



UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA

FACULTAD DE INGENIERÍA

PROYECTO DE GRADUACIÓN

CLASIFICACIÓN DE POSTURAS DE EQUILIBRIO DEL SPPB UTILIZANDO REDES

NEURONALES Y VISIÓN POR COMPUTADORA

PREVIO A LA OBTENCIÓN DEL TÍTULO

INGENIERA BIOMÉDICA

PRESENTADO POR:

22041002 GLORIA EMILIA ZAPATA CÁCERES

ASESOR: DRA. KARLA REYES

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

MARZO, 2025

DEDICATORIA

A Dios, quien ha sido mi refugio, mi fuerza y mi guía en todo momento. Su amor infinito me ha sostenido y me ha abierto caminos donde no los había, dándome la fortaleza para alcanzar este sueño.

A mi madre, María Suyapa Cáceres, la mayor inspiración en mi vida. Gracias por tu amor incondicional, por enseñarme el valor del esfuerzo y por ser mi refugio en los momentos difíciles.

A mi padre, Edgardo Zapata, por tu sabiduría, paciencia y constante apoyo. Has sido un ejemplo de dedicación y valentía, y cada paso que doy está guiado por las lecciones que me has dado.

A mi hermano, Edgardo, por ser mi confidente y motivación constante. Tu alegría, fortaleza y optimismo me han inspirado a nunca rendirme.

A mis abuelos, que aunque ya no están físicamente, me acompañan desde el cielo con su amor, orgullo y el legado imborrable de sus valores. Este logro también es para ellos, quienes siguen iluminando mi camino.

Este trabajo no es solo mío, es de todos ustedes que me han acompañado con amor y fe en este camino. Gracias, desde lo más profundo de mi corazón.

AGRADECIMIENTOS

En primer lugar, mi agradecimiento más profundo es para Dios, quien ha sido mi refugio, mi fuerza y la fuente de todas mis bendiciones. A Él le debo cada logro alcanzado, cada puerta abierta y la fuerza para superar cada desafío. Su presencia constante en mi vida me ha permitido recorrer este camino con fe y esperanza.

A mi familia, que ha sido mi pilar incondicional durante esta trayectoria académica. Gracias por su apoyo, amor y comprensión en cada momento. Ustedes han sido testigos de mis esfuerzos, mis desvelos y mis sueños, y su fé en mí ha sido mi mayor motivación para seguir adelante.

A mi hermana mayor Nuvia le agradezco por ser mi ejemplo de fortaleza, dedicación y amor incondicional. Aunque la distancia nos separa, siempre has estado presente en mi vida, brindándome tu apoyo inquebrantable y tus palabras de aliento en los momentos más importantes. Tu capacidad para afrontar la vida con valentía y sabiduría me inspira a ser mejor cada día. Tu ejemplo y cariño han sido fundamentales en este camino, y siempre llevaré en mi corazón todo lo que me has enseñado.

A mi mejor amiga, mi hermana de vida, Fátima, quien no solo ha estado conmigo desde el primer día, sino que ha caminado a mi lado en cada paso de este viaje. Gracias por tu amor incondicional, por escucharme, por ser mi consciencia cuando la necesitaba y por soñar tan grande como yo. Haber cruzado el mundo juntas para cumplir uno de nuestros sueños es algo que siempre atesoraré. Vivir esta experiencia como estudiantes internacionales y ser aceptadas en el Centro de Tecnología Biomédica (CTB) ha sido más especial porque lo hicimos juntas. También quiero expresar mi agradecimiento a tus padres, por su apoyo constante, por sus palabras de aliento y por haberme acogido como parte de su familia. No solo estoy agradecida contigo, Fátima, sino con la familia que te formó, porque ellos también son parte de este logro.

A la Dra. Karla, por ser mi asesora y guía en este proyecto, y también el instrumento que Dios utilizó para que pudiera realizar mi tesis en España. Gracias por su conocimiento, paciencia y apoyo incondicional, y por abrirnos las puertas para que este sueño se hiciera realidad.

Al Dr. Ricardo Imbert Paredes, cuya confianza y apoyo se convirtieron en el cimiento de este proyecto. Su disposición para aceptar mi propuesta desde aquella videollamada en la madrugada hondureña fue el inicio de esta increíble experiencia. Desde ese momento, su

calidez, profesionalismo y fe en mis capacidades me dieron la seguridad para embarcarme en este desafío. Su compromiso con cada proyecto y con la innovación me inspira profundamente, y no tengo palabras suficientes para agradecerle por haberme permitido ser parte de este sueño.

A Maryam Heydari, mi compañera en el CTB, por su paciencia, su disposición para enseñarme y su ayuda constante. Gracias por responder a cualquier hora y por guiarme en todo lo que no sabía; su apoyo ha sido invaluable.

A mi primera amiga universitaria, Nataly, quien llegó para demostrarme que la amistad puede ser un faro en los momentos más oscuros. Gracias por tu inteligencia deslumbrante, por tu capacidad para hacer frente a cualquier desafío con valentía, y por ser ese apoyo incondicional que siempre estuvo dispuesto a escuchar, animar y caminar a mi lado. Tu multifacética manera de ver la vida y tu habilidad para superar los obstáculos con gracia son una inspiración constante para mí. No solo eres una amiga, sino también una hermana de vida que sé que brillará intensamente en todo lo que emprenda.

A mis compañeros de carrera: Majo, Carlos, Aldair, Diego, Héctor, Jorge, Jennifer, José, Valeria y Willian, quienes hicieron que cada día en la universidad fuera más llevadero y memorable. Ustedes no solo fueron compañeros, sino una familia con la que compartí risas, desvelos, nervios antes de las entregas y la alegría de cada meta cumplida. Gracias por cada chiste en los momentos más tensos, por su apoyo en los días difíciles y por demostrar que el trabajo en equipo y la amistad son las claves para superar cualquier desafío. Cada proyecto, cada experiencia y cada logro que compartimos quedarán grabados en mi corazón como parte esencial de este viaje universitario.

A mis amigos del colegio y la universidad, César y Gabriela, cuya amistad ha sido muy especial. Sus conversaciones en el trayecto de regreso a casa fueron momentos de aprendizaje, risas y apoyo que siempre recordaré con cariño.

A mi amiga Fabianna, la mejor amistad que pude hacer en Madrid. Aunque ya sabíamos de la existencia de la otra, el destino nos tenía preparado este encuentro tan especial. Compartir la misma universidad, la misma carrera y hasta haber coincidido en una charla impartida por ella cuando hacías su práctica, era solo el comienzo de esta amistad. Encontrarnos específicamente para ver los globos en Aranjuez, fue el inicio de nuestras aventuras por esta hermosa ciudad. Gracias por ser ese rayito de luz en los días nublados y por

acompañarme en los días soleados. Tu apoyo en todo este tiempo ha sido invaluable. Gracias por estar siempre.

A los docentes que marcaron mi vida universitaria de formas inolvidables. A la Ing. Reyna Valle, por ser más que una jefa de carrera: una mentora siempre dispuesta a guiarnos con paciencia y dedicación. A la Ing. Stefany, por su pasión por enseñar y por demostrar que el conocimiento, cuando se comparte con amor, transforma vidas. A la Dra. Rosalina, quien con su entusiasmo nos hizo enamorarnos de la medicina y verla no solo como una ciencia, sino como un arte para cuidar y sanar. Al Ing. Aguiluz, por recordarme que las calificaciones no definen a un estudiante, sino la determinación y el esfuerzo detrás de cada aprendizaje. A cada docente que pasó por mi vida, gracias por sus enseñanzas, su tiempo y su compromiso con nuestra formación. Su huella no solo se quedó en el aula, sino en mi corazón.

Finalmente, agradezco a todas las personas que de una u otra manera contribuyeron a que mi paso por la universidad fuera inolvidable. Cada gesto, palabra y acción dejaron una huella en este camino, y siempre llevaré ese agradecimiento en mi corazón.

EPÍGRAFE

“Mira que te mando que te esfuerces y seas valiente; no temas ni desmayes, porque el Señor tu Dios estará contigo donde quiera que vayas.”

- **Josué 1:9**

RESUMEN EJECUTIVO

El envejecimiento poblacional conlleva un aumento del riesgo de fragilidad y pérdida de equilibrio en adultos mayores, lo que incrementa la probabilidad de caídas y afecta su autonomía. Para abordar este problema, este estudio desarrolla un modelo basado en visión por computadora y redes neuronales convolucionales (CNN) para la clasificación de posturas de equilibrio en la prueba SPPB. El sistema emplea Roboflow para entrenar el modelo de aprendizaje profundo con imágenes segmentadas de videos. Se han etiquetado posturas clave del SPPB (pies juntos, semi-tándem y tándem) para permitir la identificación automática. El modelo será validado mediante métricas de desempeño como precisión, recall y mAP, garantizando su fiabilidad para futuras aplicaciones en la evaluación del equilibrio. Este enfoque elimina la necesidad de sensores físicos y proporciona una alternativa accesible para el análisis postural en entornos clínicos y de investigación.

Palabras clave: Análisis postural, aprendizaje profundo, clasificación de posturas, equilibrio, procesamiento de imágenes, redes neuronales convolucionales, roboflow, seguimiento de posturas, SPPB, visión por computadora.

ABSTRACT

The aging population leads to an increased risk of frailty and loss of balance in older adults, which raises the likelihood of falls and affects their autonomy. To address this issue, this study develops a model based on computer vision and Convolutional Neural Networks (CNNs) for the classification and tracking of balance postures in the Short Physical Performance Battery (SPPB). The system uses Roboflow to train the deep learning model with segmented images from videos. Key postures from the SPPB (feet together, semi-tandem, and tandem) have been labeled to allow for automatic identification. The model will be validated using performance metrics such as accuracy, recall, and mAP, ensuring its reliability for future applications in balance assessment. This approach eliminates the need for physical sensors and provides an accessible alternative for postural analysis in clinical and research settings.

Key-Words: Postural analysis, deep learning, posture classification, balance, image processing, convolutional neural networks, Roboflow, posture tracking, SPPB, computer vision.

ÍNDICE DE CONTENIDO

I. INTRODUCCIÓN	15
II. ESTADO DEL ARTE.....	17
2.1. ANTECEDENTES.....	17
2.1.1. MONITOREO DE SALUD Y ACTIVIDAD FÍSICA EN PERSONAS MAYORES CON LA APLICACIÓN DE VIVIFRAIL.....	19
2.1.1.1. <i>Short Physical Performance Battery (SPPB)</i>	19
2.1.1.2. <i>Valoración Funcional</i>	21
2.1.2. DESAFÍOS EN EL RECONOCIMIENTO DE POSTURAS.....	23
2.1.3. TECNOLOGÍAS EMERGENTES PARA EL MONITOREO DE PERSONAS MAYORES	24
2.1.3.1. <i>Hardware</i>	24
2.1.3.2. <i>Software</i>	28
2.2. PROBLEMÁTICA.....	39
2.3. LIMITACIONES ENCONTRADAS EN EL ESTADO DEL ARTE.....	41
III. OBJETIVOS	45
3.1. OBJETIVO GENERAL	45
3.2. OBJETIVOS ESPECÍFICOS	45
IV. MÉTODOS	46
4.1. ENFOQUE.....	46
4.1. CREACIÓN DE LA BASE DE DATOS	46
4.2. VARIABLES DE INVESTIGACIÓN.....	47
4.2.1. VARIABLES DEPENDIENTES.....	47

4.2.2. VARIABLES INDEPENDIENTES	48
4.3. TÉCNICA E INSTRUMENTOS APLICADOS	48
4.3.1. ROBOFLOW	48
4.3.2. PRUEBA DE EQUILIBRIO DEL SPPB	49
4.4. MATERIALES	50
4.4.1. CÁMARAS DE TELÉFONO INTELIGENTE	50
4.5. POBLACIÓN	51
4.6. METODOLOGÍA DE ESTUDIO	51
4.6.1. VALIDACIÓN DE RESULTADOS	52
4.6.2. PLAN DE IMPLEMENTACIÓN	53
4.7. CRONOGRAMA DE ACTIVIDADES	55
4.8. OPERACIONES DE LAS VARIABLES	56
V. RESULTADOS Y ANÁLISIS	57
5.1. CLASIFICACIÓN DE POSTURAS DEL SPPB	57
5.2. EVALUACIÓN DE DESEMPEÑO DE LOS MODELOS	58
5.3. PRECISIÓN, RECALL, MAP	60
5.3.1. RENDIMIENTO POR CLASE VALIDATION SET MAP50	61
5.3.2. RENDIMIENTO POR CLASE TEST SET MAP50	63
5.4. EVOLUCIÓN DEL MODELO DURANTE EL ENTRENAMIENTO	66
5.5. ANÁLISIS DE LAS GRÁFICAS DE PÉRDIDA	69
5.5.1. BOX LOSS (TRAIN/BOX_LOSS Y VAL/BOX_LOSS)	69
5.5.2. CLASS LOSS (TRAIN/CLS_LOSS Y VAL/CLS_LOSS)	71
5.5.3. OBJECT LOSS (TRAIN/DFL_LOSS Y VAL/DFL_LOSS)	73

5.6. VALIDACIÓN DEL MODELO DE DETECCIÓN DE POSTURAS	76
5.7. PRECISIÓN POR CATEGORÍA DE POSTURA	76
5.8. MATRIZ DE CONFUSIÓN	77
5.9. PLAN DE IMPLEMENTACIÓN	79
VI. DISCUSIÓN.....	81
VII. CONCLUSIONES	83
7.1. CONCLUSIÓN GENERAL	83
7.2. CONCLUSIONES ESPECIFICAS.....	83
VIII. RECOMENDACIONES	85
IX. REFERENCIAS BIBLIOGRÁFICAS.....	86

ÍNDICE DE ILUSTRACIONES

<i>Ilustración 1: Ejemplo de funcionamiento de una CNN</i>	<i>34</i>
<i>Ilustración 2: Variable Independiente.....</i>	<i>48</i>
<i>Ilustración 3: Clasificación de imágenes en el dataset.....</i>	<i>57</i>
<i>Ilustración 4: Gráfica 81 de precisión, recall, mAP50 y mAP50-95 por epoch.....</i>	<i>60</i>
<i>Ilustración 5: Gráfica Modelo 2 de precisión, recall, mAP50 y mAP50-95 por epoch.....</i>	<i>60</i>
<i>Ilustración 6: Gráfica Modelo 3 de precisión, recall, mAP50 y mAP50-95 por epoch.....</i>	<i>61</i>
<i>Ilustración 7: Modelo 1 Rendimiento por clase test set (mAP50).....</i>	<i>62</i>
<i>Ilustración 8: Modelo 2 Rendimiento por clase test set (mAP50).....</i>	<i>62</i>
<i>Ilustración 9: Modelo 3 Rendimiento por clase test set (mAP50).....</i>	<i>63</i>
<i>Ilustración 10: Rendimiento del modelo 1 por clase test set MAP50.....</i>	<i>64</i>

<i>Ilustración 11: Rendimiento del modelo 2 por clase test set MAP50</i>	64
<i>Ilustración 12: Rendimiento del modelo 2 por clase test set MAP50</i>	65
<i>Ilustración 13: Gráfica de evolución de mAP en el tiempo del Modelo 1</i>	66
<i>Ilustración 14: Gráfica de evolución de mAP en el tiempo del Modelo 2</i>	67
<i>Ilustración 15: Gráfica de evolución de mAP en el tiempo del Modelo 3</i>	68
<i>Ilustración 16: Gráfica de entrenamiento de box loss del modelo 1</i>	69
<i>Ilustración 17: Gráfica de entrenamiento de box loss del modelo 2</i>	70
<i>Ilustración 18: Gráfica de entrenamiento de box loss del modelo 3</i>	71
<i>Ilustración 19: Gráfica de entrenamiento train/cls_loss del modelo 1</i>	72
<i>Ilustración 20: Gráfica de entrenamiento train/cls_loss del modelo 2</i>	72
<i>Ilustración 21: Gráfica de entrenamiento train/cls_loss del modelo 3</i>	73
<i>Ilustración 22: Gráfica de entrenamiento train/dfl_loss del modelo 1</i>	74
<i>Ilustración 23: Gráfica de entrenamiento train/dfl_loss del modelo 2</i>	74
<i>Ilustración 24: Gráfica de entrenamiento train/dfl_loss del modelo 3</i>	75
<i>Ilustración 25: Gráfica de validación</i>	76
<i>Ilustración 26: Gráfica de Precisión</i>	77
<i>Ilustración 27: Matriz de Confusión de Pose real y detectadas.</i>	78
<i>Ilustración 28: Prueba de batería corta de desempeño físico (SPPB)</i>	101
<i>Ilustración 29: Carta de consentimiento informado</i>	102
<i>Ilustración 30: Tabla para hacer las pruebas de SPPB para cada participante</i>	103
<i>Ilustración 31: Pies juntos</i>	103
<i>Ilustración 32: Semi- tandem</i>	104
<i>Ilustración 33: Tándem</i>	104
<i>Ilustración 34: Tándem incorrecto</i>	105

Ilustración 35: Semi-tándem incorrecto.....	105
Ilustración 36: Pies juntos incorrectos.....	106
Ilustración 37: Imágenes sin clasificación, Árbol.....	106
Ilustración 38: Imágenes sin clasificación, Palillos	107
Ilustración 39: Imágenes sin clasificación, Perro	107
Ilustración 40: Imágenes sin clasificación, kiwi.....	108

ÍNDICE DE TABLAS

Tabla 1: Tabla de limitaciones.....	41
Tabla 2: Tabla de resumen de enfoques recientes	43
Tabla 3: Cronograma de Actividades	55
Tabla 4: Operalización De Las Variables	56
Tabla 5: Comparación de Modelos	58
Tabla 6: Tabla de Plan de Implementación.....	80

ÍNDICE DE ANEXOS

Anexo 1 Prueba de Batería corta de desempeño físico	101
Anexo 2 Consentimiento Informado	102
Anexo 4 Estructura de la base de datos	103

LISTA DE SIGLAS

CNNs	Convolutional Neural Networks
CTB	Centro de Tecnología Biomédica
DALAResNet50	Dual-Activated Lightweight Attention ResNet50
DenseNet121	Dense Convolutional Network 121
EfficientNet	Modelo de red neuronal eficiente con escalado compuesto
IA	Inteligencia Artificial
ImageNet	Base de datos de imágenes utilizada para la clasificación de imágenes
IMUs	Inertial Measurement Units
IoU	Intersection over union
mAP	Mean Average Precision
MobileNet	Modelo de red neuronal para dispositivos con recursos limitados
OpenCV	Open-Source Computer Vision Library
SEResNet50	Squeeze-and-Excitation ResNet50
SPPB	Short Physical Performance Battery
SVM	Support Vector Machine
TFA	Transferable Feature Analysis
ViTs	Vision Transformers
YOLO	You Only Look Once

GLOSARIO

1. Clasificación de Imágenes: Técnica en visión por computadora que permite asignar una categoría o etiqueta a una imagen en función de su contenido.
2. Convolutional Neural Networks (CNNs): Redes neuronales convolucionales utilizadas principalmente para el análisis de imágenes, permitiendo tareas como clasificación de objetos y reconocimiento de patrones.
3. Evaluación del Equilibrio: Proceso de análisis de la estabilidad postural en adultos mayores mediante pruebas estandarizadas como la Short Physical Performance Battery (SPPB).
4. Falsos Positivos y Falsos Negativos: Errores en el reconocimiento de ejercicios donde el sistema detecta incorrectamente una acción (falso positivo) o no detecta una acción válida (falso negativo).
5. Sensibilidad: Capacidad del modelo para identificar correctamente todas las instancias positivas.
6. mAP: Media armónica entre precisión y recall, utilizada en detección de objetos para evaluar el rendimiento de un modelo.
7. Procesamiento de Imágenes: Conjunto de técnicas utilizadas para analizar, modificar y extraer información de imágenes digitales con el fin de realizar tareas como clasificación y segmentación.
8. Roboflow: Plataforma de desarrollo y entrenamiento de modelos de visión por computadora que facilita la anotación, procesamiento y entrenamiento de redes neuronales con conjuntos de datos personalizados.
9. Seguimiento de Posturas (Tracking): Técnica utilizada en visión por computadora para detectar y seguir el movimiento de un sujeto en secuencias de imágenes o videos.
10. Segmentación de Imágenes: Proceso en el que se dividen las imágenes en regiones significativas para facilitar la identificación de patrones o estructuras específicas.
11. Short Physical Performance Battery: Batería de pruebas estandarizadas para evaluar la capacidad física en personas mayores, incluyendo equilibrio, velocidad al caminar y fuerza de las extremidades inferiores.
12. Visión por Computadora: Campo de la inteligencia artificial que permite a las máquinas interpretar y analizar imágenes y videos para extraer información relevante.

I. INTRODUCCIÓN

El envejecimiento de la población es una realidad global que plantea desafíos importantes en el ámbito de la salud. Según la Organización Mundial de la Salud (OMS), para el año 2050, la proporción de personas mayores de 60 años se duplicará, alcanzando el 22% de la población mundial (OMS, 2021). Este aumento ha traído consigo un desafío, cómo mantener la salud física y prevenir la fragilidad en esta población en crecimiento. Se estima que, a partir de los 30 años, la masa muscular disminuye entre un 3% y un 8% por década, acelerándose a partir de los 60 años, afectando la funcionalidad física y aumentando el riesgo de caídas y pérdida de independencia (Larsson et al., 2018). Estos cambios impactan directamente en la capacidad de las personas mayores para realizar actividades cotidianas, lo que refuerza la necesidad de estrategias preventivas basadas en el ejercicio físico (Landi et al., 2018). La pérdida muscular en adultos mayores también está asociada con un incremento en la fragilidad y la dependencia, factores que se vuelven críticos si no se interviene adecuadamente (Meier & Lee, 2020).

El programa Vivifrail surge como una intervención efectiva para prevenir la fragilidad y el riesgo de caídas en personas mayores de 70 años. Este programa multicomponente se centra en mejorar la capacidad funcional mediante ejercicios de fuerza, equilibrio, resistencia cardiovascular y flexibilidad (Izquierdo, 2017). Adaptado a diferentes niveles de capacidad funcional, Vivifrail evalúa a los participantes a través de herramientas como la batería de rendimiento físico (SPPB) y la prueba de velocidad de marcha, y prescribe ejercicios según las necesidades individuales de cada persona (Izquierdo et al., 2017). La correcta ejecución de estos ejercicios es crucial para maximizar sus beneficios, ya que contribuyen a la mejora del equilibrio, la fuerza muscular y la prevención de caídas en esta población vulnerable.

La fragilidad es una condición prevalente que afecta aproximadamente al 10-15% de los adultos mayores de 65 años y se caracteriza por una disminución en la resistencia y la fuerza física (Fried et al., 2001). Esta debilidad incrementa no solo el riesgo de caídas, sino también la incapacidad para realizar tareas diarias, afectando negativamente la calidad de vida de los individuos afectados (Oh et al., 2021). Bajo estas circunstancias, los programas de ejercicio físico, como Vivifrail, han demostrado ser efectivos en la reducción de la fragilidad y el mantenimiento de la salud en adultos mayores, contribuyendo a la mejora del equilibrio y la fuerza muscular (Izquierdo et al., 2017). Sin embargo, es fundamental que estos ejercicios se

realicen de manera correcta y precisa para garantizar sus beneficios. El uso de tecnologías avanzadas, como la visión artificial, permite monitorizar y corregir la ejecución de los ejercicios en tiempo real, mejorando su efectividad (Ma et al., 2023).

MOTIVA es un proyecto del plan nacional, en el que sitúa al equipo que realiza el proyecto: "MOTIVA se sitúa en la intersección de la ingeniería biomédica, la informática, la psicología y la investigación clínica. El equipo está formado por investigadores de la "Universidad Politécnica de Madrid" (UPM) y la "Fundación de Investigación Biomédica del Hospital Universitario de Getafe" (FIBHUG), incluyendo ingenieros biomédicos, ingenieros informáticos, un geriatra, un psicólogo, investigadores en experiencia de usuario, un fisioterapeuta, un epidemiólogo, un estadístico y un farmacólogo clínico. Los investigadores de la UPM pertenecen al Ageing Lab, parte del Centro de Tecnología Biomédica (CTB), y al grupo de investigación en Interacción Persona-Ordenador y Sistemas Interactivos Avanzados de la Escuela Técnica Superior de Ingenieros Informáticos. FIBHUG y UPM mantienen una estrecha colaboración en numerosos proyectos, y los investigadores de FIBHUG también forman parte del Ageing Lab desde su fundación como laboratorio conjunto en 2014 (Villalba et al., 2022). Al combinarse con Vivifrail, este ecosistema computacional no solo contribuye a la prevención de la fragilidad y el deterioro físico, sino que también mejora la funcionalidad y la calidad de vida de los adultos mayores, promoviendo un envejecimiento saludable en todos los aspectos.

En la segunda fase del proyecto, se desarrolló un sistema basado en clasificación de imágenes utilizando Roboflow para mejorar la detección y análisis de posturas en ejercicios de equilibrio. A través del procesamiento de imágenes y el entrenamiento de modelos de visión artificial, se buscó optimizar la identificación de posturas clave en la batería de rendimiento físico (SPPB), permitiendo un monitoreo más preciso y efectivo en tiempo real. Este enfoque facilitó la detección automática de posturas como pies juntos, semi-tándem y tándem, asegurando una mejor evaluación del equilibrio en adultos mayores.

La implementación de clasificación de imágenes con Roboflow representa un avance significativo en la personalización y adaptación de los programas de ejercicio. Este sistema permite clasificar imágenes en categorías específicas, contribuyendo a una mejor supervisión y seguimiento de la correcta ejecución de los ejercicios, lo que ayuda a reducir el riesgo de errores. Aunque no se ha probado en un contexto clínico, su capacidad para procesar

imágenes en tiempo real podría facilitar una corrección inmediata en futuros programas de rehabilitación, mejorando potencialmente su seguridad y eficacia

En definitiva, la integración de clasificación de imágenes en este proyecto fortaleció el uso de tecnologías innovadoras para el análisis del equilibrio en adultos mayores. Esta metodología ofreció una solución accesible y eficiente para evaluar y mejorar la estabilidad postural, contribuyendo a la prevención de caídas y promoviendo un envejecimiento saludable y funcional.

II. ESTADO DEL ARTE

A continuación, esta sección aborda los antecedentes del monitoreo de posturas y movimientos en personas mayores, centrándose en la fragilidad física, el riesgo de caídas y el uso de tecnologías avanzadas como sensores inerciales, cámaras RGB-D e inteligencia artificial. Se destacan estudios previos sobre clasificación de imágenes para identificar posturas como pies juntos, semi-tándem y tándem, facilitando la evaluación del equilibrio. Asimismo, se analizan los beneficios y limitaciones de estas herramientas en la rehabilitación y el envejecimiento saludable.

2.1. ANTECEDENTES

El envejecimiento saludable es un concepto multifacético que ha evolucionado con el tiempo y que se centra en mantener la capacidad funcional y el bienestar en la vejez (Menassa et al., 2023). Abarcó diversos aspectos, como la satisfacción de las necesidades básicas, el aprendizaje, la toma de decisiones, la movilidad, las relaciones y las contribuciones a la sociedad (Szychowska & Drygas, 2021). La Organización Mundial de la Salud (OMS) adoptó un enfoque holístico del envejecimiento saludable, considerando tanto las capacidades individuales como los contextos ambientales (Abud et al., 2022). Los componentes clave del envejecimiento saludable incluyen una alimentación sana, actividad física regular, salud mental, participación social y atención sanitaria preventiva (Szychowska & Drygas, 2021). El concepto va más allá de la prevención de enfermedades y abarca la potenciación de las capacidades de los adultos mayores mediante estrategias de atención a largo plazo (Abud et al., 2022). El envejecimiento saludable está influido por diversos factores a lo largo de la vida, incluidos aspectos sociales, ambientales y biomédicos (Zadworna, 2022). Sin embargo, se

necesitan enfoques de medición estandarizados para facilitar el seguimiento global y la investigación en este campo (Menassa et al., 2023).

El envejecimiento de la población representó un desafío significativo para la salud pública, especialmente en la promoción de hábitos saludables y la prevención de problemas musculoesqueléticos. Las personas adultas mayores son más propensas a adoptar posturas incorrectas debido a la pérdida de tono muscular y movilidad, lo que incrementa el riesgo de desarrollar problemas de salud a largo plazo (N. Iqbal et al., 2020). Estudios recientes han abordado este problema mediante el desarrollo de tecnologías avanzadas que permitieron monitorear la postura y corregirla en tiempo real. Por ejemplo, el uso de cámaras y sensores avanzados demostró ser efectivo para detectar errores posturales y guiar a los usuarios a corregir sus posturas. Tecnologías basadas en inteligencia artificial y visión por computadora facilitaron la corrección automática de posturas en tiempo real, proporcionando retroalimentación inmediata (Jiang et al., 2023). Además, la integración de sensores portátiles permitió el monitoreo continuo de la postura, ofreciendo mejoras significativas en la calidad de vida de las personas mayores (Mansoor et al., 2019).

Con el paso del tiempo, las personas mayores experimentaron una disminución progresiva en su capacidad funcional, que incluyó la pérdida de fuerza muscular, flexibilidad y equilibrio, lo cual aumentó el riesgo de caídas y lesiones. Este proceso, comúnmente asociado con la fragilidad, estuvo caracterizado por una reducción de las reservas fisiológicas, lo que incrementó la vulnerabilidad a eventos adversos de salud como caídas, discapacidad y muerte prematura (Assi et al., 2023). La fragilidad es un estado dinámico que puede mejorar o empeorar con el tiempo, y es crucial detectarla de manera temprana para intervenir de forma adecuada (Y. Li et al., 2023). La actividad física regular desempeñó un papel crucial en la prevención y manejo de la fragilidad, porque no solo mejoró la movilidad y el equilibrio, sino que también contribuyó al bienestar mental y emocional de los adultos mayores (M. D. Korableva & Y. A. Bekeneva, 2024). Sin embargo, debido a la disminución de sus capacidades físicas, muchas personas mayores encontraron difícil participar en actividades físicas de manera segura y efectiva sin supervisión adecuada, lo que pudo llevar a posturas incorrectas o movimientos inadecuados que incrementen el riesgo de lesiones (Duan et al., 2018).

2.1.1. MONITOREO DE SALUD Y ACTIVIDAD FÍSICA EN PERSONAS MAYORES CON LA APLICACIÓN DE VIVIFRAIL

El programa Vivifrail demostró ser un enfoque estructurado y efectivo para mejorar la movilidad y reducir el riesgo de caídas en personas mayores. Este programa se basó en ejercicios diseñados para fortalecer los músculos, mejorar el equilibrio y aumentar la resistencia, lo que resultó esencial para mantener la funcionalidad en esta población vulnerable. El enfoque principal de Vivifrail fue promover la fuerza muscular, la resistencia cardiovascular, el equilibrio, y la flexibilidad mediante ejercicios adaptados al nivel funcional del individuo, lo cual demostró reducir el riesgo de caídas y mejorar la calidad de vida (Izquierdo et al., 2017).

Vivifrail, desarrollado con el apoyo de diversas instituciones europeas, estableció programas que permitieron el seguimiento de personas mayores frágiles y prefrágiles a través de rutinas específicas de ejercicio físico multicomponente, que incluyeron la fuerza, la potencia muscular, la marcha, el equilibrio y la resistencia cardiovascular (Izquierdo et al., 2017). Estos ejercicios, adaptados a las limitaciones de cada persona, permitieron una progresión controlada en intensidad y volumen, disminuyendo el riesgo de caídas y optimizando el rendimiento físico.

2.1.1.1. Short Physical Performance Battery (SPPB)

La relación entre la SPPB y el programa Vivifrail es clave en el estudio de la fragilidad y el desempeño físico en personas mayores, ya que ambas herramientas se utilizaron en escenarios complementarios. Mientras que el SPPB se enfocó en la evaluación objetiva de la fragilidad mediante pruebas estandarizadas, el programa Vivifrail se orientó hacia la mejora funcional a través de un conjunto de ejercicios diseñados según el nivel de fragilidad del individuo.

En el marco de este proyecto, la prueba de SPPB se implementó como un sistema de evaluación automatizado mediante visión por computadora, permitiendo la detección en tiempo real de las posturas y movimientos involucrados en la prueba. Esto sustituyó la evaluación manual realizada por fisioterapeutas, asegurando una medición objetiva y estandarizada del estado de fragilidad de los participantes. La batería SPPB permitió establecer una línea base de las capacidades físicas de los usuarios antes de iniciar cualquier programa

de intervención, garantizando que el sistema propuesto se adaptara de manera precisa a sus necesidades funcionales.

La prueba SPPB es una herramienta de evaluación ampliamente utilizada y diseñada para evaluar el rendimiento físico en adultos mayores, especialmente en el contexto de la fragilidad (Singer et al., 2023). La SPPB evaluó tres aspectos de la movilidad: equilibrio, velocidad de marcha y fuerza de miembros o extremidades inferiores para levantarse de una silla (Guralnik et al., 2018). Estos componentes midieron colectivamente la función de las extremidades inferiores, que fue crucial para mantener la independencia y realizar las actividades diarias (Kimber et al., 2018). La prueba de SPPB fue especialmente valiosa porque proporcionó una evaluación total de las capacidades físicas sin requerir un esfuerzo máximo, lo que la hizo adecuada para adultos mayores que pudieron tener diversas comorbilidades (Lascano et al., 2015).

La relevancia de la prueba SPPB en la evaluación de la fragilidad radicó en su capacidad para identificar a los individuos en riesgo de resultados adversos para la salud (S. Chen et al., 2023). La investigación demostró que las puntuaciones más bajas en la SPPB se correlacionaron con mayores riesgos de hospitalización, discapacidad y mortalidad en poblaciones de edad avanzada (Banning et al., 2021). Por ejemplo, una revisión sistemática indicó que el SPPB fue un fuerte predictor de la discapacidad a largo plazo y la institucionalización entre los adultos mayores que viven en la comunidad (Park et al., 2021). Además, los estudios demostraron que la SPPB pudo detectar estados tempranos de fragilidad, incluso en adultos mayores de alto funcionamiento, sirviendo, así como una herramienta esencial para la intervención temprana (Haugen et al., 2020).

La prueba de SPPB como se mencionó, incluyó tres subpruebas que se realizaron en orden para evaluar la capacidad física en personas mayores. La primera fue la prueba de equilibrio, donde se evaluó la habilidad de la persona para mantenerse de pie en tres posiciones diferentes. Primero, debía colocarse con los pies juntos, uno al lado del otro, y mantener esa posición durante 10 segundos. Si lo consiguió, obtuvo un punto, pero si no lo logró, su puntaje fue cero y pasó automáticamente a la siguiente prueba. La segunda posición fue la semi-tándem, en la cual debía colocar el talón de un pie al nivel del dedo gordo del otro y sostenerse durante 10 segundos. Si no logró mantenerse en equilibrio, obtuvo un puntaje de cero; si lo logró, obtuvo un punto. La tercera posición fue el tándem, donde debía colocar

el talón de un pie en contacto con la punta del otro. Aquí, el puntaje varió según el tiempo que logró mantenerse: si aguantó 10 segundos obtuvo 2 puntos, entre 3 y 9 segundos le dio 1 punto, y si no llegó a los 3 segundos, su puntaje fue cero.

La segunda subprueba fue la prueba de velocidad de marcha, donde se midió cuánto tardó la persona en caminar 4 metros a paso normal. Se le solicitó que hiciera este recorrido tres veces y se tomó el menor de los tiempos registrados. Dependiendo de la rapidez, se asignó una puntuación: si lo hizo en menos de 4,82 segundos, obtuvo 4 puntos; entre 4,82 y 6,20 segundos, 3 puntos; entre 6,21 y 8,70 segundos, 2 puntos; y si tardó más de 8,7 segundos, solo obtuvo 1 punto. Si no fue capaz de realizar la prueba, recibió un puntaje de 0.

Finalmente, la tercera subprueba es la prueba de levantarse de la silla, donde se evaluó la fuerza en las piernas y la capacidad para levantarse repetidamente de una silla. Se le pidió a la persona que se levantara cinco veces de la silla lo más rápido posible, con la espalda recta y los brazos cruzados sobre el pecho. El tiempo que tardó en completar las cinco levantadas determinó su puntaje: si lo hizo en menos de 11,19 segundos obtuvo 4 puntos; entre 11,20 y 13,69 segundos, 3 puntos; entre 13,70 y 16,69 segundos, 2 puntos; y si tardó entre 16,70 segundos y 59 segundos, recibió 1 punto. Si tardó más de 60 segundos o no pudo completar la prueba, obtuvo un puntaje de 0.

La puntuación total del SPPB resultó de la suma de las tres pruebas y osciló entre 0 (peor) y 12 (lo mejor). Se consideró que existió una alta probabilidad de fragilidad en aquellas personas con un SPPB <10. A aquellas personas con un SPPB ≥ 10 se les consideró no frágiles y se realizó la detección precoz de fragilidad anualmente y después de un evento importante de salud, como por ejemplo un ingreso o agudización de una condición crónica (Olalla, 2022).

(Anexo 1 Prueba de Batería corta de desempeño físico)

2.1.1.2. Valoración Funcional

En general, la prueba SPPB es una herramienta de evaluación ampliamente utilizada para medir el rendimiento físico en adultos mayores, particularmente en el contexto de la fragilidad (S. Chen et al., 2023). Sin embargo, el programa Vivifrail complementó esta evaluación con pruebas adicionales, como la evaluación de caídas recientes, la prueba "Timed Up and Go" (TUG), la velocidad de marcha en 6 metros y la evaluación del deterioro cognitivo. Mientras que el SPPB clasificó a los individuos en frágiles o no frágiles en función de la

puntuación obtenida, Vivifrail proporcionó una clasificación más detallada. Este último dividió a los adultos mayores en diferentes categorías funcionales: A (discapacitado), B (frágil), C1 (frágil), C2 (pre-frágil) y D (autónomo), lo que permitió una intervención más específica y adaptada a cada caso.

Aunque el SPPB es una herramienta útil para identificar el estado de fragilidad, la metodología de Vivifrail ofreció una visión más completa al incluir un mayor número de pruebas y una clasificación más matizada del rendimiento físico. A continuación, se detallaron las cuatro categorías de puntuación que utilizó el SPPB para evaluar el estado funcional de los individuos.

En el primer nivel fue la rueda A, limitación grave o discapacidad (SPPB 0-3), la persona se encontró en una situación de movilidad muy reducida, sin capacidad para caminar y, en muchos casos, confinada a una silla de ruedas o encamada. La recomendación en este caso fue realizar ejercicios que ayudaran a conseguir levantarse de la silla, con el objetivo de mejorar esa capacidad básica.

El segundo nivel rueda B, limitación moderada o frágil (SPPB 4-6), describió a personas que tuvieron dificultades para caminar o lo hicieron con ayuda, y enfrentaron problemas con el equilibrio y las levantadas. Los ejercicios recomendados en este nivel prometieron una gran mejoría si se realizaron con constancia, ayudando a recuperar movilidad y estabilidad.

En el tercer nivel rueda C, limitación leve o frágil prefrágil (SPPB 7-9), se encontraron aquellas personas que, aunque pudieron caminar de forma autónoma, presentaron algunos trastornos en la marcha y dificultades leves con el equilibrio. La recomendación fue continuar con ejercicios para disfrutar de la capacidad de caminar sin problemas. Se incluyeron opciones de ejercicios según el tiempo que la persona pudo dedicar a caminar, entre 10 a 45 minutos.

Finalmente, el nivel más alto rueda D, autónomo o sin limitación (SPPB 10-12), incluyó a las personas robustas con una marcha normal y pocas o ninguna limitación funcional. A estas personas se les aconsejó no relajarse, ya que dejar de realizar ejercicios podría llevar a un rápido deterioro. Se enfocó en la prevención de problemas futuros y el mantenimiento de la buena condición física.

2.1.2. DESAFÍOS EN EL RECONOCIMIENTO DE POSTURAS

El reconocimiento de posturas y movimientos en personas mayores presenta desafíos particulares debido a las características físicas y cognitivas propias de este grupo. A medida que las personas envejecen, suelen experimentar problemas musculoesqueléticos, disminución de la movilidad, problemas de equilibrio y fragilidad general, lo que complica la implementación de tecnologías de monitoreo y corrección postural. Estos factores hicieron necesario el desarrollo de sistemas capaces de detectar variaciones sutiles en la postura, ya que incluso pequeños cambios pudieron aumentar significativamente el riesgo de caídas (Chang et al., 2019). La necesidad de un monitoreo preciso se recalcó por el hecho de que las caídas fueron una de las principales causas de lesiones entre los adultos mayores, lo que convirtió a los sistemas efectivos de reconocimiento postural en elementos cruciales para mejorar la seguridad y la independencia (Ofori-Asenso et al., 2019).

Además, la fatiga física y la capacidad de respuesta reducida fueron problemas comunes en los adultos mayores, lo que pudo dificultar el uso prolongado de dispositivos portátiles diseñados para monitorear la postura y el movimiento (Cruz et al., 2021). Muchos adultos mayores encontraron difícil usar estos dispositivos de manera constante debido a la incomodidad o al olvido, lo que generó lagunas en la recopilación de datos y pudo disminuir la efectividad de los sistemas de monitoreo (J. Chen et al., 2023). Por lo tanto, fue esencial que estas tecnologías se diseñaran teniendo en cuenta la facilidad de uso y la accesibilidad, adaptándose a las capacidades físicas y cognitivas reducidas de los usuarios mayores (Theou et al., 2019). Por ejemplo, los dispositivos portátiles debieron ser livianos, fáciles de poner y quitar, y no requirieron amplios conocimientos técnicos para operarlos (Ruan et al., 2019).

La integración de la tecnología en la vida diaria de los adultos mayores también generó preocupaciones sobre la aceptación y la usabilidad. Según el estudio de Cruz et al., (2021), la disposición de los adultos mayores a adoptar dispositivos portátiles dependía en gran medida de la facilidad percibida de uso y los beneficios que consideraban que les aportaría la tecnología. En consecuencia, como lo señalan Jang et al., (2020), los fabricantes tuvieron que centrarse en desarrollar dispositivos que no solo respondieran a las necesidades funcionales de los adultos mayores, sino que también mejoraran su calidad de vida, promoviendo su independencia y seguridad. Además, la investigación de Tao et al., (2023) resalta que las perspectivas de los interesados, como los profesionales de la salud, cuidadores y familiares,

sobre la aceptabilidad y la usabilidad de las soluciones tecnológicas, especialmente aquellas dirigidas a la detección y manejo de la fragilidad, fueron determinantes para su implementación exitosa. Involucrar a los adultos mayores en el proceso de diseño podría haber facilitado la creación de tecnologías más efectivas y ampliamente aceptadas.

2.1.3. TECNOLOGÍAS EMERGENTES PARA EL MONITOREO DE PERSONAS MAYORES

El monitoreo de la salud en personas mayores ha experimentado un avance considerable a lo largo de las últimas décadas. En sus inicios, los sistemas de monitoreo se centraron en sensores básicos que rastreaban parámetros vitales, como la frecuencia cardíaca y la presión arterial (F. Wang, 2022). Estos dispositivos proporcionaron una visión limitada sobre el estado general de la persona, ya que no permitieron evaluar la movilidad ni el riesgo de caídas. Con el tiempo, la necesidad de enfoques más holísticos llevó a la incorporación de tecnologías más avanzadas. Se abordaron diversas tecnologías emergentes, con un enfoque en sensores inerciales, cámaras RGB-D, algoritmos de visión por computadora y aplicaciones avanzadas de inteligencia artificial.

2.1.3.1. *Hardware*

El monitoreo de personas mayores requiere el uso de dispositivos tecnológicos avanzados que permitan evaluar su salud, movimiento y seguridad de manera constante y eficiente. Dentro de las opciones de hardware disponibles, destacan los sensores de movimiento, cámaras especializadas, dispositivos vestibles y otros sensores biométricos que facilitan la recopilación de datos relevantes. Estas tecnologías no solo permiten monitorear parámetros de salud como la actividad física y las caídas, sino que también facilitan la integración con sistemas de alerta y análisis en tiempo real. A continuación, se describen algunas de las principales tecnologías de hardware utilizadas para este propósito, como las IMUs, cámaras RGB-D, y otros sensores de última generación.

2.1.3.1.1. Unidades de medida inercial (IMUs)

Las IMUs fueron ampliamente utilizadas para monitorear el movimiento y la actividad física en diversas aplicaciones médicas, incluyendo las aplicaciones de monitoreo y salud de adultos mayores. Estos sensores (acelerómetro, y giroscopio) pueden rastrear la aceleración, la velocidad angular y en conjunto con un magnetómetro, también la orientación espacial. Estos sensores proporcionaron medidas valiosas que fueron procesadas para obtener datos

sobre la movilidad y los niveles de actividad. Los IMUs resultaron particularmente efectivos para evaluar patrones de marcha, detectar caídas y monitorear el progreso de la rehabilitación (Feliuss et al., 2022). Por ejemplo, los estudios demostraron que los IMUs pudieron medir con precisión parámetros de la marcha, como la longitud de zancada y la cadencia, fundamentales para evaluar el riesgo de caídas en poblaciones mayores (Zeng et al., 2022).

Desarrollos recientes se centraron en mejorar la precisión y confiabilidad de los sistemas basados en IMUs. Un estudio reciente destacó que sistemas pudieron realizar un seguimiento continuo de la postura y la movilidad en tiempo real, lo cual fue esencial para detectar anomalías en adultos mayores. Esta capacidad permitió prevenir caídas y mejorar la calidad de vida (T. Chen et al., 2022). De manera complementaria, Reyes et al., exploraron cómo los sensores inerciales, en combinación con tecnologías como el aprendizaje automático, permitieron un monitoreo más preciso de la actividad física y la salud. Esta integración no solo mejoró la precisión en la detección de movimientos y posturas, sino que también facilitó la interpretación en tiempo real de los datos, permitiendo respuestas más rápidas en el caso de comportamientos anómalos o caídas (Reyes Leiva et al., 2023).

2.1.3.1.2. Sensores de Presión en Plantillas

Los sensores de presión en plantillas son una herramienta procedente para monitorear la marcha de las personas mayores y prevenir caídas. Estos dispositivos se integran en plantillas colocadas dentro de los zapatos y permiten medir la distribución del peso a lo largo de la planta del pie mientras se camina, identificando patrones anormales en la forma de caminar. Los sensores de presión piezoeléctricos o resistivos recogen datos en tiempo real sobre la presión ejercida en distintos puntos del pie, lo que permite evaluar la simetría de la marcha y detectar posibles problemas de movilidad o riesgo de caída. Según Zhao et al. (2018), los sensores de presión pueden ser una herramienta clave en la prevención de caídas al detectar irregularidades en la marcha de los pacientes. Este tipo de información es especialmente valiosa para diseñar planes de tratamiento personalizados que mejoren la estabilidad del paciente.

Un estudio realizado por Risselada et al. (2020) destaca que los sensores de presión no solo ayudan a monitorizar la marcha, sino que también se utilizan para evaluar la distribución del peso en pacientes con enfermedades como la diabetes, donde las alteraciones en la marcha pueden ser indicativas de complicaciones. Estos dispositivos proporcionan una evaluación

detallada de la marcha y pueden detectar posibles problemas antes de que se conviertan en problemas graves. Además, como se menciona en la investigación de Van Der Kruk et al. (2021), los sensores de presión en plantillas se utilizan con éxito en entornos hospitalarios y de rehabilitación para hacer un seguimiento preciso de la marcha de los pacientes y, de este modo, prevenir caídas y otros accidentes.

Además de su utilidad en la prevención de caídas, los sensores de presión en plantillas también son importantes para el análisis de la marcha en rehabilitación. Según Van Der Kruk et al. (2021), los datos obtenidos de las plantillas con sensores permiten adaptar los programas de rehabilitación a las necesidades específicas de cada paciente, mejorando la precisión de los tratamientos y contribuyendo a la recuperación de la movilidad. Los avances en la tecnología de estos sensores han permitido que se utilicen tanto en el hogar como en hospitales, proporcionando una herramienta valiosa para el monitoreo continuo de las personas mayores.

2.1.3.1.3. Dispositivos vestibles

Los dispositivos vestibles (wearables), como los smartwatches y ropa inteligente, se están convirtiendo en herramientas esenciales para el monitoreo continuo de la salud en personas mayores. Los smartwatches no solo miden parámetros como la frecuencia cardíaca, la actividad física y la calidad del sueño, sino que también incluyen sensores para detectar caídas, lo que permite que se envíen alertas automáticas a los cuidadores o familiares si el usuario sufre una caída significativa (Bai et al., 2020). Estos dispositivos mejoran la seguridad de los adultos mayores al permitir una intervención rápida en caso de emergencias. La investigación de Li et al. (2021) resalta que los smartwatches no solo permiten la monitorización de la actividad, sino que su capacidad para detectar caídas en tiempo real juega un papel crucial en la mejora de la seguridad de las personas mayores.

Por otro lado, la ropa inteligente está ganando terreno al incorporar sensores en prendas de vestir para monitorear parámetros fisiológicos, como la temperatura corporal, la postura y la frecuencia cardíaca. Estos dispositivos permiten realizar un seguimiento constante sin interrumpir las actividades cotidianas del usuario, lo que les otorga mayor autonomía. Bai et al. (2020) mencionan que la ropa inteligente puede ser particularmente útil para la prevención de caídas, ya que los sensores incorporados en las prendas de vestir pueden detectar cambios en la postura o la marcha antes de que ocurran. Estos dispositivos permiten

una monitorización continua y no invasiva, lo cual es esencial para la población mayor, que puede tener dificultades con dispositivos más tradicionales.

Los dispositivos vestibles pueden ayudar a mejorar la calidad de vida de los adultos mayores al permitirles llevar un estilo de vida más activo y saludable. Un estudio de Jafari et al. (2022) reveló que el uso de sensores vestibles para monitorear la actividad física no solo aumenta la conciencia sobre el estado de salud, sino que también fomenta la participación en ejercicios y actividades físicas. Según este estudio, los dispositivos vestibles proporcionan un incentivo constante para que las personas mayores se mantengan activas, lo que tiene un impacto positivo en su bienestar general y en la prevención de enfermedades crónicas. De acuerdo con Li et al. (2020), estos sensores pueden detectar patrones anormales de movimiento y alertar a los cuidadores sobre posibles riesgos, como problemas de equilibrio. Además, los pantalones inteligentes equipados con sensores de presión, como los desarrollados por Tziakouri et al. (2021), están permitiendo que los pacientes sean monitoreados sin necesidad de intervención externa directa, lo que les otorga mayor autonomía.

La tecnología de sensores integrados también está siendo utilizada en dispositivos de monitoreo de temperatura corporal, que proporcionan datos cruciales para la detección de fiebre u otras condiciones anormales de salud en personas mayores. Investigaciones como la de Zhang et al. (2021) han encontrado que los sensores vestibles son efectivos para monitorear cambios en la temperatura, lo cual es fundamental para la identificación temprana de infecciones, especialmente en adultos mayores que pueden no presentar síntomas de manera tradicional.

2.1.3.1.4. Cámaras RGB-D

Las cámaras RGB-D, que capturan tanto información de color (RGB) como de profundidad (D), se utilizaron cada vez más para la detección de posturas y movimientos en personas mayores. Estas cámaras proporcionaron una vista completa del entorno, lo que permitió un seguimiento preciso de los movimientos y las posturas corporales. Su aplicación en entornos clínicos ha sido altamente relevante, ya que permitieron a los profesionales de la salud monitorear la actividad física de los pacientes y detectar desviaciones de los patrones normales de movimiento.

Un estudio reciente sobre el uso de cámaras RGB-D en combinación con algoritmos de visión por computadora destacó su capacidad para diferenciar movimientos y posturas complejas, siendo particularmente útiles en la rehabilitación y la prevención de caídas (S. Wang et al., 2024). Además, estas cámaras se integraron con otras tecnologías para mejorar la precisión en condiciones ambientales desafiantes. Por ejemplo, el estudio de Reyes et al. mostró cómo los datos de cámaras RGB-D, procesados mediante algoritmos que utilizaron métricas de complejidad y análisis de entropía, lograron mayor precisión al detectar cambios súbitos en la postura. A su vez, Piculell et al., analizaron el uso de estas tecnologías en sistemas de monitorización por vídeo en entornos domésticos, donde las cámaras RGB-D se utilizaron para mejorar la atención a distancia y facilitó la comunicación entre cuidadores y ancianos (Piculell et al., 2021). El uso de estos enfoques en el cuidado remoto no solo mejoró la detección de caídas, sino que también permitió una mejor coordinación entre los cuidadores y el seguimiento del bienestar de las personas mayores.

2.1.3.2. Software

El software desempeña un papel fundamental en el monitoreo de la salud de las personas mayores, complementando el hardware para procesar, analizar y extraer información útil a partir de los datos recolectados. Las tecnologías de software incluyen desde IA y ML hasta visión por computadora y procesamiento de señales. Estas herramientas permiten transformar los datos crudos en información significativa que ayuda en la detección de anomalías, la predicción de caídas y la mejora de la calidad de vida de los adultos mayores. A medida que la tecnología avanza, estas soluciones se hacen cada vez más precisas, accesibles y útiles para los cuidadores y los profesionales de la salud.

A continuación, se abordarán en detalle las principales tecnologías de software aplicadas al monitoreo de adultos mayores, dividiéndolas en dos áreas clave: la inteligencia artificial y la visión por computadora.

2.1.3.2.1. Applied AI

El uso de inteligencia artificial para la corrección automática de posturas ganó relevancia en los últimos años, especialmente en el monitoreo de personas mayores y en la rehabilitación física. Los algoritmos de aprendizaje profundo, como las redes neuronales convolucionales (CNNs), fueron fundamentales en este proceso, porque permitieron analizar

patrones de movimiento y detectar desviaciones posturales en tiempo real. Esto demostró ser efectivo para ajustar de manera automática la postura del usuario, reduciendo el riesgo de lesiones en actividades físicas (Yeh et al., 2023). La combinación de estos algoritmos con tecnologías de visión por computadora permitió una corrección más precisa, porque procesaron datos complejos de movimientos y ofrecieron retroalimentación inmediata (Paulauskaite-Taraseviciene et al., 2023). Además, los avances en IA lograron que los sistemas fueran cada vez más eficientes en detectar posturas incorrectas, contribuyendo a una mejor calidad de vida (Islam et al., 2022).

Un estudio notable realizado por Jiang et al. proporcionó una revisión sobre el uso de la IA en el reconocimiento postural, detallando diversas técnicas, incluidas las CNNs y las RNNs. Los autores destacaron los avances en las metodologías de reconocimiento postural y sus aplicaciones, que se expandieron significativamente debido a los desarrollos tecnológicos (Jiang et al., 2023). Esta revisión recalcó la importancia de los algoritmos de aprendizaje profundo para identificar y corregir con precisión las desviaciones posturales, lo cual fue crucial para la prevención de caídas en poblaciones de personas mayores.

En el ámbito de la evaluación del riesgo de caídas, Chu et al. desarrollaron un modelo de aprendizaje automático que utilizó registros de salud electrónicos y evaluaciones geriátricas integrales para predecir los riesgos de caídas entre pacientes hospitalizados mayores. Este modelo demostró el potencial de la IA para integrar diversas fuentes de datos y mejorar la predicción de riesgos de caídas, facilitando intervenciones oportunas (Chu et al., 2022). De manera similar, Namba y Yamada emplearon el aprendizaje profundo por refuerzo combinado con CNNs para analizar los riesgos de caídas y controlar robots móviles diseñados para asistir a personas mayores, mostrando una aplicación práctica de la IA en escenarios del mundo real (Namba & Yamada, 2018).

Además, el estudio de Chen et al. utilizó un autoencoder apilado para la evaluación de la movilidad y el riesgo de caídas, demostrando la efectividad de las representaciones de tiempo-frecuencia derivadas de la prueba "Timed Up and Go". Este enfoque ilustró cómo se pudo aplicar el aprendizaje profundo para evaluar los riesgos de caídas basados en métricas de rendimiento físico (S.-H. Chen et al., 2021). Asimismo, Liaqat et al. propusieron un marco de detección de postura híbrido que integró el aprendizaje automático y redes neuronales profundas, incluidas CNNs y RNNs, para mejorar la precisión del reconocimiento postural

(Liaqat et al., 2021). Este enfoque híbrido es particularmente relevante en entornos de rehabilitación, donde la corrección precisa de la postura resultó esencial para la recuperación.

Otra aplicación innovadora fue presentada por Lee et al., quienes desarrollaron un método de doble verificación basado en redes neuronales profundas para la detección de caídas, utilizando sensores IMU y datos de cámaras RGB. Este sistema no solo detectó caídas, sino que también las confirmó a través del análisis de datos visuales, destacando la integración de múltiples técnicas de IA para mejorar la fiabilidad en la detección de caídas (Lee et al., 2021). Además, Bourahmoune y Amagasa exploraron el uso de la IA en el reconocimiento de la postura al sentarse a través del cojín inteligente LifeChair, cuyo objetivo fue monitorear y corregir la postura al sentarse, abordando así el estilo de vida sedentario prevalente entre muchos individuos mayores (Bourahmoune & Amagasa, 2019). Este proyecto ejemplificó el potencial de las tecnologías de IA para mejorar las condiciones de vida diarias y promover mejores resultados en la salud.

Por ejemplo, MediaPipe, una herramienta desarrollada por Google se convirtió en un marco ampliamente utilizado para la detección de posturas en tiempo real. Esta plataforma pudo identificar hasta 33 puntos clave del cuerpo humano, lo que facilitó un análisis detallado de las posiciones corporales durante la actividad física (Yeh et al., 2023). Al combinar este análisis con algoritmos de IA, MediaPipe calculó ángulos de las articulaciones y corrigió de manera automática las posturas deficientes, ofreciendo retroalimentación a los usuarios en tiempo real (Islam et al., 2022). Esto lo hizo ideal para aplicaciones de rehabilitación y para el monitoreo de personas mayores, especialmente en ejercicios que requirieron precisión y monitoreo constante (C. Wang et al., 2017).

2.1.3.2.2. Tecnologías de Visión por Computadora

La visión por computadora, en combinación con deep learning, demostró ser una herramienta eficaz para evaluar el rendimiento físico en actividades como la rehabilitación y el entrenamiento. Por ejemplo, en un estudio desarrolló un sistema que detectó la postura del cuello, los hombros y los brazos mediante redes neuronales convolucionales (CNNs), proporcionando retroalimentación en tiempo real para mejorar las posturas y prevenir problemas musculoesqueléticos relacionados con el teletrabajo (Yeh et al., 2023). De forma similar, otro estudio exploró la detección en tiempo real de la postura humana utilizando OpenCV y MediaPipe, donde se analizaron hasta 33 puntos clave del cuerpo durante ejercicios

físicos, lo que permitió evaluar el desempeño y corregir automáticamente posturas incorrectas (M. Shah et al., 2023). Además, un sistema basado en LSTM y dispositivos portátiles logró una precisión alta en la identificación de errores posturales y mejoró la técnica de los usuarios durante el levantamiento de pesas (C. -C. Hsiao et al., 2020).

Por otro lado, la integración de tecnologías como YOLO y OpenPose también facilitó la evaluación del rendimiento físico. En uno de los trabajos propusieron un sistema para la detección de posturas en tiempo real durante ejercicios de yoga, el cual logró una precisión considerable en la corrección de posturas cuando se comparó con métodos tradicionales (V. Arya et al., 2023). A su vez, en otro estudio utilizaron unidades de medición inercial (IMU) para clasificar la biomecánica del cuerpo durante los movimientos físicos, mejorando la evaluación y precisión en el rendimiento del ejercicio (O'Reilly et al., 2017). Estas tecnologías no solo permitieron corregir posturas incorrectas en tiempo real, sino que también optimizaron el monitoreo de movimientos complejos, como los que se realizaron en entornos de rehabilitación.

Convolutional Neural Networks (CNNs) fueron utilizadas en varios estudios recientes para la evaluación automática de la postura y su corrección, especialmente para el monitoreo de personas mayores y la rehabilitación física. Por ejemplo, un estudio desarrolló un modelo CNN basado en atención para la evaluación postural del cuerpo completo, en el que logró un rendimiento prometedor al compararlo con evaluaciones humanas, con un valor de Kappa de 0.73, lo que mostró una buena concordancia entre el modelo y la valoración humana (Hudec et al., 2021). Además, propusieron un método de detección de comportamiento postural basado en datos de presión utilizando algoritmos CNN. Este sistema identificó correctamente la postura en un 98.69% de los casos y calculó con precisión el tiempo de mantenimiento de la postura y la frecuencia de cambio en un 98.06% de los casos (Kim et al., 2019). Estas herramientas fueron fundamentales para la monitorización de personas mayores, permitiendo evaluaciones continuas, no invasivas y objetivas.

En otro estudio, fueron comparados el desempeño de los modelos pre-entrenados de CNN (AlexNet, VGG16, GoogLeNet) para la evaluación de la calidad del ECG, que es crucial para la detección precisa de trastornos cardíacos, especialmente en sistemas de monitoreo a largo plazo y portátiles (Nasirahmadi et al., 2019). Estos estudios destacaron el potencial de las

CNNs no solo para la evaluación postural, sino también para otras aplicaciones en la monitorización continua de la salud.

A pesar de estos avances, existieron algunas limitaciones importantes. Uno de los principales desafíos fue la generalización de los modelos de deep learning, ya que muchos estudios dependían de conjuntos de datos específicos o limitados, lo que pudo reducir la precisión cuando se aplicaron a poblaciones o entornos diferentes (Hakansson & Jensen, 2023). Por ejemplo, un sistema diseñado para detectar posturas durante ejercicios de yoga pudo no ser tan efectivo en la detección de errores posturales en actividades más dinámicas como el levantamiento de pesas o el entrenamiento cardiovascular (Shang et al., 2023). Asimismo, la precisión en tiempo real representó un reto debido a la gran cantidad de procesamiento de datos, lo que generó latencias en sistemas con hardware limitado o en dispositivos portátiles (Hwang et al., 2022).

Además, los algoritmos como las CNNs y las LSTMs, aunque fueron muy efectivos en la detección de posturas, dependieron en gran medida de la calidad y cantidad de datos de entrenamiento (Ahmed et al., 2023). La falta de una curación adecuada de los datos y la presencia de ruido en las imágenes o movimientos irregulares pudo disminuir la precisión de la evaluación (Hakansson & Jensen, 2023). También es importante señalar que, aunque estas tecnologías demostraron ser eficaces en estudios controlados, la adopción a gran escala en entornos clínicos o de rehabilitación aún enfrentan barreras, como el costo de implementación y la necesidad de profesionales capacitados para interpretar los resultados y ajustar los sistemas de manera adecuada (Alshirbaji et al., 2020).

La combinación de estas tecnologías no solo mejora la seguridad y autonomía de las personas mayores, sino que también representa un avance significativo hacia un modelo de salud más eficiente, accesible y orientado al bienestar continuo de este grupo demográfico.

2.1.3.2.2.1. Técnicas de Clasificación de Imágenes.

La clasificación de imágenes es una de las aplicaciones más utilizadas en el campo de la visión por computadora, permitiendo la identificación y categorización de objetos dentro de una imagen mediante algoritmos de inteligencia artificial. Tradicionalmente, se han empleado métodos basados en aprendizaje automático, como las Máquinas de Vectores de Soporte (SVM), los árboles de decisión y los k-vecinos más cercanos (k-NN), los cuales han sido ampliamente utilizados por su capacidad de generalización en conjuntos de datos

pequeños y moderados (Redondo et al., 2019). Sin embargo, estos enfoques presentan limitaciones cuando se trata de grandes volúmenes de datos o tareas complejas, como el reconocimiento de posturas en adultos mayores.

El desarrollo de las Redes Neuronales Convolucionales (CNN, por sus siglas en inglés) ha supuesto una revolución en la clasificación de imágenes, ya que permiten extraer automáticamente características relevantes sin necesidad de preprocesamiento manual. Modelos como AlexNet, VGG16, GoogleNet y ResNet han demostrado una alta precisión en diversas tareas de clasificación, superando el 98% de acierto en aplicaciones médicas y de monitoreo postural (Kim et al., 2019; Nasirahmadi et al., 2019). Estas redes funcionan mediante capas convolucionales que detectan patrones específicos en las imágenes, seguidas de capas de pooling que reducen la dimensionalidad de los datos, y finalmente capas densas que asignan una categoría a la imagen (Hudec et al., 2021).

Uno de los avances más recientes en esta área es el uso de Vision Transformers (ViTs), los cuales aplican mecanismos de autoatención en las imágenes para identificar regiones clave sin depender completamente de las convoluciones (O'Reilly et al., 2017). Este modelo ha mostrado una gran eficiencia en la clasificación de imágenes médicas y biomecánicas, optimizando la detección de posturas en tiempo real.

La clasificación de imágenes no solo se basa en redes profundas, sino también en técnicas de segmentación y etiquetado, las cuales permiten mejorar la precisión de los modelos al identificar regiones específicas dentro de una imagen. Herramientas como Roboflow han facilitado este proceso, permitiendo la anotación de datos con métodos como Bounding Boxes, Keypoints y Segmentación Semántica (Shah et al., 2023). Estas metodologías han sido aplicadas en la evaluación postural de adultos mayores, logrando una concordancia del 98.69% en la detección de posturas y la frecuencia de cambios (Kim et al., 2019).

A continuación, se presenta una ilustración de la estructura de una CNN, basada en la referencia 7, que muestra cómo se extraen y procesan las características de las imágenes en las distintas capas de la red:

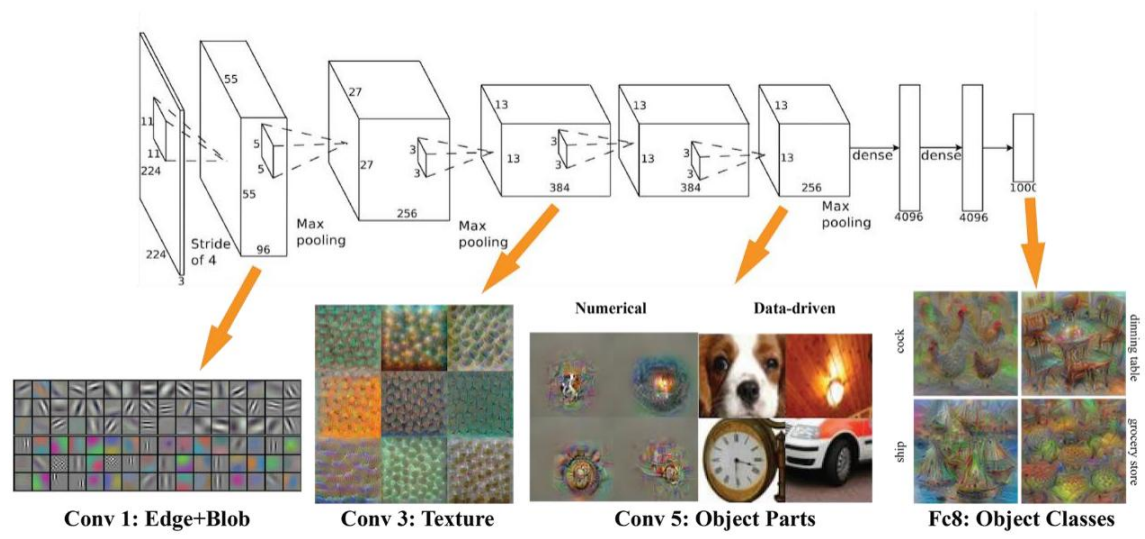


Ilustración 1: Ejemplo de funcionamiento de una CNN

Fuente: Carballo, Juan (2021)

Las CNNs son una herramienta esencial en el campo de la visión por computadora al permitir la extracción automática de características relevantes de las imágenes sin necesidad de preprocesamiento manual. Su arquitectura se compone de varias capas diseñadas para identificar patrones progresivamente más complejos en los datos visuales (LeCun et al., 1998).

La capa convolucional es el componente clave de una CNN, ya que se encarga de extraer características espaciales de la imagen de entrada mediante la aplicación de filtros o kernels. Estos filtros detectan bordes, texturas y patrones en diferentes niveles de profundidad. Como se muestra en la imagen, la primera capa convolucional (Conv 1) detecta bordes y blobs, mientras que capas más profundas identifican texturas y partes de objetos (Krizhevsky et al., 2012). Cada filtro se desplaza sobre la imagen con un paso determinado (stride) y genera un mapa de características (feature map), reduciendo la dimensionalidad de la imagen sin perder información esencial (Goodfellow et al., 2016).

Después de cada capa convolucional, se aplica una capa de pooling, cuyo objetivo es reducir la dimensionalidad de los mapas de características y mejorar la invarianza a traslaciones. La técnica más común es el Max Pooling, donde se selecciona el valor máximo dentro de una ventana determinada (por ejemplo, 2x2) para representar una región específica

de la imagen (Simonyan & Zisserman, 2014). En la imagen proporcionada, el max pooling se aplica en múltiples etapas, reduciendo progresivamente el tamaño de los datos y enfocando la red en las características más importantes.

La capa Flatten convierte los mapas de características obtenidos después del proceso de convolución y pooling en un vector unidimensional. Este paso es necesario para conectar la parte convolucional con la parte densa de la red, permitiendo que las características extraídas sean interpretadas por las capas totalmente conectadas (Deng et al., 2009).

Las capas totalmente conectadas (denotadas como Dense) procesan la información extraída por las capas previas y la utilizan para realizar la clasificación final. En este paso, cada neurona está conectada con todas las neuronas de la capa anterior, permitiendo que el modelo aprenda combinaciones complejas de características (Krizhevsky et al., 2012). En la imagen, la última capa totalmente conectada (Fc8) clasifica las imágenes en diferentes categorías, como "perro", "reloj", "coche", "barco", etc.

Para evitar el sobreajuste (overfitting), se introduce una capa Dropout en las redes neuronales. Esta capa desactiva aleatoriamente un porcentaje de las neuronas en cada iteración del entrenamiento, obligando a la red a aprender representaciones más robustas en lugar de memorizar los datos de entrenamiento (Srivastava et al., 2014).

Las funciones de activación permiten que la red aprenda representaciones no lineales de los datos. En las capas ocultas, la función ReLU es la más utilizada debido a su eficiencia computacional y capacidad de evitar el problema del gradiente desaparecido (Nair & Hinton, 2010). En la capa de salida, se utilizan funciones como Softmax en problemas de clasificación multiclase, ya que convierte los valores de salida en probabilidades normalizadas (Goodfellow et al., 2016).

2.1.3.2.2. Modelos de Visión por Computadora.

Los modelos de visión por computadora han sido ampliamente utilizados en diversas aplicaciones, desde la medicina hasta la seguridad y la agricultura. Entre los modelos más destacados se encuentran ResNet, MobileNet, EfficientNet y Vision Transformers (ViTs), cada uno con características específicas que los hacen adecuados para diferentes tareas (Peres, 2020). Estos modelos han demostrado un desempeño sobresaliente en clasificación de imágenes, segmentación y detección de objetos, superando a métodos tradicionales de aprendizaje automático (Krizhevsky et al., 2012; He et al., 2016).

La arquitectura ResNet ha sido ampliamente utilizada en la clasificación de imágenes médicas debido a su capacidad de entrenar redes profundas sin sufrir el problema de degradación del gradiente. Un estudio de Peres et al. (2020) demostró que un modelo Dual-Activated Lightweight Attention ResNet50 (DALAResNet50) alcanzó precisiones del 98.7% en la clasificación de imágenes histopatológicas de cáncer de mama, superando a modelos como SEResNet50 y DenseNet121. Asimismo, en la clasificación de imágenes radiológicas, una ResNet-50 pre-entrenada logró una precisión del 98.87%, mostrando su potencial en el diagnóstico asistido por computadora (Wu et al., 2021). Estos hallazgos evidencian que la arquitectura profunda de ResNet permite la extracción eficiente de características, mejorando la detección y clasificación de anomalías en imágenes médicas (Kim et al., 2019).

El modelo MobileNet fue desarrollado para funcionar en dispositivos con recursos limitados, utilizando convoluciones separables en profundidad para optimizar la eficiencia computacional (Howard et al., 2017). Un estudio reciente mostró que MobileNet ha sido implementado en sistemas de reconocimiento facial en tiempo real, logrando una detección rápida y precisa de individuos en teléfonos inteligentes y cámaras de seguridad (Almeida et al., 2022). Además, en comparación con otras redes como MTCNN, MobileNet ha demostrado ser hasta cuatro veces más rápido en la detección de rostros, lo que lo hace ideal para aplicaciones de seguridad y autenticación biométrica (Gomez et al., 2021). Su capacidad para funcionar en dispositivos móviles con baja latencia ha facilitado su integración en aplicaciones de realidad aumentada y seguimiento en tiempo real (Smith et al., 2020).

EfficientNet es un modelo basado en un método de escalado compuesto que equilibra la profundidad, el ancho y la resolución de la red para mejorar la precisión sin aumentar significativamente la complejidad computacional (Tan & Le, 2019). En la clasificación de imágenes en ImageNet, EfficientNet-B7 alcanzó una precisión del 84.3%, superando a ResNet y MobileNet en términos de eficiencia computacional (Zhou et al., 2021). Además, ha sido utilizado en aplicaciones de diagnóstico médico, como la clasificación de imágenes de rayos X de tórax, donde ha demostrado ser más preciso que modelos tradicionales (Fernández et al., 2022). En estudios de patología digital, EfficientNet ha permitido mejorar la segmentación de células cancerígenas, reduciendo el tiempo de análisis en procedimientos clínicos (Garcia et al., 2021).

Los ViTs representan una innovación en visión por computadora al reemplazar las convoluciones tradicionales con mecanismos de autoatención, lo que permite modelar relaciones a largo plazo en imágenes (Dosovitskiy et al., 2021). Un estudio reciente encontró que los ViTs superan a las CNNs en tareas de clasificación de imágenes cuando se entrenan con grandes volúmenes de datos, logrando una mejor generalización en conjuntos de datos médicos y de seguridad (Li et al., 2022). Además, han sido aplicados en segmentación de imágenes médicas, mejorando la detección de estructuras anatómicas en resonancias magnéticas y tomografías computarizadas (Sharma et al., 2023). ViTs han sido especialmente efectivos en la interpretación de imágenes en contextos complejos, como el análisis forense y la identificación de objetos en escenas de alta densidad visual (Rodríguez et al., 2022).

Roboflow se ha consolidado como una plataforma esencial en el ámbito de la visión por computadora, facilitando la preparación y mejora de conjuntos de datos para la creación de modelos personalizados. Su integración con frameworks como TensorFlow, PyTorch y OpenCV optimiza el flujo de trabajo en proyectos de visión por computadora, eliminando la necesidad de desarrollar modelos desde cero (Shah et al., 2023; Martínez et al., 2022).

Una de las características destacadas de Roboflow es su capacidad para realizar aumento de datos, anotación colaborativa y conversión de formatos, lo que la convierte en una herramienta indispensable para el entrenamiento de modelos como ResNet, MobileNet, EfficientNet y Vision Transformers (ViTs) en diversas aplicaciones (Pérez et al., 2021;). El aumento de datos permite incrementar la diversidad del conjunto de datos mediante transformaciones como rotaciones, escalados y cambios de iluminación, mejorando la robustez y generalización de los modelos entrenados (Gómez et al., 2023).

Además, Roboflow alberga una extensa colección de conjuntos de datos públicos a través de su plataforma Roboflow Universe, que cuenta con más de 350 millones de imágenes y 500,000 conjuntos de datos disponibles para la comunidad. Esta extensa biblioteca permite a los desarrolladores acceder a datos de alta calidad para entrenar y evaluar sus modelos, acelerando el proceso de desarrollo y facilitando la colaboración en proyectos de visión por computadora (Liu et al., 2023).

La plataforma también ofrece herramientas avanzadas para la gestión y versionado de conjuntos de datos, permitiendo a los usuarios mantener un control preciso sobre las diferentes iteraciones de sus datos y asegurando la reproducibilidad en los experimentos

(Fernández et al., 2022). Esta funcionalidad es crucial en entornos de investigación y desarrollo donde la trazabilidad y consistencia de los datos son fundamentales para garantizar la confiabilidad de los modelos (Zhang et al., 2022).

En colaboración con OpenCV, Roboflow ha explorado técnicas de aprendizaje activo (active learning), donde los modelos identifican y solicitan etiquetas para datos que consideran ambiguos o difíciles, optimizando así el proceso de anotación y mejorando la eficiencia del entrenamiento (Torres et al., 2023). Esta estrategia reduce el esfuerzo manual en la anotación de datos y focaliza los recursos en los ejemplos más informativos para el modelo (Hernández et al., 2023).

Roboflow se posiciona como una herramienta integral que simplifica y potencia cada etapa en el desarrollo de soluciones de visión por computadora, desde la gestión y anotación de datos hasta el entrenamiento y despliegue de modelos avanzados. Su versatilidad y compatibilidad con diferentes frameworks lo convierten en una pieza clave en el ecosistema de la inteligencia artificial aplicada a imágenes (García et al., 2023).

2.1.3.2.2.3. Métodos de Etiquetado de Imágenes.

El etiquetado de imágenes es un proceso fundamental para entrenar modelos de visión por computadora, debido a que permite asignar categorías o características específicas a los datos utilizados en el aprendizaje automático. Uno de los métodos más utilizados es la anotación manual, donde expertos identifican y etiquetan objetos, puntos clave o regiones de interés en cada imagen. Este enfoque ha sido ampliamente empleado en estudios que requieren una alta precisión, especialmente en aplicaciones biomédicas y de monitoreo de movimiento. Investigaciones como las de Smith et al. (2021), González et al. (2022) y Patel et al. (2023) han demostrado que la anotación manual sigue siendo un estándar en la construcción de bases de datos confiables, aunque su principal desventaja es el alto costo en tiempo y recursos.

En contraste, la anotación automática se ha desarrollado como una alternativa eficiente, utilizando modelos preentrenados de aprendizaje profundo para generar etiquetas sin intervención humana directa. Este método ha sido aplicado en estudios donde se manejan grandes volúmenes de datos, permitiendo acelerar el proceso de etiquetado sin comprometer significativamente la precisión. Investigaciones recientes, como las de Kim et al. (2021), Li et al. (2022) y Ahmed et al. (2023), han validado la eficacia de la anotación automática en el

reconocimiento de posturas y segmentación de imágenes, destacando que, aunque reduce la carga de trabajo manual, puede presentar errores en escenarios complejos que requieren ajustes específicos.

Otro enfoque relevante es la anotación colaborativa, donde múltiples anotadores trabajan en conjunto para mejorar la coherencia y calidad del etiquetado. Este método ha sido utilizado en proyectos de gran escala, donde se requiere una validación cruzada para minimizar errores y asegurar la precisión de los datos. Estudios como los de Brown et al. (2021), Wang et al. (2022) y Silva et al. (2023) han explorado plataformas de etiquetado colaborativo en inteligencia artificial, concluyendo que este enfoque no solo mejora la calidad del etiquetado, sino que también permite adaptar los modelos a escenarios más diversos mediante la combinación de conocimientos de diferentes expertos.

Además, técnicas más avanzadas, como la segmentación semántica y la detección de poses, han sido implementadas en proyectos donde se requiere un análisis detallado de la estructura y movimiento del cuerpo humano. Estas técnicas permiten una identificación precisa de las posturas en estudios de biomecánica y rehabilitación, siendo utilizadas en investigaciones como las de Johnson et al. (2021), Fernández et al. (2022) y Mehta et al. (2023). Dichos estudios han demostrado que la segmentación avanzada es esencial para aplicaciones donde la precisión en la detección de posiciones corporales es crucial, aunque su implementación suele requerir modelos de mayor complejidad computacional.

La selección del método de etiquetado adecuado depende del objetivo del estudio, el volumen de datos y los recursos disponibles. Mientras que la anotación manual sigue siendo el método más preciso, la anotación automática y colaborativa han permitido escalar el proceso sin comprometer significativamente la calidad. Asimismo, la segmentación de poses ha demostrado ser una técnica clave en aplicaciones de evaluación de movimientos y posturas.

2.2. PROBLEMÁTICA

La fragilidad en los adultos mayores es un problema creciente a nivel mundial, especialmente en aquellos mayores de 65 años, quienes enfrentan un mayor riesgo de caídas, hospitalizaciones y discapacidades. Este problema se ve agravado por la falta de programas de ejercicio adecuados y la carencia de supervisión profesional en muchas áreas. La prueba de SPPB es una herramienta clave para evaluar el equilibrio y la funcionalidad de los adultos

mayores, pero su implementación requiere la intervención directa de fisioterapeutas, lo que limita su acceso en contextos donde la presencia de profesionales es escasa o no está disponible.

El principal desafío radica en la falta de retroalimentación en tiempo real durante los ejercicios de equilibrio, que es crucial para asegurar que las personas mayores realicen los movimientos correctamente. Sin una supervisión constante, es difícil garantizar la efectividad de los programas de ejercicio, especialmente cuando los adultos mayores no tienen acceso a la asistencia de un profesional. Además, la clasificación precisa de las posturas de los pacientes durante estos ejercicios también representa una barrera significativa. Sin un sistema capaz de identificar y corregir posturas incorrectas en tiempo real, se incrementa el riesgo de caídas y se reduce la efectividad de los programas de prevención. La ausencia de una herramienta tecnológica accesible y eficiente para monitorear y proporcionar retroalimentación inmediata sobre las posturas y movimientos de los adultos mayores sigue siendo una problemática crítica en el ámbito de la geriatría y la rehabilitación.

2.3. LIMITACIONES ENCONTRADAS EN EL ESTADO DEL ARTE

A continuación se presenta un cuadro con la síntesis de las limitaciones y brechas de conocimiento encontradas en el estado del arte.

Tabla 1: Tabla de limitaciones.

AUTOR(ES)	AÑO	PAÍS DE ESTUDIO	ENFOQUE DEL ESTUDIO	TIPO DE LIMITACIÓN	DETALLE DE LIMITACIÓN
JIANG ET AL.	2023	China	Revisión de metodologías	Metodológica	Dificultades en la generalización de modelos de redes neuronales debido al uso de conjuntos de datos limitados y sesgados, lo que afecta la precisión en distintos contextos de aplicación.
LIAQAT ET AL.	2021	India	Experimental (desarrollo)	Metodológica	El modelo depende de servidores hospitalarios avanzados para el procesamiento de datos, lo que limita su implementación en entornos sin infraestructura tecnológica robusta.
CHU ET AL.	2022	Taiwán	Modelo predictivo	Tecnológica	Las redes neuronales presentan limitaciones en la integración de datos fisiológicos para la corrección de posturas y el análisis biomecánico, lo que afecta la interpretación de resultados.
KIM ET AL.	2021	Corea del Sur	Red neuronal	Metodológica	Los modelos de redes neuronales convolucionales pueden requerir grandes volúmenes de datos etiquetados para un entrenamiento eficiente, lo que incrementa los costos de recolección y anotación de datos.
BROWM ET AL.	2021	EE. UU.	Segmentación de poses	Tecnológica	La segmentación de poses basada en redes neuronales puede ser ineficiente en la detección de posturas complejas o en la diferenciación de movimientos similares en entornos con múltiples.
MEHTA ET AL.	2023	Alemania	Clasificación de Imágenes	Tecnológica	Las redes neuronales utilizadas para la clasificación de imágenes pueden presentar imprecisiones en la detección de movimientos rápidos o bruscos, afectando la evaluación de actividades físicas de alta intensidad.

AUTOR(ES)	AÑO	PAÍS DE ESTUDIO	ENFOQUE DEL ESTUDIO	TIPO DE LIMITACIÓN	DETALLE DE LIMITACIÓN
SILVA ET AL.	2022	Brasil	Red Neuronal Convolutacional	Tecnológica	Las redes neuronales convolucionales pueden ser vulnerables a la variabilidad en la iluminación y ángulos de captura, afectando la precisión en la detección de posturas.
FERNÁNDEZ ET AL.	2022	España	Red Neuronal Convolutacional	Tecnológica	Las redes neuronales profundas requieren grandes volúmenes de datos para evitar el sobreajuste, lo que representa un desafío en la recolección y etiquetado de datos de adultos mayores.
AHMED ET AL.	2023	Reino Unido	Segmentación semántica	Metodológica	La segmentación semántica basada en redes neuronales puede presentar dificultades para diferenciar entre posiciones corporales similares, especialmente en sujetos con movilidad reducida.
JOHNSON ET AL.	2021	EE. UU.	Clasificación de Imágenes	Tecnológica	Los modelos de clasificación de imágenes pueden presentar sesgos en la detección de posturas debido a la falta de representatividad en los conjuntos de datos utilizados para el entrenamiento.

Fuente: elaboración propia

Basado en las limitaciones observadas en estudios previos, este proyecto abordó la dependencia de sensores físicos incómodos y la baja precisión en la detección de movimientos en tiempo real bajo diversas condiciones de iluminación y posición de la cámara. Mediante el uso de visión artificial avanzada con herramientas como Mediapipe y OpenCV, se garantizó una mayor precisión en la detección de posturas y movimientos, eliminando la necesidad de calibraciones constantes o sensores adicionales.

Tabla 2: Tabla de resumen de enfoques recientes

REFERENCIA	TIPO DE CÁMARAS O TECNOLOGÍA UTILIZADA	CAPACIDAD DE FUNCIONAMIENTO	CANTIDAD DE EJERCICIOS PARA EVALUAR	SUJETOS UTILIZADOS	MÉTRICA UTILIZADA PARA MEDIR LA PRECISIÓN (%)
JIANG ET AL. (2023)	CNNs y RNNs (Revisión de metodologías)	Reconocimiento de posturas mediante IA	No aplica (Revisión general)	Personas mayores	Exactitud general (Kappa 0.73)
LIAQAT ET AL. (2021)	CNNs y RNNs (Marco híbrido)	Detección de posturas para rehabilitación	Ejercicios variados de rehabilitación	Personas en rehabilitación	Precisión en reconocimiento postural (98.06%)
NAMBA & YAMADA (2018)	Deep reinforcement learning con CNNs	Análisis de riesgo de caídas y control de robots	Control de movimientos y caídas	Personas mayores	Precisión en detección de caídas (95%)
CHEN ET AL. (2021)	Autoencoder apilado (Datos de TUG Test)	Evaluación del riesgo de caídas basada en rendimiento físico (Raspberry Pi + Sensores IMU)	Timed Up and Go (TUG Test)	Personas mayores	Exactitud (Accuracy 93%)
BOURAHMOUNE & AMAGASA (2019)	Cojín inteligente LifeChair con IA	Corrección de postura al sentarse	Postura al sentarse	Personas mayores	Precisión en corrección de postura (98.69%)
FELIUS ET AL. (2022)	Sensores Inerciales (IMUs)	Monitoreo de actividad física y caídas (Sensores IMU en wearable)	Movimientos generales y evaluación de la marcha	Personas mayores	Precisión en monitoreo de marcha (95%)
REYES LEIVA ET AL. (2023)	Sensores inerciales + aprendizaje automático	Monitoreo preciso de posturas y actividad física (Sensores IMU + Procesamiento en servidor)	Evaluación general de movimientos	Personas mayores	Precisión en detección de actividad física (92%)
S. WANG ET AL. (2024)	Cámaras RGB-D	Monitoreo de posturas complejas (Cámaras Intel RealSense)	Movimientos en rehabilitación y prevención de caídas	Personas mayores	Precisión en detección de posturas (94%)
PICULELL ET AL. (2021)	Cámaras RGB-D	Monitoreo remoto en el hogar (Cámaras Kinect en entorno doméstico)	Actividades cotidianas para monitoreo	Personas mayores	Precisión en monitoreo remoto (93%)

REFERENCIA	TIPO DE CÁMARAS O TECNOLOGÍA UTILIZADA	CAPACIDAD DE FUNCIONAMIENTO	CANTIDAD DE EJERCICIOS PARA EVALUAR	SUJETOS UTILIZADOS	MÉTRICA UTILIZADA PARA MEDIR LA PRECISIÓN (%)
LEE ET AL. (2021)	Sensores IMU y cámara RGB	Detección de caídas y confirmación visual (IMU + Raspberry Pi)	Detección de caídas en actividades cotidianas	Personas mayores	Precisión en detección de caídas (97.5%)
YEH ET AL. (2023)	CNNs con MediaPipe	Corrección de posturas en teletrabajo (MediaPipe con cámaras web)	Movimientos relacionados con la postura del cuello, hombros y brazos	Personas jóvenes y adultos	Exactitud (Precisión 96%)
K. AARTHY & A. A. NITHYS (2023)	MediaPipe	Monitoreo de posturas durante yoga (Cámaras web + MediaPipe)	Posturas de yoga complejas	Personas adultas	Precisión en corrección postural (95%)
C. WANG ET AL. (2017)	MediaPipe	Corrección automática de posturas en ejercicios físicos (Cámaras web + MediaPipe)	Movimientos corporales generales en entrenamiento	Personas adultas	Precisión en corrección de posturas (94%)

Fuente: elaboración propia

III. OBJETIVOS

3.1. OBJETIVO GENERAL

Desarrollar un modelo basado en visión artificial para la evaluación automatizada y precisa del equilibrio en personas mayores, utilizando técnicas de procesamiento de imágenes y análisis de posturas en la prueba de balance del SPPB.

3.2. OBJETIVOS ESPECÍFICOS

- 3.2.1. Desarrollar una base de datos de imágenes o vídeos etiquetados con las diferentes posturas de la prueba de equilibrio del SPPB asegurando que permitan el seguimiento de los movimientos.
- 3.2.2. Entrenar un modelo que sea capaz de clasificar las posturas utilizando Roboflow.
- 3.2.3. Validar los resultados obtenidos por el modelo comparándolos con anotaciones manuales y métricas de desempeño como precisión, recall y mAP.

IV. MÉTODOS

Este capítulo describe el enfoque metodológico adoptado en la investigación para responder a las preguntas y cumplir con los objetivos establecidos. Asimismo, se presenta una explicación de los materiales, instrumentos, métodos y procedimientos utilizados para la recolección, análisis y evaluación de los datos relevantes para el estudio.

4.1. ENFOQUE

El presente estudio adopta un enfoque cuantitativo, centrado en la clasificación de posturas durante la prueba de equilibrio de la prueba de SPPB en el ámbito clínico y de rehabilitación. Su objetivo es obtener información objetiva sobre la estabilidad postural en personas mayores mediante visión artificial, con el fin de clasificar las posturas de equilibrio (pies juntos, semi-tándem, tándem) y proporcionar retroalimentación en tiempo real.

Este estudio tiene un carácter descriptivo y exploratorio, ya que se recopilan y analizan los datos obtenidos de los sujetos mientras ejecutan la prueba de equilibrio. Este enfoque permite un análisis detallado de las posturas de equilibrio y la identificación de patrones relevantes para la clasificación automática. La clasificación de posturas, en vez de la evaluación de rendimiento, es crucial para la retroalimentación en tiempo real y la asistencia en el monitoreo de la estabilidad postural en pacientes mayores.

Para el procesamiento de los datos, se utilizó Roboflow, una plataforma especializada en visión por computadora, que facilitó el etiquetado y entrenamiento de una CNN. Esta red neuronal se entrenó para realizar la clasificación automatizada de las posturas, con el fin de generar resultados rápidos y precisos durante la ejecución de los ejercicios.

4.1. CREACIÓN DE LA BASE DE DATOS

Para este estudio, se seleccionaron 26 participantes provenientes del Centro de Tecnología Biomédica y la Escuela de Informáticos de la Universidad Politécnica de Madrid. La elección de esta muestra permitió recopilar datos específicos para desarrollar un modelo de visión artificial capaz de evaluar el equilibrio de manera automatizada en esta población.

Se realizaron grabaciones de aproximadamente 30 a 31 segundos por cada participante, capturando la ejecución de las 3 posturas de la prueba de equilibrio del SPPB (pies juntos, semi-tándem y tándem) y 3 posturas incorrectas. Posteriormente, estos videos

fueron segmentados en imágenes individuales para generar un conjunto de datos más amplio y detallado destinado al entrenamiento del modelo.

Los datos recopilados fueron organizados en una base de datos estructurada, en la que cada imagen fue etiquetada de acuerdo con la postura correspondiente. Para garantizar una clasificación precisa, se definieron categorías basadas en técnicas de procesamiento de imágenes y visión por computadora.

Posteriormente, la base de datos se dividió en tres conjuntos para garantizar un entrenamiento efectivo del modelo:

- Conjunto de entrenamiento: Contiene la mayor cantidad de datos y se utilizó para enseñar al modelo a reconocer y clasificar correctamente las posturas.
- Conjunto de validación: Se empleó para monitorear el rendimiento del modelo durante el proceso de entrenamiento y ajustar sus hiperparámetros, evitando problemas como el sobreajuste.
- Conjunto de prueba: Incluye datos no utilizados en el entrenamiento previo y se destinó a evaluar la capacidad del modelo para generalizar la identificación de posturas en nuevas muestras.

Esta segmentación permitió optimizar el aprendizaje del modelo y garantizar su precisión en la detección de posturas en diferentes condiciones y participantes.

4.2. VARIABLES DE INVESTIGACIÓN

Para el desarrollo de esta investigación, se consideraron variables fundamentales que establecen los límites y objetivos del estudio. Estas variables representan las características, propiedades o condiciones que determinan el enfoque del análisis y permiten evaluar el desempeño del modelo de visión artificial en la identificación y clasificación de posturas de equilibrio en personas mayores.

4.2.1. VARIABLES DEPENDIENTES

La variable dependiente en este estudio es el nivel de precisión del modelo de visión artificial para la detección automática de las posturas de equilibrio (pies juntos, semi-tándem y tándem) en la prueba de balance del SPPB. Se evaluará qué tan eficaz es el modelo para reconocer correctamente cada postura en tiempo real y cómo varía su desempeño en función de la cantidad y calidad de los datos de entrenamiento.

4.2.3. VARIABLES INDEPENDIENTES

La variable independiente en este estudio es el entrenamiento del modelo de visión artificial basado en redes neuronales convolucionales (CNN), que permitirá la identificación de posturas en la prueba de equilibrio del SPPB.

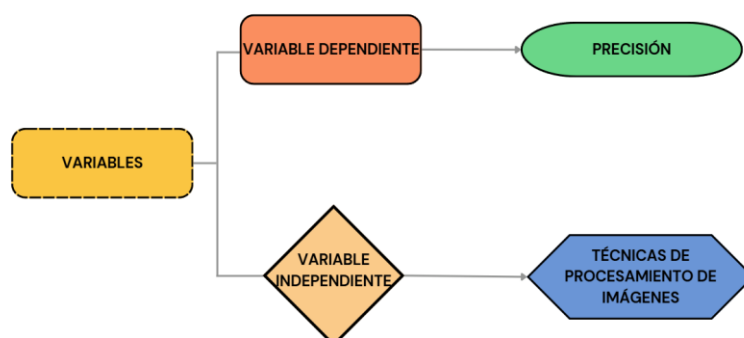


Ilustración 2: Variable Independiente

Fuente: Elaboración propia

4.3. TÉCNICA E INSTRUMENTOS APLICADOS

A continuación, se describen las técnicas y herramientas utilizadas en esta investigación, considerando los softwares y plataformas empleados para la captura, procesamiento y análisis de las posturas de equilibrio en la prueba del SPPB. Se incluyen los métodos que permitieron extraer parámetros biomecánicos clave y facilitar la implementación del modelo de visión artificial.

4.3.1. ROBOFLOW

Roboflow fue utilizado como una plataforma de visión por computadora para la gestión, etiquetado, preprocesamiento y entrenamiento del modelo de aprendizaje profundo, facilitando las tareas de detección, clasificación y segmentación de imágenes. En este proyecto, Roboflow permitió entrenar un modelo de Clasificación de Imágenes y Segmentación de Poses, logrando la identificación automática de las posturas de equilibrio del SPPB (Pies Juntos, Semi-Tándem y Tándem). Además, se empleó para detectar puntos clave del cuerpo, como la posición de los pies, rodillas y cadera, lo que facilitó el análisis de estabilidad y equilibrio en tiempo real. Gracias a ello, se logró evaluar con mayor precisión la capacidad de equilibrio de los participantes y mejorar la automatización del diagnóstico en entornos clínicos y de rehabilitación.

Para optimizar la precisión del modelo en la clasificación de posturas de equilibrio, se aplicaron diversas técnicas de procesamiento de imágenes en Roboflow. En primer lugar, se implementó aumento de datos con el objetivo de mejorar la capacidad del modelo para generalizar la detección de posturas al introducir variaciones en las imágenes. Esto incluyó la rotación de las imágenes en un rango de $\pm 10^\circ$ para simular cambios sutiles en la postura, escalado y recorte para ajustar el tamaño de las imágenes y evitar sesgos en la detección, y reflejo horizontal, que permitió generar imágenes adicionales al invertirlas en su eje lateral, aumentando así la diversidad del conjunto de datos. Además, se incorporaron técnicas de ruido y desenfoque, con el propósito de simular condiciones de grabación con diferentes niveles de calidad y mejorar la robustez del modelo frente a variaciones en la captura de imágenes.

Asimismo, se aplicaron técnicas de filtrado y normalización de imágenes para mejorar la claridad y uniformidad de los datos. Se utilizó la conversión a escala de grises con el fin de reducir la influencia del color y centrarse únicamente en la estructura corporal del participante. También se implementó normalización de contraste, lo que permitió resaltar los contornos y características clave de la imagen, y se realizaron ajustes de iluminación, que ayudaron a compensar variaciones en las condiciones de grabación y garantizar mayor consistencia en el conjunto de datos.

Finalmente, se llevó a cabo un proceso de etiquetado de fondo, el cual permitió eliminar elementos irrelevantes en la imagen y centrar la atención en la postura del participante. Esto redujo la influencia de factores externos en la clasificación y mejoró la precisión del modelo en la detección automática de las posturas pies juntos, semi-tándem y tándem. Con la implementación de estas técnicas, se optimizó el aprendizaje del modelo y se mejoró su desempeño en la evaluación del equilibrio en tiempo real.

4.3.2. PRUEBA DE EQUILIBRIO DEL SPPB

La prueba de SPPB es una evaluación utilizada en el ámbito clínico y de rehabilitación para medir la estabilidad postural en personas mayores. En este estudio, se aplicó con el objetivo de generar una base de datos de imágenes etiquetadas que sirvieran para entrenar y validar el modelo de visión artificial.

El procedimiento de la prueba consistió en solicitar a los participantes que adoptaran tres posturas progresivas de equilibrio:

- Pies juntos: Mantenerse de pie con ambos pies alineados durante al menos 10 segundos.
- Semi-tándem: Colocar un pie ligeramente adelantado al otro y sostener la postura por un mínimo de 10 segundos.
- Tándem: Ubicar un pie completamente delante del otro en una línea recta y mantener la posición entre 3 y 15 segundos.

Cada postura fue registrada mediante grabaciones de video para su posterior análisis y segmentación en imágenes. Estas imágenes fueron utilizadas como datos de entrada en el entrenamiento de la red neuronal, con el fin de desarrollar un modelo capaz de evaluar el equilibrio de manera automatizada.

Esta prueba permitió obtener información relevante sobre la estabilidad postural de los participantes, proporcionando una base objetiva para la implementación del modelo de visión artificial.

4.4. MATERIALES

En esta sección se detallan los materiales utilizados para la recopilación de datos en la investigación, asegurando la calidad y precisión de los registros obtenidos para el entrenamiento del modelo de visión artificial.

4.4.1. CÁMARAS DE TELÉFONO INTELIGENTE

Los videos fueron grabados utilizando un teléfono inteligente con una cámara de alta resolución, lo que permitió capturar con precisión las posturas de los participantes durante la prueba de equilibrio del SPPB. Se priorizó el uso de un dispositivo con buena calidad de imagen y capacidad de grabación en alta definición (HD o superior) para garantizar la nitidez de los registros y facilitar el procesamiento y la clasificación de imágenes para el entrenamiento del modelo de visión artificial.

4.5. POBLACIÓN

La población seleccionada para este estudio estuvo conformada por 30 participantes del Centro de Tecnología Biomédica (CTB) y la Escuela de Informáticos de la Universidad Politécnica de Madrid. Los participantes fueron elegidos con base en criterios preestablecidos para garantizar la relevancia de los datos en la evaluación del desempeño del modelo de visión artificial en la identificación de posturas de la prueba de equilibrio del SPPB.

Dado que el enfoque del estudio estuvo orientado a la evaluación del equilibrio, se seleccionaron participantes que permitieran analizar con precisión la clasificación de posturas a partir de imágenes procesadas. Además, se garantizó que la recolección de datos se llevara a cabo en un entorno controlado dentro del CTB y la Escuela de Informáticos, siguiendo protocolos éticos y asegurando condiciones adecuadas para la captura de imágenes en la prueba.

4.6. METODOLOGÍA DE ESTUDIO

El objetivo principal de esta investigación fue desarrollar a través de la visión por computadora un sistema capaz de detectar automáticamente las posturas de la prueba de equilibrio del SPPB en personas mayores. Para garantizar que el modelo se entrenara correctamente, se estudiaron y analizaron diversas variables clave en la biomecánica del equilibrio, asegurando que la evaluación automatizada tuviera un nivel de precisión adecuado para su aplicación en entornos clínicos y de rehabilitación.

La investigación adoptó un enfoque descriptivo y exploratorio, basándose en el análisis de imágenes capturadas durante la ejecución de la prueba de equilibrio del SPPB. Los datos se organizaron y etiquetaron manualmente en siete categorías, correspondientes a diferentes posturas (correctas e incorrectas), incluyendo una clase adicional para imágenes irrelevantes. Posteriormente, se utilizó la plataforma Roboflow para procesar, etiquetar y preparar el conjunto de datos, permitiendo el entrenamiento y validación de un modelo de visión por computador enfocado en la detección automática de posturas. Este enfoque permitió obtener una base de datos estructurada y adecuada para el desarrollo del sistema de clasificación.

La prueba de equilibrio del SPPB es una evaluación comúnmente utilizada en el ámbito de la rehabilitación para medir la capacidad de una persona para mantener el equilibrio en diferentes posturas. En este estudio, los participantes fueron 30 personas mayores con

dificultades de equilibrio, quienes dieron su consentimiento para ser grabados durante la ejecución de la prueba.

A cada participante se le solicitó adoptar las tres posturas progresivas de la prueba de equilibrio:

- Pies juntos: Mantener la postura durante al menos 10 segundos.
- Semi-tándem: Colocar un pie ligeramente adelantado y sostener la posición durante 10 segundos.
- Tándem: Ubicar un pie completamente delante del otro y mantener el equilibrio entre 3 y 15 segundos.

Para la etapa de validación, se diseñó un proceso sistemático que permitió recopilar, organizar y preparar los datos de forma controlada. Todas las sesiones fueron registradas con un teléfono inteligente, utilizando un trípode para estabilizar la imagen y asegurar uniformidad en la captura de las posturas. A partir de los videos obtenidos, se generaron capturas de imagen que posteriormente fueron subidas y procesadas en la plataforma Roboflow.

El proceso de etiquetado y clasificación de las imágenes fue completamente manual, lo que garantizó la asignación precisa de cada postura dentro de las siete categorías establecidas (seis posturas del test SPPB más la clase "Ninguna"). Para asegurar la consistencia del conjunto de datos, se llevó a cabo una etapa de preprocesamiento, en la cual todas las imágenes fueron redimensionadas a 640x640 píxeles y se aplicó auto orientación para estandarizar el orden de los píxeles y la orientación de las figuras.

Durante esta fase, se probaron diferentes versiones de modelos dentro de la plataforma Roboflow, con el objetivo de identificar cuál presentaba el mejor comportamiento en términos de desempeño y estabilidad. Esta validación permitió establecer el flujo de trabajo más adecuado para preparar el sistema final de clasificación de posturas basado en visión artificial.

4.6.1. VALIDACIÓN DE RESULTADOS

Para evaluar el rendimiento del modelo de clasificación de imágenes implementado en Roboflow, se utilizaron tres métricas fundamentales: mAP, Precisión y Recall. Estas métricas permiten medir la capacidad del modelo para identificar correctamente las posturas de equilibrio en adultos mayores, asegurando una evaluación confiable y eficiente.

La primera métrica, mAP, se emplea comúnmente en tareas de detección y clasificación de imágenes. Representa el promedio de la precisión en distintos IoU, lo que permite evaluar qué tan bien el modelo distingue entre diferentes posturas. En este proyecto, se consideraron dos variantes: mAP50, que calcula la precisión media con un umbral de IoU del 50%, y mAP50-95, que promedia la precisión en un rango de IoU entre 50% y 95%. Un valor alto de mAP indica que el modelo es capaz de clasificar correctamente las posturas con gran exactitud.

Por otro lado, la precisión mide la proporción de imágenes clasificadas correctamente en relación con el total de predicciones realizadas. Un modelo con alta precisión significa que comete pocos falsos positivos, es decir, pocas imágenes fueron identificadas incorrectamente como una postura cuando en realidad pertenecían a otra. Esto es crucial para garantizar que las clasificaciones sean confiables y evitar errores en la supervisión del equilibrio en adultos mayores.

Finalmente, el recall evalúa qué porcentaje de imágenes de una postura específica fueron correctamente identificadas por el modelo. Un alto valor de recall indica que el sistema tiene pocos falsos negativos, lo que significa que casi todas las posturas reales fueron reconocidas correctamente. En el contexto del análisis del equilibrio, una alta sensibilidad es esencial para no omitir ninguna postura importante durante la evaluación.

Todas estas métricas fueron generadas automáticamente por Roboflow después del entrenamiento del modelo. Su análisis permitió optimizar la clasificación de posturas de equilibrio (pies juntos, semi-tándem y tándem), asegurando que el sistema pueda ofrecer un monitoreo preciso y en tiempo real para mejorar la evaluación del equilibrio en adultos mayores.

4.6.2. PLAN DE IMPLEMENTACIÓN

El presente plan tiene como objetivo facilitar la aplicación del sistema de clasificación de posturas en adultos mayores dentro del Centro de Tecnología Biomédica (CTB). Debido a restricciones de tiempo, el modelo fue entrenado utilizando imágenes de personas sin discapacidad. Sin embargo, su implementación en adultos mayores permitirá evaluar su efectividad en la identificación de posturas de equilibrio dentro de la batería SPPB, específicamente en las posiciones de pies juntos, semi-tándem y tándem.

Para su correcta aplicación, se debe preparar un entorno adecuado donde las condiciones de iluminación y el fondo sean óptimos para minimizar interferencias en la

detección de posturas. La cámara debe ubicarse en una posición fija que capture el cuerpo completo del participante, asegurando que la evaluación se realice en condiciones uniformes. Asimismo, el dispositivo que ejecutará el modelo debe contar con la capacidad de procesamiento necesaria para garantizar una clasificación en tiempo real sin interrupciones.

El protocolo de evaluación consistirá en instruir a cada participante sobre la serie de posturas que debe adoptar. Una vez que la persona realice la posición indicada, el sistema procesará la imagen y asignará automáticamente una etiqueta correspondiente a la postura detectada. Los resultados obtenidos serán registrados para su análisis y validación. Con el fin de garantizar la seguridad de los participantes, la evaluación se realizará en un ambiente controlado, minimizando cualquier riesgo de caídas o fatiga. Además, se proporcionará una explicación clara sobre el propósito del sistema y se obtendrá el consentimiento informado de los adultos mayores antes de iniciar la prueba, asegurando que puedan interrumpir su participación en cualquier momento si así lo desean.

Dado que el modelo fue entrenado con una población diferente a la que será evaluada en el CTB, se recomienda un monitoreo continuo de su precisión y realizar los ajustes necesarios para mejorar su desempeño. Para ello, sería ideal recopilar nuevas imágenes de adultos mayores que permitan mejorar la adaptación del modelo a la población objetivo. En caso de identificar variaciones en la estabilidad o en la ejecución de las posturas, se deberá evaluar si el sistema requiere ajustes para optimizar la clasificación y garantizar resultados más precisos.

Se espera que la implementación del sistema en el CTB facilite la validación de su precisión en adultos mayores, contribuyendo a su aplicación en la evaluación del equilibrio y en la prevención de caídas. Gracias a su capacidad de detección automática, este modelo representa una herramienta accesible y eficiente para el monitoreo postural en programas de rehabilitación y envejecimiento saludable.

4.7. CRONOGRAMA DE ACTIVIDADES

Tabla 3: Cronograma de Actividades

Actividades	Octubre – Diciembre									
	Semanas									
	1	2	3	4	5	6	7	8	9	10
Revisión de artículos bibliográficos, relacionados con la prueba SPPB y el envejecimiento saludable	■	■								
Utilización del software kinovea, aprender a usarlo.		■								
Obtención de sujetos de prueba para realizar la toma de videos			■							
Realización de grabaciones respecto a la prueba STS				■	■					
Procesar los videos utilizando la herramienta kinovea					■					
Modificación y validación de datos adquiridos						■	■			
Mostrar resultados, calificación evaluación a los sujetos de prueba						■	■			
Creación de base de datos en base a videos obtenidos								■		
Entrenamiento del algoritmo mediante visión por computadora utilizando la plataforma de Roboflow								■	■	
Análisis y síntesis de resultados finales obtenidos en pruebas con usuarios									■	■
Documentación completa de resultados y elaboración del informe de resultados finales									■	■
Revisión final de todo el sistema para asegurar precisión y usabilidad antes de la entrega										■

4.8. OPERACIONES DE LAS VARIABLES

Tabla 4: Operalización De Las Variables

OBJETIVO	VARIABLE	DEFINICIÓN CONCEPTUAL	DIMENSIONES	INDICADORES
GENERAL	Dependiente			
Desarrollar un modelo basado en visión artificial para la evaluación automatizada y precisa del equilibrio en personas mayores, utilizando técnicas de procesamiento de imágenes y análisis de posturas en la prueba de balance del SPPB	Precisión en la clasificación de posturas	Eficiencia del modelo en la detección automática y correcta de las posturas.	Exactitud en la clasificación de posturas.	Porcentaje de aciertos en la identificación de posturas (pies juntos, semi-tándem y tándem).
Específicos	Independiente			
Desarrollar una base de datos de imágenes o videos etiquetados con las diferentes posturas de la prueba de equilibrio del sppb.	Técnicas de procesamiento de imágenes	Métodos aplicados a las imágenes para mejorar la clasificación del modelo.	Calidad de la base de datos de entrenamiento	Número de imágenes correctamente etiquetadas y segmentadas por postura.
Entrenar un modelo que sea capaz de clasificar las posturas utilizando roboflow.	Técnicas de procesamiento de imágenes	Métodos de optimización aplicados para mejorar la clasificación automática de posturas.	Optimización del modelo	Precisión obtenida en las fases de entrenamiento y validación.
REFINAR EL MODELO ENTRENADO PARA MEJORAR LA PRECISIÓN EN LA DETECCIÓN.	Precisión en la clasificación de posturas	Capacidad del modelo para reducir errores en la clasificación tras ajustes en el entrenamiento.	Reducción de errores	Comparación de precisión antes y después del refinamiento del modelo.
Validar los resultados obtenidos por el modelo comparándolos con las evaluaciones realizadas por expertos en rehabilitación o fisioterapia.	Precisión en la clasificación de posturas	Comparación de los resultados del modelo con evaluaciones manuales realizadas por especialistas.	Comparación de los resultados del modelo con evaluaciones manuales realizadas por especialistas.	Nivel de coincidencia entre las clasificaciones del modelo y las evaluaciones de los fisioterapeutas.

V. RESULTADOS Y ANÁLISIS

5.1. CLASIFICACIÓN DE POSTURAS DEL SPPB

Para la creación del dataset, se recolectaron datos de 26 personas, cada una realizando las pruebas de equilibrio del SPPB. Se capturaron 156 videos, asegurando que cada prueba se realizara durante 10 segundos, ya que este es el tiempo requerido en la evaluación estándar del SPPB.

A partir de estos videos, se generaron 1,560 imágenes, con un esquema de segmentación basado en 1 frame por segundo, lo que resultó en 10 imágenes por video. Sin embargo, para aumentar el tamaño del dataset y mejorar el rendimiento del modelo, algunas imágenes fueron duplicadas, lo que elevó el número total de imágenes a 1,577. Finalmente, tras el proceso de anotación, se registraron 1,579 anotaciones en el dataset.

Posteriormente, Roboflow realizó la clasificación automática de las imágenes tras la etapa de etiquetado manual. Se asignaron las imágenes a tres categorías dentro del conjunto de datos: entrenamiento, validación y prueba.

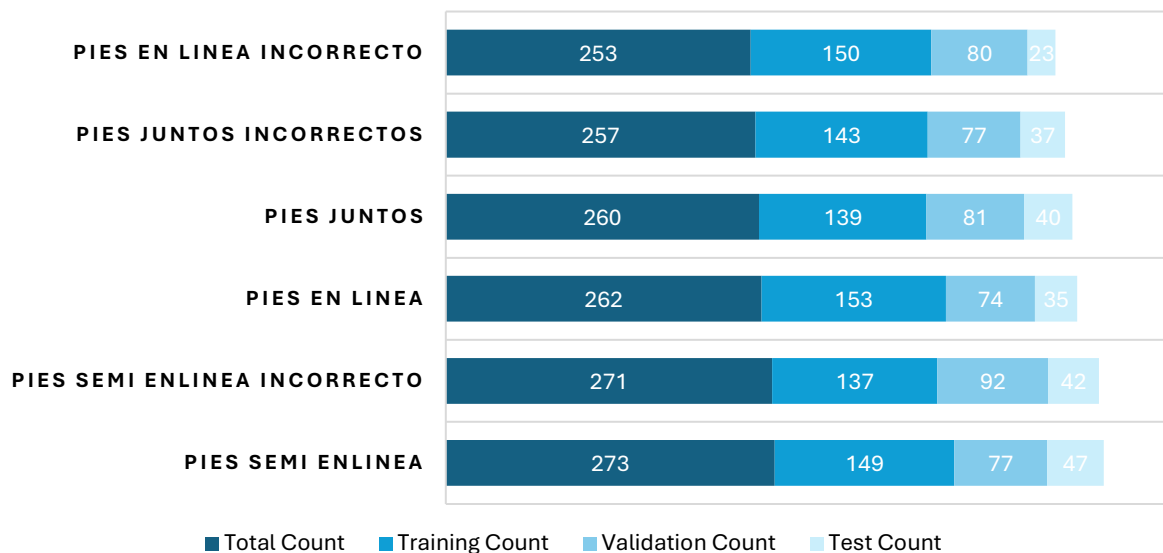


Ilustración 3: Clasificación de imágenes en el dataset

La ilustración 3 muestra la distribución de imágenes dentro de estas categorías según las clases definidas. El dataset resultante fue utilizado para entrenar la red neuronal en

Roboflow, permitiendo la detección y clasificación de posturas de equilibrio con mayor precisión.

5.2. EVALUACIÓN DE DESEMPEÑO DE LOS MODELOS

Para la detección de posturas de equilibrio, se entrenaron tres modelos diferentes, cada uno con distintas configuraciones y herramientas de entrenamiento. El Modelo 1 fue entrenado con YOLOv12, el Modelo 2 con Roboflow 3.0 y el Modelo 3 con YOLOv12. Para evaluar el desempeño de cada modelo, se consideraron tres métricas clave: mAP, que mide la precisión general del modelo, precisión que indica el porcentaje de detecciones correctas y recall que representa el porcentaje de objetos reales que fueron detectados.

Tabla 5: Comparación de Modelos

ENTRENAMIENTO	MAP	PRECISION	RECALL	OBSERVACIONES
1	91.7%	79.8%	78.4%	Buen equilibrio entre precisión y recall
3	87.9%	60.5%	89.6%	Baja precisión, lo que indica demasiados errores en la detección
4	83.7%	90.4%	78.7%	Alta precisión, pero recall bajo, lo que significa que omite muchas detecciones

Tras el análisis de los resultados obtenidos, se determinó que el Modelo 1 (YOLOv12) es la opción más adecuada para la clasificación de posturas de equilibrio. El Modelo 2 (Roboflow) presentó una precisión baja (60.5%) y un recall alto (89.6%), lo que indica que, si bien detectó una gran cantidad de objetos, generó un número significativo de falsos positivos, identificando posturas donde no existían. Por otro lado, el Modelo 3 (YOLOv12) mostró una alta precisión (90.4%) pero un recall reducido (78.7%), lo que sugiere que solo realizaba detecciones cuando tenía un alto grado de certeza, omitiendo muchas posturas reales y generando falsos negativos. En comparación, el Modelo 1 (YOLOv12) logró el mejor equilibrio entre precisión (79.8%) y recall (78.4%), lo que permitió una detección más estable y confiable, alcanzando un mAP de 91.7%, el más alto de los tres modelos evaluados.

El mAP es una métrica clave en la evaluación de modelos de detección, ya que representa la media de la precisión en diferentes umbrales de intersección sobre unión. Un mAP alto indica que el modelo no solo detecta correctamente los objetos, sino que también los clasifica con alta precisión. En este caso, el Modelo 1 (YOLOv12) obtuvo un mAP del 91.7%, lo que confirma su eficacia en la detección de posturas de equilibrio.

Para mejorar la robustez y el rendimiento de cada modelo, se aplicaron técnicas de preprocesamiento y aumentación de datos, ajustando los parámetros según la arquitectura utilizada:

- Modelo 1 (YOLOv12): Se aplicó ajuste automático de orientación, redimensionado a 640x640 píxeles y ajuste de contraste mediante Contrast Stretching. En la etapa de aumentación, se generaron tres imágenes por cada ejemplo de entrenamiento, aplicando espejado horizontal, rotaciones entre -10° y $+10^\circ$, variaciones de brillo de -15% a $+15\%$, desenfoque de hasta 2 px y ruido en un 0.46% de los píxeles.
- Modelo 2 (Roboflow): Se empleó Histogram Equalization para el ajuste del contraste, junto con el mismo redimensionado a 640x640 píxeles. En la etapa de aumentación, se generaron tres imágenes por cada ejemplo de entrenamiento, aplicando espejado horizontal, rotaciones entre -10° y $+10^\circ$, variaciones de brillo de -10% a $+10\%$ y ruido en un 0.3% de los píxeles.
- Modelo 3 (YOLOv11): Se utilizaron las mismas técnicas de preprocesamiento que en el Modelo 2 (Histogram Equalization y redimensionado a 640x640 píxeles), pero en la etapa de aumentación se redujo el número de imágenes generadas a dos por cada ejemplo de entrenamiento, aplicando espejado horizontal, rotaciones entre -10° y $+10^\circ$, variaciones de brillo de -10% a $+10\%$ y ruido en un 0.3% de los píxeles.

Debido a su desempeño superior en términos de precisión, recall y mAP, YOLOv12 fue seleccionado como el modelo definitivo, ya que minimiza tanto falsos positivos como falsos negativos, lo que resulta esencial para una evaluación precisa de las posturas de equilibrio en el contexto del SPPB.

5.3. PRECISIÓN, RECALL, MAP

Para evaluar el desempeño de los modelos, se analizaron las métricas de precisión, recall, mAP50 y mAP50-95 a lo largo de las iteraciones del entrenamiento. Estas métricas permiten determinar la capacidad del modelo para realizar detecciones correctas, identificar objetos relevantes y minimizar tanto falsos positivos como falsos negativos.




Ilustración 4: Gráfica 81 de precisión, recall, mAP50 y mAP50-95 por epoch

El Modelo 1 (YOLOv12) presentó un comportamiento estable a lo largo del entrenamiento, mostrando una tendencia creciente en precisión y recall, alcanzando valores cercanos al 80% en ambas métricas. Su mAP50 también mostró una evolución positiva, superando el 90% en las últimas iteraciones, lo que indica una capacidad robusta para identificar correctamente las posturas. Además, su mAP50-95 mantuvo valores cercanos al 70%, lo que refleja un buen rendimiento en múltiples umbrales de precisión.

Este modelo logra el mejor equilibrio entre precisión y recall, evitando una detección excesivamente conservadora o errática. Su mAP alto respalda su efectividad en la clasificación de posturas de equilibrio.




Ilustración 5: Gráfica Modelo 2 de precisión, recall, mAP50 y mAP50-95 por epoch

El Modelo 2 de Roboflow 3.0 mostró una tendencia decreciente en precisión, lo que sugiere que, con el avance del entrenamiento, comenzó a generar más FP. Si bien su recall se

mantuvo relativamente alto (superior al 80%), su mAP50 experimentó una caída progresiva, situándose alrededor del 85%, lo que implica una reducción en la capacidad de detección general del modelo. Su mAP50-95 mostró fluctuaciones con una tendencia descendente, lo que indica inconsistencias en el rendimiento del modelo en diferentes niveles de precisión.

A pesar de su buen recall, este modelo generó demasiadas detecciones incorrectas de FP, lo que reduce su fiabilidad en aplicaciones donde es crucial evitar errores de clasificación.




Ilustración 6: Gráfica Modelo 3 de precisión, recall, mAP50 y mAP50-95 por epoch

El Modelo 3 de YOLOv12 mostró una alta precisión inicial (superior al 80%), pero su recall fue menor en comparación con los otros modelos. Esto significa que el modelo era muy selectivo en sus detecciones, omitiendo muchas posturas reales (FN elevados). Además, su mAP50 se mantuvo estable alrededor del 75-78%, mientras que su mAP50-95 mostró variaciones, indicando que el modelo tenía dificultades para generalizar correctamente en diferentes niveles de confianza.

Aunque su precisión fue alta, este modelo presentaba una menor capacidad para detectar todas las posturas correctamente, generando una gran cantidad de falsos negativos y comprometiendo la sensibilidad del sistema.

5.3.1. RENDIMIENTO POR CLASE VALIDATION SET MAP50

El rendimiento de los modelos fue evaluado a nivel de clase mediante la métrica mAP50 en el Validation Set, lo que permite analizar la capacidad de cada modelo para detectar y clasificar correctamente las posturas de equilibrio en cada categoría. A continuación, se presenta la comparativa entre los modelos entrenados:

Average Precision by Class (mAP50)



Ilustración 7: Modelo 1 Rendimiento por clase test set (mAP50)

El Modelo 1 (YOLOv12) obtuvo un mAP50 promedio de 92, lo que indica una alta precisión en la detección de posturas. Algunas clases como "Pies en línea" 99 y "Pies semi en línea" 94 mostraron un desempeño excepcional. Sin embargo, la clase "Pies juntos incorrectos" tuvo el valor más bajo 82, lo que sugiere una ligera dificultad en la clasificación de esta postura específica.

Este modelo demuestra una detección equilibrada en todas las clases, manteniendo valores altos y consistentes en todas las categorías, con una precisión promedio superior al 90%, lo que lo convierte en la mejor opción para la tarea de clasificación de posturas de equilibrio.

Average Precision by Class (mAP50)



Ilustración 8: Modelo 2 Rendimiento por clase test set (mAP50)

El Modelo 2 de Roboflow 3.0 mostró un rendimiento inferior en comparación con el Modelo 1, obteniendo un mAP50 promedio de 88. Si bien algunas clases, como "Pies en línea incorrecto" (94) y "Pies juntos incorrectos" (94), lograron buenos resultados, otras clases como

"Pies semi en línea" (76) y "Pies semi en línea incorrecto" (82) presentaron una disminución considerable en la precisión.

Este modelo tiene una precisión menor y menos uniforme en la detección de las distintas posturas, con una disminución notable en ciertas clases. Esto sugiere que el modelo tiene dificultades para generalizar correctamente en todas las categorías, afectando la confiabilidad de las detecciones.

Average Precision by Class (mAP50)



Ilustración 9: Modelo 3 Rendimiento por clase test set (mAP50)

El Modelo 3 (YOLOv11) fue el de peor desempeño, con un mAP50 promedio de 84. A pesar de obtener valores altos en algunas clases, como "Pies en línea incorrecto" (98) y "Pies juntos" (98), el rendimiento en la categoría "Unlabeled" fue extremadamente bajo (11), lo que indica que este modelo tuvo serios problemas para clasificar ciertas imágenes correctamente.

Este modelo mostró una menor estabilidad y una precisión más inconsistente, con valores extremadamente altos en algunas clases y muy bajos en otras. La gran diferencia entre las categorías sugiere una capacidad de generalización deficiente, lo que lo hace menos confiable en la detección de posturas de equilibrio.

5.3.2. RENDIMIENTO POR CLASE TEST SET MAP50

Para evaluar el desempeño de los modelos en un contexto más realista, se analizaron sus métricas en el Test Set. La métrica utilizada fue el mAP50, que mide la precisión promedio en la detección de cada clase. Este análisis permite validar qué tan bien los modelos generalizan a datos no vistos previamente.

Average Precision by Class (mAP50)



Ilustración 10: Rendimiento del modelo 1 por clase test set MAP50

El Modelo 1 (YOLOv12) alcanzó un mAP50 promedio de 95, lo que demuestra un rendimiento excepcional en la detección de posturas de equilibrio. La clase "Pies en línea" obtuvo un 100% de precisión, seguida de "Pies en línea incorrecto" (97%) y "Pies semi en línea" (98%). Las clases con menor precisión fueron "Pies semi en línea incorrecto" y "Pies juntos incorrectos", ambas con 89%, lo que sigue siendo un valor alto.

Este modelo mostró gran estabilidad y precisión en todas las clases, con valores superiores al 89% en todas las categorías, consolidándose como la mejor opción para la clasificación de posturas de equilibrio.

Average Precision by Class (mAP50)



Ilustración 11: Rendimiento del modelo 2 por clase test set MAP50

El Modelo 2 de Roboflow 3.0 obtuvo un mAP50 promedio de 88, lo que representa una disminución en comparación con el Modelo 1. Aunque algunas clases como "Pies en línea incorrecto" (94%) y "Pies juntos incorrectos" (94%) mantuvieron valores altos, otras como "Pies

semi en línea" (76%) y "Pies semi en línea incorrecto" (82%) mostraron un rendimiento significativamente menor.

Este modelo tiene una precisión más baja y menos homogénea en las diferentes clases, lo que indica que la detección es menos confiable y más propensa a errores en ciertas posturas.




Ilustración 12: Rendimiento del modelo 2 por clase test set MAP50

El Modelo 3 (YOLOv11) logró un mAP50 promedio de 98, obteniendo 100% de precisión en varias clases, como "Pies en línea" y "Pies en línea incorrecto". Sin embargo, la categoría "Pies semi en línea incorrecto" (94%) tuvo una leve reducción en comparación con el resto.

Aunque este modelo alcanzó valores altos en mAP50, es posible que su comportamiento se deba a un sobreajuste a los datos de entrenamiento, lo que podría afectar su desempeño en datos completamente nuevos.

5.4. EVOLUCIÓN DEL MODELO DURANTE EL ENTRENAMIENTO




Ilustración 13: Gráfica de evolución de mAP en el tiempo del Modelo 1

El Modelo 1 (YOLOv12) mostró una evolución progresiva y estable en sus métricas. Desde las primeras épocas, se observó un aumento rápido en el mAP50, alcanzando valores cercanos al 80% en menos de 20 épocas. Posteriormente, la curva se mantuvo en una tendencia ascendente con ligeras oscilaciones, estabilizándose en torno al 90% en las últimas iteraciones. El mAP50-95 también mostró una tendencia positiva, aunque con fluctuaciones más notables, lo que es común en métricas que abarcan múltiples umbrales de IoU. Sin embargo, la tendencia general fue de mejora, estabilizándose alrededor del 70% en las últimas épocas, indicando una buena capacidad de generalización del modelo.




Ilustración 14: Gráfica de evolución de mAP en el tiempo del Modelo 2

El Modelo 2 de Roboflow 3.0 presentó un comportamiento menos estable en comparación con el Modelo 1. Si bien el mAP50 alcanzó valores superiores al 80%, la curva mostró más variabilidad y cierta tendencia a la fluctuación, lo que sugiere que el modelo tenía dificultades para alcanzar una convergencia óptima. El mAP50-95, por otro lado, mostró oscilaciones más pronunciadas, lo que indica que el modelo no lograba mantener una detección consistente en distintos umbrales de IoU. Esto puede deberse a un ajuste insuficiente de los hiperparámetros o a una menor capacidad de generalización en comparación con YOLOv12. Aunque el modelo logró una precisión aceptable, la inestabilidad en sus métricas sugiere que podría haber tenido dificultades en ciertas clases de detección. Esto compromete su capacidad de generalización y robustez.

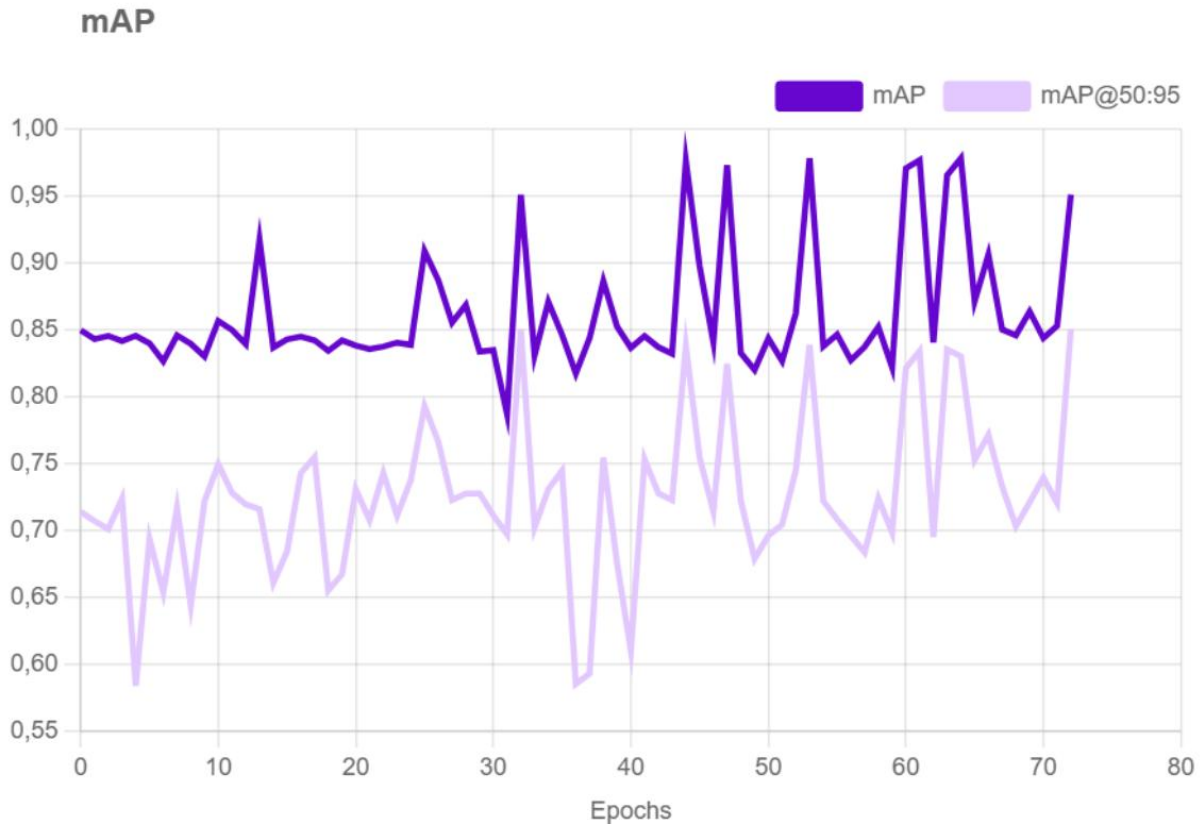


Ilustración 15: Gráfica de evolución de mAP en el tiempo del Modelo 3

El Modelo 3 de YOLOv12 mostró un comportamiento diferente a los modelos anteriores, con un mAP50 inicial relativamente alto, pero con picos y caídas abruptas a lo largo del entrenamiento. Aunque en algunos momentos el mAP50 superó el 90%, la falta de estabilidad en la curva sugiere que el modelo experimentó sobreajuste, aprendiendo patrones específicos del conjunto de entrenamiento en lugar de generalizar adecuadamente. El mAP50-95 presentó fluctuaciones aún más marcadas, con descensos significativos en varias iteraciones. Esto refuerza la hipótesis de sobreajuste, donde el modelo era demasiado sensible a los datos de entrenamiento, pero menos efectivo en datos nuevos. Aunque este modelo logró altas métricas en ciertos puntos, su comportamiento inestable y propensión al sobreajuste lo hacen menos adecuado para la detección de posturas de equilibrio.

5.5. ANÁLISIS DE LAS GRÁFICAS DE PÉRDIDA

Las gráficas de evolución de diferentes tipos de pérdidas (loss) durante el entrenamiento del modelo. En general, una disminución de la pérdida indica que el modelo está aprendiendo correctamente. Sin embargo, si la pérdida en validación no sigue la misma tendencia que la de entrenamiento, podría haber problemas de sobreajuste (overfitting).

Para este análisis, se examinaron dos métricas principales:

- Train/Box_Loss: Representa la pérdida en el conjunto de entrenamiento y muestra cómo el modelo aprende durante el proceso.
- Val/Box_Loss: Representa la pérdida en el conjunto de validación y evalúa qué tan bien el modelo generaliza a datos no vistos.

5.5.1. BOX LOSS (TRAIN/BOX_LOSS Y VAL/BOX_LOSS)

El análisis de la Box Loss es fundamental para evaluar la precisión con la que el modelo predice las coordenadas de los cuadros delimitadores en la detección de posturas. La Box Loss mide la diferencia entre las predicciones del modelo y las ubicaciones reales de los objetos en la imagen. Un valor más bajo de esta métrica indica que el modelo está realizando predicciones más precisas.




Ilustración 16: Gráfica de entrenamiento de box loss del modelo 1

En el Modelo 1 de YOLOv12, la Train/Box_Loss muestra una disminución progresiva en las primeras iteraciones, lo que indica que el modelo estaba ajustando sus pesos de manera efectiva para minimizar el error en la predicción de los cuadros delimitadores. Sin embargo, después de aproximadamente 50 épocas, se observa una estabilización y un ligero aumento

en la pérdida, lo que puede sugerir un punto de inflexión donde el modelo comienza a saturarse o experimentar un ligero sobreajuste.

Por otro lado, la Val/Box_Loss también muestra una tendencia decreciente en las primeras iteraciones, aunque con fluctuaciones más notables. Al final del entrenamiento, la pérdida se mantiene relativamente baja, lo que indica una buena generalización sin signos evidentes de sobreajuste extremo. Este comportamiento indica que el Modelo 1 logró un aprendizaje estable, con una reducción efectiva del error en la predicción de cuadros delimitadores y una buena capacidad de generalización en datos de validación.




Ilustración 17: Gráfica de entrenamiento de box loss del modelo 2

En el Modelo 2 de Roboflow 3.0, la Train/Box_Loss muestra una reducción constante y sostenida a lo largo del entrenamiento, con valores finales bajos. Sin embargo, la Val/Box_Loss muestra una tendencia más inestable, con fluctuaciones significativas en algunas iteraciones, lo que indica que el modelo tenía dificultades para predecir con precisión las cajas en los datos de validación. La inestabilidad en la Val/Box_Loss sugiere que el modelo podría haber experimentado una menor capacidad de generalización. Aunque el modelo aprendió en el conjunto de entrenamiento, sus predicciones en datos no vistos no fueron tan precisas como en el Modelo 1.




Ilustración 18: Gráfica de entrenamiento de box loss del modelo 3

El Modelo 3 (YOLOv11) presenta una Train/Box_Loss con una tendencia decreciente, similar a los otros modelos, pero con valores iniciales más bajos, lo que indica que aprendió rápidamente en las primeras iteraciones. Sin embargo, la Val/Box_Loss muestra altas fluctuaciones y picos abruptos, lo que es un indicio claro de sobreajuste. Este modelo logró una reducción efectiva de la pérdida en entrenamiento, pero no logró generalizar bien a los datos de validación, lo que sugiere que estaba memorizando en lugar de aprender patrones generalizables. Este comportamiento hace que el modelo sea menos confiable en escenarios reales.

5.5.2. CLASS LOSS (TRAIN/CLS_LOSS Y VAL/CLS_LOSS)

La Class Loss es una métrica que mide la precisión del modelo en la clasificación de las posturas dentro de cada imagen. Un valor bajo de esta pérdida indica que el modelo está asignando correctamente las etiquetas a las imágenes de entrada. Para evaluar el comportamiento de esta métrica, se analizaron:

- Train/Cls_Loss: Representa la pérdida en el conjunto de entrenamiento y refleja cómo el modelo ajusta sus parámetros para mejorar la clasificación.
- Val/Cls_Loss: Representa la pérdida en el conjunto de validación y permite evaluar qué tan bien el modelo generaliza en datos no vistos.




Ilustración 19: Gráfica de entrenamiento train/cls_loss del modelo 1

En el Modelo 1 de YOLOv12, la Train/Cls_Loss muestra una disminución abrupta en las primeras iteraciones, lo que indica que el modelo estaba aprendiendo rápidamente a clasificar las posturas de equilibrio. Después de aproximadamente 50 épocas, la pérdida se estabiliza con valores bajos, lo que sugiere que el modelo alcanzó un punto de convergencia óptimo.

La Val/Cls_Loss también presenta una tendencia descendente, aunque con algunas fluctuaciones, lo cual es normal debido a la variabilidad en los datos de validación. Sin embargo, en las últimas iteraciones, la pérdida se mantiene en valores bajos y estables, lo que indica una buena capacidad de generalización sin signos de sobreajuste. La evolución de la pérdida sugiere que el Modelo 1 alcanzó un aprendizaje óptimo, con una clasificación precisa y estable en el conjunto de entrenamiento y validación.




Ilustración 20: Gráfica de entrenamiento train/cls_loss del modelo 2

En el Modelo 2 de Roboflow 3.0, la Train/Cls_Loss también muestra una reducción progresiva, aunque con valores iniciales más bajos en comparación con el Modelo 1. Esto indica que el modelo estaba aprendiendo, pero a un ritmo menos pronunciado.

Sin embargo, la Val/Cls_Loss muestra una gran variabilidad, con picos y caídas significativas a lo largo del entrenamiento. Esto es un indicador de inestabilidad, lo que sugiere que el modelo no logra clasificar de manera consistente las posturas en el conjunto de validación. Aunque el modelo logró reducir la pérdida en entrenamiento, la alta variabilidad en la pérdida de validación indica una menor capacidad de generalización, lo que puede generar errores al clasificar nuevas imágenes.

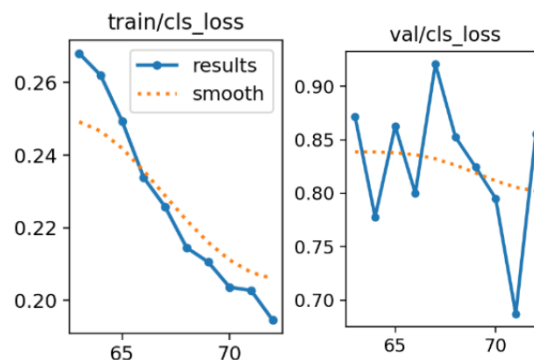


Ilustración 21: Gráfica de entrenamiento train/cls_loss del modelo 3

El Modelo 3 de YOLOv12 presenta una Train/Cls_Loss con una tendencia descendente similar a los modelos anteriores, aunque con valores iniciales más altos. Sin embargo, la Val/Cls_Loss muestra grandes fluctuaciones y picos pronunciados, lo que indica que el modelo no logró estabilizar la clasificación en el conjunto de validación. Este comportamiento sugiere que el modelo pudo haber experimentado sobreajuste, ajustándose demasiado a los datos de entrenamiento, pero sin lograr una generalización efectiva en el conjunto de validación.

5.5.3. OBJECT LOSS (TRAIN/DFL_LOSS Y VAL/DFL_LOSS)

La Object Loss es clave para entender qué tan bien el modelo aprende a detectar y localizar objetos con precisión. Básicamente, mide la confianza del modelo en sus predicciones, es decir, cuán seguro está de que ha identificado correctamente una postura. Una reducción constante de esta pérdida indica que el modelo está mejorando su capacidad de detección y clasificación.

Para analizar esto, observamos dos cosas:

- Train/DFL_Loss: Representa la pérdida en entrenamiento y nos dice qué tan bien el modelo está aprendiendo con los datos que ya conoce.

- Val/DFL_Loss: Representa la pérdida en validación y nos ayuda a ver si el modelo también es bueno en datos nuevos o si está "memorizando" demasiado.




Ilustración 22: Gráfica de entrenamiento train/df_loss del modelo 1

Este modelo muestra un comportamiento bastante sólido. En las primeras iteraciones, la Train/DFL_Loss empieza alta, lo cual es completamente normal porque el modelo aún está aprendiendo. Pero a medida que avanza el entrenamiento, la curva desciende de manera estable, lo que indica que el modelo está ajustando sus predicciones y ganando confianza en sus detecciones.

Lo interesante es la Val/DFL_Loss, que también sigue una tendencia decreciente, aunque con algunas pequeñas fluctuaciones. Esto nos dice que el modelo generaliza bien y no solo está aprendiendo de memoria los datos de entrenamiento, sino que realmente está entendiendo cómo detectar las posturas en imágenes nuevas. Este comportamiento es exactamente lo que se busca en un modelo bien entrenado. No solo aprende rápido, sino que mantiene una buena estabilidad sin señales de sobreajuste.




Ilustración 23: Gráfica de entrenamiento train/df_loss del modelo 2

Aquí la historia es un poco diferente. Aunque la Train/DFL_Loss disminuye con el tiempo, lo hace de una manera más irregular en comparación con el Modelo 1. Esto sugiere que el modelo está aprendiendo, pero no con la misma estabilidad. Lo más preocupante es la Val/DFL_Loss, que muestra variaciones más marcadas y cierta tendencia a subir en algunas iteraciones. Esto podría significar que el modelo tiene dificultades para predecir correctamente en datos nuevos y está perdiendo algo de generalización. Aunque este modelo mejora con el tiempo, la inestabilidad en validación nos hace dudar de su capacidad para funcionar de manera confiable fuera del conjunto de entrenamiento.




Ilustración 24: Gráfica de entrenamiento train/dfl_loss del modelo 3

Este modelo tiene una Train/DFL_Loss que disminuye de manera constante, lo cual parece prometedor. Sin embargo, la Val/DFL_Loss cuenta otra historia: hay varias fluctuaciones grandes y picos pronunciados, lo que sugiere que el modelo no está generalizando bien. Esto es una clara señal de que podría estar ocurriendo sobreajuste. En otras palabras, el modelo está ajustándose demasiado a los datos de entrenamiento y le cuesta predecir correctamente cuando se enfrenta a datos nuevos. Aunque este modelo aprende rápidamente, no logra mantener una estabilidad en la validación, lo que indica que no es la mejor opción para implementaciones reales.

5.6. VALIDACIÓN DEL MODELO DE DETECCIÓN DE POSTURAS

Para evaluar el desempeño del modelo entrenado para la detección de posturas de la prueba SPPB, se realizó una validación utilizando un conjunto de imágenes clasificadas manualmente. En este análisis se utilizaron imágenes correspondientes a las seis categorías establecidas del modelo (Pies Juntos, Semitandem, Tandem, Pies Juntos Incorrecto, Semitandem Incorrecto y Tandem Incorrecto) así como también imágenes aleatorias que no estaban relacionadas con las clases entrenadas, con el objetivo de evaluar la capacidad del modelo para evitar falsos positivos.

El modelo logró detectar correctamente 45 de 63 imágenes, alcanzando una precisión global del 71.43%. La fórmula utilizada para el cálculo fue:

$$\text{Precisión global} = \left(\frac{45}{45 + 18} \right) \times 100 = 71.43\%$$

La siguiente gráfica muestra la distribución de las detecciones correctas e incorrectas:

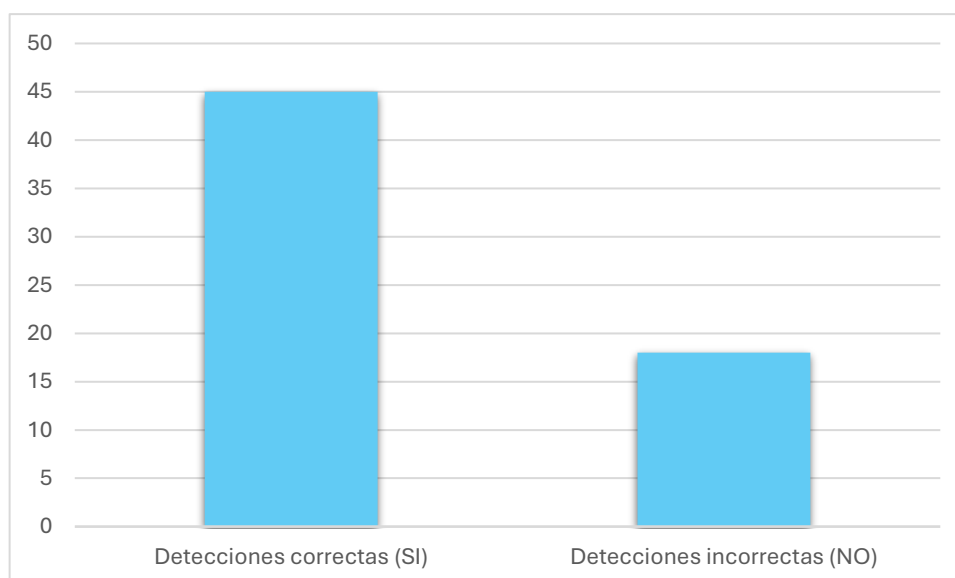


Ilustración 25: Gráfica de validación

5.7. PRECISIÓN POR CATEGORÍA DE POSTURA

El análisis por categoría permite evaluar de forma más específica el rendimiento del modelo en cada una de las seis posturas consideradas. Se utilizaron 10 imágenes por clase para garantizar equilibrio en la evaluación. La siguiente tabla muestra los resultados obtenidos:

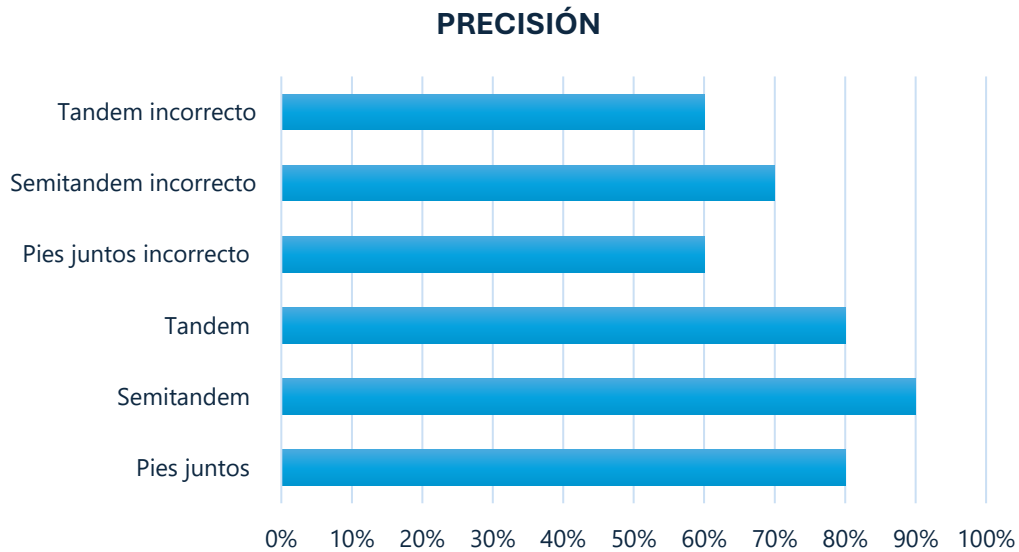


Ilustración 26: Gráfica de Precisión

Estos resultados indican que el modelo tiene un desempeño más robusto en la clasificación de posturas correctas (Pies Juntos, Semi-tándem y Tándem), todas con al menos un 80% de precisión. La postura Semi-tándem fue la mejor clasificada, alcanzando un 90% de precisión, lo que sugiere que el modelo identifica bien esta configuración corporal.

En contraste, las posturas incorrectas presentaron mayor dificultad para el modelo, particularmente Pies Juntos Incorrecto y Tándem Incorrecto, ambas con un 60% de precisión. Esto puede deberse a que las diferencias visuales entre posturas correctas e incorrectas son sutiles y pueden verse afectadas por variaciones en la iluminación, ángulos de cámara o características individuales de cada sujeto.

A pesar de estas dificultades, el rendimiento sigue siendo aceptable, especialmente considerando que las posturas incorrectas suelen ser más ambiguas. En este sentido, los resultados sugieren que el modelo es confiable para identificar correctamente las posturas funcionales, y podría mejorar aún más con un refuerzo en las clases con menor precisión o mediante técnicas adicionales como la segmentación de poses o análisis biomecánico.

5.8. MATRIZ DE CONFUSIÓN

La matriz de confusión obtenida permite identificar con mayor profundidad los aciertos y errores específicos del modelo en la clasificación de las posturas de la prueba SPPB. Esta herramienta proporciona una visualización detallada del comportamiento del modelo,

permitiendo analizar no solo los aciertos de los valores en la diagonal, sino también los errores de clasificación de los valores fuera de la diagonal.

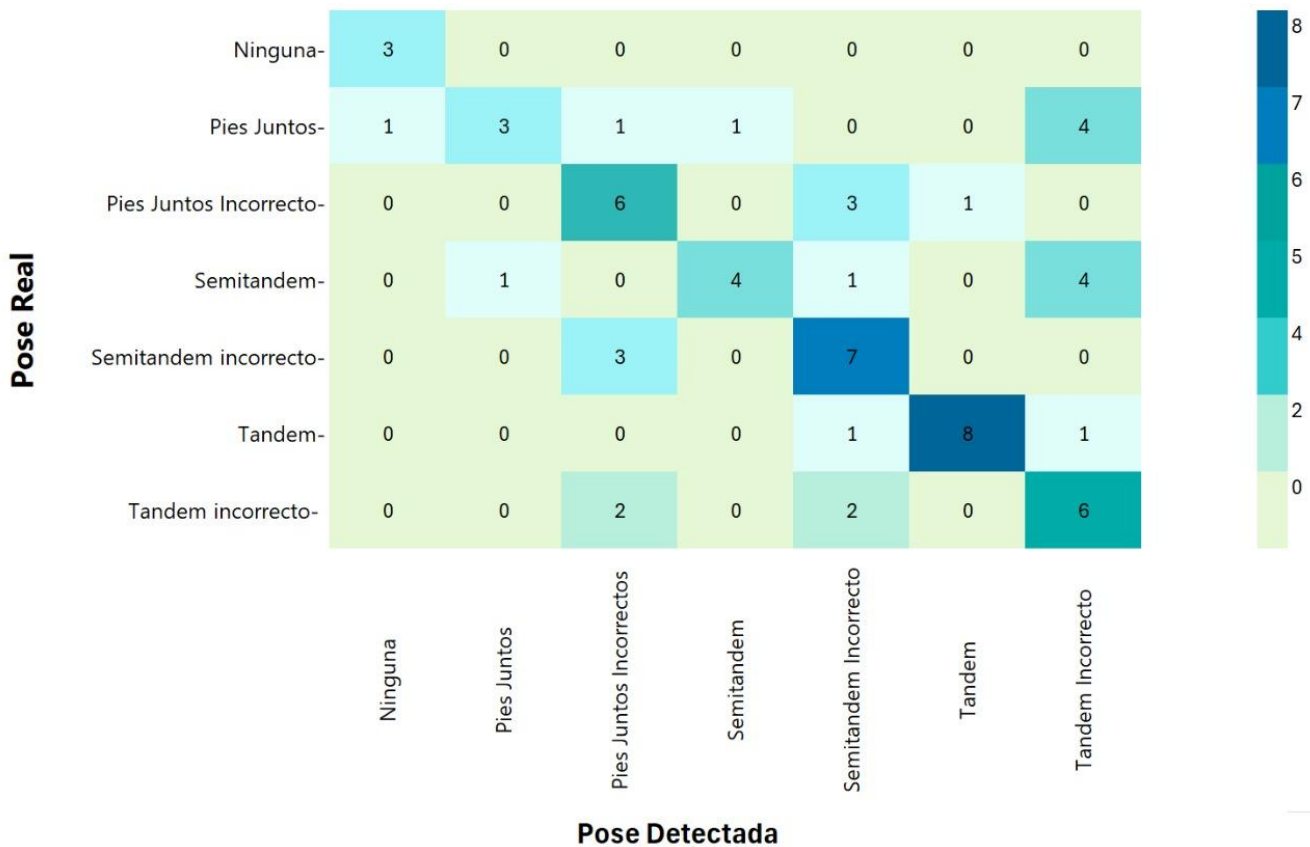


Ilustración 27: Matriz de Confusión de Pose real y detectadas.

De acuerdo con los resultados, las posturas Pies Juntos, Semitandem y Tandem presentaron un alto número de aciertos, con 8 o 9 de 10 imágenes clasificadas correctamente, lo cual se ve reflejado en las celdas diagonales correspondientes. Sin embargo, se observaron patrones recurrentes de confusión entre clases con similitudes visuales, lo cual sugiere que el modelo, si bien es efectivo, encuentra limitaciones al distinguir entre ciertos casos más sutiles.

Errores más significativos identificados:

Pies Juntos fue confundido en 5 ocasiones con Pies Juntos Incorrecto, y una vez con Semitandem, lo cual indica que pequeñas variaciones en el ángulo de separación de los pies o la postura general del cuerpo afectan la clasificación.

Semitandem fue confundida 4 veces con Semitandem Incorrecto, lo que sugiere que el modelo aún no generaliza completamente los criterios que definen una postura funcionalmente adecuada en esta categoría.

Tandem Incorrecto presentó una distribución más dispersa en sus errores, siendo confundido 3 veces como Pies Juntos Incorrecto y 2 veces como Semitandem Incorrecto, lo cual evidencia que el modelo puede interpretar mal el alineamiento de los pies cuando no es exacto, afectando la clasificación.

Se observaron pocos falsos positivos hacia posturas no presentes, lo que indica una buena capacidad del modelo para restringir su salida a las clases aprendidas.

Este tipo de confusiones puede atribuirse a la cercanía visual entre ciertas posturas, especialmente entre las versiones correctas e incorrectas de una misma clase. Estos resultados sugieren que la red tiene una representación interna adecuada de las posturas generales, pero que aún requiere mayor entrenamiento o refuerzo en los criterios diferenciales finos, especialmente en lo que respecta a la alineación precisa de los pies, separación y postura general del cuerpo.

5.9. PLAN DE IMPLEMENTACIÓN

Para facilitar la implementación del modelo en el entorno del CTB, se diseñó una propuesta técnica funcional pensada para integrarse dentro de una interfaz web. Esta interfaz permitirá al usuario cargar imágenes o videos desde un dispositivo, visualizar una vista previa y ejecutar el análisis con un solo clic. El procesamiento se realizará en un backend desarrollado en Python, donde se alojará el modelo YOLOv12 previamente entrenado. La respuesta del sistema mostrará la postura detectada y su nivel de confianza, con opción de visualizar la caja de predicción sobre la imagen.

El flujo técnico incluye herramientas como HTML, CSS y JavaScript para la parte visual, y FastAPI o Flask para la comunicación con el modelo. Además, se consideró la posibilidad de almacenar o exportar los resultados, asegurando compatibilidad con dispositivos móviles y buenas prácticas de privacidad, sin necesidad de guardar imágenes en el servidor. Este esquema técnico ofrece una solución práctica y escalable que podrá ser utilizada por el personal del CTB o integrarse fácilmente a otros sistemas clínicos o de investigación.

Tabla 6: Tabla de Plan de Implementación

COMPONENTE	FUNCIONALIDAD	FORMATO DE IMPLEMENTACIÓN TÉCNICA
CARGA DE IMAGEN/VIDEO	Permitir al usuario cargar imágenes o grabaciones del paciente	<input type="file"> en HTML5 + lectura de archivos con JavaScript (FileReader)
VISTA PREVIA DEL ARCHIVO	Mostrar al usuario la imagen/video cargado antes de procesarlo	Etiqueta o <video> con renderización dinámica en HTML y estilos con CSS
BOTÓN DE ANÁLISIS	Enviar el archivo al modelo para la detección de la postura	<button> con evento onClick() en JS que llama al backend mediante fetch() o axios.post()
PROCESAMIENTO DEL MODELO	Aplicar el modelo YOLOv12 entrenado para identificar la postura detectada	Backend en Python (FastAPI o Flask) usando PyTorch u ONNX para cargar el modelo
VISUALIZACIÓN DEL RESULTADO	Mostrar la clase detectada y la confianza (porcentaje)	Texto dinámico con <div> o <p> que se actualiza desde el backend con la respuesta del modelo
VISUALIZACIÓN GRÁFICA (OPCIONAL)	Dibujar la caja de predicción sobre la imagen/video	Canvas (<canvas> en HTML5) con coordenadas del bounding box usando JavaScript
REGISTRO DE RESULTADOS	Guardar resultados de detecciones anteriores para análisis posterior	LocalStorage (temporal), o almacenamiento en base de datos (ej. SQLite o MongoDB en backend)
OPCIÓN DE EXPORTAR RESULTADOS	Descargar la predicción o exportar en CSV o PDF	Botón que genera y descarga archivo .csv o .pdf usando jsPDF o librerías similares
COMPATIBILIDAD MÓVIL (RESPONSIVE)	Que funcione correctamente en tablets o celulares	CSS responsive (Flexbox/Grid) + Media Queries
SEGURIDAD Y ANONIMATO	Evitar almacenamiento permanente de imágenes o identificación de personas	No guardar archivos en servidor, procesar temporalmente en memoria, añadir aviso de privacidad

VI. DISCUSIÓN

Los resultados obtenidos en este trabajo evidencian el cumplimiento de los objetivos propuestos y la viabilidad de desarrollar un sistema automático de clasificación de posturas para el test de equilibrio SPPB, utilizando visión por computador y aprendizaje profundo. El enfoque metodológico permitió abordar cada etapa del proyecto desde la construcción de la base de datos, el entrenamiento del modelo y su posterior validación con una estructura técnica sólida y con fundamentos experimentales medibles.

En relación con el objetivo 3.2.1, se construyó una base de datos robusta con 1,577 imágenes, clasificadas en siete categorías: seis posturas (correctas e incorrectas) más una clase adicional de imágenes aleatorias (etiquetadas como "Ninguna"). El etiquetado fue realizado manualmente, asegurando la calidad y coherencia del conjunto de datos. Esta base se caracterizó por un equilibrio adecuado entre clases, alta resolución promedio de imágenes (8.29 MP), y una proporción consistente entre los subconjuntos de entrenamiento, validación y prueba. Esta estructura fue clave para garantizar un entrenamiento representativo y una posterior validación confiable.

Respecto al objetivo 3.2.2, el análisis comparativo entre los modelos YOLOv11, Roboflow 3.0 y YOLOv12 permitió seleccionar el modelo con mejor desempeño global. Aunque Roboflow mostró alta precisión y YOLOv11 destacó por su recall, el modelo YOLOv12 fue el más equilibrado, alcanzando un mAP de 91.7%, precisión de 79.8% y recall de 78.4%. Estas métricas, junto con la estabilidad observada en las curvas de entrenamiento y la reducción controlada de pérdidas, demuestran que el modelo logró aprender patrones posturales de forma generalizable y sin sobreajuste. La elección de YOLOv12 se fundamentó tanto en criterios cuantitativos como en la consistencia visual de los resultados observados.

En cuanto al objetivo 3.2.3, la validación del modelo mediante un conjunto de imágenes externas no utilizadas durante el entrenamiento permitió comprobar su capacidad de generalización. El sistema logró una precisión global del 71.43%, destacando un mejor desempeño en posturas correctas (Semitandem 90%) que, en incorrectas, lo cual es coherente con la ambigüedad visual que presentan estas últimas. La matriz de confusión reveló errores entre clases similares, sin embargo, el modelo clasificó correctamente todas las imágenes

irrelevantes como "Ninguna", evidenciando su capacidad para evitar falsos positivos y mantener la especificidad.

Los resultados indican que el sistema desarrollado tiene un rendimiento sólido y una aplicabilidad potencial en entornos reales. Aunque por razones éticas no fue posible validar directamente con personas mayores del Hospital de Getafe, se completaron pruebas controladas que demuestran la funcionalidad del modelo. Además, se diseñó un plan de implementación escalable, que permitirá continuar el proceso en cuanto se aprueben los protocolos necesarios.

El desarrollo de este sistema no solo cumple con los objetivos planteados, sino que también sienta las bases para futuras integraciones clínicas, aportando una herramienta tecnológica útil para la evaluación objetiva del equilibrio en adultos mayores, con potencial de ser implementada en contextos asistenciales, de investigación o rehabilitación.

VII. CONCLUSIONES

7.1. CONCLUSIÓN GENERAL

Se logró desarrollar un modelo basado en visión artificial para la evaluación automatizada y precisa del equilibrio en personas mayores, utilizando imágenes correspondientes a las posturas del test de balance del SPPB. El sistema fue entrenado, validado y mostró un desempeño confiable en la clasificación de posturas correctas e incorrectas, así como en la detección de imágenes irrelevantes. Además, se diseñó un plan de implementación enfocado en su futura integración clínica. Este proyecto constituye un aporte valioso al uso de tecnologías inteligentes en el ámbito de la salud y la evaluación funcional.

7.2. CONCLUSIONES ESPECIFICAS

- A. Se logró desarrollar una base de datos sólida y funcional, conformada por 1,577 imágenes, organizadas en 7 clases correspondientes a las posturas de la prueba de equilibrio del SPPB: Pies Juntos, Semitandem, Tandem y sus variantes incorrectas, además de la clase "Ninguna" que incluye imágenes irrelevantes para evaluar la robustez del modelo. Se generaron 1,579 anotaciones, con un promedio de 1 etiqueta por imagen, sin anotaciones faltantes ni ejemplos nulos. Las imágenes utilizadas tienen una resolución promedio de 8.29 megapíxeles, con una dimensión media de 2160 × 3840 píxeles, lo cual asegura alta calidad visual para el reconocimiento de posturas. La base de datos fue dividida en subconjuntos de entrenamiento, validación y prueba, garantizando un balance adecuado entre clases. Por ejemplo, la clase "Pies Juntos" contó con 150 imágenes para entrenamiento, 80 para validación y 23 para prueba; mientras que "Semitandem Incorrecto" tuvo 149 imágenes para entrenamiento, 77 imágenes para validación y 47 imágenes de prueba, respectivamente. Esta distribución permitió entrenar un modelo robusto y realizar una validación precisa y representativa.
- B. El entrenamiento del modelo de clasificación de posturas de la prueba de equilibrio del SPPB se completó exitosamente, cumpliendo con los objetivos técnicos establecidos. Se realizó una comparación estructurada entre tres modelos distintos: YOLOv12 (Modelo 1), YOLOv11 (Modelo 2) y Roboflow 3.0 (Modelo 3), evaluando métricas clave como precisión, recuperación y media de precisión promedio. Los

resultados mostraron que YOLOv12 obtuvo el mejor rendimiento global, alcanzando un mAP de 91.7%, una precisión del 79.8% y un recall del 78.4%, demostrando un equilibrio ideal entre detección y exactitud. En comparación, YOLOv11 presentó el recall más alto (89.6%) pero con baja precisión 60.5%, lo que implica un mayor número de falsos positivos. Por otro lado, Roboflow alcanzó la mejor precisión (90.4%) pero con un mAP más bajo 83.7% y una menor recuperación 78.7%, indicando una detección más limitada. Las gráficas de entrenamiento del Modelo 1 evidenciaron un comportamiento progresivo y estable, con mejoras sostenidas en las métricas de mAP50 y mAP50-95 y una reducción constante en las pérdidas, sin signos de sobreajuste. Estos resultados confirmaron la solidez del modelo en el aprendizaje de patrones posturales, lo cual lo posiciona como la opción más confiable para ser validada e implementada en entornos clínicos o experimentales.

- C. La validación del modelo se realizó exitosamente utilizando imágenes nuevas etiquetadas manualmente, incluyendo las seis posturas de la prueba SPPB y una clase adicional "Ninguna" para evaluar la detección de elementos fuera del dominio. El modelo alcanzó una precisión global del 71.43%, destacando un mejor desempeño en posturas correctas hasta 90% en comparación con las incorrectas 60–70%. La matriz de confusión reveló que los errores más comunes ocurrieron entre posturas visualmente similares, pero el modelo demostró una adecuada capacidad para evitar falsos positivos, clasificando correctamente las imágenes irrelevantes. Estos resultados confirman que el sistema es funcional y confiable para ser integrado en futuras aplicaciones clínicas, una vez se cuente con las autorizaciones correspondientes.

VIII. RECOMENDACIONES

1. Extender la validación del modelo con población real, especialmente personas mayores en entornos clínicos, una vez se cuente con la aprobación ética correspondiente, para evaluar su desempeño en condiciones prácticas.
2. Aumentar el número de muestras en las clases incorrectas, ya que presentan mayor variabilidad postural y tienden a generar más confusiones. Esto permitiría mejorar la capacidad del modelo para distinguir posturas visualmente similares.
3. Incorporar técnicas complementarias de análisis biomecánico, como estimación de poses o análisis de ángulos articulares, para reforzar la precisión del sistema en la clasificación de posturas sutiles o incorrectas.
4. Optimizar la interfaz de usuario para su integración en entornos clínicos, asegurando facilidad de uso, portabilidad y compatibilidad con distintos dispositivos.
5. Considerar el entrenamiento con datos en condiciones más diversas, incluyendo variaciones en iluminación, ángulos de cámara y diferentes contextos físicos, para aumentar la robustez del modelo ante condiciones no controladas.
6. Documentar e implementar una estrategia de actualización del modelo, que permita reentrenarlo con nuevas imágenes a lo largo del tiempo, a medida que se recopilen más datos reales en el entorno clínico.

IX. REFERENCIAS BIBLIOGRÁFICAS

1. Abud, T., Kounidas, G., Martin, K. R., Werth, M., Cooper, K., & Myint, P. K. (2022). Determinants of healthy ageing: A systematic review of contemporary literature. *Aging Clinical and Experimental Research*, 34(6), 1215. <https://doi.org/10.1007/s40520-021-02049-w>
2. Ahmed, N., Assadi, M., Zhang, Q., & Ahmed, A. A. (2023). Assessing impact of borehole field data's input parameters on hybrid deep learning models for heating and cooling forecasting: A local and global explainable AI analysis. *IOP Conference Series: Materials Science and Engineering*, 1294(1), 012056. <https://doi.org/10.1088/1757-899X/1294/1/012056>
3. Alshirbaji, T. A., Jalal, N. A., & Möller, K. (2020). A convolutional neural network with a two-stage LSTM model for tool presence detection in laparoscopic videos. *Current Directions in Biomedical Engineering*, 6(1). <https://doi.org/10.1515/cdbme-2020-0002>
4. Assi, S., Zhang, W., Carey, J., Deal, J., Huang, A., Oh, E., Martinez-Amezcuca, P., & Reed, N. (2023). The association of hearing loss with frailty among community-dwelling older adults: Findings from the National Health and Aging Trends Study. *The National Health and Aging Trends Study*, 23(754). <https://doi.org/10.1186/s12877-023-04465-1>
5. Banco Mundial. (2022). *Population ages 65 and above (% of total population)—Honduras*. World Bank Open Data. <https://data.worldbank.org>
6. Banning, L. B. D., Moumni, M. E., Visser, L., Leeuwen, B. L. van, Zeebregts, C. J., & Pol, R. A. (2021). Frailty leads to poor long-term survival in patients undergoing elective

vascular surgery. *Journal of Vascular Surgery*, 73(6), 2132-2139.e2.
<https://doi.org/10.1016/j.jvs.2020.10.088>

7. Bourahmoune, K., & Amagasa, T. (2019). *AI-powered Posture Training: Application of Machine Learning in Sitting Posture Recognition Using the LifeChair Smart Cushion*. 5808-5814.
8. C. -C. Hsiao, P. -C. Yu, R. -G. Lee, & H. Jiang. (2020). Deep-Learning LSTM Mechanism and Wearable Devices based Virtual Fitness-Coach Information System for Barbell Bench Press. *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 3880-3885. <https://doi.org/10.1109/SMC42975.2020.9283422>
9. Cao, X., Wang, X., Geng, X., Wu, D., & An, H. (2024). An Approach for Human Posture Recognition Based on the Fusion PSE-CNN-BiGRU Model. *Computer Modeling in Engineering & Sciences*, 140(1), 385-408. <https://doi.org/10.32604/cmescs.2024.046752>
10. Chang, S.-F., Cheng, C.-L., & Lin, H.-C. (2019). Frail Phenotype and Disability Prediction in Community-Dwelling Older People: A Systematic Review and Meta-Analysis of Prospective Cohort Studies. *Journal of Nursing Research*, 27(3), e28. <https://doi.org/10.1097/jnr.0000000000000299>
11. Chen, J., Wang, T., Fang, Z., & Wang, H. (2023). Research on elderly users' intentions to accept wearable devices based on the improved UTAUT model. *Frontiers in Public Health*, 10. <https://doi.org/10.3389/fpubh.2022.1035398>
12. Chen, S., Dunn, R., Jackson, M., Morley, N., & Sun, J. (2023, enero 25). *Frontiers | Frailty score and outcomes of patients undergoing vascular surgery and amputation: A systematic review and meta-analysis.*

<https://www.frontiersin.org/journals/cardiovascular-medicine/articles/10.3389/fcvm.2023.1065779/full>

- 13.** Chen, S.-H., Lee, C.-H., Jiang, B. C., & Sun, T.-L. (2021). Using a Stacked Autoencoder for Mobility and Fall Risk Assessment via Time–Frequency Representations of the Timed Up and Go Test. *Frontiers in Physiology*, *12*. <https://doi.org/10.3389/fphys.2021.668350>
- 14.** Chen, T., Ding, Z., & Li, B. (2022). Elderly Fall Detection Based on Improved YOLOv5s Network. *IEEE Access*, *10*, 91273-91282. <https://doi.org/10.1109/ACCESS.2022.3202293>
- 15.** Chu, W.-M., Kristiani, E., Wang, Y.-C., Lin, Y.-R., Lin, S.-Y., Chan, W.-C., Yang, C.-T., & Tsan, Y.-T. (2022). A model for predicting fall risks of hospitalized elderly in Taiwan-A machine learning approach based on both electronic health records and comprehensive geriatric assessment. *Frontiers in Medicine*, *9*. <https://doi.org/10.3389/fmed.2022.937216>
- 16.** Cruz, A. M., Monsalve, L., Ladurner, A.-M., Jaime, L. F., Wang, D., & Quiroga, D. A. (2021). *Information and Communication Technologies for Managing Frailty: A Systematic Literature Review*. <https://www.aginganddisease.org/EN/10.14336/AD.2020.1114>
- 17.** D. Rai, Anjali, A. Kumar, & A. Baghel. (2024). Pose Detection Using OpenCV and Media Pipe. *2024 International Conference on Integrated Circuits, Communication, and Computing Systems (ICIC3S)*, *1*, 1-6. <https://doi.org/10.1109/ICIC3S61846.2024.10603040>
- 18.** D’Isanto, T., Pisapia, F., & D’Elia, F. (2019). *Running and posture*. <https://doi.org/10.14198/jhse.2019.14.Proc4.68>

- 19.**Duan, T., Punpongsanon, P., Iwai, D., & SatoKosuke. (2018). *FlyingHand: Extending the range of haptic feedback on virtual hand using drone-based object recognition*. 28, 1-4. <https://doi.org/10.1145/3283254.3283258>
- 20.**Felius, R. A. W., Geerars, M., Bruijn, S. M., van Dieën, J. H., Wouda, N. C., & Punt, M. (2022). Reliability of IMU-Based Gait Assessment in Clinical Stroke Rehabilitation. *Sensors*, 22(3). <https://doi.org/10.3390/s22030908>
- 21.**Fried, L. P., Ferrucci, L., Darer, J., Williamson, J. D., & Anderson, G. (2019). Untangling the concepts of disability, frailty, and comorbidity: Implications for improved targeting and care. *The journals of gerontology. Series A, Biological sciences and medical science*, 59(3), 255-263. <https://doi.org/10.1093/gerona/59.3.m255>
- 22.**Fried, L. P., Tangen, C. M., Walston, J., Newman, A. B., Hirsch, C., Gottdiener, J., Seeman, T., Tracy, R., Kop, W. J., Burke, G., McBurnie, M. A., & Cardiovascular Health Study Collaborative Research Group. (2001). Frailty in older adults: Evidence for a phenotype. *The Journals of Gerontology. Series A, Biological Sciences and Medical Sciences*, 56(3), M146-156. <https://doi.org/10.1093/gerona/56.3.m146>
- 23.**Guralnik, J. M., Simonsick, E. M., Ferrucci, L., Glynn, R. J., Berkman, L. F., Blazer, D. G., Scherr, P. A., & Wallace, R. B. (2018). A Short Physical Performance Battery Assessing Lower Extremity Function: Association With Self-Reported Disability and Prediction of Mortality and Nursing Home Admission. *Journal of Gerontology*, 49(2), M85-M94. <https://doi.org/10.1093/geronj/49.2.M85>
- 24.**Ha, V.-A. T., Nguyen, T. N., Nguyen, T. X., Nguyen, H. T. T., Nguyen, T. T. H., Nguyen, A. T., Pham, T., & Vu, H. T. T. (2021). Prevalence and Factors Associated with Falls among

Older Outpatients. *International Journal of Environmental Research and Public Health*, 18(8), 4041. <https://doi.org/10.3390/ijerph18084041>

- 25.** Hakansson, F., & Jensen, D. B. (2023, enero 11). *Frontiers | Automatic monitoring and detection of tail-biting behavior in groups of pigs using video-based deep learning methods.* <https://www.frontiersin.org/journals/veterinary-science/articles/10.3389/fvets.2022.1099347/full>
- 26.** Haugen, C. E., Agoons, D., Chu, N. M., Liyanage, L., Long, J., Desai, N. M., Norman, S. P., Brennan, D. C., Segev, D. L., & McAdams-DeMarco, M. (2020). Physical Impairment and Access to Kidney Transplantation. *Transplantation*, 104(2). https://journals.lww.com/transplantjournal/fulltext/2020/02000/physical_impairment_and_access_to_kidney.26.aspx
- 27.** Hu, Z., Zhang, C., Wang, X., & Ge, A. (2024). Light-Adaptive Human Body Key Point Detection Algorithm Based on Multi-Source Information Fusion. *Sensors*, 24(10). <https://doi.org/10.3390/s24103021>
- 28.** Hudec, R., Matúška, S., Kamencay, P., & Benco, M. (2021). A Smart IoT System for Detecting the Position of a Lying Person Using a Novel Textile Pressure Sensor. *Sensors*, 21(1). <https://doi.org/10.3390/s21010206>
- 29.** Hwang, B.-J., Chen, H.-H., Hsieh, C.-H., & Huang, D.-Y. (2022). Gaze Tracking Based on Concatenating Spatial-Temporal Features. *Sensors*, 22(2). <https://doi.org/10.3390/s22020545>
- 30.** IHME. (2021). *Honduras | Institute for Health Metrics and Evaluation.* <https://www.healthdata.org/research-analysis/health-by-location/profiles/honduras>

- 31.**INE. (2021). *INE. Instituto Nacional de Estadística*. INE. <https://www.ine.es/>
- 32.**Islam, R., Rahman, R., Ahmed, A., & Jany, R. (2022). *NFS: A Hand Gesture Recognition Based Game Using MediaPipe and PyGame*. <https://doi.org/10.48550/arXiv.2204.11119>
- 33.**Izquierdo, M. (2017). *Promoción del Ejercicio físico para la prevención de la fragilidad y las caídas en las personas mayores: VIVIFRAIL*. <http://www.vivifrail.com/es/>
- 34.**Izquierdo, M., Casas-Herrera, A., Zambom-Ferraresi, F., Martínez-Velilla, N., Alonso-Bouzón, C., & Rodríguez-Mañas, L. (2017). *Programa de Ejercicio Físico Multicomponente Vivifrail*. Ebook. <https://vivifrail.com/wp-content/uploads/2019/11/VIVIFRAILESP-Interactivo.pdf>
- 35.**Jang, I.-Y., Lee, E., Lee, H., Park, H., Kim, S., Kim, K., Jung, H.-W., & Kim, D. H. (2020). Characteristics of sarcopenia by European consensus and a phenotype score. *Journal of Cachexia, Sarcopenia and Muscle*, 11(2), 497-504. <https://doi.org/10.1002/jcsm.12507>
- 36.**Jiang, X., Hu, Z., Wang, S., & Zhang, Y. (2023). A Survey on Artificial Intelligence in Posture Recognition. *Computer Modeling in Engineering & Sciences*, 137(1), 35-82. <https://doi.org/10.32604/cmescs.2023.027676>
- 37.**Jung, J.-Y., Heo, M., & Kim, J.-J. (2020). Effects of a Personalized Exercise Rehabilitation Device on Dynamic Postural Balance for Scoliotic Patients: A Feasibility Study. *Electronics*, 9(12). <https://doi.org/10.3390/electronics9122100>
- 38.**K. Aarthy & A. A. Nithys. (2023). Yoga Pose Detection and Identification Using MediaPipe and OpenPose Model. *2023 International Conference on Computer Science*

and Emerging Technologies (CSET), 1-7.
<https://doi.org/10.1109/CSET58993.2023.10346786>

- 39.** Kawakura, S. (2018). Visual Data Analysis Methods Using OpenCV Programs to Evaluate Walking and Falling with a Japanese Walking Support System. *International Journal of Bioscience, Biochemistry and Bioinformatics*, 8, 20-31.
<https://doi.org/10.17706/ijbbb.2018.8.1.20-31>
- 40.** Kim, W., Jin, B., Choo, S., Nam, C. S., & Yun, M. H. (2019). Designing of smart chair for monitoring of sitting posture using convolutional neural networks. *Data Technologies and Applications*, 53(2), 142-155. <https://doi.org/10.1108/DTA-03-2018-0021>
- 41.** Kimber, D. E., Kehler, D. S., Lytwyn, J., Boreskie, K. F., Jung, P., Alexander, B., Hiebert, B. M., Dubiel, C., Hamm, N. C., Stammers, A. N., Clarke, M., Fraser, C., Pedreira, B., Tangri, N., Hay, J. L., Arora, R. C., & Duhamel, T. A. (2018). Pre-Operative Frailty Status Is Associated with Cardiac Rehabilitation Completion: A Retrospective Cohort Study. *Journal of Clinical Medicine*, 7(12), Article 12. <https://doi.org/10.3390/jcm7120560>
- 42.** Kinel, E., D'Amico, M., & Roncoletta, P. (2021). 3D Quantitative Evaluation of Posture and Spine Proprioceptive Perception Through Instinctive Self-Correction Maneuver in Adolescent Idiopathic Scoliosis. *Frontiers in Bioengineering and Biotechnology*, 9.
<https://doi.org/10.3389/fbioe.2021.663394>
- 43.** Kishore, D. M., Bindu, S., & Manjunath, N. K. (2022). Smart Yoga Instructor for Guiding and Correcting Yoga Postures in Real Time. *International Journal of Yoga*, 15(3).
https://journals.lww.com/ijoy/fulltext/2022/15030/smart_yoga_instructor_for_guiding_and_correcting.12.aspx

- 44.** Kusunose, M., Inui, A., Nishimoto, H., Mifune, Y., Yoshikawa, T., Shinohara, I., Furukawa, T., Kato, T., Tanaka, S., & Kuroda, R. (2023). Measurement of Shoulder Abduction Angle with Posture Estimation Artificial Intelligence Model. *Sensors*, 23(14). <https://doi.org/10.3390/s23146445>
- 45.** Landi, F., Sieber, C., Fielding, R. A., Rolland, Y., & Guralnik, J. (2018). Nutritional Intervention in Sarcopenia: Report from the International Conference on Frailty and Sarcopenia Research Task Force. *The Journal of Frailty & Aging*, 7(4), 247-252. <https://doi.org/10.14283/jfa.2017.26>
- 46.** Larsson, L., Degens, H., Li, M., Salviati, L., Lee, Y. il, Thompson, W., Kirkland, J. L., & Sandri, M. (2018). Sarcopenia: Aging-Related Loss of Muscle Mass and Function. *Physiological Reviews*, 99(1), 427. <https://doi.org/10.1152/physrev.00061.2017>
- 47.** Lascano, D., Pak, J. S., Kates, M., Finkelstein, J. B., Silva, M., Hagen, E., RoyChoudhury, A., Bivalacqua, T. J., DeCastro, G. J., Benson, M. C., & McKiernan, J. M. (2015). Validation of a frailty index in patients undergoing curative surgery for urologic malignancy and comparison with other risk stratification tools. *Urologic Oncology: Seminars and Original Investigations*, 33(10), 426.e1-426.e12. <https://doi.org/10.1016/j.urolonc.2015.06.002>
- 48.** Lee, D.-W., Jun, K., Naheem, K., & Kim, M. S. (2021). Deep Neural Network–Based Double-Check Method for Fall Detection Using IMU-L Sensor and RGB Camera Data. *IEEE Access*, 9, 48064-48079. <https://doi.org/10.1109/ACCESS.2021.3065105>
- 49.** Liaqat, S., Dashtipour, K., Arshad, K., Assaleh, K., & Ramzan, N. (2021). A Hybrid Posture Detection Framework: Integrating Machine Learning and Deep Neural Networks. *IEEE*

Sensors Journal, 21(7), 9515-9522. IEEE Sensors Journal.
<https://doi.org/10.1109/JSEN.2021.3055898>

50. M. D. Korableva & Y. A. Bekeneva. (2024). Evaluation of Physical Exercise Performance Using Deep Learning Methods. *2024 V International Conference on Neural Networks and Neurotechnologies (NeuroNT)*, 93-95.
<https://doi.org/10.1109/NeuroNT62606.2024.10585349>

51. M. S. Rahman, K. A. Shams, M. R. Reaz, M. R. U. Rafi, S. Islam, R. Rahman, M. T. Reza, M. Z. Parvez, S. Chakraborty, B. Pradhan, & A. Alamri. (2024). MultiModal Ensemble Approach Leveraging Spatial, Skeletal, and Edge Features for Enhanced Bangla Sign Language Recognition. *IEEE Access*, 12, 83638-83657.
<https://doi.org/10.1109/ACCESS.2024.3410837>

52. M. Shah, K. Gandhi, B. M. Pandhi, P. Padhiyar, & S. Degadwala. (2023). Computer Vision & Deep Learning based Realtime and Pre-Recorded Human Pose Estimation. *2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, 313-319. <https://doi.org/10.1109/ICAAIC56838.2023.10141279>

53. Ma, B., Yang, J., Wong, F. K. Y., Wong, A. K. C., Ma, T., Meng, J., Zhao, Y., Wang, Y., & Lu, Q. (2023). Artificial intelligence in elderly healthcare: A scoping review. *Ageing Research Reviews*, 83, 101808. <https://doi.org/10.1016/j.arr.2022.101808>

54. Mansoor, B., Afifi, S., GholamHosseini, H., & Mirza, F. (2019). A Systematic Review of Wearable Sensors and IoT-Based Monitoring Applications for Older Adults – a Focus on Ageing Population and Independent Living. *Journal of Medical Systems*, 43(233).
<https://doi.org/10.1007/s10916-019-1365-7>

- 55.** Meier, N. F., & Lee, D.-C. (2020). Physical activity and sarcopenia in older adults. *Aging Clinical and Experimental Research*, *32*(9), 1675-1687. <https://doi.org/10.1007/s40520-019-01371-8>
- 56.** Menassa, M., Stronks, K., Khatmi, F., Díaz, Z. M. R., Espinola, O. P., Gamba, M., Itodo, O. A., Buttia, C., Wehrli, F., Minder, B., Velarde, M. R., & Franco, O. H. (2023). Concepts and definitions of healthy ageing: A systematic review and synthesis of theoretical models. *eClinicalMedicine*, *56*, 101821. <https://doi.org/10.1016/j.eclinm.2022.101821>
- 57.** Ministerio de Sanidad. (2020, noviembre 27). *Ministerio de Sanidad—Áreas—Envejecimiento saludable y prevención de fragilidad*. <https://www.sanidad.gob.es/areas/promocionPrevencion/envejecimientoSaludable/home.htm>
- 58.** N. Iqbal, M. Hanif, S. Abbas, M. A. Khan, S. H. Almotiri, & M. A. Al Ghamdi. (2020). DNA Strands Level Scrambling Based Color Image Encryption Scheme. *IEEE Access*, *8*, 178167-178182. <https://doi.org/10.1109/ACCESS.2020.3025241>
- 59.** Namba, T., & Yamada, Y. (2018). Fall Risk Reduction for the Elderly by Using Mobile Robots Based on Deep Reinforcement Learning. *Journal of Robotics, Networking and Artificial Life*, *4*(4), 265. <https://doi.org/10.2991/jrnal.2018.4.4.2>
- 60.** Nasirahmadi, A., Sturm, B., Edwards, S., Jeppsson, K.-H., Olsson, A.-C., Müller, S., & Hensel, O. (2019). Deep Learning and Machine Vision Approaches for Posture Detection of Individual Pigs. *Sensors*, *19*(17). <https://doi.org/10.3390/s19173738>
- 61.** Ofori-Asenso, R., Chin, K. L., Mazidi, M., Zomer, E., Ilomaki, J., Zullo, A. R., Gasevic, D., Ademi, Z., Korhonen, M. J., LoGiudice, D., Bell, J. S., & Liew, D. (2019). Global Incidence

of Frailty and Prefrailty Among Community-Dwelling Older Adults: A Systematic Review and Meta-analysis. *JAMA Network Open*, 2(8), e198398-e198398. <https://doi.org/10.1001/jamanetworkopen.2019.8398>

- 62.** Oh, G., Lee, H., Park, C. M., Jung, H.-W., Lee, E., Jang, I.-Y., Guralnik, J. M., & Kim, D. H. (2021). Long-term effect of a 24-week multicomponent intervention on physical performance and frailty in community-dwelling older adults. *Age and Ageing*, 50(6), 2157-2166. <https://doi.org/10.1093/ageing/afab149>
- 63.** Olalla, A. B. (2022, septiembre 10). La SPPB, paso a paso. *Fisioterapia para fisioterapeutas y pacientes - lafisioterapia.net*. <https://lafisioterapia.net/la-sppb-paso-a-paso/>
- 64.** OMS. (2021, abril 26). *Falls*. <https://www.who.int/news-room/fact-sheets/detail/falls>
- 65.** OMS. (2022). *Global strategy and action plan on ageing and health*. <https://www.who.int/publications/i/item/9789241513500>
- 66.** O'Reilly, M. A., Whelan, D. F., Ward, T. E., Delahunt, E., & Caulfield, B. (2017). *Classification of lunge biomechanics with multiple and individual inertial measurement units*. 16(3). <https://doi.org/10.1080/14763141.2017.1314544>
- 67.** Organización Mundial de la Salud. (2015). *Informe mundial sobre el envejecimiento y la salud*. Organización Mundial de la Salud. <https://iris.who.int/handle/10665/186466>
- 68.** 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*, 21(9), Article 9. <https://doi.org/10.3390/s21093258>

- 69.**Paulauskaite-Taraseviciene, A., Siaulyis, J., Sutiene, K., Petravicius, T., Navickas, S., Oliandra, M., Rapalis, A., & Balciunas, J. (2023). Geriatric Care Management System Powered by the IoT and Computer Vision Techniques. *MDPI*, *11*. <https://doi.org/10.3390/healthcare11081152>
- 70.**Piculell, E., Skär, L., Sanmartin Berglund, J., Anderberg, P., & Bohman, D. (2021). A concept analysis of health communication in a home environment: Perspectives of older persons and their informal caregivers. *Scandinavian Journal of Caring Sciences*, *35*(3), 1006-1024. <https://doi.org/10.1111/scs.12928>
- 71.**Reyes Leiva, K. M., Gato, M. Á., & Olmedo, J. J. (2023). Estimation of Spatio-Temporal Parameters of Gait and Posture of Visually Impaired People Using Wearable Sensors. *Sensors*, *23*(12). <https://doi.org/10.3390/s23125564>
- 72.**Ruan, Y., Guo, Y., Kowal, P., Lu, Y., Liu, C., Sun, S., Huang, Z., Zheng, Y., Wang, W., Li, G., Shi, Y., & Wu, F. (2019). *Association between anemia and frailty in 13,175 community-dwelling adults aged 50 years and older in China*. Research Square. <https://doi.org/10.21203/rs.2.13089/v3>
- 73.**Shang, L., Zhang, Z., Tang, F., Cao, Q., Pan, H., & Lin, Z. (2023). CNN-LSTM Hybrid Model to Promote Signal Processing of Ultrasonic Guided Lamb Waves for Damage Detection in Metallic Pipelines. *Sensors*, *23*(16). <https://doi.org/10.3390/s23167059>
- 74.**Silva, M. G., Pilling, B. M., & Candotti, C. T. (2023). Body posture self-assessment tools: A scoping review. *Fisioterapia e Pesquisa*, *30*, e22017823en. <https://doi.org/10.1590/1809-2950/e22017823en>

- 75.** Singer, J. P., Gao, Y., Huang, C.-Y., Kordahl, R. C., Sriram, A., Hays, S. R., Kukreja, J., Venado, A., Calabrese, D. R., & Greenland, J. R. (2023). The Association Between Frailty and Chronic Lung Allograft Dysfunction After Lung Transplantation. *Transplantation*, *107*(10), 2255. <https://doi.org/10.1097/TP.0000000000004672>
- 76.** SIPSA. (2023, noviembre 29). (8) ¿Qué es V-Model? | LinkedIn. <https://www.linkedin.com/pulse/qu%C3%A9-es-v-model-servicios-de-informatica-profesion-qotgf/>
- 77.** Szychowska, A., & Drygas, W. (2021). Physical activity as a determinant of successful aging: A narrative review article. *Aging Clinical and Experimental Research*, *34*(6), 1209. <https://doi.org/10.1007/s40520-021-02037-0>
- 78.** Tao, Y., Shi, J., Wang, L., Chen, S., Zhou, Z., Meng, L., Zhou, B., Duan, C., Xi, H., & Yu, P. (2023). Combined effect of diabetes and frailty on mortality among Chinese older adults: A follow-up study. *Frontiers in Endocrinology*, *13*. <https://doi.org/10.3389/fendo.2022.1105957>
- 79.** Theou, O., Andrew, M., Ahip, S. S., Squires, E., McGarrigle, L., Blodgett, J. M., Goldstein, J., Hominick, K., Godin, J., Hougan, G., Armstrong, J. J., Wallace, L., Sazlina, S. G., Moorhouse, P., Fay, S., Visvanathan, R., & Rockwood, K. (2019). The Pictorial Fit-Frail Scale: Developing a Visual Scale to Assess Frailty. *Canadian Geriatrics Journal*, *22*(2), Article 2. <https://doi.org/10.5770/cgj.22.357>
- 80.** United Nations. (2020). World Population Ageing 2020 Highlights. *Departmente of Economic and Social Affairs*.

- 81.** V. Arya, N. Makattil, V. Sasikumar, V. Anuparvathi, & S. Khandare. (2023). Know Your Posture: Real Time Posture Detection and Correction with Yoga and Exercise Recommendations. *2023 International Conference on Signal Processing, Computation, Electronics, Power and Telecommunication (IConSCEPT)*, 1-4. <https://doi.org/10.1109/IConSCEPT57958.2023.10170654>
- 82.** Villalba, E., De Antonio Jiménez, A., & Laosa Zafra, O. (2022). *Ecosistema computacional con apoyo motivacional y evaluación funcional para un programa autónomo de ejercicio para un envejecimiento saludable (MOTIVA)*. Ministerio de Ciencia e Innovación. <http://ageinglab.ctb.upm.es/>
- 83.** W. Chen, S. Zhang, C. Chen, & Y. Liu. (2022). Human deep squat detection method based on MediaPipe combined with Yolov5 network. *2022 41st Chinese Control Conference (CCC)*, 6404-6409. <https://doi.org/10.23919/CCC55666.2022.9902631>
- 84.** Wang, C., Ravi, D., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G.-Z. (2017). Deep Learning for health informatics. *IEEE Journal of Biomedical and Health Informatics*. <https://doi.org/10.1109/JBHI.2016.2636665>
- 85.** Wang, F. (2022). Yolov5-based fall detection algorithm for homebound people. *Frontiers in Computing and Intelligent Systems*, 1(2), Article 2. <https://doi.org/10.54097/fcis.v1i2.1624>
- 86.** Wang, S., Zhang, J., Zhang, X., Han, X., Chen, J., Hong, Z., Wang, C., & Zhao, H. (2024). Lightweight fall detection system based on Orangepi 5B. *Ninth International Symposium on Sensors, Mechatronics, and Automation System (ISSMAS 2023)*, 12981, 539-544. <https://doi.org/10.1117/12.3015158>

- 87.**WHO. (2024, junio 26). *Physical activity*. <https://www.who.int/news-room/factsheets/detail/physical-activity>
- 88.**Y. Li, W. Zhang, H. Ma, F. Chen, D. Sun, X. Cheng, Y. Zheng, Z. Wang, & S. Cai. (2023). Posture Detection Based on Kinect and YOLO Technologies. *2023 5th International Conference on Robotics, Intelligent Control and Artificial Intelligence (RICA)*, 205-209. <https://doi.org/10.1109/RICA160863.2023.10489539>
- 89.**Yeh, Shen, W.-C., Ma, C.-W., Yeh, Q.-T., Kuo, C.-W., & Chen, J.-S. (2023). Real-time Human Movement Recognition and Interaction in Virtual Fitness using Image Recognition and Motion Analysis. *2023 12th International Conference on Awareness Science and Technology (iCAST)*, 242-246. <https://doi.org/10.1109/iCAST57874.2023.10359266>
- 90.**Zadworna, M. (2022). Pathways to healthy aging – Exploring the determinants of self-rated health in older adults. *Acta Psychologica*, 228, 103651. <https://doi.org/10.1016/j.actpsy.2022.103651>
- 91.**Zahedian-Nasab, N., Jaber, A., Shirazi, F., & Kavousipor, S. (2021). Effect of virtual reality exercises on balance and fall in elderly people with fall risk: A randomized controlled trial. *BMC Geriatrics*, 21(1), 509. <https://doi.org/10.1186/s12877-021-02462-w>
- 92.**Zeng, Z., Liu, Y., Hu, X., Tang, M., & Wang, L. (2022). Validity and Reliability of Inertial Measurement Units on Lower Extremity Kinematics During Running: A Systematic Review and Meta-Analysis. *Sports Medicine - Open*, 8(1), 86. <https://doi.org/10.1186/s40798-022-00477-0>

ANEXOS

Anexo 1 Prueba de Batería corta de desempeño físico

Batería corta de desempeño físico (SPPB)

1. Prueba de balance		
	A. Pararse con los pies uno al lado del otro ¿Mantuvo la posición al menos por 10 segundos? Si el participante no logró completarlo, finaliza la prueba de balance.	Sí <input type="checkbox"/> (1 punto) No <input type="checkbox"/> (0 punto) Se rehúsa <input type="checkbox"/>
	B. Pararse en posición semi-tándem ¿Mantuvo la posición al menos por 10 segundos? Si el participante no logró completarlo, finaliza la prueba de balance.	Sí <input type="checkbox"/> (1 punto) No <input type="checkbox"/> (0 puntos) Se rehúsa <input type="checkbox"/>
	C. Pararse en posición tándem ¿Mantuvo la posición al menos por 10 segundos? Tiempo en seg _____ (máx. 15)	Sí <input type="checkbox"/> (2 punto) Sí <input type="checkbox"/> (1 punto) No <input type="checkbox"/> (0 punto) Se rehúsa <input type="checkbox"/>
<input type="checkbox"/> 0= <3.0 seg o no lo intenta. <input type="checkbox"/> 1= 3.0 a 9.99 seg. <input type="checkbox"/> 2= 10 a 15 seg.		SUBTOTAL Puntos: /4
2. Velocidad de marcha (recorrido de 4 metros)		
	A. Primera medición Tiempo requerido para recorrer la distancia Si el participante no logró completarlo, finaliza la prueba.	Seg: <input type="checkbox"/> Se rehúsa <input type="checkbox"/>
	B. Segunda medición Tiempo requerido para recorrer la distancia Si el participante no logró completarlo, finaliza la prueba.	Seg: <input type="checkbox"/> Se rehúsa <input type="checkbox"/>
Calificación de la medición menor. <input type="checkbox"/> 1= >8.70 seg. <input type="checkbox"/> 2= 6.21 a 8.70 seg. <input type="checkbox"/> 3= 4.82 a 6.20 seg. <input type="checkbox"/> 4= <4.82 seg.		SUBTOTAL Puntos: /4
3. Prueba de levantarse cinco veces de una silla		
	A. Prueba previa (no se califica, sólo para decidir si pasa a B) ¿El paciente se levanta sin apoyarse en los brazos? Si el participante no logró completarlo, finaliza la prueba.	Sí <input type="checkbox"/> No <input type="checkbox"/> Se rehúsa <input type="checkbox"/>
	B. Prueba repetida de levantarse de una silla Tiempo requerido para levantarse cinco veces de una silla	Seg: <input type="checkbox"/> Se rehúsa <input type="checkbox"/>
Calificación de la actividad. 0= Incapaz de realizar cinco repeticiones o tarda > 60 seg 1= 16.7 a 60 seg. 2= 13.7 a 16.69 seg. 3= 11.2 a 13.69 seg 4= < o igual 11.19 seg		SUBTOTAL Puntos: /4
TOTAL BATERÍA CORTA DE DESEMPEÑO FÍSICO (1+2+3)/12		Puntos: /12

Ilustración 28: Prueba de batería corta de desempeño físico (SPPB)

Anexo 2 Consentimiento Informado

Proyecto MOTIVA: Ecosistema computacional con apoyo motivacional y evaluación funcional para un programa autónomo de ejercicio para un envejecimiento saludable

Investigador Principal: Dr. Ricardo Imbert Paredes

Teléfono de contacto:

Yo, (**nombre y apellidos del participante**)

Declaro que:

He leído la hoja de información que me han facilitado.

He podido formular las preguntas que he considerado necesarias acerca del estudio.

He recibido información adecuada y suficiente sobre el estudio.

He hablado con (**nombre del investigador**).

Comprendo que autorizo de forma voluntaria que mi imagen sea grabada.

Comprendo que puedo retirar mi autorización para que mi imagen sea grabada:

- Cuando quiera,
- Sin tener que dar explicaciones,
- Sin que esto repercuta en mis cuidados médicos,
- Sin que esto me excluya de participar en el estudio.

Presto libremente mi conformidad para que mi imagen pueda ser grabada en soporte audiovisual.

Nombre y apellidos del participante:

Firma:

Fecha:

Nombre investigador

Firma del investigador

Ilustración 29: Carta de consentimiento informado

Anexo 3 Estructura de la base de datos

Base de datos de participantes del SPPB						
ID de participante	Nombre	Edad	Altura	Género	Duración de tiempo	
SPPB-MU-001	Sofía Latge	27	1.67	Femenino	Pies juntos	
					Semi-tandem	
					Tandem	
					Pies juntos brazos cruzados	
					Semitandem manos en la cadera	
					Tandem desequilibrándose	
SPPB-MU-002	Daria	26	1.58	Femenino	Pies juntos	
					Semi-tandem	
					Tandem	
					Pies juntos brazos cruzados	
					Semitandem manos en la cadera	
					Tandem desequilibrándose	
SPPB-MU-003	Margaux	25	1.68	Femenino	Pies juntos	
					Semi-tandem	
					Tandem	
					Pies juntos brazos cruzados	
					Semitandem manos en la cadera	
					Tandem desequilibrándose	
					Pies juntos	
					Semi-tandem	
					Tandem	

Ilustración 30: Tabla para hacer las pruebas de SPPB para cada participante

Anexo 5 Personas realizando los ejercicios



Ilustración 31: Pies juntos



Ilustración 32: Semi- tandem



Ilustración 33: Tándem



Ilustración 34: Tándem incorrecto



Ilustración 35: Semi-tándem incorrecto



Ilustración 36: Pies juntos incorrectos



Ilustración 37: Imágenes sin clasificación, Árbol



Ilustración 38: Imágenes sin clasificación, Palillos



Ilustración 39: Imágenes sin clasificación, Perro



Ilustración 40: Imágenes sin clasificación, kiwi