoubi, M., Hannink, E., Waller, B., & Dawes, H. (2023). Accuracy of a computer vision system for estimating biomechanical measures of body function in axial spondyloarthritis patients and healthy subjects. *Clinical Rehabilitation*, 37(8), 1087-1098. <https://doi.org/10.1177/02692155221150133>

15. Klöpfer-Krämer, I., Brand, A., Wackerle, H., Müßig, J., Kröger, I., & Augat, P. (2020). Gait analysis—Available platforms for outcome assessment. *Injury, 51 Suppl 2*, S90-S96.
<https://doi.org/10.1016/j.injury.2019.11.011>
16. Lam, W. W. T., Tang, Y. M., & Fong, K. N. K. (2023). A systematic review of the applications of markerless motion capture (MMC) technology for clinical measurement in rehabilitation. *Journal of Neuroengineering and Rehabilitation, 20*(1), 57.
<https://doi.org/10.1186/s12984-023-01186-9>
17. Park, C., Mishra, R., Sharafkhaneh, A., Bryant, M. S., Nguyen, C., Torres, I., Naik, A. D., & Najafi, B. (2021). Digital Biomarker Representing Frailty Phenotypes: The Use of Machine Learning and Sensor-Based Sit-to-Stand Test. *Sensors (Basel, Switzerland), 21*(9), 3258. <https://doi.org/10.3390/s21093258>
18. Tanaka, R., Ishii, Y., Yamasaki, T., & Kawanishi, H. (2019). Measurement of the total body center of gravity during sit-to-stand motion using a markerless motion capture system. *Medical Engineering & Physics, 66*, 91-95.
<https://doi.org/10.1016/j.medengphy.2018.12.020>
19. Atrsaei, A., Paraschiv-Ionescu, A., Krief, H., Henchoz, Y., Santos-Eggimann, B., Büla, C., & Aminian, K. (2022). Instrumented 5-Time Sit-To-Stand Test: Parameters Predicting Serious Falls beyond the Duration of the Test. *Gerontology, 68*(5), 587-600.
<https://doi.org/10.1159/000518389>
20. Bennett, T., Kumar, P., & Garate, V. R. (2022). A Machine Learning Model for Predicting Sit-to-Stand Trajectories of People with and without Stroke: Towards Adaptive Robotic Assistance. *Sensors (Basel, Switzerland), 22*(13), 4789.
<https://doi.org/10.3390/s22134789>
21. Nakano, N., Sakura, T., Ueda, K., Omura, L., Kimura, A., Iino, Y., Fukashiro, S., & Yoshioka, S. (2020). Evaluation of 3D Markerless Motion Capture Accuracy Using

- OpenPose With Multiple Video Cameras. *Frontiers in Sports and Active Living*, 2.
<https://www.frontiersin.org/articles/10.3389/fspor.2020.00050>
22. Puig-Diví, A., Escalona-Marfil, C., Padullés-Riu, J. M., Busquets, A., Padullés-Chando, X., & Marcos-Ruiz, D. (2019). Validity and reliability of the Kinovea program in obtaining angles and distances using coordinates in 4 perspectives. *PloS One*, 14(6), e0216448.
<https://doi.org/10.1371/journal.pone.0216448>
23. Fernández-González, P., Koutsou, A., Cuesta-Gómez, A., Carratalá-Tejada, M., Miangolarra-Page, J. C., & Molina-Rueda, F. (2020). Reliability of Kinovea® Software and Agreement with a Three-Dimensional Motion System for Gait Analysis in Healthy Subjects. *Sensors (Basel, Switzerland)*, 20(11), 3154.
<https://doi.org/10.3390/s20113154>
24. Augustine, C., Gujjari, A. K., Paul, N., Neelan, S., & Swamy, R. (2022). Prosthetic Rehabilitation and Its Effect on Head Posture. *Cureus*, 14(4), e24630.
<https://doi.org/10.7759/cureus.24630>
25. Reyes Leiva, K. M., Jaén-Vargas, M., Codina, B., & Serrano Olmedo, J. J. (2021). Inertial Measurement Unit Sensors in Assistive Technologies for Visually Impaired People, a Review. *Sensors*, 21(14), Article 14. <https://doi.org/10.3390/s21144767>
26. Ghorbani, S., Mahdavian, K., Thaler, A., Kording, K., Cook, D. J., Blohm, G., & Troje, N. F. (2021). MoVi: A large multi-purpose human motion and video dataset. *PloS One*, 16(6), e0253157. <https://doi.org/10.1371/journal.pone.0253157>
27. Jaén-Vargas, M., Leiva, K. M. R., Fernandes, F., Gonçalves, S. B., Silva, M. T., Lopes, D. S., & Olmedo, J. J. S. (2022). Effects of sliding window variation in the performance of acceleration-based human activity recognition using deep learning models. *PeerJ Computer Science*, 8, e1052. <https://doi.org/10.7717/peerj-cs.1052>

28. Moro, M., Marchesi, G., Hesse, F., Odone, F., & Casadio, M. (2022). Markerless vs. Marker-Based Gait Analysis: A Proof of Concept Study. *Sensors*, 22(5), Article 5. <https://doi.org/10.3390/s22052011>
29. Hume, D. R., Kefala, V., Harris, M., & Shelburne, K. B. (2018). Comparison of Marker-Based and Stereo Radiography Knee Kinematics in Activities of Daily Living. *Annals of biomedical engineering*, 46(11), 1806-1815. <https://doi.org/10.1007/s10439-018-2068-9>
30. Jo, S., Song, S., Kim, J., & Song, C. (2022). Agreement between Azure Kinect and Marker-Based Motion Analysis during Functional Movements: A Feasibility Study. *Sensors (Basel, Switzerland)*, 22(24), 9819. <https://doi.org/10.3390/s22249819>
31. Onitsuka, K., Kubota, K., Yokoyama, M., Miyazawa, T., Hamaguchi, T., Taniguchi, H., Usuki, N., Miyamoto, S., Okazaki, K., Murata, K., & Kanemura, N. (2023). Clinical utility of markerless motion capture for kinematic evaluation of sit-to-stand during 30 s-CST at one year post total knee arthroplasty: A retrospective study. *BMC Musculoskeletal Disorders*, 24(1), 254. <https://doi.org/10.1186/s12891-023-06364-3>
32. Mennella, C., Maniscalco, U., Pietro, G. D., & Esposito, M. (2023). A deep learning system to monitor and assess rehabilitation exercises in home-based remote and unsupervised conditions. *Computers in Biology and Medicine*, 166, 107485. <https://doi.org/10.1016/j.compbiomed.2023.107485>
33. Kalbhor, M., Shinde, S., Wajire, P., & Jude, H. (2023). CerviCell-detector: An object detection approach for identifying the cancerous cells in pap smear images of cervical cancer. *Heliyon*, 9(11), e22324. <https://doi.org/10.1016/j.heliyon.2023.e22324>
34. Wade, L., Needham, L., McGuigan, P., & Bilzon, J. (2022). Applications and limitations of current markerless motion capture methods for clinical gait biomechanics. *PeerJ*, 10, e12995. <https://doi.org/10.7717/peerj.12995>

35. Takeda, I., Yamada, A., & Onodera, H. (2021). Artificial Intelligence-Assisted motion capture for medical applications: A comparative study between markerless and passive marker motion capture. *Computer Methods in Biomechanics and Biomedical Engineering*, 24(8), 864-873. <https://doi.org/10.1080/10255842.2020.1856372>
36. Rizk, M., & Bayad, I. (2023). Human Detection in Thermal Images Using YOLOv8 for Search and Rescue Missions. *2023 Seventh International Conference on Advances in Biomedical Engineering (ICABME)*, 210-215. <https://doi.org/10.1109/ICABME59496.2023.10293139>
37. Jiang, Y., Hang, R., Wu, Y., Huang, W., Pan, X., & Tao, Z. (2023). Design and Development of Posture Detection System Based on YOLO - OpenPose. *2023 19th International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, 1-7. <https://doi.org/10.1109/ICNC-FSKD59587.2023.10281033>
38. Kavzoglu, T. (2009). Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling & Software*, 24(7), 850-858. <https://doi.org/10.1016/j.envsoft.2008.11.012>
39. Zhang, L., Song, J., Gao, A., Chen, J., Bao, C., & Ma, K. (2019). *Be Your Own Teacher: Improve the Performance of Convolutional Neural Networks via Self Distillation*. 3713-3722. https://openaccess.thecvf.com/content_ICCV_2019/html/Zhang_Be_Your_Own_Teacher_Improve_the_Performance_of_Convolutional_Neural_ICCV_2019_paper.html