



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Doctorado en Mecatrónica



Sistema inteligente de pronóstico para la rehabilitación de pacientes
con lesiones de extremidades inferiores

Tesis

Que como parte de los requisitos para obtener el grado de
Doctor en Mecatrónica

Presenta

M. en C. Rogelio Cedeño Moreno

Dirigido por:

Dr. Irving Armando Cruz Albarrán

Codirigido por:

Dr. Luis Alberto Morales Hernández

Dr. Irving Armando Cruz Albarrán

Presidente

Dr. Luis Alberto Morales Hernández

Secretario

Dr. Juan Primo Benítez Rangel

Vocal

Dr. Emmanuel Reséndiz Ochoa

Suplente

Dra. Arely Guadalupe Morales Hernández

Suplente

San Juan del Río, Qro.

22 de agosto del 2025

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciatario no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:

 **Atribución** — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciatario.

 **NoComercial** — Usted no puede hacer uso del material con [propósitos comerciales](#).

 **SinDerivadas** — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.

Dedicatoria

Dedicado a mi abuelito
Rogelio Cedeno Ledesma

El mejor profesor que esta vida me podría dar
que con simples pláticas me has dejado lecciones
que continuarán resonando en cada decisión y en
cada pensamiento.

A ti te dedico este esfuerzo y cada
logro presente y futuro.

Agradecimientos

Me gustaría agradecer a todas las personas que me han acompañado durante mi desarrollo profesional y personal, comenzando con mi familia que me ha dado su completo apoyo durante este largo camino y quienes me han amenazado de que sea mi ultima titulación. Agradezco a mi novia Nadia que en todo momento me ha incentivado con su amor y paciencia, incluso en las situaciones más difíciles cuando dudaba de mis propias capacidades. Y agradezco a mis amigos que pareciera que me han acompañado toda una vida y espero que pueda seguir celebrando y compartiendo cada logro tanto los míos como los de ellos, y también a los nuevos amigos que he hecho durante el camino a quienes les deseo el éxito y espero poder seguir contando por mucho tiempo con su amistad.

Agradezco a los doctores e investigadores que me han asistido no solo durante la elaboración de este proyecto sino durante todo mi desarrollo académico, comenzando por mi director de tesis el Dr. Irving Armando Cruz Albarrán y mi codirector el Dr. Luis Alberto Morales Hernández, quienes me han apoyado desde la licenciatura y me han incentivado a tomar nuevos retos, siempre con el fin de aportar a mi desarrollo como ingeniero e investigador y aportarme de nuevas experiencias. También agradezco a los miembros del sínodo, el Dr. Juan Primo Benítez Rangel, el Dr. Emmanuel Reséndiz Ochoa, la Dra. Arely Guadalupe Morales Hernández y un agradecimiento especial al Dr. Roque Alfredo Osornio Ríos quienes dejaron una impresión de admiración de lo que representa ser un investigador y profesor. Y a la Maestra Mayra P. Gonzalez-Hernandez y al personal de la clínica SUAF del campus corregidora y CU de la UAQ les agradezco su constante apoyo para la realización de pruebas y asistencia con pacientes.

Agradezco al sistema CONAHCYT por apoyarme con los recursos de la beca de posgrado a nivel doctorado, a la Universidad Autónoma de Querétaro por su apoyo a través de los programas FOPER (FOPER-2021-FEN02370) y en apoyo para la realización de la estancia en el Instituto de Ciencias de Tokio.

Índice

Dedicatoria	1
Agradecimientos	2
Índice.....	3
Índice de cuadros.....	7
Índice de Figuras	8
Abreviaturas y siglas	11
RESUMEN.....	12
ABSTRACT.....	13
I. DESCRIPCIÓN DEL PROBLEMA.....	14
II. JUSTIFICACIÓN	15
III. ANTECEDENTES.....	16
IV. HIPÓTESIS.....	19
V. OBJETIVOS	19
VI. FUNDAMENTACIÓN TEÓRICA.....	21
6.1. Esguince de tobillo.....	21
6.1.1. Mecánica de la lesión	21
6.1.2. Valoración	22
6.1.3. Tratamiento	24
6.1.4. Secuelas.....	24
6.2. Biomecánica.....	26
6.3. Marcha.....	27
6.3.1. Efectos del esguince sobre la marcha.....	28
6.3.2. Indicadores espaciotemporales de la marcha	29

6.3.3.	Indicadores cinemáticos de la marcha.....	30
6.4.	Visión artificial.....	32
6.4.1.	Estimación de pose.....	32
6.5.	Machine Learning	35
6.5.1.	Long Short-Term Memory (LSTM).....	35
6.5.2.	Softmax	38
6.6.	Deep Learning.....	39
6.6.1.	Convolutional Neuronal Network (CNN).....	39
6.6.2.	Stacked Auto Encoder (SAE)	41
VII.	METODOLOGÍA	43
7.1.	Reconstrucción de la biomecánica	44
7.1.1.	Protocolo de pruebas de la marcha.....	44
7.1.2.	Extracción de la biomecánica.....	45
7.1.3.	Posprocesamiento.....	48
7.2.	Extracción de indicadores	49
7.2.1.	Indicadores cinemáticos	49
7.2.2.	Indicadores espaciotemporales.....	51
7.3.	Base de datos.....	52
7.3.1.	Base de datos propia.....	53
7.3.2.	Base de datos publica	53
7.4.	Creación de modelos de ML	54
7.4.1.	Stacked Autoencoder	54
7.4.2.	Clasificador NN	55
7.4.3.	Validación del rendimiento de modelos.....	55

7.5.	Cuantificación del grado de recuperación.....	56
7.5.1.	Error de reconstrucción del SAE.....	57
7.5.2.	Puntaje de pertenencia del Clasificador	58
7.6.	Predicción de la tasa de recuperación	59
7.7.	Implementación en sistema de visión embebido.....	60
7.7.1.	Software del sistema de visión artificial	60
7.7.2.	Hardware del sistema de visión artificial	61
7.8.	Consideraciones éticas	62
VIII.	RESULTADOS.....	64
8.1.	Reconstrucción de la biomecánica	64
8.1.1.	Realización de pruebas de la marcha	64
8.1.1.1.	Área de trabajo	64
8.1.1.2.	Preparación de los voluntarios	66
8.1.1.3.	Protocolo de distribución del sistema de visión artificial	67
8.1.1.4.	Aplicación del protocolo de pruebas.....	69
8.1.2.	Extracción de la biomecánica mediante detección de pose	70
8.2.	Extracción de indicadores	73
8.2.1.	Indicadores cinemáticos	73
8.2.2.	Indicadores espaciotemporales.....	74
8.3.	Bases de datos	77
8.3.1.	Población de voluntarios	77
8.3.2.	Criterios de inclusión	78
8.3.3.	Estructura de la base de datos	79
8.4.	Modelado de Stacked AutoEncoder (SAE)	82
8.5.	Clasificador	85

8.6.	Cuantificación del grado de recuperación.....	87
8.7.	Proyección del grado de recuperación	94
8.8.	Sistema de visión artificial embebido	99
8.8.1.	Desarrollo de hardware	99
8.8.2.	Desarrollo de software	102
8.8.3.	Implementación de software	105
8.8.3.1.	Software de pruebas	105
8.8.3.2.	Software de ML.....	108
IX.	CONCLUSIONES	110
X.	REFERENCIAS BIBLIOGRÁFICAS.....	112
	Anexos	120
	Anexo A	121
	Anexo B.....	122
	Anexo C	123
	Anexo D	124

Índice de cuadros

Tabla 1.- Características de los tipos de esguince (Wexler, 1998).	23
Tabla 2.- Índices predefinidos de YOLOv8	34
Tabla 3.- Estructura de los modelos de SAE utilizados	83
Tabla 4.- Rendimiento de los modelos de SAE con muestras sanas.....	83
Tabla 5.- Modelos más destacados de la prueba de ablación.....	86
Tabla 6.- Incorporación del MSE como indicador.....	86
Tabla 7.- Caracterización de los indicadores de cada población	89
Tabla 8.- Rendimiento de los modelos de SAE con muestras sanas.....	92
Tabla 9.- Rendimiento del clasificador	93
Tabla 10.- Desempeño de modelos de regresión	96
Tabla 11.- Componentes de hardware del sistema embebido.....	100

Índice de Figuras

Fig. 6.1.- Movimientos del tobillo durante el evento de esguince por inversión.....	21
Fig. 6.2.- Anatomía del tobillo con enfoque en los ligamentos laterales (inspirado en Ivins, 2006).	22
Fig. 6.3.- Clasificación del grado de afectación del ligamento.....	23
Fig. 6.4.- Factores de la autoorganización presentes en el tratamiento de un esguince.....	26
Fig. 6.5.- Fases del ciclo de la marcha.....	28
Fig. 6.6.- Representación gráfica de los indicadores de la marcha.....	29
Fig. 6.7.- Aplicación de YOLOv8 para identificación de personas y sus keypoints.....	34
Fig. 6.8.- Estructura básica del modelo LSTM.....	35
Fig. 6.9.- Puerta del olvido dentro del LSTM.....	36
Fig. 6.10.- Selección y actualización de los parámetros provistos por la nueva información.....	37
Fig. 6.11.- Selección de la salida del LSTM.....	38
Fig. 6.12.- Ejemplo de la operación de convolución.....	40
Fig. 6.13.- Ensamble de un SAE.....	41
Fig. 6.14.- Estructura base de un AE.....	42
Fig. 7.1.- Metodología para la evaluación y predicción de la tasa de recuperación.....	44
Fig. 7.2.- Realización de pruebas de la marcha.....	45
Fig. 7.3.- Detección de pose en los planos frontal y lateral.....	45
Fig. 7.4.- Información de la bounding box obtenida de la detección de poses.....	46
Fig. 7.5.- Reconstrucción de la persona en un plano tridimensional a partir de datos bidimensionales.....	48
Fig. 7.6.- Eliminación de puntos nulos mediante interpolación en el desplazamiento del tobillo.....	48
Fig. 7.7.- Suavizado de las señales mediante EMAF. A) Señal original. B) Señal suavizada.....	49
Fig. 7.8.- Graficas de desplazamiento del tobillo con sistema de coordenadas fijo (A) y dinámico (B).....	50
Fig. 7.9.- Cálculo de ángulos de cadera, rodilla y tobillo.....	51

Fig. 7.10.- Evaluación de variaciones en el puntaje de predicción.....	55
Fig. 7.11.- Comparación de la reconstrucción de señales de tobillo sano (A) y con lesión (B).	57
Fig. 7.12.- Pipeline para la evaluación del MSE.....	58
Fig. 7.13.- Estructura de los modelos de proyección del grado de recuperación.....	59
Fig. 7.14.- Propuesta del sistema embebido.....	61
Fig. 8.1.- Espacio total para pruebas de marcha, considerando espacio medible (verde) y excedente (amarillo)......	65
Fig. 8.2.- Espacio de trabajo para la adquisición de videos.....	66
Fig. 8.3.- Disposición del sistema de visión en el espacio de trabajo.....	68
Fig. 8.4.- Distribución del sistema de visión artificial.....	69
Fig. 8.5.- Detección de pose en el plano lateral (A) y el plano frontal (B)......	71
Fig. 8.6.- Visualización de la reconstrucción del esqueleto en un espacio tridimensional..	72
Fig. 8.7.- Calculo de la velocidad de keypoints a partir del desplazamiento. A. Desplazamiento de tobillo. B. Velocidad de tobillo.	73
Fig. 8.8.- Desplazamiento angular en las principales articulaciones de la pierna.....	74
Fig. 8.9.- Cálculo de la longitud de zancada mediante picos y valles. A) Datos en sistema de coordenadas dinámico. B) Datos en el sistema de coordenadas estático.....	75
Fig. 8.10.- Cálculo de tiempos de balanceo, soporte y periodo.	76
Fig. 8.11.- Presencia de múltiples tiempos de balanceo en una prueba.	76
Fig. 8.12.- Medición del α_{max} el α_{min} . A. Tobillo. B. Rodilla. C. Cadera.	77
Fig. 8.13.- Tablas relacionales de la base de datos en SQL.....	80
Fig. 8.14.- Tablas relacionales en SQL con base de datos GaitRec.....	81
Fig. 8.15.- Estructura del modelo final del modelo SAE.....	84
Fig. 8.16.- Comparativa de la marcha en estado sano contra la marcha con esguince de tobillo por inversión. A. Primera semana. B. Segunda semana. C. Tercera semana. D. Cuarta semana. E. Quinta semana.	88
Fig. 8.17.- Comparativa de la caracterización del estado sano y con esguince de la base de datos pública.....	91
Fig. 8.18.- Pipeline para el cálculo del grado de recuperación.	92

Fig. 8.19.- Progreso de la recuperación de la población con esguince de tobillo.	94
Fig. 8.20.- Caracterización del progreso del grado de recuperación durante el tratamiento.	95
Fig. 8.21.- Estructura en cascada de modelos de regresión.	96
Fig. 8.22.- Evaluación de una muestra con mal seguimiento del tratamiento. A. Predicción con base a 1 sesión, B. Ajuste de predicción con base en la segunda sesión. C. Variación entre la recuperación real y la predicción anterior.	98
Fig. 8.23.- Prototipo del sistema de visión embebido.	100
Fig. 8.24.- Conexión de componentes del sistema embebido.	101
Fig. 8.25.- Ensamble final del sistema embebido de visión artificial.	102
Fig. 8.26.- División de las tareas realizadas por el software de visión artificial con sus respectivas herramientas.	102
Fig. 8.27.- Diseño de UI mediante QtDesigner.	103
Fig. 8.28.- Distribución de tareas entre softwares.	105
Fig. 8.29.- Estructura para el registro de pruebas.	106
Fig. 8.30.- UI del software de pruebas para el sistema embebido.	107
Fig. 8.31.- UI del software de ML para el sistema embebido.	108

Abreviaturas y siglas

CSAE: Convolutional Stacked Auto Encoder

DL: Deep Learning

HS: Heel strike

IA: Inteligencia artificial

LDA: Latent Dirichlet Allocation

LSTM: Long Short-Term Memory

ML: Machine Learning

MSE: Mean Square Error

NN: Neuronal Network

PCA: Principal component analysis

ROM: Range of Motion

SAE: Stacked Auto Encoder

TO: Toe-off

RESUMEN

Los esguinces de tobillo por inversión son las lesiones más comunes en piernas, presentándose posterior a un movimiento brusco o a un esfuerzo anormal, causando rasgaduras parciales o totales de los ligamentos. Lo cual ante la ausencia o ineficiencia de un tratamiento puede causar un desgaste sobre tejidos y articulaciones sanas, volviéndose propensos a la presencia de secuelas, recurrencia de la lesión o el surgimiento de nuevas lesiones. Para evitar esto, los especialistas en fisioterapia concluyen que una recuperación apropiada depende de la eficiencia y velocidad del tratamiento, así como la realización de ajustes oportunos del tratamiento acorde al progreso del paciente. Esto permitiría obtener el mayor impacto sobre la condición en el menor tiempo; sin embargo, el estimar el desarrollo de la condición del paciente tiende a ser una tarea compleja, influenciada por factores particulares para cada paciente. Por lo cual, los especialistas tienden a depender de la descripción detallada de la condición y su experiencia para interpretarla, lo cual limita su capacidad para reaccionar a la presencia de anormalidades o cambios en el desarrollo de la lesión. Con el fin de minimizar estas incertidumbres, se ha propuesto el desarrollo de una metodología de evaluación con Machine learning enfocada en la detección de patrones para la cuantificación del grado de recuperación. El cual pueda sustentarse de información cuantitativa para describir el estado de una lesión, así como proyectar el progreso esperado conforme se siga un tratamiento. Permitiendo tener una descripción objetiva de la condición del paciente que facilite las tareas de comparación y registro y les permitiría a los especialistas tener una retroalimentación de los efectos del tratamiento sobre el paciente. Aportando información adicional para la identificación de anormalidades, falta de progreso y los tiempos apropiados para realizar ajustes del tratamiento que mejoren el impacto.

Palabras clave: Machine learning, visión artificial, fisioterapia, esguince, recuperación

ABSTRACT

Inversion ankle sprains are the most common leg injuries, occurring after a sudden movement or an abnormal effort, causing partial or total tears of the ligaments. In the absence or inefficiency of treatment, this can cause wear and tear on healthy tissues and joints, making them prone to the presence of sequelae, recurrence of the injury or the emergence of new injuries. To avoid this, physical therapy specialists conclude that proper recovery depends on the efficiency and speed of treatment, as well as making prompt treatment adjustments according to the patient's progress. This would allow for the greatest impact on the condition in the shortest time; however, estimating the development of the patient's condition tends to be a complex task, influenced by factors particular to each patient. Therefore, specialists tend to rely on the detailed description of the condition and their experience to interpret it, which limits their ability to react to the presence of abnormalities or changes in the development of the lesion. To minimize these uncertainties, it has been proposed the development of an evaluation methodology with Machine learning focused on the detection of patterns for the quantification of the degree of recovery. Which can be supported by quantitative information to describe the state of an injury, as well as to project the expected progress during treatment. This would result in an objective description of the patient's condition, which could facilitate the tasks of comparison and registration and provides the specialists with feedback on the effects of the treatment on the patient. Where abnormalities, lack of progress and appropriate times to make treatment adjustments can be identified to improve the impact.

Keywords: Machine learning, artificial vision, physiotherapy, sprain, recovery.

I. DESCRIPCIÓN DEL PROBLEMA

La recuperación apropiada de un esguince de tobillo por inversión depende de la velocidad y eficiencia del tratamiento, para lo cual las metodologías y herramientas utilizadas tienden a basarse en observaciones subjetivas que pueda dificultar la descripción detallada de la condición.

La eficiencia del tratamiento depende de ajustes continuos basados en el impacto del tratamiento en el desarrollo de la lesión. Sin embargo, no se cuenta con una metodología que pueda describir a detalle la respuesta particular de cada paciente mediante datos cuantitativos que sean robustos ante la variabilidad de cada caso.

Los medios para cuantificar el progreso del desarrollo de una lesión tienden a ser limitados por el uso de metodologías subjetivas, que no proveen una descripción clara de la efectividad del tratamiento y dependen completamente de la interpretación del especialista, lo cual puede dificultar las tareas la proyección de la recuperación esperada o la detección de anomalías durante el tratamiento.

II. JUSTIFICACIÓN

La implementación de una metodología para la adquisición y análisis de la biomecánica permite realizar una descripción detallada de la lesión mediante indicadores cuantitativos. Los cuales pueden respaldar la toma de decisiones de los especialistas, al poder establecer las propiedades de una condición sana, determinar sus patrones y realizar comparaciones de forma objetiva.

Los métodos de Machine Learning (ML) y Deep Learning (DL) han demostrado capacidades para utilizar los patrones presentes en los indicadores biomecánicos como base para calcular de forma cuantitativa la diferencia entre dos clases, lo cual podría ser correlacionado con el grado de recuperación.

Los modelos de Machine Learning (ML) han destacado en la identificación de patrones y tendencias, por lo cual mediante el uso de datos históricos del progreso de la lesión se puede caracterizar el impacto del tratamiento sobre la lesión a largo plazo, permitiendo proyectar el grado de la recuperación ideal que pueda sustentar los diagnósticos del tiempo de recuperación, el grado de recuperación y la presencia de anomalías.

III. ANTECEDENTES

La realización de la locomoción en los seres humanos depende de la coordinación de los sistemas muscular, óseo y nervioso, para la generación de movimiento, la estabilidad y la distribución de fuerzas durante actividades estáticas y dinámicas (Trew & Everett, 2006). En el caso de la marcha los tobillos, rodillas y caderas son las articulaciones más significativas, definiendo la biomecánica para la locomoción, los ejes de rotación, los rangos de movimiento y mantienen unida la estructura de la propia articulación (Griffin et al., 2000). Debido a estas circunstancias los ligamentos también son los primeros afectados cuando se presenta un evento que genera una carga o esfuerzo anormal sobre la articulación, causando rasgaduras o desgarres sobre los ligamentos, conocidos como esguinces (Golanó et al., 2010; Wexler, 1998). Convirtiéndose en una de las lesiones más comunes reportadas en las salas de urgencia y en las clínicas de fisioterapia, tanto en México como a nivel mundial, donde de 2 a 7 pacientes de cada 100 sufren de esguince de tobillo y de 6 a 10 de cada mil sufren esguinces de rodilla (Ordóñez-Flores et al., 2024). Cuando se presentan estas lesiones se recomienda buscar un tratamiento inmediatamente para minimizar su agravamiento, la afectación de otros músculos o ligamentos en estado sano y asegurar su recuperación apropiada para evitar la presencia de secuelas.

Para su tratamiento apropiado se debe tener información detallada de la lesión, para diseñar de forma apropiada una rutina de rehabilitación y seguimiento que pueda tener el mayor beneficio para el paciente (Hassebrock et al., 2020). En la actualidad la información es obtenida de diferentes fuentes, siendo la más común una inspección visual y el uso de palpación que permite obtener un diagnóstico rápido del tipo de lesión y su gravedad, comúnmente fundamentada en el conocimiento y experiencia del especialista (Wolfe et al., 2001). Para una valoración más precisa sin el uso de herramientas, se utilizan pruebas físicas como la prueba de Lachman, cambio de pivote y cajón anterior y posterior, por mencionar algunas de las más comunes (Alcado García et al., 2017). De ser necesario contar con una descripción más detallada se pueden utilizar rayos x o imágenes de resonancia magnética para la visualización clara de los ligamentos (Sukru et al., 2022). Para complementar se puede describir el propio movimiento mediante el uso de herramientas de adquisición como sensores iniciales (IMU) (Noor et al., 2021), sistemas de visión (Suo et al., 2024) y placas

de presión (Horsak et al., 2020), por mencionar algunos de los más comunes, para obtener mediciones estáticas y dinámicas de la biomecánica de los pacientes. Lo que permite cuantificar los efectos de la lesión durante la evaluación y el tratamiento (Hsu et al., 2014; Villa M. et al., 2008; Winter, 2009). En los últimos años incluso se ha incorporado el uso de la Inteligencia artificial (IA) para el análisis de patrones o características, utilizando información provista por alguno de los métodos previamente mencionados, para la realización de inferencias que puedan sustentar la toma de decisiones, el diagnóstico y el seguimiento del paciente del especialista (Alcocer et al., 2012).

Los sistemas de IA se han logrado adaptar al área de fisioterapia como herramientas complementarias, gracias a su versatilidad, flexibilidad y accesibilidad para el análisis de todo tipo de información, permitiendo la integración tanto de nuevos sensores como de equipos ya presentes en la clínica (Harrison & Kennedy, 2005). El funcionamiento del IA está inspirado en el comportamiento del cerebro humano para el análisis de grandes cantidades de información compleja y sin estructura, identificando patrones que correlacionen la información provista con la información deseada, permitiendo realizar tareas como detección, clasificación, evaluación, diagnóstico y predicción (Malik, 2021). La implementación de AI en fisioterapia ha demostrado resultados prometedores para la evaluación y diagnóstico de diferentes condiciones y acciones, como lo demuestran los trabajos de Hwang et al. (2025) para la clasificación de casos con inestabilidad crónica en el tobillo al analizar la fuerza, el rango de movimiento, control postural y deformidades anatómicas, Yin et al. (2025) quienes utilizan Deep Learning (DL) para analizar imágenes de resonancia magnética y detectar lesiones en ligamento lateral y medial y Yunas & Ozanyan (2021) quienes desarrollaron un sistema para la clasificación de acciones a partir del análisis de la biomecánica de la marcha. Estos trabajos demuestran como se puede adquirir más información para el beneficio de los especialistas, aun que tienden a limitarse a proveer información al momento de la evaluación y pocos sistemas han considerado que la detección de patrones y tendencias pueden ser utilizarlos para predecir el desarrollo de una condición o la presencia de un evento. Algunos trabajos que ejemplifican esta predicción son Connaboy et al. (2019) quien recopila información biomecánica durante la realización de actividades físicas, y lo correlaciona a la probabilidad de sufrir lesiones en las extremidades inferiores o

el trabajo de Li et al. (2021), donde a partir de señales de placas de presión realiza una predicción de la intención de levantarse de un adulto mayo, con el fin de proveer asistencia oportuna para la reducción de carga sobre las articulaciones. Permitiendo que los especialistas consideren tanto información actual de la condición como su posible desarrollo para la toma de decisiones y la aplicación y seguimiento del tratamiento.

En el caso de los esguinces para su identificación y clasificación en los diferentes grados de severidad, resulta redundante el uso de IA, ya que los métodos tradicionales presentan una alta precisión y velocidad. Sin embargo, tener la posibilidad de identificar el progreso que puede tener la lesión y el impacto del tratamiento puede tener un impacto significativo para el desempeño de las personas a largo plazo. Trabajos como el de Bleakley et al. (2010) y Chaudhari et al. (2008) han llegado a la conclusión que la calidad y velocidad del tratamiento pueden tener un impacto positivo en la reducción de la presencia de secuelas, siendo que hasta un 30% de las personas tratadas presenta a largo plazo dolor crónico, rigidez en las articulaciones, perdida de fuerza y estabilidad, osteoartritis o reaparición de la lesión (Herzog et al., 2019; Lorenzo Galván et al., 2017). De tal forma que, al contar con proyecciones del desarrollo de la lesión, se pueden realizar intervenciones oportunas que puedan modificar el tratamiento y mejorar los efectos y el tiempo de la rehabilitación. Para esto se estaría cuantificando el grado de recuperación y proyectando su progreso durante el periodo de tratamiento, para lo cual se utilizará como base lo propuesto por Chakraborty et al. (2022) y Malik (2021) quienes utilizan DL para cuantificar la diferencia entre la lesión y el estado sano mediante el cálculo del error de reconstrucción de un Stacked Auto Encoder (SAE) y (Guo et al., 2025) quien utiliza el score de un clasificador de ML como indicador de la diferencia entre sano y con lesión. Partiendo de esto se propone una metodología para el seguimiento de pacientes con esguinces de tobillo durante su periodo de recuperación, mediante el análisis de la biomecánica de la marcha con visión artificial, para realizar la proyección del grado de recuperación, el tiempo de convalecencia y el grado de recuperación. Permitiendo al especialista realizar comparaciones directas del progreso real contra el esperado, cuantificar el progreso que se está teniendo por sesión y tomar decisiones oportunas para el ajuste del tratamiento con el propósito de mejorar el impacto que tiene el tratamiento sobre la condición del paciente y los tiempos de recuperación.

IV. HIPÓTESIS

Utilizando visión artificial y Machine Learning se puede establecer una metodología para caracterizar los cambios de la marcha ante la presencia de esguince de tobillo por inversión, cuantificar del grado de recuperación y proyectar el progreso esperado de la condición con tratamiento, los cuales puedan ser presentados ante los especialistas mediante un sistema embebido para sustentar sus diagnósticos y el ajuste del tratamiento.

V. OBJETIVOS

Objetivo general

Desarrollar e implementar una metodología para cuantificar el grado de recuperación del esguince de tobillo y la proyección de su desarrollo durante el tratamiento, mediante la adquisición y análisis de la biomecánica de la marcha utilizando visión artificial y Machine Learning, con el fin de proveer un seguimiento detallado del progreso de la lesión, una robustez ante la variabilidad de factores de cada paciente y una clara comparación entre el progreso esperado contra el obtenido para el sustento y ajuste del tratamiento por parte de los especialistas.

Objetivos específicos

- Desarrollar una metodología de adquisición a partir de un sistema de visión artificial para la reconstrucción de la biomecánica de la marcha y la adquisición de sus indicadores.
- Desarrollar modelos de ML para la caracterización de las condiciones sanas y con esguince de tobillo utilizando bases de datos con información periódica de los cambios en los indicadores de la marcha de ambas poblaciones.
- Validar una metodología para cuantificar el progreso de la recuperación, partiendo del análisis de indicadores de la marcha mediante ML, para dar seguimiento cuantitativo y detallado.
- Diseñar un modelo de ML para la proyección de la recuperación esperada, utilizando la detección de tendencias en casos de recuperación exitosas para proveer información que pueda sustentar ajustes del tratamiento.

- Diseñar un sistema embebido para la gestión del sistema de visión, posprocesamiento, análisis, entrenamiento e implementación de modelos de ML, para su fácil manejo por parte de los especialistas.

VI. FUNDAMENTACIÓN TEÓRICA

6.1. Esguince de tobillo

Los esguinces de tobillo representan la lesión musculoesquelética más común tanto en México (Lomelí-Rivas et al., 2014) como a nivel mundial, estimando que se presentan de 2 a 7 casos anuales por cada 1,000 habitantes (Gribble et al., 2016) y reportando que hasta un 7% de los ingresos a urgencias es a causa de esguinces de tobillo (Herzog et al., 2019).

6.1.1. Mecánica de la lesión

El esguince de tobillo más común se presenta como consecuencia de una inversión abrupta, donde se presentan movimientos de rotación y flexión plantar (Alcado García et al., 2017), los cuales se muestran en la Fig. 6.1, forzando a los ligamentos a estirarse más allá de su límite generando un estrés anormal que puede resultar en la ruptura parcial o total del tejido (Cavazos & Harkless, 2021).

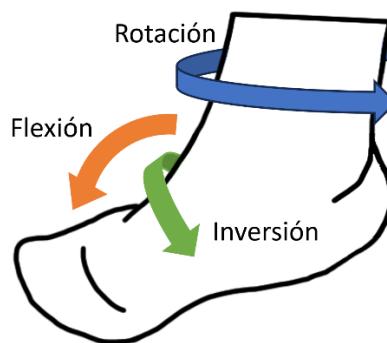


Fig. 6.1.- Movimientos del tobillo durante el evento de esguince por inversión.

De los ligamentos laterales, comúnmente se ven afectados los responsables de la estabilidad, siendo el subgrupo de ligamentos laterales colaterales, compuestos por el ligamento peroneo astragalino anterior (ATFL, Anterior Talo Fibular Ligament), el calcáneo peroneo (Calcaneus Fibular Ligament, CFL) y el tibioperoneo inferior posterior (Posterior Talo Fibular Ligament, PTFL), al ser los elementos menos robustos del tobillo (Golanó et al., 2010), su ubicación se muestra en la Fig. 6.2.



Fig. 6.2.- Anatomía del tobillo con enfoque en los ligamentos laterales (inspirado en Ivins, 2006).

6.1.2. Valoración

La valoración apropiada de la lesión es fundamental para el desarrollo de un plan de tratamiento que se adapte a las condiciones particulares del paciente, con el fin de obtener resultados óptimos. Una recuperación pronta, minimizar la presencia de complicaciones y un menor riesgo de recurrencia de lesiones (Cavazos & Harkless, 2021; Golanó et al., 2010). Para esto se considera indispensable contar con el historial clínico y una examinación detallada de la extremidad afectada, para identificar la mecánica de la lesión y las estructuras anatómicas afectadas, enfocándose en la presencia de deformidades, hinchazón y dislocación (Kaminski et al., 2013).

Tradicionalmente la valoración se inicia realizando la palpación del tobillo (Gisondi, 2008) y la observación detallada del área afectada, lo cual guía al especialista para la selección de la metodología de evaluación del grado de afectación de los tejidos particulares, siendo las más comunes la prueba del cajón anterior, prueba de la pierna cruzada y prueba de inclinación talar que describen el daño en el ATFL, CFL y PTFL, respectivamente (Ivins, 2006). La información obtenida de estos puede ser complementada mediante el uso de goniometría, imágenes de resonancia magnética (Cavazos & Harkless, 2021) y, recientemente en el área de investigación, sistema de visión artificial (Doherty et al., 2015), sensores iniciales (Di Raimondo et al., 2023) y placas de presión (Chakraborty et al., 2022).

La gravedad de los esguinces se clasifica acorde al daño presentado en los ligamentos, ya sea sin rasgaduras o rasgaduras microscópicas como grado I, rasgadura parcial como grado II y rasgadura total como Grado III (Wexler, 1998), como se puede apreciar en la Fig. 6.3. Comúnmente se le da mayor consideración al daño presentado en el ATFL, siendo el tejido que presenta rasgaduras en el 80% de los casos de esguince por inversión (Yang et al., 2024).

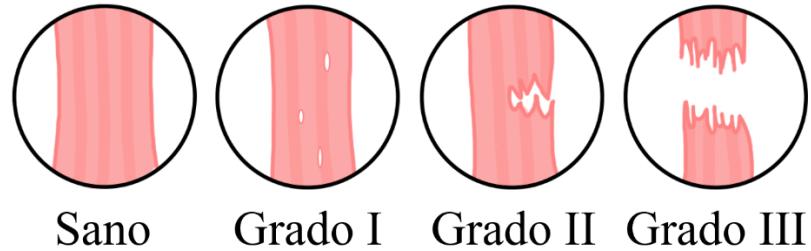


Fig. 6.3.- Clasificación del grado de afectación del ligamento.

Para determinar el grado del esguince también se pueden contemplar otros factores que se presentan como consecuencia de la lesión, tal como se muestra en la Tabla 1, la cual puede ser utilizada como guía por el especialista.

Tabla 1.- Características de los tipos de esguince (Wexler, 1998).

Síntomas	Primer Grado	Segundo Grado	Tercer Grado
Ruptura de ligamento	Nada	Parcial	Completo
Perdida de funcionalidad	Bajo	Medio	Alto
Dolor	Mínimo	Moderado	Severo
Hinchazón	Mínimo	Moderado	Severo
Hematoma	Raro	Común	Constante
Dificultad para soportar peso	Nada	Usualmente	Siempre

6.1.3. Tratamiento

El tratamiento debe adaptarse a las condiciones de la lesión, por lo que la metodología del tratamiento se limita a definir el orden de prioridad en el que se deben atender los efectos de la lesión. Primeramente, al presentarse el evento del esguince en tobillo, se debe priorizar el alivio de la hinchazón y el dolor, para lo cual diversos trabajos reportan el uso de la técnica RICE (Rest, Ice, Compresion and Elevation) (Wexler, 1998; Wolfe et al., 2001), o también se puede optar por el uso de terapias laser (Chen et al., 2023) o de ultrasonido (Jasmine Yohan Putri et al., 2024). Así como el uso de medicinas antiinflamatorias no esteroideas, las cuales apoyan en la reducción de hinchazón y permiten acelerar la recuperación (Ivins, 2006).

Posteriormente, se busca la recuperación del rango de movimiento (Range Of Motion, ROM) (Ivins, 2006) inicialmente utilizando ejercicios pasivos, donde el especialista guía el movimiento de la articulación para la realización de la flexión planar, dorsiflexión, inversión y eversión. Conforme el paciente recupera movilidad, se comienza con ejercicios activos en donde se realizan los mismos movimientos, pero sin la intervención del especialista.

Cuando el tobillo afectado comienza a presentar un menor nivel de hinchazón y mayor movilidad, se comienza con los ejercicios para la recuperación de fuerza y estabilidad. Estos pueden variar acorde a las observaciones del especialista, pero tienden a enfocarse en ejercicios isométricos e isotónico (Ivins, 2006). Este proceso es el que abarcará la mayoría del periodo del tratamiento, y puede llegar a tener una duración promedio de 4 a 6 semanas (Wolfe et al., 2001), del cual se llevan registros generales del progreso observado en la movilidad, hinchazón, fuerza y equilibrio. Al finalizar este periodo se realiza una revaloración con el fin de validar una recuperación apropiada o de lo contrario prolongar el tratamiento, reestructurándolo a partir de una revaloración de la condición (Guo et al., 2025).

6.1.4. Secuelas

De los casos que han sufrido un esguince de tobillo por inversión, se ha reportado que entre el 30-40% presentan secuelas como dolor, inestabilidad, debilidad, alteraciones de la marcha, recurrencia de la lesión, nuevas lesiones en tejido previamente sano e incluso degenerándose hasta presentar osteoartritis o una discapacidad funcional (Gribble et al., 2016).

Algunos estudios han sugerido que las personas se vuelven más propensas a sufrir secuelas a causa de una falta de la recuperación funcional, una recuperación inadecuada o un daño

remanente en los ligamentos (Attenborough et al., 2014), ya que algunos de estos no cuentan con los medios apropiados para recuperarse de forma exitosa sin tratamiento (Yang et al., 2024). El surgimiento de estas secuelas puede pasar desapercibido, incluso después de haber sido dado de alta los pacientes tienen un riesgo de hasta en el 72% presentar secuelas, las cuales puedes aparecer incluso 2 años después del esguince de tobillo (Anandacoomarasamy & Barnsley, 2005; Drakos et al., 2010).

Con el fin de prevenir o minimizar las probabilidades de que se presenten secuelas, se recomienda el llevar un seguimiento detallado de la respuesta del paciente ante el tratamiento y realizar intervenciones oportunas para el ajuste de este, buscando obtener la mejor recuperación en el menor tiempo (Bleakley et al., 2010; Chaudhari et al., 2008; Di Raimondo et al., 2023; Suo et al., 2024). Esta es una tarea compleja ya que requiere de información precisa con la que se pueda cuantificar el progreso del paciente, para lo cual no se puede depender únicamente de observaciones visuales, sino que se requiere de la implementación de sistemas de medición de la biomecánica (Yang et al., 2024). Además de esto es necesario considerar que el proceso de recuperación no puede ser generalizado, ya que los efectos de la lesión y la respuesta al tratamiento pueden ser únicos para cada paciente. Esto se debe a la autoorganización (Selforganization), el cual es el conjunto de factores mecánicos, conductuales y sensoriales, presentados en la Fig. 6.4, que afectan la respuesta particular del paciente durante el tratamiento, y cuyo impacto puede ser difícilmente considerado (Hertel & Corbett, 2019).

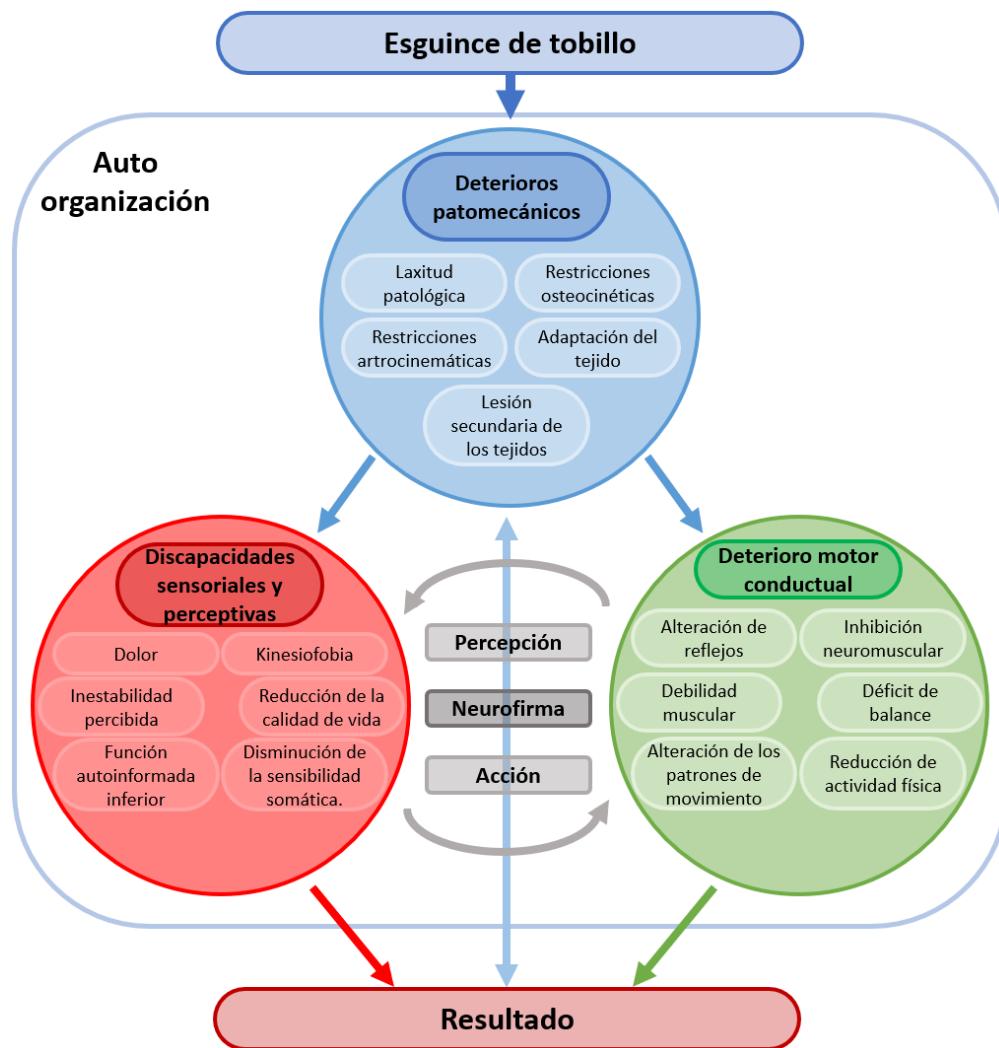


Fig. 6.4.- Factores de la autoorganización presentes en el tratamiento de un esguince.

6.2. Biomecánica

La biomecánica del ser humano se enfoca en la descripción de fases y evaluación de movimiento, mediante datos cuantitativos derivados de mediciones con diversas herramientas (Winter, 2009). Esto permite la realización de un análisis objetivo del movimiento, permitiendo la extracción de información derivada y la búsqueda de patrones, tendencias, anomalías y cambios funcionales (Lorenz et al., 2024).

La descripción detallada de una condición guía a los especialistas en fisioterapia para determinar la causa del problema o la mecánica de la lesión, lo cual puede sustentar el diagnóstico y tratamiento inicial. De la misma manera se puede utilizar los datos para la

comparación de diferentes casos que se hayan presentado bajo condiciones similares permitiendo realizar predicciones informadas del desarrollo de la condición. Y el registro del progreso de la condición del paciente permite tener una retroalimentación para la optimización y ajuste del tratamiento (Lorenz et al., 2024; Winter, 2009).

El análisis de la biomecánica puede ser realizado mediante métodos tradicionales, basados en observaciones y el uso de herramientas básicas como el goniómetro para describir los movimiento y fuerzas presentes durante una actividad. Sin embargo, herramientas modernas como los sistemas de visión artificial, los sensores iniciales (IMU) y las placas de presión, por mencionar algunas (Suo et al., 2024), permiten una evaluación más objetiva, sensible y confiable que no podrían ser realizadas de forma manual con los métodos existentes (Maura et al., 2023).

6.3. Marcha

La marcha es una serie de movimientos coordinados que balancean el equilibrio de fuerzas internas y externas para realizar la locomoción (Long & Krzak, 2023). Este conjunto de movimientos es realizado en un orden específico y en constante repetición, lo cual es definido como un ciclo de la marcha. Estos se dividen en dos etapas principales y un traslape de estas, comenzando por la etapa de soporte que inicia con el evento de golpe de talón (Heel strike, HS), donde la pierna tiene un primer contacto con la superficie y se realiza la aceptación del peso sobre esta misma extremidad. Su duración es el 60% del ciclo, durante el cual la carga del propio peso de la persona se incrementa progresivamente hasta sostenerlo en su totalidad. Esta carga comienza a decrementar una vez que la extremidad contraria hace contacto con la superficie, comenzando un traslape entre las etapas de soporte de ambas piernas conocida como doble soporte. Posteriormente, la pierna pierde todo contacto con la superficie, conocido como el evento de despegue o despegue de dedos (Toe-off, TO), para comenzar la fase de balanceo que tiene una duración de 40% del ciclo y es la responsable de generar el desplazamiento. Esta finaliza con el HS y marca el final de un ciclo de la marcha, tal como se describe en la Fig. 6.5, el cual puede continuar repitiéndose indefinidamente (Gazit et al., 2020; Koldenhoven et al., 2019; Lippert, 2011).

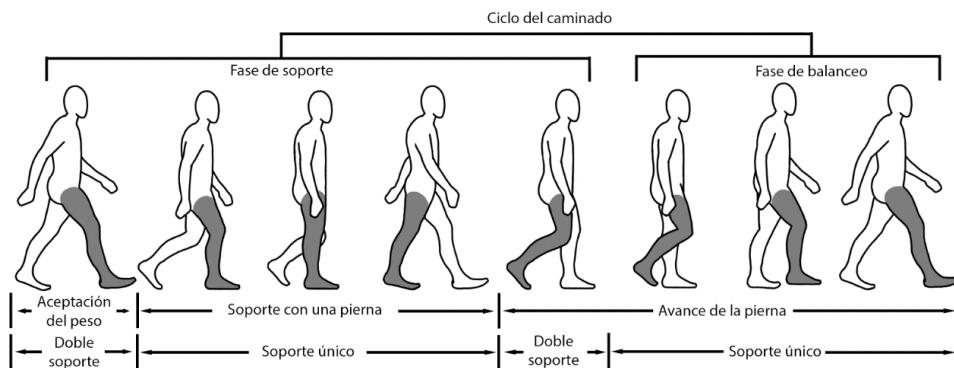


Fig. 6.5.- Fases del ciclo de la marcha.

6.3.1. Efectos del esguince sobre la marcha

Al presentarse un esguince en tobillo por inversión tiene un impacto directo sobre la cinemática y cinética de la marcha, la cual se aprecia directamente en los esguinces de grado I y II al ser capaces de mantener la locomoción. Estos cambios se deben en gran medida a la reducción del ROM del tobillo, teniendo un decremento de la dorsiflexión de la extremidad afectada, además de la presencia de dolor e hinchazón (Punt et al., 2015). Estos últimos causan que la persona afectada genere cambios conscientes e inconscientes en la biomecánica de su caminado en la búsqueda de amortiguar el impacto sobre el tobillo afectado y mantener una posición de mayor estabilidad, para minimizar el riesgo percibido de caída durante la marcha (Doherty et al., 2015).

Algunos de los cambios más significativos que se han reportado es la reducción de la flexión plantar máxima, manteniendo una posición cercana a la neutra durante el levantamiento, balanceo y golpe de talón para incrementar la estabilidad. A su vez se ha observado una exageración de los movimientos en las articulaciones próximas para el amortiguamiento de fuerzas de reacción sobre el tobillo afectado. Por lo cual durante el golpe de talón se presentan incrementos en la extensión de la rodilla, desplazamiento angular en valgo, reducción en la abducción de la cadera y un incremento en la inversión del talón. En cuanto al despegue se presenta un decremento en la extensión de la cadera y una reducción del impulso, con el fin de minimizar las cargas sobre el tobillo afectado (Doherty et al., 2015; Punt et al., 2015). Lo cual se ve reflejado como un decremento en la velocidad de caminado, longitud de paso y el tiempo de soporte de la extremidad afectada, además de la reducción significativa del índice de simetría entre la extremidad afectada y sana.

6.3.2. Indicadores espaciotemporales de la marcha

Son indicadores derivados de mediciones de la cinemática que han sido utilizados en el área de la fisioterapia para la descripción cuantitativa de características de la marcha, las cuales se muestran en el diagrama de la Fig. 6.6.

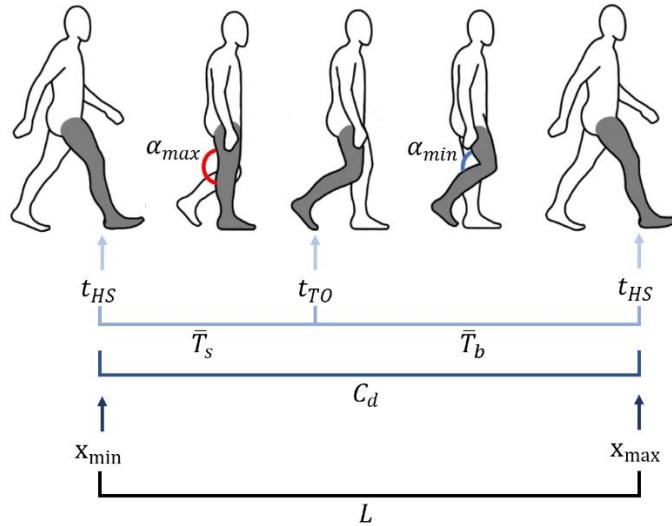


Fig. 6.6.- Representación gráfica de los indicadores de la marcha.

Estos pueden variar ligeramente acorde a la referencia; sin embargo, para el trabajo presente se estarán considerando los siguientes:

Cadencia:

La cadencia (C_d) es una medición derivada de la velocidad de caminado, en donde se consideran el número de pasos realizados en 1 minuto y se describe por la ecuación:

$$C_d = \left(\frac{60}{\bar{T}_p} \right) * 2 \quad (1)$$

Donde \bar{T}_p es el periodo de una zancada en segundos, por ello el resultado de la división es multiplicado por dos, ya que cada zancada está compuesta por dos pasos.

Rangos de movimiento (ROM):

Los rangos de movimiento de las articulaciones están relacionados directamente con la fuerza y estabilidad de los pacientes durante la marcha, tanto en los tobillos, rodillas y cadera. Para esto se mide el ángulo máximo (α_{max}), el ángulo mínimo (α_{min}) y se determina el rango de movimiento (ROM_α) mediante la ecuación:

$$ROM_\alpha = |\alpha_{max} - \alpha_{min}| \quad (2)$$

Tiempo de balance y soporte:

Los tiempos de balance (\bar{T}_b) y soporte (\bar{T}_s) permite identificar anomalías, al incrementarse o decrementarse para minimizar el soporte del peso en alguna de las extremidades, o para incrementar la estabilidad percibida.

$$\bar{T}_b = t_{TO,i} - t_{HS,i+1} \quad (3)$$

$$\bar{T}_s = t_{HS,i} - t_{TO,i} \quad (4)$$

Donde t_{HS} es el tiempo en el que se presentó el golpe de talón (Heel Strike, HS) y t_{TO} es el tiempo donde se realizó el despegue (Toe-off, TO). Para estas mediciones se puede tomar la consideración que para el cálculo de \bar{T}_s se utiliza el HS y TO del mismo ciclo, y para \bar{T}_b se utiliza el TO del mismo ciclo y el HS del próximo ciclo.

Longitud de zancada:

La longitud de zancada (L) permite marcar el inicio y fin de un ciclo de la marcha, se encuentra constituido por un paso por cada una de las extremidades y permite conocer el desplazamiento total obtenido de un ciclo. Para esto se considera la posición inicial en el eje x durante HS de una de las piernas (x_{min}) y su posición al finalizar un ciclo de la marcha (x_{max}).

$$L = |x_{max} - x_{min}| \quad (5)$$

6.3.3. Indicadores cinemáticos de la marcha

La cinemática se enfoca en la descripción detallada del movimiento, sin considerar la fuerzas externas o internas que lo generan. Esto es realizado mediante la medición cuantitativa del desplazamiento, velocidad y aceleración de puntos clave en el cuerpo (Winter, 2009). Tradicionalmente se utilizan herramientas como goniómetros manuales y eléctricos, pero en los últimos años se han optado por el desarrollo e implementación de sistemas de visión artificial, sensores iniciales y placas de presión, para extracción de información de la cinemática de movimiento dinámicos complejos, al no mostrar una interferencia durante su realización. Estos pueden considerar el desplazamiento de los segmentos individuales de las

extremidades, la rotación de las articulaciones y los patrones de movimiento (Lorenz et al., 2024; Suo et al., 2024).

Para el análisis de la cinemática del cuerpo humano se puede simplificar la fisiología del cuerpo como vectores que existen en un plano tridimensional, los cuales representen cada uno de los segmentos de las extremidades. Para el análisis particular de la marcha, se puede dar prioridad a las extremidades inferiores, tomando como puntos clave (keypoints) los tobillos, las rodillas y cadera, para definir la posición y orientación de los vectores (Winter, 2009). Partiendo de esto se puede utilizar conceptos básicos de cinemática para la descripción del desplazamiento y velocidad lineal de cada segmento mediante las ecuaciones:

$$r_i = \sqrt{\Delta x^2 + \Delta y^2 + \Delta z^2} \quad (6)$$

$$v_i = \lim_{\Delta t \rightarrow 0} \frac{r_{i+1} - r_{i-1}}{2\Delta t} = \frac{dr}{dt} \quad (7)$$

Donde Δx , Δy , Δz son la diferencia de las coordenadas de un punto clave en x , y y z , respectivamente, en dos instantes de tiempo, mientras que r es el desplazamiento lineal, v es la velocidad lineal y t es el tiempo transcurrido. En este caso se toma una consideración de $2\Delta t$ para evitar un desfases en la señal de velocidad obtenida.

La misma metodología puede ser utilizada para la descripción del desplazamiento angular en las articulaciones, mediante la ecuación:

$$\theta_{ij} = \tan^{-1} \left(\frac{y_j - y_i}{x_j - x_i} \right) \quad (8)$$

Donde θ es el desplazamiento angular del vector relativo al plano, (x_i, y_i) y (x_j, y_j) son los puntos clave que definen un segmento de la extremidad como vector.

6.4. Visión artificial

La visión artificial se ha popularizado en los últimos años al ser capaz de extraer e identificar información de imágenes y videos, permitiendo la realización de tareas como detección, clasificación, seguimiento, monitoreo y evaluación, por mencionar algunos. Su implementación en la adquisición de la biomecánica del movimiento humano se ha destacado por la capacidad de extraer información de forma no intrusiva, con alta precisión y con un amplio grado de flexibilidad para su uso en diversos ambientes (Suo et al., 2024). Permitiendo la descripción detallada de actividades complejas y dinámicas como la marcha, mediante la extracción de la cinemática precisa y robusta de forma automática, tarea en la cual otros sistemas se pueden ver limitados.

La extracción de la cinemática del movimiento mediante visión artificial puede utilizar diversas metodologías, como el uso de múltiples cámaras para la detección y seguimiento de marcadores pasivos que son colocados directamente sobre los puntos de interés del cuerpo. Sin embargo, este tipo de sistemas cuenta con una baja accesibilidad y requieren de equipo especializado (Lorenz et al., 2024), por lo cual se ha popularizado el uso de deep learning (DL) para la estimación de poses. Este se basa en la detección de objetos y la reconstrucción del esqueleto, los cuales han ganado popularidad gracias a su accesibilidad con librerías open-source como Ultralytics, Mediapipe, Openpose, por mencionar algunas, además de que son altamente flexibles para su implementación en diverso hardware y software.

6.4.1. Estimación de pose

La estimación de pose consiste en la identificación de puntos clave del cuerpo, enfocándose en las articulaciones más prominentes, a partir de las cuales se puede reconstruir un modelo del cuerpo humano a base de vectores. Este puede ser utilizado para la extracción y análisis de indicadores del movimiento permitiendo el reconocimiento de acciones, el análisis biomecánico, la evaluación de condiciones particulares y el tratamiento de lesiones, por mencionar algunas de las tareas destacadas (Suo et al., 2024).

Una de las APIs open-source más comunes para esta tarea es YOLOv8 de la compañía Ultralytics, el cual se enfoca en la detección de objetos de forma precisa y rápida sin la necesidad de procesos iterativos (Ultralytics, 2016). La arquitectura que se puede dividir en tres componentes principales:

Columna vertebral:

Se encarga de la extracción de indicadores de alto nivel mediante el uso de redes neuronales convolucionales (CNN). Esto permite minimizar la cantidad de información que debe ser procesada, impactando de forma positiva al flujo de la información y la velocidad de procesamiento (Terven et al., 2023).

Cuello:

Es la conexión entre la columna vertebral y la cabeza, siendo su función principal el flujo de información. En el caso de YOLOv8 esta ha sido acondicionada para realizar la concatenación de indicadores de diferentes resoluciones espaciales, lo cual beneficia a la detección de objetos pequeños ya que los indicadores de menor nivel proveen un contexto más claro(Terven et al., 2023).

Cabeza:

Es la etapa final del modelo en donde se realizan inferencias para la detección de objetos, su clasificación y su escala de pertenencia. En YOLOv8 esta tarea se ve dividida en tres cabezas, cada una enfocada a la detección de objetos en diferente escala, ya sea grandes, medianos o pequeños, para lo cual se toman del cuello indicadores de diferentes resoluciones espaciales (Terven et al., 2023).

Como salida del modelo YOLOv8 para la detección de pose, se obtiene una bounding box que encapsula a la persona o personas detectadas dentro de la imagen, así como su puntaje de pertenencia. Además de esto se obtiene un arreglo de coordenadas que indican la presencia y posición de cada uno de los keypoints de la persona, ordenándolos mediante índices predefinidos como se muestra en la Tabla 2 (Ultralytics, 2016), y siendo representados gráficamente como se muestra en la Fig. 6.7.

Tabla 2.- Índices predefinidos de
YOLOv8

Índice	Keypoint
0	Nariz
1	Ojo izquierdo
2	Ojo derecho
3	Oreja izquierda
4	Oreja derecha
5	Hombro izquierdo
6	Hombro derecho
7	Codo izquierdo
8	Codo derecho
9	Muñeca izquierda
10	Muñeca derecha
11	Cadera izquierda
12	Cadera derecha
13	Rodilla izquierda
14	Rodilla derecha
15	Tobillo izquierdo
16	Tobillo derecho

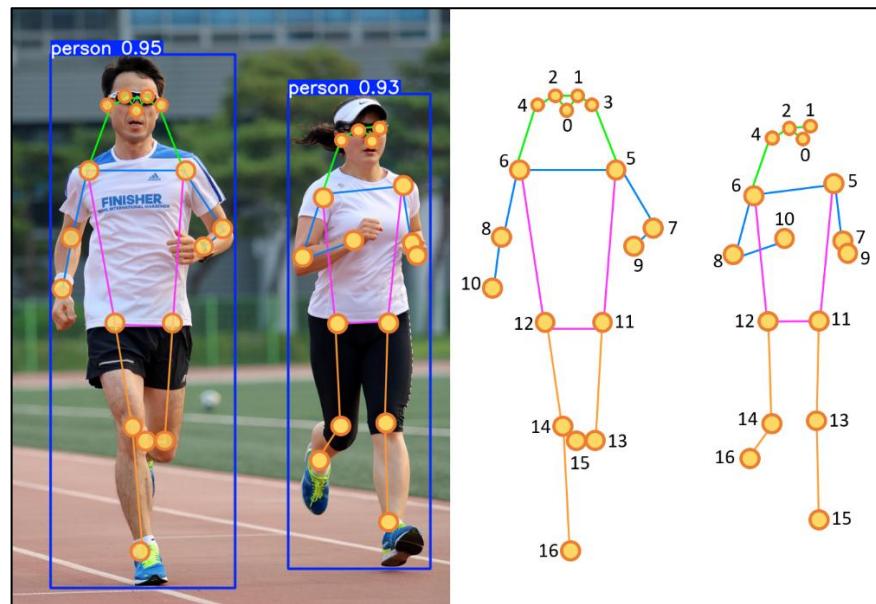


Fig. 6.7.- Aplicación de YOLOv8 para identificación de personas y sus keypoints.

6.5. Machine Learning

Es una subrama de la inteligencia artificial que se basa en el análisis de bases de datos para la identificación de patrones e indicadores que puedan sustentar la toma de inferencias. Estos algoritmos funcionan a base de un aprendizaje supervisado, donde se les entrena para identificar las relaciones entre la información provista y la respuesta deseada (Alpaydin, 2014). Estos han destacado en la realización de tareas como clasificación, detección y predicción de sistemas lineales y no lineales, por mencionar las más comunes (Jakhar & Kaur, 2020).

6.5.1. Long Short-Term Memory (LSTM)

Es una estructura de ML cuyo enfoque particular es la identificación de dependencias a largo plazo para secuencias de datos. Esto se debe a que otras estructuras tienden a tener una pérdida de gradiente, por lo que normalmente solo se pueden identificar las relaciones de los datos próximos de la secuencia. Para lidiar con este problema se incorpora una unidad de memoria destinada únicamente al almacenamiento de parámetros, la cual es consultada y actualizada en cada iteración del modelo para identificar los parámetros que históricamente han tenido mayor relevancia (Okut, 2021).

La memoria del LSTM es representada como un flujo de información llamada estado de la celda (C_t), la cual se asegura que los parámetros más relevantes de una iteración pasen a la siguiente. Este se puede ver actualizado en cada iteración al agregar o remover parámetros mediante la estructura presentada en la Fig. 6.8.

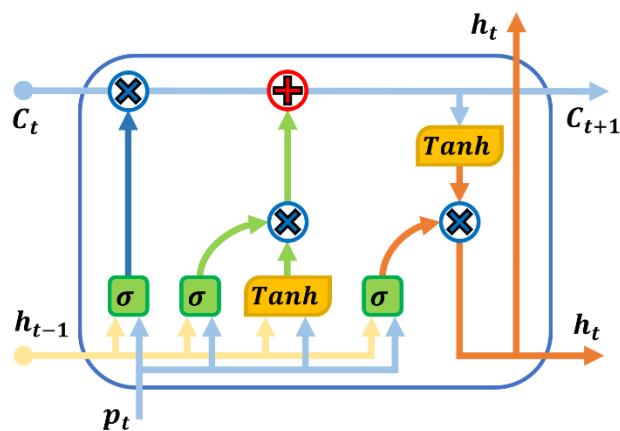


Fig. 6.8.- Estructura básica del modelo LSTM.

La gestión del flujo de información en la estructura del LSTM es realizada mediante la coordinación de tres puertas:

Puerta del olvido (Forget gate):

Esta tiene como responsabilidad identificar y separar la información obsoleta de C_t , donde se aplica una función de activación sigmoide (σ) que toma como argumentos la nueva entrada (p_t), sus pesos (W_f), la salida de la iteración anterior, conocida como estado escondido, (h_{t-1}) y un bias (b_f). Este comportamiento es representado por la ecuación:

$$f_t = \sigma(W^{(f)}(p_t, h_{t-1}) + b^{(f)}) = \frac{1}{1+e^{-(W^{(f)}(p_t, h_{t-1}) + b^{(f)})}} \quad (9)$$

El flujo de la información en la capa de olvido se resalta en la Fig. 6.9.

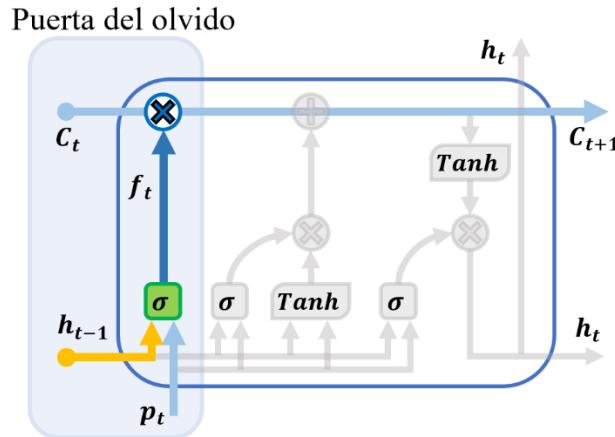


Fig. 6.9.- Puerta del olvido dentro del LSTM.

Puerta de la Entrada (Input gate):

Su función radica en el análisis de la nueva entrada con el fin de determinar la información más significativa que deba ser agregada a la celda de memoria. Primeramente, se determinarán los valores de la puerta de entrada (i_t) mediante la ecuación:

$$i_t = \sigma(W^i(p_t, h_{t-1}) + b^i) = \frac{1}{1+e^{-(W^i(p_t, h_{t-1}) + b^i)}} \quad (10)$$

Estos son utilizados para determinar si los candidatos a parámetros deben ser agregados, estos nuevos parámetros \tilde{C}_t son determinados mediante la ecuación:

$$\tilde{C}_t = \tanh(W^c(p_t, h_{t-1}) + b^c) = \frac{e^{(W^c(p_t, h_{t-1}) + b^c)} - e^{-(W^c(p_t, h_{t-1}) + b^c)}}{e^{-(W^c(p_t, h_{t-1}) + b^c)} + e^{-(W^c(p_t, h_{t-1}) + b^c)}} \quad (11)$$

Posteriormente se actualiza la celda de memoria mediante la ecuación:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (12)$$

El flujo de información para la incorporación de nueva información en la celda de memoria es remarcado en la Fig. 6.10.

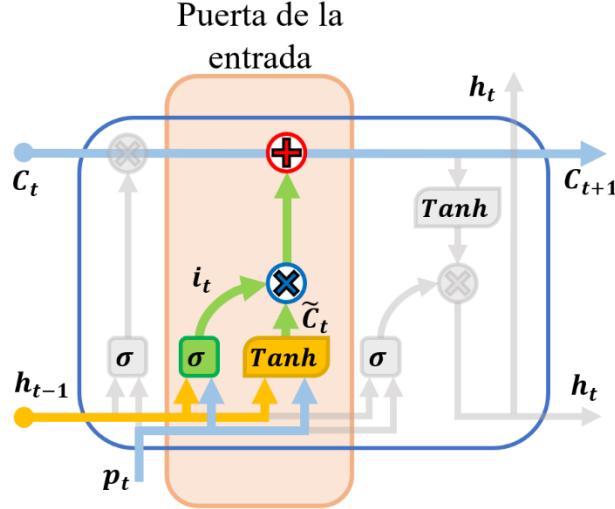


Fig. 6.10.- Selección y actualización de los parámetros provistos por la nueva información.

Puerta de la Salida (Output gate):

Esta se encarga de determinar la información que formara parte de la salida del modelo de LSTM. Para esto, primeramente, se obtienen los valores de la puerta de salida (o_t), los cuales consideran la entrada (p_t) y el estado escondido (h_{t-1}) para aplicar la ecuación:

$$o_t = \sigma(W^o(h_{t-1}, p_t) + b^o) \quad (13)$$

Posteriormente se utiliza la celda de memoria C_t para realizar un control de la información más significativa que debe pasar a la salida del sistema y a al estado oculto de la siguiente iteración h_t , para lo cual se aplica le ecuación:

$$h_t = o_t \odot \tanh(C_t) = o_t \cdot \frac{e^{(f_t \odot C_{t-1} + i_t \odot \tilde{C}_t)} - e^{-(f_t \odot C_{t-1} + i_t \odot \tilde{C}_t)}}{e^{(f_t \odot C_{t-1} + i_t \odot \tilde{C}_t)} + e^{-(f_t \odot C_{t-1} + i_t \odot \tilde{C}_t)}} \quad (14)$$

El flujo de información de la puerta de salida se remarcó en la Fig. 6.11.

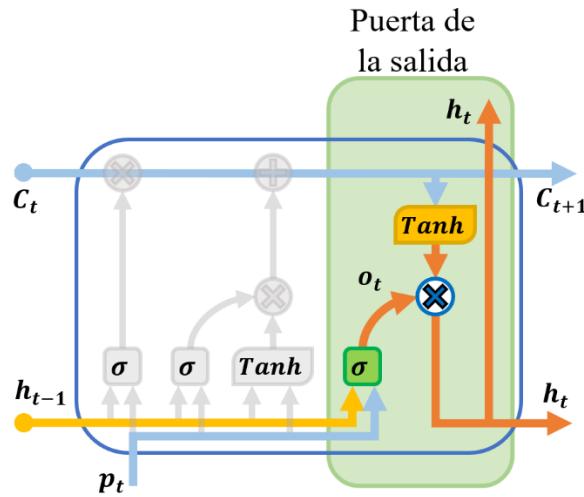


Fig. 6.11.- Selección de la salida del LSTM.

La salida obtenida del modelo de LSTM comúnmente es complementada con una capa densa o una capa de softmax para la realización de inferencias, ya sea clasificación o predicción por mencionar las más comunes.

6.5.2. Softmax

Es una función de activación que destaca en las tareas de clasificación multiclase y que es ampliamente utilizada en la capa de salida de múltiples modelos. Su funcionamiento se basa en la reinterpretación de datos en bruto (logits) como una distribución probabilística que describe la pertenencia de los datos de entrada en cada una de las clases (Okut, 2021). Estos se obtienen a partir de la ecuación:

$$y_i = \frac{e^{(W_i^T x + b_i^0)}}{\sum_{j=1}^K e^{(W_j^T x + b_j^0)}}, i = 1, \dots, K \quad (15)$$

Donde x es la entrada del softmax, W son los pesos por clase, b es el bias y K es el número de clases. El resultado de esta es un vector de valores normalizados con $\sum_{i=1}^K y_i$, lo que facilita su interpretación al considerar que el valor más cercano a 1 es la clase con la que tiene mayor pertenencia la entrada (Alpaydin, 2014).

6.6. Deep Learning

Es una subrama del machine learning especializada en el uso de modelos no supervisados comúnmente utilizados para reinterpretación de la información, permitiendo la representación de información compleja mediante datos abstractos (Ghosh et al., 2019). A estos se les conoce como indicadores de alto nivel y representan características particulares del conjunto de datos analizados, los cuales no corresponden con el cálculo o medición de un parámetro específico y cuya interpretación se vuelve abstracta.

La obtención de indicadores de alto nivel parte del análisis de una amplia cantidad de información (Big data) donde se identifica de forma automática dependencias, patrones e irregularidades. Lo cual posteriormente permite la descripción de la estructura de la información de entrada, siendo especialmente útil cuando se trabaja con información sin procesar (raw data) (Alpaydin, 2014).

La implementación de DL ha provisto como una alternativa al uso de métodos como PCA (Principal Component Analysis) o LDA (Latent Dirichlet Allocation) para la identificación de la información más significativa. Ya que provee ventajas como la reducción de la labor manual, al prescindir de un etiquetado de los datos, una reducción del costo computacional, al reducir la dimensionalidad de los datos, y una mejor descripción de la información, al utilizar indicadores de alto nivel de abstracción (Goodfellow et al., 2016). Esto último, ha permitido que los modelos de DL destaque en tareas como el reconocimiento de imágenes y de voz, el procesamiento de lenguaje y textos y el entrenamiento por refuerzo.

6.6.1. Convolutional Neuronal Network (CNN)

Es un algoritmo de DL no supervisado utilizado para la extracción de indicadores de alto nivel de la información de entrada, siendo comúnmente utilizado para el análisis de imágenes. Su implementación consiste en una estructura de cascada, en donde se coloca un número indefinido de capas conformados por CNN seguidos de bloques de muestreo, ya sea maxpooling, minpooling, averagepooling, etc. De este proceso se obtienen indicadores de diferentes niveles, donde la complejidad y abstracción de los indicadores incremente de forma proporcional al número de capas. Esto es deseable gracias a que el uso de indicadores de alto nivel tiene una mayor eficiencia en su correlación con la información espacial dentro de las imágenes, al minimizar la información e incrementando su robustez. Permitiendo que

los CNN destaque en tareas relacionadas a objetos como detección, clasificación y seguimiento, siendo uno de los componentes principales en la mayoría de los modelos para detección de pose.

La aplicación de la capa de convolución se basa en la ecuación:

$$y_j = b_j + (x \otimes w) = b_j + \sum_{c=0}^{n_c-1} \sum_{k=-p}^p x_{c,j-k} w_{c,k} \quad (16)$$

Donde x es la matriz de entrada, la cual puede ser la imagen original, w es la matriz de pesos llamada Kernel, b es el bias y como salida se obtiene el mapa de indicadores y (Ghosh et al., 2019), un ejemplo de su aplicación se puede observar en la Fig. 6.12.

1	0	-2	1
-1	0	2	2
0	2	1	0
1	0	0	1

 \otimes

0	1
-1	2

 $=$

1		

Input (x) Kernel (w) Mapa de indicadores (y)

Fig. 6.12.- Ejemplo de la operación de convolución.

El proceso de convolución provee diversas ventajas como una reducción de dimensionalidad de los datos, al haber realizado la extracción de indicadores de mayor nivel, una optimización en el manejo del almacenamiento, al requerir menos pesos a diferencia de una capa densa, y un menor consumo de carga computacional, al utilizar las operaciones de producto punto.

El resultado de la operación de convolución pasa a la capa de muestreo, el cual tiene como principal objetivo la reducción de dimensionalidad del mapa de indicadores, tomando solo la información más relevante y sin aplicar pesos que puedan cambiar su valor. Uno de los muestreos más comunes es maxpooling (Ghosh et al., 2019), el cual se describe con la ecuación:

$$P_{gmax} = \max_{i=0}^{M-1} \max_{j=0}^{N-1} x(i, j) \quad (17)$$

Donde x es la matriz de entrada, la cual siempre corresponde con un mapa de indicadores, y del cual se obtendrá como resultado P_{gmax} un mapa de indicadores reducido. Esto tiene como ventaja una disminución considerable de la dimensionalidad de la entrada original, lo cual

minimiza la carga computacional de los procesos subsecuentes, pero con el compromiso de afectar el rendimiento del modelo, por lo que se recomienda utilizar con cautela.

6.6.2. Stacked Auto Encoder (SAE)

Es un modelo de DL no supervisado utilizado comúnmente para la extracción de los indicadores más significativos de datos sin procesar. Los modelos de SAE se han destacado en la extracción de indicadores robustos tanto de sistemas lineales como no lineales, teniendo incluso un mejor desempeño que otros métodos como lo son PCA o LDA (Goodfellow et al., 2016). Su funcionamiento se basa en la reducción de dimensionalidad de los datos de entrada x mediante un proceso de codificación $h = f(x)$ y un proceso de reconstrucción de los datos originales mediante un decodificador $r = g(h)$ (Hinton & Salakhutdinov, 2006). El SAE es un modelo compuesto por ensamble en cascada de estructuras más simples conocidas como Auto Encoder (AE), tal como se muestra en la Fig. 6.13.

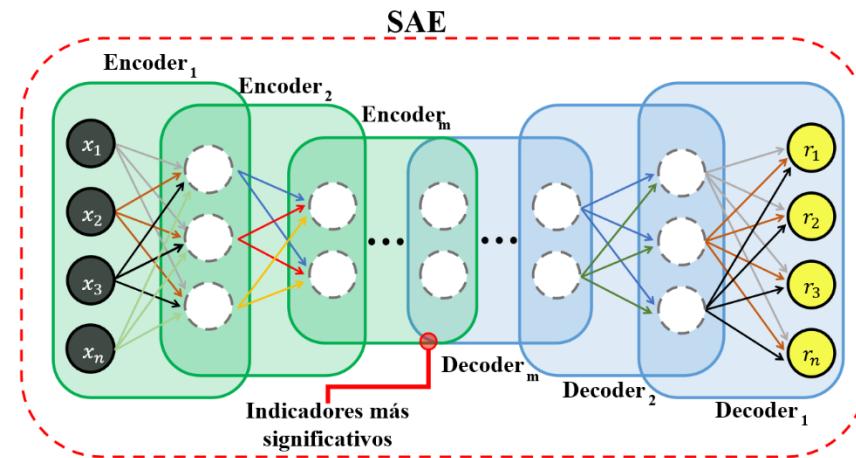


Fig. 6.13.- Ensamble de un SAE.

Estos AE se asemeja a las conexiones de una capa densa, tal como se presenta en la Fig. 6.14.

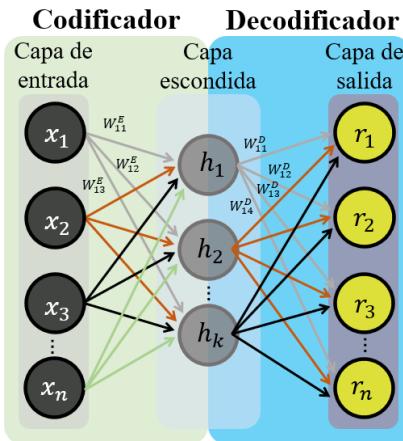


Fig. 6.14.- Estructura base de un AE.

Por lo cual su comportamiento se puede describir a partir de las ecuaciones:

$$h = \sigma(W_k^E x + b^E) \quad (18)$$

$$r = \sigma(W_k^D h + b^D) \quad (19)$$

Donde h es la información codificada, σ es la función de activación, W es la matriz de pesos, b es el bias, r es la decodificación de la información y E y D únicamente establece si pertenece al codificador o al decodificador, respectivamente. Cada uno de los AE busca ser entrenado de forma independiente, para lo cual se utiliza un ajuste iterativo con el fin de minimizar la función de perdida:

$$L = \frac{1}{N} \sum_{i=1}^N (x_i - r_i)^2 \quad (20)$$

Donde x es la información de entrada, r es la salida reconstruida, N es el número de datos y L es el error cuadrático medio (MSE) y representa la diferencia entre entrada y salida, comúnmente llamado error de reconstrucción (Kong & Yan, 2020). Una vez entrenado se ensambla el SAE, donde la etapa de codificación consiste en el agrupamiento de todos los codificadores en cascada y cuya salida serían los indicadores más significativos, mientras que el proceso de decodificación es realizado por el agrupamiento de los decodificadores de cada AE, con la finalidad de establecer la relación:

$$x \approx r_k = g(f(x)) \quad (21)$$

VII. METODOLOGÍA

La metodología planteada para la predicción de la tasa de recuperación del esguince de tobillo por inversión se describe paso a paso en el diagrama de la Fig. 7.1. El análisis se centra en la biomecánica de una marcha sostenida, donde idealmente se presenten diferencias en la mecánica del movimiento entre los voluntarios en estado sano y con esguince de tobillo por inversión. Lo cual se estará cuantificando mediante la extracción de indicadores espacio temporales y cinemáticos utilizando el procesamiento de videos con modelos de DL. Estos datos serán recabados en una base de datos dedicada a llevar un registro del progreso de la condición de los voluntarios con esguince de tobillo que estén llevando a cabo un proceso de rehabilitación. Partiendo de esta base de datos y una base de datos publica, se estarían estructurando y validando los modelos de ML destinados a la extracción de indicadores de mayor nivel y a la clasificación de datos, al identificar los patrones presentes en los indicadores de las poblaciones de interés y las diferencias entre estos. Mismas que serán utilizadas para cuantificar la pertenencia de una muestra a una de las poblaciones y correlacionarlo con el grado de recuperación. A partir del cual se estaría evaluando el impacto del tratamiento sobre los voluntarios con esguince de tobillo, para generar un modelo de regresión que correlacione la tendencia de la recuperación con los indicadores de la marcha. Permitiendo que al evaluar nuevos casos se pueda tener una proyección de su recuperación esperada durante el tratamiento. Finalmente, estos procesos serán incorporados en un sistema de visión artificial embebido, enfocado en la adquisición y análisis de la marcha como herramienta complementaria para los especialistas en fisioterapia. El sistema se encargaría en su mayoría de la gestión de las tareas de adquisición de videos, almacenamiento, procesamiento, análisis y entrenamiento y aplicación de modelos de inteligencia artificial. Permitiendo que los especialistas tengan acceso a la descripción cuantitativa de la lesión, obtenida en los procesos anteriores, y puedan ser utilizadas para sustentar sus diagnósticos, la aplicación de tratamientos y el ajuste de estos.

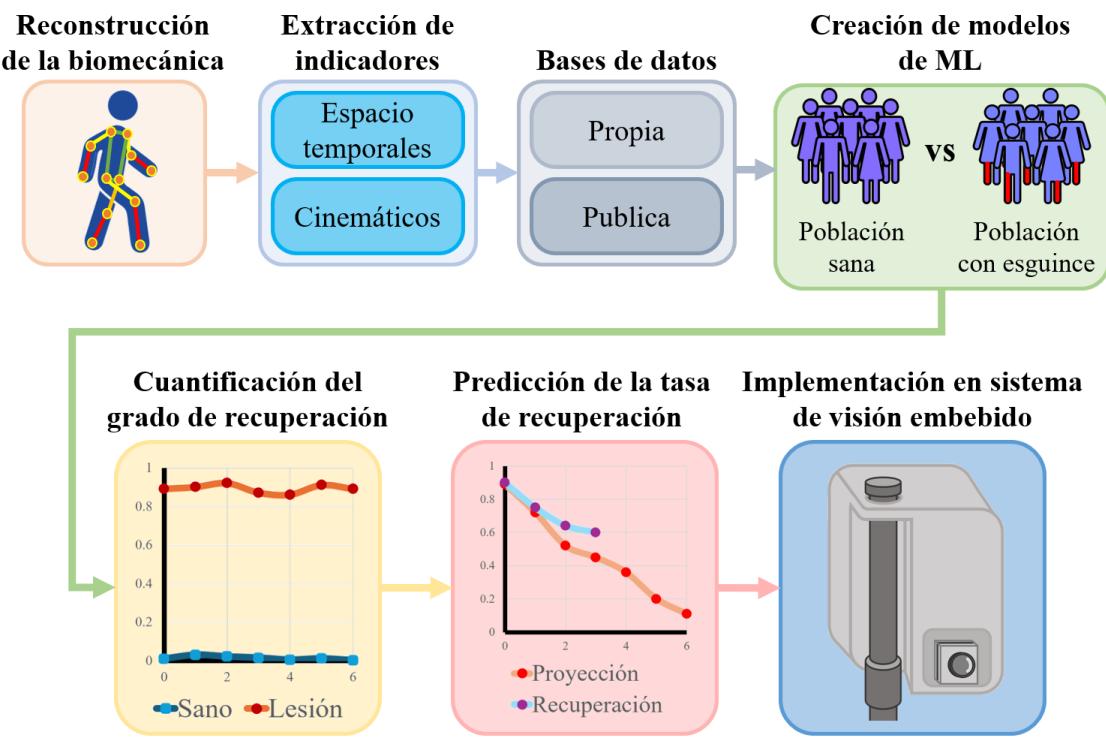


Fig. 7.1.- Metodología para la evaluación y predicción de la tasa de recuperación.

7.1. Reconstrucción de la biomecánica

La reconstrucción de la biomecánica se enfocará en la marcha, ya que de esta se estarán derivando los indicadores mencionados en la sección 6.3, para lo cual se considera el uso de un sistema de visión artificial multicámara que monitoree la marcha desde un plano frontal y lateral, utilizando modelos de DL para la detección de la pose. Identificando las articulaciones principales del cuerpo como keypoints, tal como se mencionó en la sección 6.4.1, permitiendo generar una representación vectorizada del esqueleto.

7.1.1. Protocolo de pruebas de la marcha

Para las pruebas de la marcha se delimitaría un área de trabajo, definida por marcadores para proporcionar una referencia clara para el inicio y final del circuito, donde los voluntarios puedan realizar caminatas cortas en línea recta de un extremo del área al otro, a una velocidad de confort que asimile a su marcha de la vida cotidiana. Esta acción se realizaría en ambos sentidos y sería considerado como una repetición, permitiendo la obtención de múltiples

muestras de ciclos completos de la marcha mantenida de cada voluntario. La dinámica de las pruebas se muestra de forma general en la Fig. 7.2.

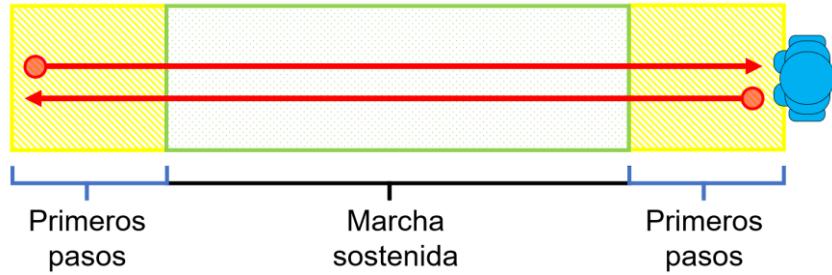


Fig. 7.2.- Realización de pruebas de la marcha.

7.1.2. Extracción de la biomecánica

Este proceso será realizado mediante YOLOv8, el cual provee como respuesta de los modelos de detección de pose se obtienen representaciones bidimensionales de los keypoints a través de coordenadas (x, y) relativas al origen de la imagen, el cual se encuentra en la esquina superior derecha. Este proceso se aplica para los videos obtenidos del plano frontal y lateral, tal como se muestra en la Fig. 7.3.

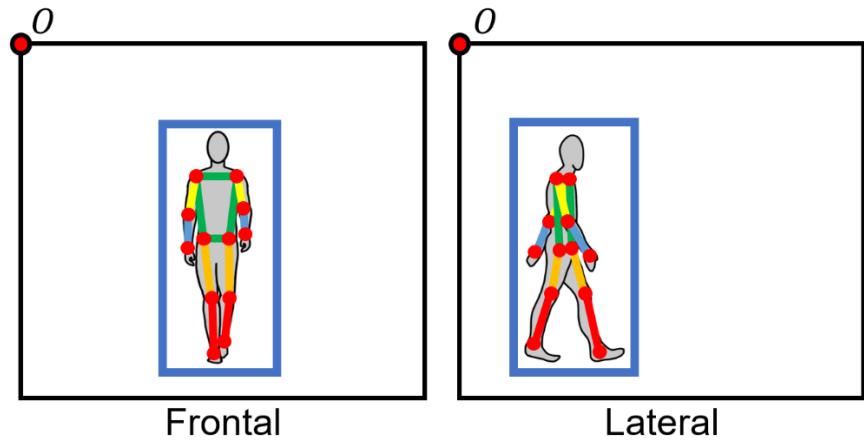


Fig. 7.3.- Detección de pose en los planos frontal y lateral.

La información de la pose obtenida es interpretada como la proyección de un objeto tridimensional en planos bidimensionales perpendiculares, por lo cual simplifica el proceso de reconstrucción tridimensional mediante álgebra básica. A este proceso se le conoce como multi-view, del cual se pueden obtener mediciones de movimientos complejos y dinámicos con mayor precisión y robustes (Shan et al., 2021). Para realizar esto se debe considerar la

información que se obtiene como resultado de la detección de poses, la cual se puede visualizar en la Fig. 7.4.

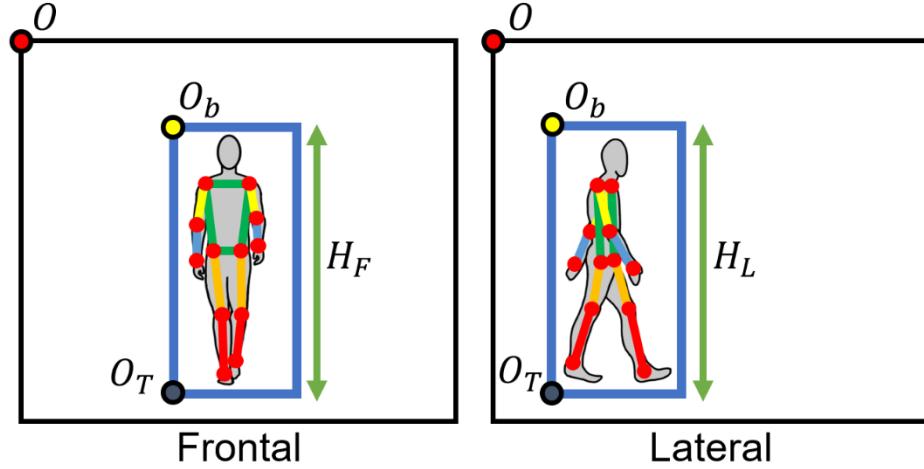


Fig. 7.4.- Información de la bounding box obtenida de la detección de poses.

El análisis de imágenes tiene como resultado una bounding box, el cual es un polígono que delimita la presencia de una persona dentro de la imagen. Estos son representados por medio de su origen ($O_b = (x_b, y_b)$), su alto (H) y su ancho (W), los cuales se ajustan acorde a la posición y tamaño de la persona dentro de la imagen. Por lo tanto, esta información puede ser utilizada para la obtención de keypoints que se ajusten al movimiento de la persona y faciliten el cálculo de las variables espaciotemporales. Para realizar esto se opta por un traslado de origen, buscando que los keypoints sean relativos a la base de la bounding box en ambos planos, siendo este el origen trasladado ($O_T = (x_T, y_T)$) y obteniéndose mediante las ecuaciones:

$$x_T = x_b \quad (22)$$

$$y_T = y_b + H \quad (23)$$

Donde H será la altura del bounding box, la cual puede variar para el plano frontal y lateral, por lo que se utiliza H_F o H_L respectivamente. Una vez que se obtiene O_T se realiza el traslado de los keypoints ($Kp = (x_p, y_p)$) al aplicar las ecuaciones:

$$x'_p = x_p - x_T \quad (24)$$

$$y'_p = |(y_p - y_T)| \quad (25)$$

Donde x'_p y y'_p son utilizados como los nuevos valores de los keypoints.

Para realizar la combinación de la información de ambos planos, se tiene que considerar que el tamaño de la persona estará variando conforme realice las pruebas, principalmente en el plano frontal donde se estará acercando o alejando de la cámara. Para compensar esto se utiliza la cámara lateral como referencia, ya que el tamaño de la persona dentro de la imagen no cambia bajo ninguna condición. Considerando esto se realiza el cálculo del factor de escalado (S) mediante la ecuación:

$$S = \frac{H_L}{H_F} \quad (26)$$

Este es aplicado a cada uno de los keypoints ($Kp = (x_p, y_p)$) provenientes del plano frontal, mediante las ecuaciones:

$$x'_p = S * x_p \quad (27)$$

$$y'_p = S * y_p \quad (28)$$

Asegurando así que la reconstrucción tridimensional de la persona se mantendrá en una escala constante.

Una vez que los datos se han acondicionado para ambos planos, se utilizan los $Kp_F = (x_F, y_F)$ y los laterales $Kp_L = (x_L, y_L)$ para la reconstrucción de los keypoints en un espacio tridimensional $Kp_{3D} = (x_{3D}, y_{3D}, z_{3D})$, mediante las relaciones:

$$x_{3D} = x_L \quad (29)$$

$$y_{3D} = x_F \quad (30)$$

$$z_{3D} = y_L \quad (31)$$

Como resultado se obtiene algo similar a lo representado en la Fig. 7.5 en donde la información de cada plano pasa a ser utilizado como proyecciones del movimiento tridimensional de la persona.

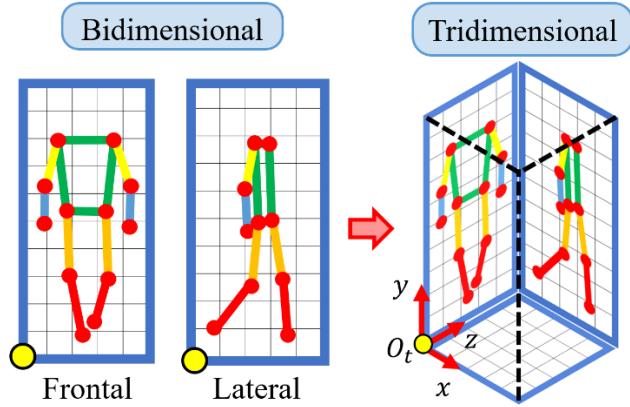


Fig. 7.5.- Reconstrucción de la persona en un plano tridimensional a partir de datos bidimensionales.

7.1.3. Posprocesamiento

El posprocesamiento consiste en la eliminación ruido y valores nulos, buscando que los indicadores cinéticos tengan una representación clara de la cual se puedan derivar los indicadores espacio temporales, como se mencionó en las secciones anteriores. Para la eliminación de datos nulos se utiliza un barrido de la señal con interpolación, en donde cualquier cambio brusco a un valor de 0 pueda ser removido sin afectar el resto de la información, mediante la ecuación:

$$y = y_0 + \frac{x-x_0}{x_1-x_0} (y_1 - y_0) \quad (32)$$

Donde (x_0, y_0) es el punto previo al valor nulo en la serie de tiempo, (x_1, y_1) es el punto siguiente y (x, y) son los valores que reemplazarán al punto nulo. Este proceso se puede ver exemplificado en la Fig. 7.6.

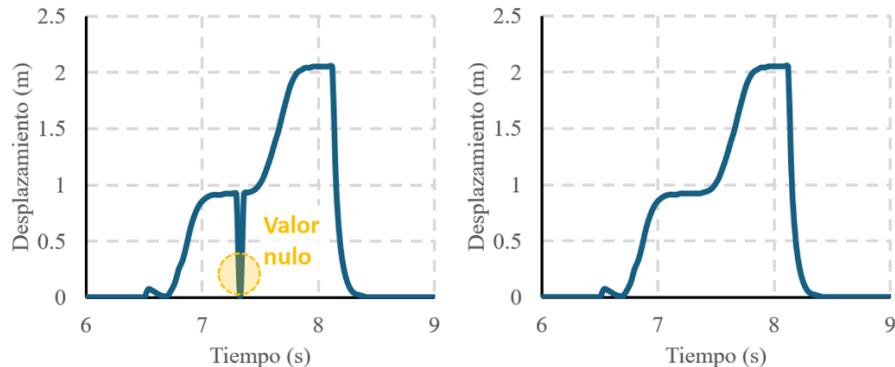
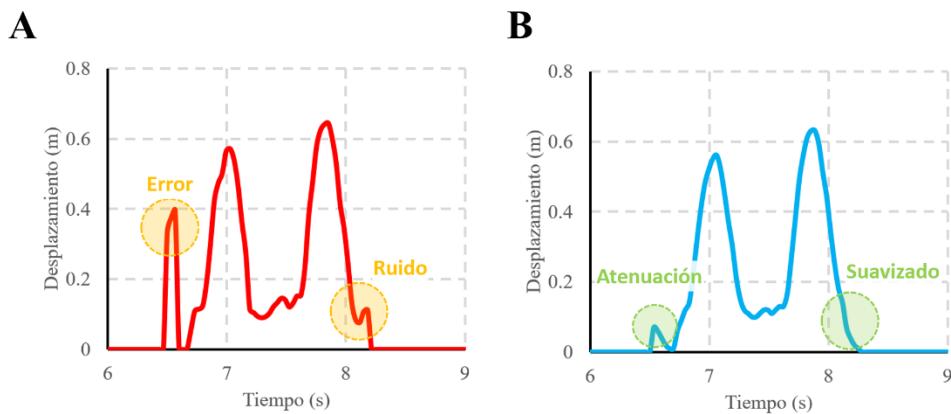


Fig. 7.6.- Eliminación de puntos nulos mediante interpolación en el desplazamiento del tobillo.

Como complemento se estaría aplicando un filtro de media móvil exponencial (Exponential Moving Average Filter, EMAF), con el fin de suavizar las señales y evitar cambios abruptos que se hayan podido presentar por errores de detección o monitoreo durante el procesamiento de los videos. Para esto se utiliza la ecuación:

$$y'_i = (s * y_i) + (1 - s)y_{i-1} \quad (33)$$

Donde s es el factor de atenuación, mientras que y_i es el valor por modificar, y_{i-1} es el valor anterior en la serie de tiempo y y'_i es el nuevo valor filtrado. El efecto de este filtro se puede apreciar en la Fig. 7.7.



7.2. Extracción de indicadores

Para la descripción de la marcha se estructuraría la realización de pruebas donde los voluntarios puedan realizar una marcha sostenida a velocidad de confort, similar a la de la vida cotidiana, donde se puedan presentar de forma clara los efectos de la lesión sobre la mecánica de la marcha. De esta manera se podrían extraer indicadores espaciotemporales y cinemáticos que serán posteriormente utilizados para caracterizar las condiciones.

7.2.1. Indicadores cinemáticos

El cálculo de los indicadores cinemáticos se enfoca en los puntos clave (keypoints) obtenidos en la reconstrucción tridimensional del cuerpo durante la realización de la marcha. En estos primeramente se aplica la ecuación 6, tomando cada uno de los fotogramas del video como instantes de tiempo. Esto se aplica para todos los keypoints exceptuando a los pertenecientes

a la cabeza, ya que estos tienden a presentar una mayor dificultad para el seguimiento y pueden resultar en valores nulos, los cuales tienden a interferir con el desempeño de los modelos de clasificación y predicción.

De los keypoints restantes se realiza el cálculo del desplazamiento tomando dos puntos de referencia, considerando los keypoints obtenidos bajo un sistema de coordenadas fijo y dinámico. Esto se debe a la extracción de algunos indicadores espaciotemporales puede simplificarse con el uso de un sistema de coordenadas estáticas, mientras que otras se benefician del uso de un punto de referencia dinámico, la diferencia se puede visualizar en la Fig. 7.8.

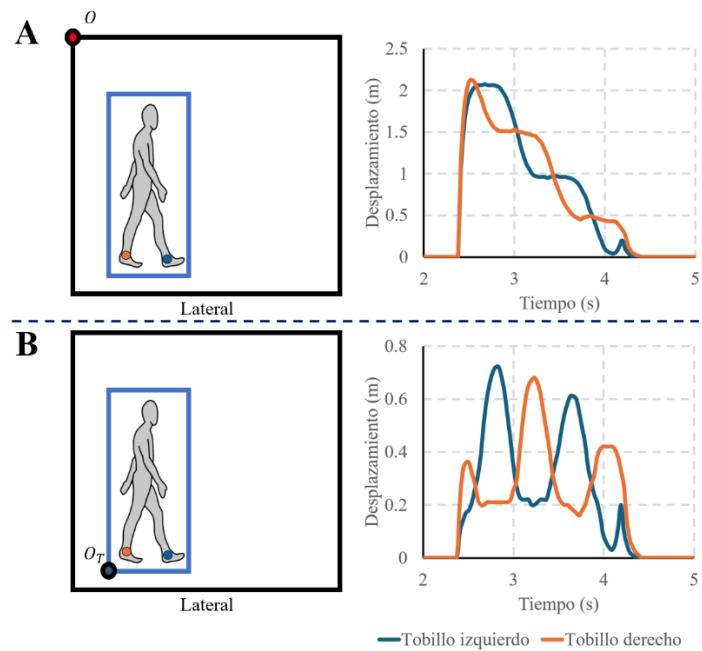


Fig. 7.8.- Graficas de desplazamiento del tobillo con sistema de coordenadas fijo (A) y dinámico (B).

A partir de los desplazamientos de cada keypoint se aplicaría la ecuación 7, para generar sus respectivas señales de velocidad.

Para el cálculo del desplazamiento angular se utiliza el sistema de coordenadas dinámico, el cual permite interpretar el movimiento como si la persona se encontrara en un estado estático y mientras que solo las extremidades realizan un desplazamiento angular. Estos son calculados para las articulaciones principales de ambas piernas mediante la ecuación 7, donde

se obtienen los ángulos relativos a la superficie θ_h , θ_k y θ_a , los cuales son utilizados para aplicar las ecuaciones:

$$\theta_H = 180 + \theta_h - \theta_k \quad (34)$$

$$\theta_K = 180 + \theta_a - \theta_k \quad (35)$$

$$\theta_A = \theta_a \quad (36)$$

Las cuales corresponden a los ángulos de cadera, rodilla y tobillo, respectivamente y se calcula para ambas piernas. Los ángulos obtenidos pueden verse claramente mediante el diagrama de la Fig. 7.9.

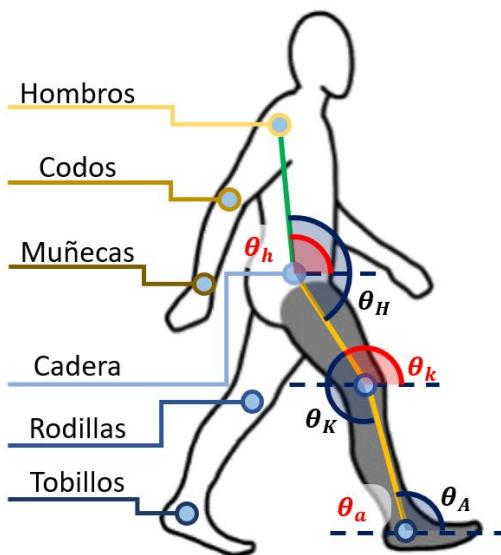


Fig. 7.9.- Cálculo de ángulos de cadera, rodilla y tobillo.

7.2.2. Indicadores espaciotemporales

Los indicadores espacio temporales se derivan del uso de las señales obtenidas de los indicadores cinemáticos, donde por medio del desplazamiento del tobillo en el eje x se estarían buscando identificar los eventos de golpe de talón (HS) y el despegue (TO), ya que estos marcan el inicio y final de cada paso. Estos eventos coinciden que, durante el movimiento, la extremidad llega a tener una velocidad de 0, lo que se vería reflejado en el desplazamiento como un pico o un valle. En este caso se puede asociar el valle con el golpe de talón ya que su desplazamiento debería mantenerse cercano a cero, al corresponder con la etapa de soporte en donde la pierna se mantiene inmovilizada. Permitiendo conocer el tiempo

en el que se presenta el golpe de talón (t_{HS}) y el despegue (t_{TO}) a partir de los cuales se puede determinar el periodo (\bar{T}_p) utilizando la ecuación:

$$\bar{T}_p = t_{HS,i} - t_{HS,i-1} \quad (37)$$

A partir de estos datos se pueden aplicar las ecuaciones 1, 3 y 4 para la obtención de la candencia, el tiempo de balance y de soporte, respectivamente. Mientras que para determinar la longitud de la zancada (L), la ecuación 5 puede ser reescrita como:

$$L = |r_{t_{HS,i}} - r_{t_{HS,i-1}}| \quad (38)$$

Donde $r_{t_{HS}}$ es el desplazamiento de la pierna al momento de realizar el golpe de talón.

En cuanto al cálculo del ROM, se considerará el desplazamiento angular de las principales articulaciones de las piernas, tal como se mencionó en la sección anterior, de los cuales de buscará identificar los picos y valles que serán interpretados como el α_{max} y α_{min} , respectivamente. Permitiendo aplicar la ecuación 2 para definir el ROM de cada articulación.

7.3. Base de datos

Toda la información utilizada para los procesos de desarrollo de modelos de ML tendrá como fuente dos bases de datos, una generada desde cero, bajo una propuesta de protocolo propia, y otra que forme parte del dominio público. Esta última se utilizará para mantener un desarrollo continuo del proyecto de investigación sin verse afectado por los tiempos necesarios para la recopilación de datos o la cantidad de voluntarios, permitiendo que se valide la funcionalidad de la metodología propuesta de los modelos de ML. De esta manera también se podrá identificar la presencia de bias causados por desbalances o limitantes en la información disponible.

Las bases de datos se incorporarán mediante SQL para facilitar el acceso y filtro de la información, ya que el desarrollo de los modelos de ML puede llegar a requerir de información específica, así como estructuras particulares.

7.3.1. Base de datos propia

El presente trabajo busca el desarrollo de una base de datos propia con el apoyo de la clínica SUAF de la facultad de enfermería, donde se recopilaría información de la marcha tanto de voluntarios sanos como con esguince de tobillo por inversión en el que se reflejen los cambios en la biomecánica de la marcha. Los cuales puedan ser extraídos en forma de indicadores, tal como se menciona en la sección 7.2, para ser almacenados localmente en una base de datos de SQL. De tal forma que se pueda relacionar a los pacientes con cada una de sus sesiones, sus pruebas y sus indicadores.

7.3.2. Base de datos publica

En este caso se opta como alternativa a la base de datos de la marcha GaitRec, la cual se ha recopilado por más de 10 años por parte del Austrian rehabilitation center of the Austrian Workers' Compensation Board (AUVA), con el fin de ser utilizada para el desarrollo de modelos de inteligencia artificial. Esta está compuesta por la participación de más de 2084 pacientes con diferentes condiciones de espalda, cadera, rodilla, tobillo e incluso en estado sano. En este caso particular solo se estará considerando el uso de los casos de ruptura de ligamento en tobillo que hayan seguido un tratamiento y una muestra de los casos catalogados como sanos. Al igual que la base de datos propia, esta sería almacenada en una base de datos en SQL, incorporando los datos generales y las señales obtenidas de sus pruebas. Estas se componen principalmente por señales de fuerza de reacción (Ground Reaction Forces, GRF) obtenidas de placas de presión colocadas a lo largo de un trayecto de 10 metros, por lo que se estarían trabajando con indicadores cinéticos de la marcha. A pesar de que estos pueden diferir de los establecidos en la base de datos propia, cuentan con similitudes como un comportamiento a base de patrones y una reacción directa ante los cambios mecánicos causados por el esguince de tobillo, tal como se comentó en la sección 6.31 donde las personas afectadas buscan minimizar el impacto sobre la extremidad afectada.

7.4. Creación de modelos de ML

Para la creación de modelos se estarían considerando principalmente las acciones de la extracción de indicadores de alto nivel, para reducción de dimensionalidad e incremento en la robustez del sistema, y la clasificación de clases.

7.4.1. Stacked Autoencoder

Una de las fortalezas del Stacked Autoencoder (SAE) es la reducción de dimensionalidad mediante una codificación que resulte en los parámetros más significativos que comparten un conjunto de muestras, tal como se menciona a detalle en la sección 6.6.2. Por lo tanto, los indicadores extraídos deben caracterizar una condición en particular, que debe cumplirse para toda muestra que pertenezca a la misma condición sin importar las variaciones que puedan llegar a presentarse. Sin embargo, es inevitable que al momento de decodificar los indicadores se presente un error de reconstrucción, siendo la diferencia entre la entrada y la salida. Este comúnmente es evaluado mediante el error cuadrado medio (MSE), el cual idealmente se aproxima a cero cuando se evalúa una muestra perteneciente a la misma condición, y es la misma métrica utilizada para cuantificar el rendimiento del modelo. Esto se debe en gran medida a que las métricas tradicionales como precisión o exactitud son binarias, por lo que si un valor no es idéntico al esperado es marcado como error por más pequeña que sea la diferencia.

En cuanto el modelado del SAE no es una estructura rígida y que puede ser constituida por diversos tipos de capas, siempre y cuando se divida en las etapas de encoder y decoder. Ya que cada una de las estructuras de capa de ML tienen un principio de funcionamiento diferente y priorizan diferentes aspectos de la información. Por lo cual, se propone el uso de 3 diferentes tipos de SAE, uno compuesto por capas densas, siendo la estructura más simple, por capas de LSTM, los cuales destacan en la detección de patrones a largo plazo, y por capas convolucionales, las cuales destacan en interpretar información compleja. De estos se buscará utilizar reducciones de dimensionalidad con pasos similares y serán evaluadas mediante los criterios establecidos más adelante en la sección 7.7, donde se seleccionará la que presente un mejor desempeño.

7.4.2. Clasificador NN

Para la clasificación entre las muestras en estado sano y las muestras con esguince, se considera el uso de un modelo NN a base de capas densas, ya que se busca trabajar con indicadores estáticos de cada muestra. En este caso los indicadores espaciotemporales cumplen con la característica de estáticos, ya que son datos que no cambian a gran velocidad, siendo el caso contrario para los indicadores cinemáticos al requerir ser representados como series de tiempo. Esta información puede contener patrones y tendencias que pueden estar relacionadas con la condición, por lo que no se puede simplemente promediar. Por lo cual se estará utilizando el mismo modelo de SAE que se obtenga de la sección 7.4.2 para procesar los indicadores cinemáticos, extrayendo indicadores de alto nivel que puedan ser representativos de la información original. De tal forma que el pipeline para el clasificador tal como se muestra en la Fig. 7.10.

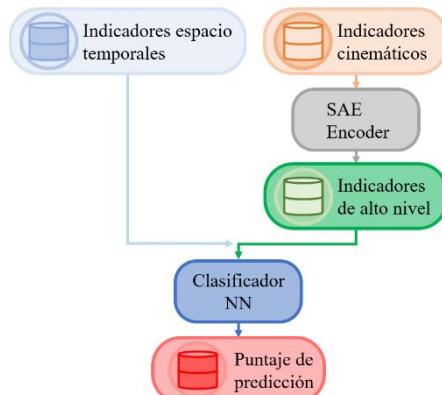


Fig. 7.10.- Evaluación de variaciones en el puntaje de predicción.

7.4.3. Validación del rendimiento de modelos

Para la validación de los modelos se utilizará la metodología de cross-validation con 5 dobleces, es decir que la información será dividida para generar 5 grupos diferentes de datos de entrenamiento y validación. Permitiendo que se generen 5 modelos con las mismas características, pero cuyo desempeño puede variar ampliamente.

Para cuantificar el desempeño se debe considerar que tipo de resultado se obtendrá en la salida de los modelos, en el caso de los clasificadores únicamente se puede asociar la muestra con una de las clases, por lo cual su resultado puede ser evaluado de forma binaria como

correcto o incorrecto. Por lo tanto, se pueden utilizar las métricas de precisión, exactitud, recall y F1-score para evaluar el desempeño del modelo (Pang et al., 2003), utilizando las ecuaciones:

$$\text{Presición} = \frac{TP}{TP+FP} \quad (39)$$

$$\text{Exactitud} = \frac{TP+TN}{TP+FP+NT+FN} \quad (40)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (41)$$

$$F1 - score = \frac{2*Precisión*Recall}{Precision+Recall} \quad (42)$$

En donde TP es la cantidad de elementos pertenecientes a la clase clasificados de manera correcta, TN los que no pertenecen clasificados de manera correcta, FP que pertenece y fueron mal clasificados y FN que no pertenecen y fueron mal clasificados.

Por otra parte, para todos aquellos casos donde el resultado del modelo no se puede decir si es correcto o incorrecto, como es el caso del SAE y de los modelos de regresión. Ya que estos solo buscan aproximarse al resultado deseado, pero es inevitable la presencia de variaciones durante el proceso. Por lo tanto, la alternativa es el cálculo del MSE utilizando la ecuación:

$$MSE = \frac{1}{n} \sum_{i=1}^n (h_i - y_i)^2 \quad (43)$$

Donde h seria la salida obtenida del modelo y y es la salida deseada.

7.5. Cuantificación del grado de recuperación

Para cuantificar el grado de recuperación es necesario definir que parámetros o patrones caracterizan el estado sano de la marcha, el cual puede ser considerado como Ground Truth, mediante el cual se puedan establecer las diferencia entre estados mediante valores cuantitativos. Para esto no hay una metodología preestablecida, pero se cuenta con antecedentes que describen el uso de ML para la obtención valores derivados de indicadores que muestran una diferencia cuantitativa entre dos condiciones y una correlación con el desarrollo de las condiciones (Chakraborty et al., 2022; Guo et al., 2025). Por lo cual se utilizarán dos parámetros diferentes para la cuantificar el grado de recuperación (Gr), así

como la combinación de ambas, con el objetivo de identificar cual tiene mejor correlación con el progreso del esguince.

7.5.1. Error de reconstrucción del SAE

Al utilizar un modelo SAE se busca que la salida y la entrada tengan la menor variación posible, resultando en un error de reconstrucción, calculado mediante el MSE, cercano a 0. Estos se ajustan para caracterizar una condición en particular, el cual tenga una reacción significativa al evaluar una muestra que no corresponda a la clase, obteniendo un bajo rendimiento del SAE que se refleje como un incremento significativo del MSE. El resultado esperado sería similar a lo que se muestra en la Fig. 7.11, donde se compara la diferencia en la reconstrucción obtenida con el SAE en ambos casos.

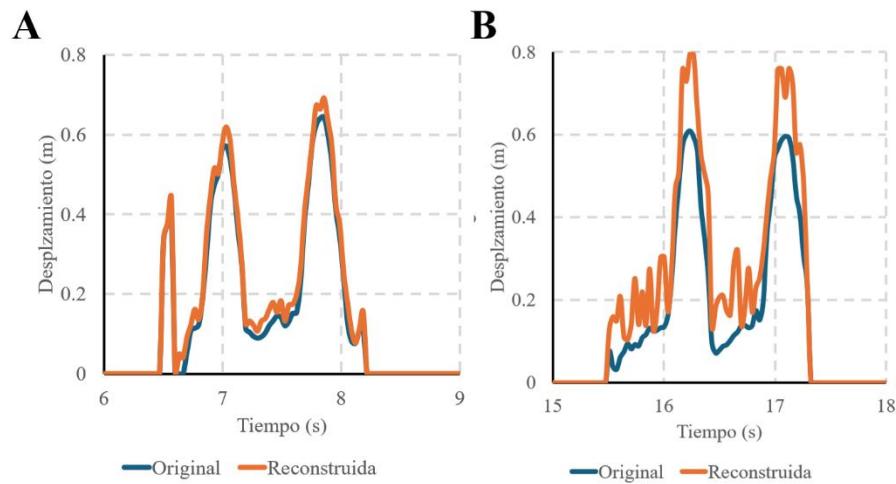


Fig. 7.11.- Comparación de la reconstrucción de señales de tobillo sano (A) y con lesión (B).

Por lo tanto, una diferencia en el MSE debería corresponder a una variación en los patrones extraídos de la información. Este proceso se limitaría al uso de los indicadores que se encuentren en un formato de serie de tiempo, siendo estos los indicadores cinemáticos. Mientras que los indicadores espaciotemporales están representados por un valor estático, por lo que la extracción de indicadores de mayor nivel o el cálculo de su MSE podrían resultar redundante. El pipeline propuesto se muestra en la Fig. 7.12, donde el MSE sea la salida principal.

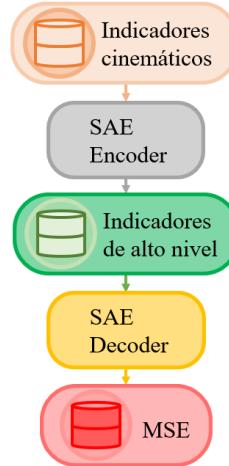


Fig. 7.12.- Pipeline para la evaluación del MSE.

Utilizando este modelo buscaría visualizar un cambio en el MSE conforme progresá el tratamiento del voluntario y los patrones de su marcha se asemejan al estado sano, por lo tanto, se consideraría la equivalencia:

$$Gr = MSE \quad (44)$$

7.5.2. Puntaje de pertenencia del Clasificador

La distribución probabilística obtenida como resultado de un clasificador sería interpretada como la pertenencia de la muestra para cada una de las clases. Bajo esta suposición se realiza la inferencia de que la pertenencia puede disminuir conforme una muestra vaya perdiendo las características que la asocian a dicha clase. Por lo cual se buscará evaluar mediante el clasificador propuesto en la sección 7.6.2, las muestras obtenidas en diferentes sesiones de tratamiento de los voluntarios para identificar cambios en las inferencias realizadas por el modelo, buscando una correlación entre las variaciones en la respuesta del modelo y el progreso de recuperación del paciente. Esperando que las últimas sesiones presenten una tendencia al error de clasificación al tratar de ser asignado a la clase de lesión, pero presentando una falla al contar con características mayormente asociadas con el estado sano.

Por lo cual se estaría utilizando la relación:

$$Gr = y_0 = \frac{e^{(W_0^T x + b_0^0)}}{\sum_{j=1}^K e^{(W_j^T x + b_j^0)}} \quad (45)$$

Donde y_0 sería el score obtenido del clasificador para clase sana.

7.6. Predicción de la tasa de recuperación

En la sección anterior se estableció la metodología que se utilizará para cuantificar el grado de recuperación y se asume que este cambia con respecto al tiempo y de forma proporcional al impacto que tiene el tratamiento sobre la condición del esguince de tobillo. Por lo tanto, se propone el uso de un modelo de regresión para relacionar las tendencias que se presenten con el grado de recuperación con los indicadores extraídos de la marcha. Para esto se estará utilizando como base un LSTM, al presentar un buen desempeño en la detección de patrones a largo plazo, el cual tomará como entrada los indicadores de la marcha y el grado de recuperación obtenido de estos para predecir el grado de recuperación de la próxima sesión. Este proceso se repetiría para conocer el desarrollo del grado de recuperación en todas las sesiones subsecuentes, por lo cual se estaría implementando un agrupamiento de modelos, donde cada uno considera una mayor cantidad de entradas para generar la inferencia del próximo grado de recuperación (Gr), siendo una estructura similar a la mostrada en la Fig. 7.13.

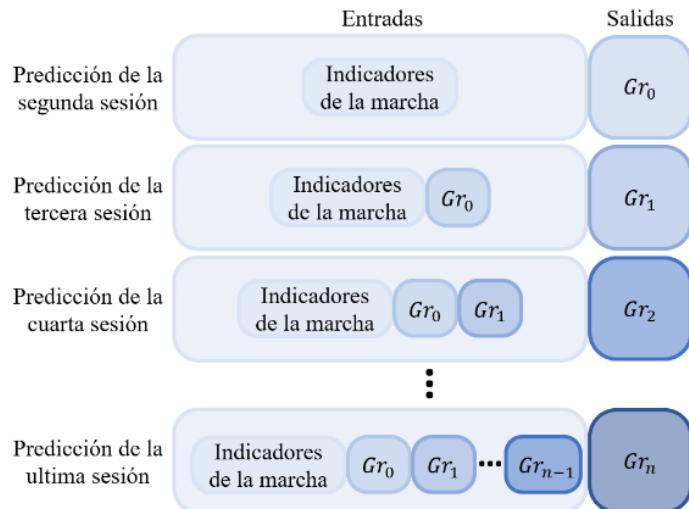


Fig. 7.13.- Estructura de los modelos de proyección del grado de recuperación.

El desempeño de estos modelos sería evaluado mediante el cálculo del MSE, tal como se menciona en la sección 7.4.3, tomando casos donde se conozca a detalle el desarrollo de su grado de recuperación y se compare con la proyección generada con el modelo de regresión.

7.7. Implementación en sistema de visión embebido

Para el desarrollo del sistema de visión artificial se tiene como prioridad que sea un dispositivo práctico para los especialistas del área de fisioterapia, los cuales puedan operarlo sin la necesidad de un amplio conocimiento técnico. Por lo tanto, para el sistema embebido se tomarán consideraciones tanto de hardware como de software que simplifiquen el proceso de instalación, transporte, uso y gestión del procesamiento e información.

7.7.1. Software del sistema de visión artificial

El software será de diseño propio orientado a la gestión de las tareas de adquisición, procesamiento, etiquetado y entrenamiento de modelos de ML, sin demandar una amplia labor manual de parte del usuario. Pero permitiendo que este tenga un nivel de configuración limitado para la modificación de parámetros y la selección de información, con el fin de que pueda ajustar el comportamiento del programa a las necesidades del protocolo de pruebas, sin la necesidad de realizar cambios a nivel código. Además de esto se ha considerado agregar elementos de visualización, para que los especialistas puedan tener una retroalimentación inmediata de los resultados obtenidos que puedan ser utilizados para fundamentar su diagnóstico y el seguimiento del paciente.

Como salida del sistema se estaría considerando preverle al usuario la capacidad de visualizar los videos adquiridos y una presentación en tiempo real de la reconstrucción de la biomecánica, con el fin de que pueda confirmar la realización apropiada de las pruebas y reiniciarlas en caso de detectar fallas en la adquisición. Posteriormente, se le proveería al usuario un despliegue de los indicadores espaciotemporales de la marcha, así como la presentación de las gráficas de los indicadores cinemáticos, permitiendo que se tengan datos cuantitativos para describir y cuantificar el desempeño de la marcha. Y como resultado principal se presentaría el grado de recuperación actual, siendo la diferencia que tiene con una marcha sana, y la proyección del impacto del tratamiento esperado en las siguientes sesiones. En caso de que no fuera la primera sesión, también se presentaría una comparativa entre la proyección ideal del grado de recuperación y el desarrollo real del grado de recuperación.

7.7.2. Hardware del sistema de visión artificial

Para el sistema embebido se considera la integración de todos los componentes en un solo dispositivo, con el fin de minimizar la cantidad de elementos que se necesiten trasportar, instalar y almacenar. Por lo tanto, se considera que el sistema embebido debe tomar como componente principal un microcontrolador para la gestión de tareas, permitiendo prescindir de una computadora de escritorio, que dificulta la movilidad, o una computadora personal (laptop), que podría no cumplir con los requisitos computacionales para la gestión del software. También se ha considerado que el microcontrolador debe tener la capacidad para alimentar y gestionar el uso de dos cámaras de tipo industrial sin tener una caída en su rendimiento.

En cuanto al ensamble se optará por realizar un prototipo que sea flexible en cuanto a la incorporación de los elementos y en su instalación, por lo cual se utilizará el modelo propuesto en la Fig. 7.14. Este permitiría la instalación de diversos tipos de cámaras, así como su instalación en cualquier tipo C para cámaras, incluso permitiendo que se instalen componentes adicionales sobre este como reflectores. La carcasa sería diseñada para que pueda ser fácilmente impresa en 3D, simplificando el proceso de manufactura y ajustándola a la integración de los componentes finales que se integrarán en el sistema.

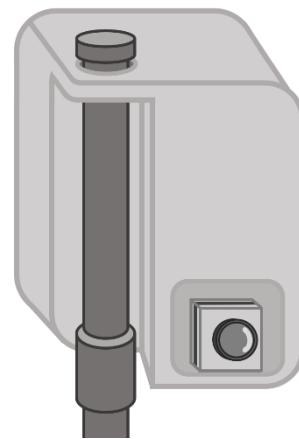


Fig. 7.14.- Propuesta del sistema embebido.

7.8. Consideraciones éticas

Para la realización del presente trabajo, se estará colaborando con la Facultad de Enfermería de la Universidad Autónoma de Querétaro del campus CU y Corregidora, la cual facilitará el acondicionamiento de un espacio dentro de sus instalaciones para su uso como área de trabajo durante la realización de pruebas. Además, se contará con el apoyo de especialistas en el área de la rehabilitación pertenecientes a la clínica SUAF, los cuales se encargarán de la evaluación de la condición de los voluntarios, el levantamiento de la ficha de identificación y proveerán asistencia a los voluntarios durante la realización de las pruebas físicas.

Como población objetivo se ha considerado la participación tanto de voluntarios en estado sano como aquellos que padezcan de un esguince de tobillo por inversión de primer o segundo grado, los cuales sean capaces de realizar una marcha independiente, cumplan con los criterios de inclusión definidos en la sección 8.3.2 y lleven un tratamiento continuo de su condición.

Las pruebas físicas se llevarían a cabo en un entorno cerrado dentro de las instalaciones de la clínica, el cual se acondicionará para la realización y monitoreo de las pruebas de la marcha utilizando un sistema de visión artificial. Dichas pruebas consistirán en una repetición de caminatas en línea recta sobre un circuito definido de 3 m a una velocidad de confort, similar a una caminata de la vida diaria, con una duración aproximada de 60 segundos. Durante las pruebas se tendrá el acompañamiento de un especialista que pueda evaluar y suspender la prueba en caso de que se presente incomodidad o dolor. Durante la caminata se lleva a cabo la medición de la biomecánica utilizando un sistema de visión artificial, el cual es de tipo no invasivo por lo que no representa un riesgo para el usuario.

A los participantes se les proporcionará una carta de confidencialidad (Anexo A) en donde se asegura que cualquier información personal no será divulgada y se encontrará resguardada por su servidor y por la facultad de enfermería, y cuyo único uso será con fines académicos. Los participantes también deberán firmar una carta de consentimiento (Anexo B) informado donde afirmen que se les ha dado la información pertinente y han aceptado los términos de la investigación. Para el desarrollo de las pruebas se considerará la NOM-012-SSA3 2012, donde se establecen todos los lineamientos referentes al aspecto ético y del bienestar e

integridad física que se le debe procurar en toda investigación con seres humanos. Además, se estarán cumpliendo los lineamientos establecidos en el Reglamento de la Ley General de Salud en Materia de Investigación para la Salud, la Declaración de Helsinki y las Buenas Prácticas Clínicas emitidas por la Comisión Nacional de Bioética.

VIII. RESULTADOS

8.1. Reconstrucción de la biomecánica

Por medio de la detección de pose se realizó la reconstrucción de la biomecánica del cuerpo humano, utilizando la identificación de keypoints (puntos clave) y el uso de cálculos vectoriales utilizando la herramienta open-source YOLOv8. Mediante la cual se realizó el análisis de cada fotograma de videos de pruebas de la marcha adquiridos desde un plano frontal y lateral de los cuales se realiza una vectorización del esqueleto para subsecuentemente realizar la medición de los indicadores espaciotemporales y cinemáticos.

8.1.1. Realización de pruebas de la marcha

Para el desarrollo del trabajo presente fue necesario la realización de pruebas con voluntarios sanos, para definir el Ground Truth de un caminado sano y voluntarios con esguince de tobillo por inversión que lleven un tratamiento apropiado de su condición. Ambas poblaciones participaron en la realización de pruebas de la marcha, tal como se define en la sección 7.1.1, donde se implementó la metodología descrita en las siguientes secciones.

8.1.1.1. Área de trabajo

Con el apoyo de la clínica SUAF fue posible establecer áreas de trabajo dentro de las instalaciones de las clínicas del Campus Corregidora y CU de la UAQ. Estos espacios de trabajo consistieron en áreas amplias en interior, donde se presentará poca luz natural y facilitará el uso de luz artificial para mantener una iluminación apropiada en el área de trabajo. También se consideró que se encontrarán aislados de zonas de alta concurrencia, para evitar que se presentarán interferencias de personas ajena a las pruebas, ya que pueden causar complicaciones en la etapa de procesamiento para la detección de la pose.

El espacio de trabajo fue delimitado mediante marcadores para orientar a los voluntarios durante la realización de pruebas, tal como se mencionó en la sección 7.1.1, definiendo de forma clara los límites del área de trabajo, de aproximadamente 5 m de longitud, una línea central para mantener una marcha recta y señalamientos que indicarán el inicio de la marcha sostenida. Esto se debe a que los primeros pasos son el arranque de la marcha y presentan características particulares en su biomecánica, ya que al cuerpo no puede compensar

inmediatamente la presencia de dolor, incomodidad, rigidez, fáctica o alguna otra condición anormal (Gazit et al., 2020). Por lo que, con fines de minimizar la complejidad del análisis de la marcha, se limitó al análisis de la marcha sostenida la cual se presenta a partir del segundo ciclo de la marcha. En la Fig. 8.1 se muestra la segmentación del área de pruebas, donde se establece que solo 3 m serán considerados, mientras que el espacio adicional es destinado al arranque y finalización de la marcha. Estas áreas de trabajo se vieron limitadas principalmente por el rango de visión de las cámaras utilizadas y los espacios disponibles dentro de las clínicas, lo cual se mencionará a detalle en la sección 8.1.1.3, por lo cual podría ser mejorado en futuras iteraciones del programa.

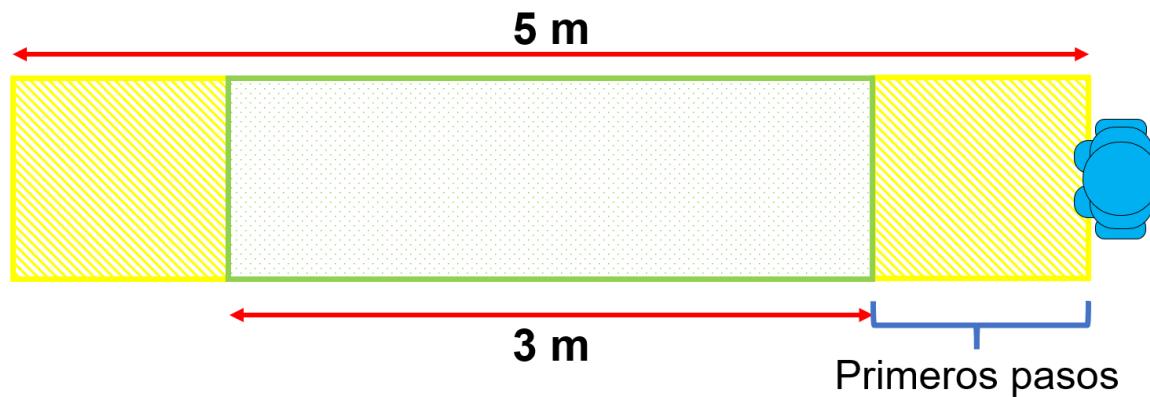


Fig. 8.1.- Espacio total para pruebas de marcha, considerando espacio medible (verde) y excedente (amarillo).

Los espacios de trabajo utilizados fueron variables al haber trabajado en diversas clínicas y se limitaba al uso de las áreas disponibles al momento, pero siempre considerando el uso de espacios con fondo claro que facilitara la visualización de los voluntarios, así como la ausencia de maquinaria, mobiliario, posters o ventanas. En el espacio donde los voluntarios realizarían las pruebas, se priorizó la ausencia de obstáculos como cables, equipos de entrenamiento físico o colchonetas que puedan interferir con el desempeño o concentración del voluntario. Bajo estas consideraciones se obtuvieron espacios de trabajo similares a los mostrados en la Fig. 8.2.



Fig. 8.2.- Espacio de trabajo para la adquisición de videos.

8.1.1.2. Preparación de los voluntarios

Para el desarrollo de las pruebas con voluntarios se consideraron algunas condiciones con las que debían cumplir para la adquisición apropiada de su marcha, estas se dieron a conocer al menos 48 h antes de la realización de las pruebas y consisten en:

1. El participante deberá evitar prendas de tonos muy claros u oscuros, ya que dificultan definir claramente las extremidades.
2. Se recomienda que la ropa sea de tipo deportiva y que no sea holgada, siendo lo más apropiado el uso de licra o shorts.
3. En el caso del calzado se recomienda que este sea de tipo deportivo, que no cuenten con plataformas o tacones y que le permitan al participante caminar cómodamente.
4. En caso de utilizar plantillas, se le invitaría al participante a removerlas al menos durante la realización de las pruebas.
5. Se recomienda evitar la realización de actividad física demandante un día antes de las pruebas.

Cabe aclarar que estos no son los criterios de inclusión, estos son especificados a detalle en la sección 8.3.

El día de las pruebas se siguió lo establecido en la sección 7.8, comenzando con un breve repaso del propósito de la investigación y del aporte que ellos estarían realizando en esta. Junto a esto se les proveería de cartas de consentimiento informado y de confidencialidad, asegurando a los participantes su seguridad física y el registro seguro y apropiado de sus

datos personales. Posteriormente, se les dará a conocer la dinámica con la cual se realizarán las pruebas, asegurando el seguimiento de las normas NOM-012-SSA3 2012 que definen de forma estricta la ética a seguir para la realización de investigaciones con personas. Además de esto, se le aseguro que las pruebas serían realizadas bajo la supervisión de un especialista en fisioterapia de la clínica, así como que son libres de detener las pruebas en cualquier momento en caso de presentarse dolor o inconformidad. Finalmente, se les afirmo que no tienen ningún compromiso con el proyecto de investigación y pueden abandonar por completo el proyecto, asegurando que toda la información relacionada a su participación no será utilizada.

8.1.1.3. Protocolo de distribución del sistema de visión artificial

Para la reconstrucción de la biomecánica se utilizó un sistema de visión artificial, el cual monitoreaba el movimiento desde un plano frontal y lateral, tal como se había establecido en la sección 7.1.2. Para realizar una representación precisa del movimiento fue necesario definir un protocolo para la distribución del sistema de visión artificial, que pudiera ajustarse a factores que estuvieran más allá del control de las pruebas como las condiciones de los espacios de pruebas disponibles dentro de las clínicas y a la altura de los voluntarios.

Ante estas limitantes se consideró que la distribución del sistema de visión y el espacio de pruebas son aspectos prioritarios durante el monitoreo de la marcha, para lo cual se establecieron los siguientes criterios:

- Las cámaras deben ser colocadas para la visualización del plano frontal y lateral del voluntario, resultando en campos de visión (Field of vision, FOV) perpendiculares.
- Se debe proveer un espacio de pruebas de al menos 1 m para el arranque y finalización de la marcha.
- Ambas cámaras deben tener una visibilidad completa del voluntario dentro del espacio de pruebas.
- La cámara del plano lateral debe cumplir con un FOV horizontal (FOV_h) mínimo de 3m, para la visualización de 2 a 3 ciclos de la marcha.

Para el cumplimiento del último punto, se consideraron las características de cada una de las cámaras utilizadas para aplicar la ecuación:

$$FOV_H = \frac{SS_H * WD}{f} \quad (46)$$

Donde WD es la distancia de trabajo, SS_H es el tamaño horizontal del sensor y f es la distancia focal.

El protocolo de distribución del sistema de visión artificial para la adquisición de la biomecánica de la marcha se puede resumir en el diagrama de la Fig. 8.3.

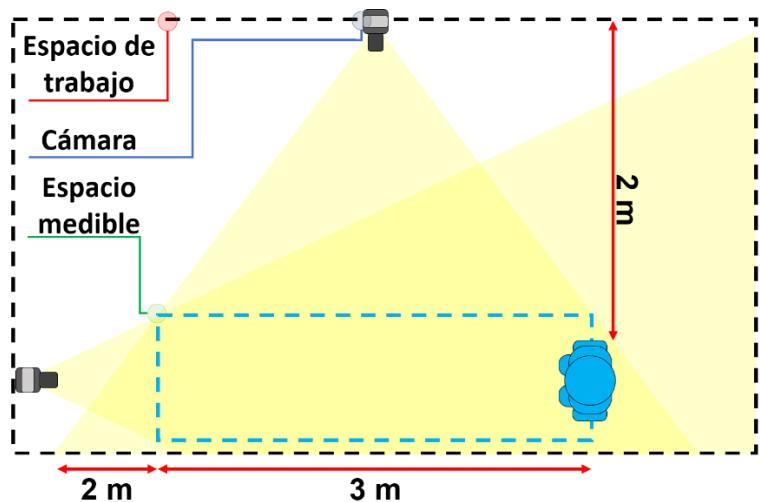


Fig. 8.3.- Disposición del sistema de visión en el espacio de trabajo.

Siguiendo estas mismas especificaciones fue posible adaptar con facilidad el sistema de visión artificial en diferentes entornos, ya que por cuestiones de disponibilidad no siempre se podían utilizar los mismos espacios dentro de la clínica. Siendo una mejoría que impedía que el proceso de pruebas o seguimiento de los voluntarios con esguince de tobillo se vieran afectado por factores ajenos. En la Fig. 8.4, se muestra una captura de la distribución utilizada en algunas de las sesiones de prueba.

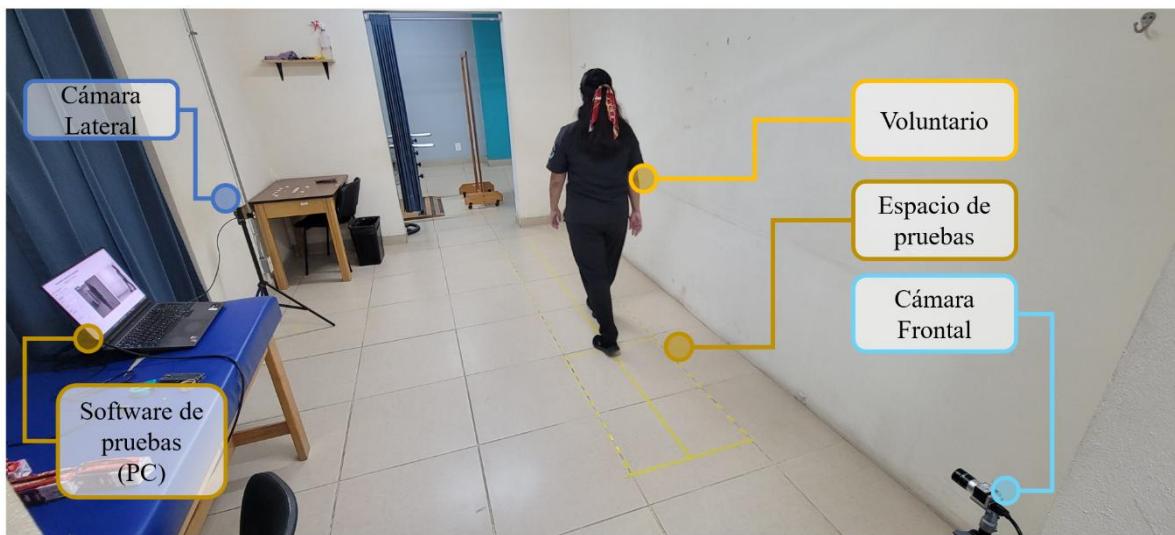


Fig. 8.4.- Distribución del sistema de visión artificial.

8.1.1.4. Aplicación del protocolo de pruebas

Para la aplicación de las pruebas con cada participante se procuró seguir lo preestablecido en las secciones 7.3.2 y 7.3.3. Por lo tanto, se buscó tener con antelación contacto directo con todo interesado en participar como voluntario del proyecto, donde se les proporcionó un contexto del propósito de del proyecto de investigación y el papel que ellos cumplirían. Con aquellos que aceptaban su participación se agendaba una fecha y horario para la realización de pruebas, los cuales se coordinaban con sus consultas en caso de ser pacientes de la clínica, y se les daba información de las condiciones en las que se debían presentar.

La dinámica utilizada para la realización de pruebas consistía en la siguiente serie de pasos:

- I.** Creación de ficha de identificación para la recopilación de datos generales e información de lesiones o condiciones previas, utilizando un cuestionario en línea.
- II.** Complementación de la ficha de identificación por parte de un especialista que verificará el cumplimiento de los criterios de inclusión.
- III.** Explicación de la dinámica de las pruebas, las herramientas utilizadas y el tipo de información que se estaría recopilando.

- IV.** Firma de cartas compromiso y de confidencialidad, donde se asegure la comprensión de su papel en el proyecto, su participación voluntaria sin búsqueda de compensación monetaria y se asegure el cuidado de su salud y datos personales.
- V.** Demostración del tipo de prueba a realizar, junto a una explicación de las restricciones durante su realización.
- VI.** Monitoreo de pruebas de la marcha, realizando de 3 a 5 repeticiones de caminatas sostenidas en el circuito preestablecido.

Para los casos con esguince de tobillo se procuró llevar un seguimiento del progreso de su condición, por lo cual el paso VI se incorporó al inicio de cada sesión de tratamiento, tomando un aproximado de 5 minutos adicionales.

La aplicación de esta dinámica para pruebas resultó exitosa, donde no se presentó ningún inconveniente que haya afectado la salud de los voluntarios. La mayoría de las pruebas realizadas fueron utilizadas en los procesos subsecuentes, descartando únicamente casos particulares donde se presentaron errores de adquisición o interferencias ajenas al proyecto.

8.1.2. Extracción de la biomecánica mediante detección de pose

La detección de pose es realizada en cada uno de los fotogramas de los videos de pruebas de la marcha, permitiendo que se describa con detalle la mecánica de la marcha de cada voluntario, tal como se describe en la sección 7.1.2. Para esta tarea se utilizaron los modelos preentrenados de YOLOv8 para la detección de pose, los cuales se encuentran sintonizados para la detección de las articulaciones principales (keypoints), como se describe en la sección 6.5.1. Su implementación se ajustó para ser utilizada para el análisis de pruebas en vivo y pregrabadas, donde se realizó la medición de indicadores cinemáticos con una frecuencia de muestreo de 10 Hz y de 20 Hz, respectivamente. Esto se debe en gran medida a la carga computacional del procesador utilizado, ya que las cámaras tienen una frecuencia nativa de 20 fps y si se realizaba el análisis de cada fotograma en tiempo real se presentaba una caída en el desempeño de la adquisición de video, siendo incluso menor a los 10 fps. Para implementar estos cambios se utilizaron diferentes modelos de detección de pose, utilizando

‘yolov8n-pose.pt’ para el análisis en vivo con el sistema embebido o para análisis rápido de pruebas y el modelo ‘yolov8x-pose.pt’ para el análisis detallado de pruebas pregrabadas utilizadas para el entrenamiento de modelos de ML. Además de esto se incorporó la librería openvino para reducir la carga computacional sobre el microcontrolador.

Al implementar el análisis de los fotogramas, se obtiene como resultado un arreglo de coordenadas (x, y) para cada uno de los keypoints y un boinding box para cada persona dentro de la imagen, lo cual se aplica para la vista lateral y frontal, tal como lo muestra la imagen resultante de la Fig. 8.5.

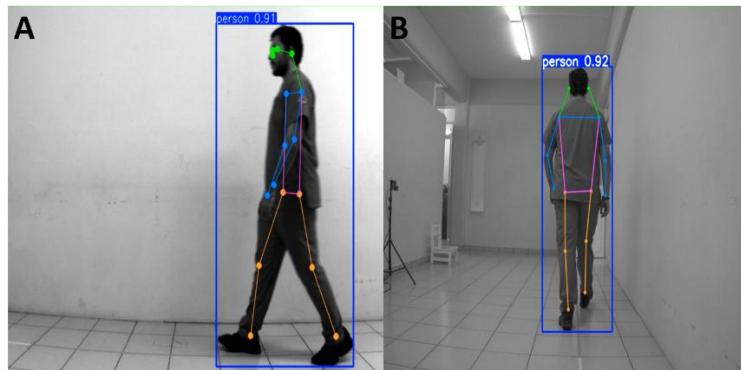


Fig. 8.5.- Detección de pose en el plano lateral (A) y el plano frontal (B).

Los keypoints obtenidos de este proceso son acondicionados con las ecuaciones 22 a 25 para el traslado del punto de referencia, siguiendo lo establecido en la sección 7.1.2. Posteriormente se utilizan las ecuaciones 26 a 28 para escalar la posición de los keypoints de la vista frontal con respecto a la bounding box de la vista lateral, esto se debe en gran medida a que la vista frontal tendrá siempre un cambio en las dimensiones de la persona ya que esta se acerca y se aleja de la cámara. En cambio, la cámara lateral se encuentra a una distancia estática de la persona sin importar su desplazamiento durante las pruebas. Posterior al acondicionamiento de los keypoints, se utilizan las ecuaciones 29 a 31 para obtener la representación tridimensional de la pose a base de vectores, lo cual únicamente es viable al haber seguido el protocolo del sistema de visión establecido en la sección 8.1.1.2.

Al haber extraído las poses de cada fotograma se generan las señales correspondientes a los indicadores cinemáticos de cada keypoint. Sin embargo, es común que esta información

cuento con errores a causa de la obstrucción de las extremidades en ciertas posiciones o la presencia de ruido durante la detección de los keypoints, causado por la falta de una referencia fija. Por lo que se pueden presentar valores nulos o la presencia de ruido, incluso cuando se mantiene una posición estática, por lo que se aplica una etapa de filtrado como posprocesamiento utilizando la interpolación y filtros EMAF, tal como se menciona en la sección 7.1.3.

El resultado de la reconstrucción de la biomecánica de la marcha se puede visualizar en la Fig. 8.6, donde se utiliza la librería de matplotlib para la representación de los keypoints y el vectorizado del esqueleto, lo cual únicamente tiene fines demostrativos, más no es una respuesta que se le provee al usuario ya que su interpretación podría ser redundante y cargaría con los mismos bias que tiene una evaluación visual de la marcha.

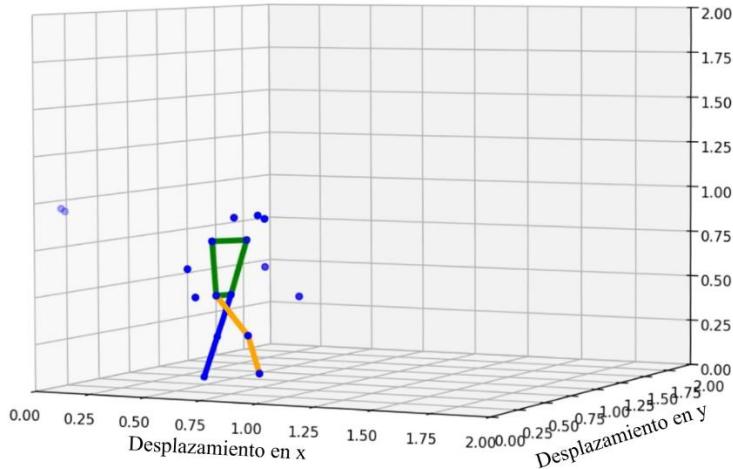


Fig. 8.6.- Visualización de la reconstrucción del esqueleto en un espacio tridimensional.

Los resultados obtenidos son los desplazamientos de los keypoints en un espacio tridimensional, los cuales son representados mediante señales de desplazamiento para cada uno de los ejes. Estos son almacenados de forma independiente y local en documentos .csv para posteriormente realizar la extracción de los indicadores.

8.2. Extracción de indicadores

Los indicadores son el principal medio utilizado para la descripción de la marcha, al permitir que su evaluación tenga un carácter más objetivo y le facilite al usuario la medición de las propiedades dinámicas de la marcha, que difícilmente pueden ser obtenidas por otros medios.

8.2.1. Indicadores cinemáticos

Partiendo únicamente de los desplazamientos obtenidos de la sección 8.1.2 se busca obtener mediciones complementarias de la biomecánica, con base a lo establecido en la sección 7.2.1. Primeramente, se obtuvo la velocidad de cada keypoint utilizando la ecuación 7 y tomando de forma individual el desplazamiento en cada eje, ya que algunos muestran una mayor relevancia en la descripción de la marcha, mientras que otros mantienen valores casi estáticos. En la Fig. 8.7 se puede apreciar la señal de velocidad derivada del desplazamiento del tobillo.

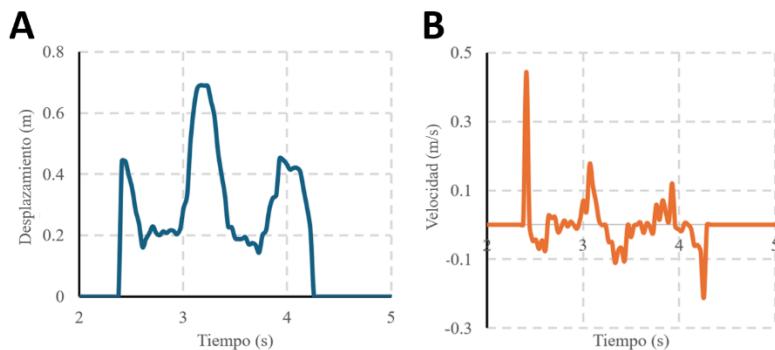


Fig. 8.7.- Calculo de la velocidad de keypoints a partir del desplazamiento. A. Desplazamiento de tobillo. B. Velocidad de tobillo.

Estos son almacenados inicialmente de forma local, permitiendo que se mantenga un fácil acceso antes de ser incorporados a la base de datos.

Posteriormente se realiza el cálculo de los ángulos del desplazamiento angular generado durante la marcha en la cadera, rodillas y tobillos. Para esto se utiliza las coordenadas (x , y , z) de los keypoints obtenidas de la reconstrucción vectorial del esqueleto, y con las cuales se aplica la ecuación 8 para la obtener los ángulos con respecto a la superficie (θ_h , θ_k y θ_a), tal como se menciona a detalle en la sección 7.2.1, y se aplican las ecuaciones 35 a 37 para el

cálculo del desplazamiento angular en cada articulación (θ_H , θ_K y θ_A) para ambas piernas, resultando en señales como las que se muestran en la Fig. 8.8.

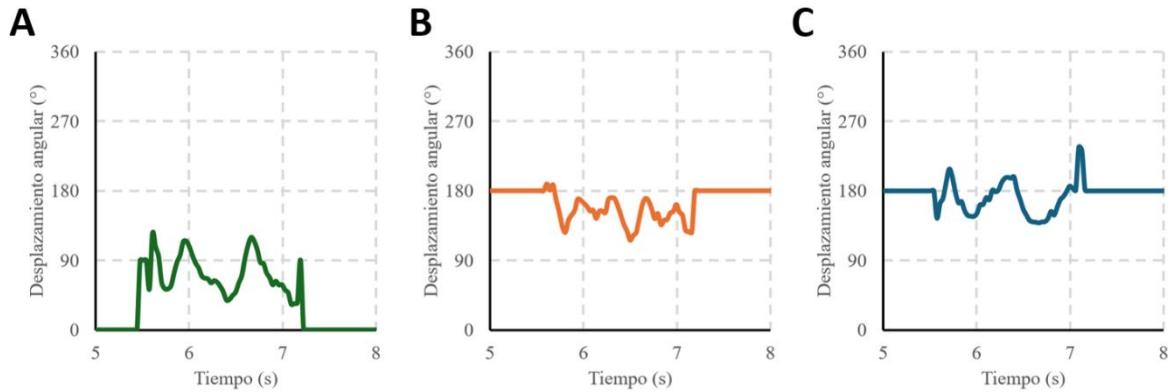


Fig. 8.8.- Desplazamiento angular en las principales articulaciones de la pierna.

A. Tobillo. B. Rodilla. C. Cadera.

Las señales obtenidas también pasaron por un proceso de suavizado con EMAF y almacenadas de forma local para su uso en los procesos subsecuentes.

8.2.2. Indicadores espaciotemporales

Como indicadores espaciotemporales utilizados para la descripción de la marcha se consideraron los mencionados en la sección 6.4.3. Para su adquisición se parte del desplazamiento del tobillo en el eje x, donde a partir de la identificación de los eventos de golpe de talón (HS) y despegue (TO) se pueden derivar las medidas de la longitud de zancada, la cadencia, el periodo y los tiempos de balanceo y soporte.

Para la detección de los picos y valles en las señales de desplazamiento del tobillo, que como se mencionó en la sección 7.2.2 corresponden con el TO y HS respectivamente, se utilizaron las herramientas de Scipy, donde se pueden especificar los parámetros que deben cumplir como el ancho del pico y la separación, permitiendo que se filtren errores remanentes en la señal. Los puntos obtenidos se pueden visualizar en la Fig. 8.9A, los cuales fueron utilizados para aplicar la ecuación 38 para el cálculo de la longitud de zancada (L), que puede ser visualizada con mayor facilidad en la Fig. 8.9B.

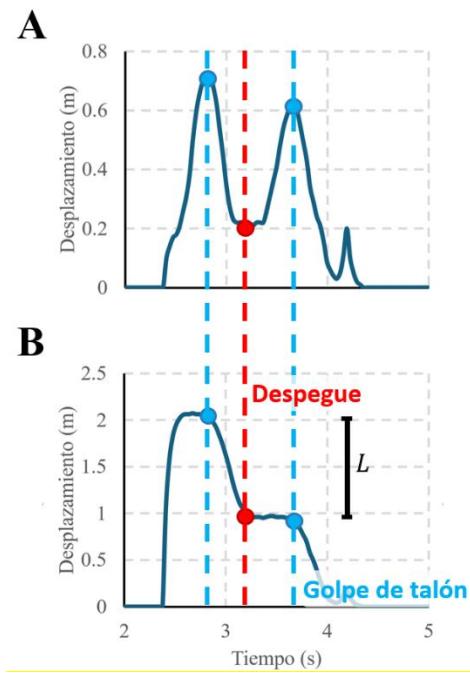


Fig. 8.9.- Cálculo de la longitud de zancada mediante picos y valles. A) Datos en sistema de coordenadas dinámico. B) Datos en el sistema de coordenadas estático.

Para la obtención del periodo (\bar{T}_p) se utilizó la información de los picos para implementar la ecuación 37, a partir de este dato se puede obtener la Cadencia (C_d) con la ecuación 1. Utilizando la misma información de los picos y valles del desplazamiento del tobillo, se utilizaron las ecuaciones 3 y 4 para la obtención del tiempo de balanceo (\bar{T}_b), mediante la diferencia de tiempos de un pico a un valle, y el tiempo de soporte (\bar{T}_s), con la diferencia entre un valle y un pico. La representación de los períodos de tiempo obtenidos se puede visualizar en la Fig. 8.10.

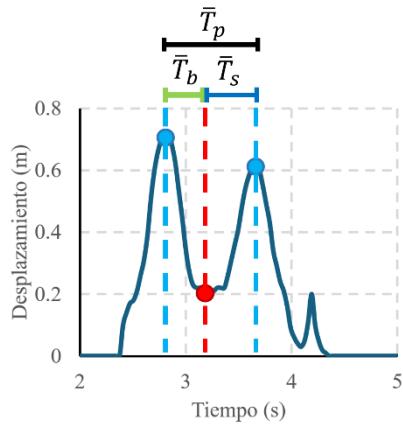


Fig. 8.10.- Cálculo de tiempos de balanceo, soporte y periodo.

En los casos donde se presentan más de un ciclo de la marcha en una prueba, como se ilustra en la Fig. 8.11, se tomó la consideración de utilizar el mayor tiempo de balance y soporte.

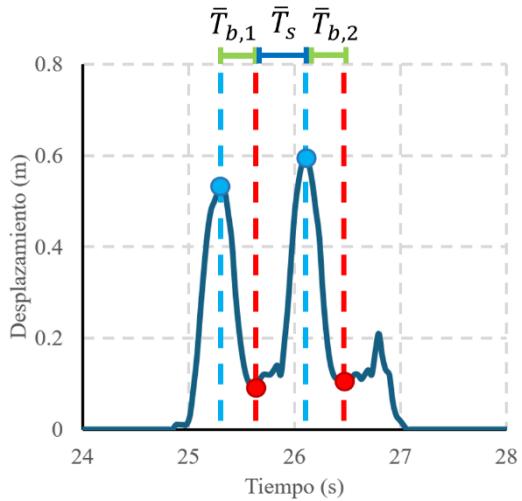


Fig. 8.11.- Presencia de múltiples tiempos de balanceo en una prueba.

Por otro lado, para la medición del ROM de cada articulación se tomaron los desplazamientos angulares de cada una de las articulaciones principales de la pierna. Para su cálculo no solo se tomaron los valores mínimos o máximos, sino que se utilizó la detección de picos y valles para una medición más robusta, que ignore los cambios abruptos que se pueden llegar a presentar por ruido o inconsistencias que hayan quedado como remanentes del proceso de adquisición, incluso después del posprocesamiento de datos. De los picos y valles obtenidos se realiza una selección de aquellos que demuestren una mayor diferencia entre amplitudes,

siendo considerados como el α_{max} y el α_{min} de la articulación, esto se puede ver ejemplificado en la Fig. 8.12.

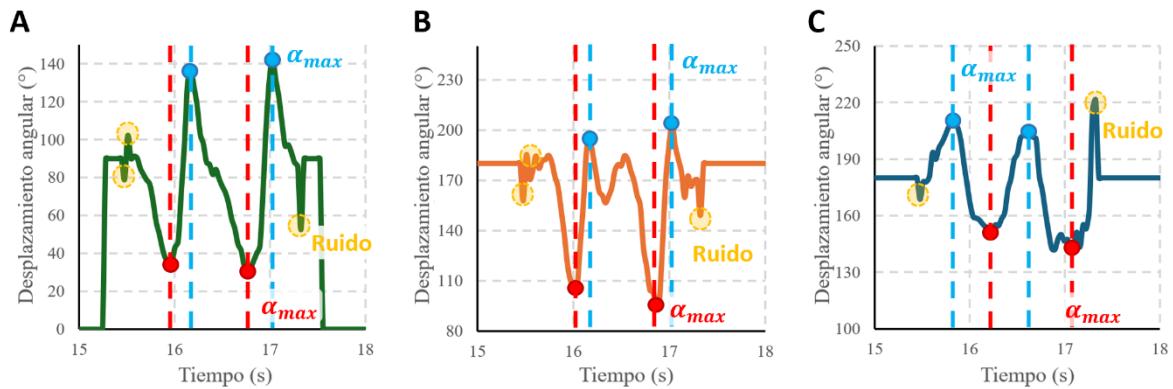


Fig. 8.12.- Medición del α_{max} y el α_{min} . A. Tobillo. B. Rodilla. C. Cadera.

El cálculo de todos los indicadores no se generalizó para cada una de las sesiones, sino que fue dividido por cada repetición las cuales fueron consideradas como pruebas individuales, permitiendo expandir la cantidad de información para el entrenamiento de los modelos ML, donde se reflejen una mayor cantidad de variaciones que se pueden presentar en ambas clases. La información recolectada no fue almacenada de forma local, sino que se incorporaron directamente en la base de datos, lo cual se desarrolla más a fondo en la próxima sección.

8.3. Bases de datos

Las bases de datos utilizadas contienen información de poblaciones específicas, siendo el caso sano y el caso con esguince de tobillo por inversión. Donde los voluntarios fueron reclutados directamente en las clínicas del SUAF y filtrados para su participación acorde a los criterios de inclusión. Como resultado su participación se obtuvo información de la biomecánica y los indicadores de la marcha la cual se estructuro para beneficiar las necesidades de los procesos subsecuentes.

8.3.1. Población de voluntarios

Con el apoyo del personal de la clínica SUAF fue posible organizar campañas de reclutamiento de voluntarios en estado sano, en donde se tuvo la colaboración de 26 miembros de la facultad de enfermería del campus corregidora. Estos fueron evaluados por especialistas mediante pruebas de inspección visual para validar que su marcha cumpliera

con los criterios de un estado sano. Para complementar la información se realizó el levantamiento de una ficha de identificación, donde se anexaron datos generales y se dio una revisión superficial de su historial médico, enfocado únicamente en lesiones, enfermedades o condiciones que hayan podido representar un efecto negativo en su locomoción o que pueda entrar en conflicto con los criterios de inclusión definidos en la sección 8.3.2.

En cuanto a la población con esguince por inversión solo se contó con 2 pacientes que cumplían con todos los criterios de inclusión y con los cuales se llevó un seguimiento exitoso de su recuperación. Para la realización de este reclutamiento se contó con el personal de la clínica SUAF como enlace con los pacientes, permitiendo que se les planteará su participación en el presente proyecto. Esto fue a partir de conversaciones directas donde se les planteo el objetivo del proyecto, el tipo de pruebas que se estarían realizando y el alcance de su participación.

Como alternativa para el desarrollo continuo y prueba de los modelos de ML, se utilizó la base de datos de la marcha GaitRec de señales de GRF, tal como se había mencionado en la sección 7.3.2. De esta se tomó una población de 50 voluntarios que constituyeran la clase sana y de la población de 627 pacientes con lesión en pierna, se tomó una muestra de 24 participantes que contaban con una lesión aislada de esguince de tobillo por inversión. Ambas poblaciones fueron utilizadas en su totalidad para el desarrollo de las tareas de clasificación; sin embargo, para la predicción de la tasa de recuperación, únicamente se utilizaron 13 casos con esguince de tobillo, ya que fueron los únicos donde se reportó a detalle un seguimiento de la condición. Es necesario mencionar que para la selección de la muestra de pacientes de esta base de datos también se consideró el cumplimiento de los mismos criterios de inclusión de la sección 8.3.2

8.3.2. Criterios de inclusión

Para la participación de voluntarios tanto sanos como con lesión, se deberá llevar a cabo una evaluación por parte de un especialista en el área de fisioterapia del Sistema Universitario de Atención en Fisioterapia (SUAF) de la Universidad Autónoma de Querétaro (UAQ). Los cuales validarán el cumplimiento de los siguientes criterios de inclusión:

1. El rango de edad de voluntarios debe ser entre los 18 a 30 años.
2. Deben de estar exentos de lesiones musculoesqueléticas, neurológicas o enfermedades que degeneren directamente la marcha y sean ajenas a la condición de interés.
3. No deben haber presentado otra lesión en los últimos 6 meses.
4. Deben ser capaces de realizar una marcha sostenida de forma independiente.

Para la población que presentaba esguince de tobillo se tomaron algunas consideraciones adicionales:

4. El esguince en tobillo debe ser por inversión donde se hayan visto afectados los ligamentos laterales colaterales (LATF, LCF, LPTF).
5. El esguince de tobillo no debe presentar una ruptura completa de ligamento (Grado III).
6. El voluntario debe de llevar un tratamiento apropiado de su lesión.

8.3.3. Estructura de la base de datos

La base de datos propia obtenida hasta el momento contiene información de 26 voluntarios en estado sano y 2 voluntarios con esguince de tobillo, que cumplieron con los criterios de inclusión y que tuvieron seguimiento durante su tratamiento. La información extraída de cada uno de los voluntarios, mencionada en la sección 8.2, requería de una estructura que facilitara su acceso y filtrado de la información para las tareas de clasificación y predicción, donde se pudiera segmentar la información con base a diferentes criterios. Para esto se utilizó la plataforma de MySQL mediante Python, para la creación de una base de datos local donde se almacene toda la información de los indicadores, el proceso de seguimiento y la ficha de identificación de cada voluntario. La selección de SQL fue deliberada para hacer uso de sus herramientas para consulta con tablas relacionales, para la selección y filtrado de la información requerida en cada proceso.

Para el diseño de la estructura de la base de datos se priorizo una estructura que simplifique la incorporación de nuevos registros, lo cual es indispensable durante el seguimiento del proceso de recuperación de los voluntarios con lesión. Para lo cual se segmentó la

información de cada voluntario en diferentes tablas, lo cual se puede ver representado en la Fig. 8.13.

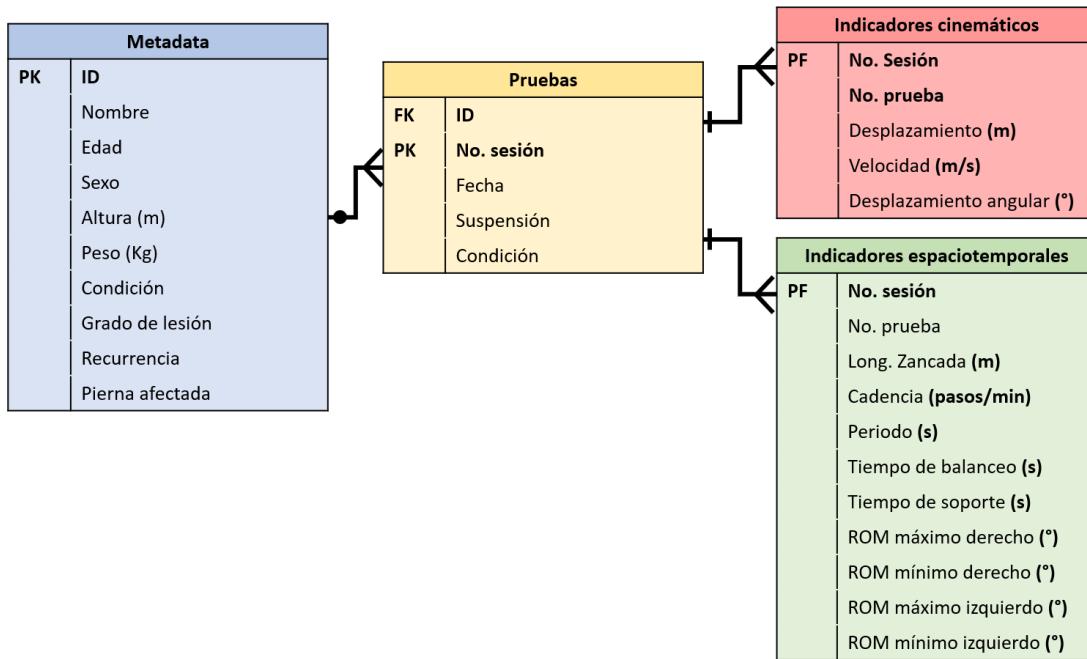


Fig. 8.13.- Tablas relacionales de la base de datos en SQL.

En esta estructura se incorpora la tabla de “Metadata” como la principal, conteniendo todos los datos de la ficha de identificación de los voluntarios, siendo estos sus datos generales, la clase a la que pertenecen, ya sea sano o con lesión, la información referente a las características de su lesión y un ID único para facilitar su segmentación. Para la realización apropiada del seguimiento del tratamiento se incorporó una tabla con toda la información relevante de las pruebas, como el número de sesión, el número de prueba, las fechas en las que se dio tratamiento, si se presentaron imprevistos y la condición del paciente, en donde se especifica si es primera valoración, revaloración, seguimiento o si se dio de alta. Permitiendo que la información pueda ser segmentada acorde a la condición para el desarrollo apropiado de los modelos de ML. En cuanto a la información extraída de las pruebas, esta fue almacenada en tablas separadas para los indicadores espacio temporales, al ser indicadores estáticos para cada prueba, y para los indicadores cinemáticos, los cuales tienen un formato de serie de tiempo para cada prueba para permitir el filtro de la información de sesiones e

indicadores particulares. De esta manera se simplificó la selección de la información acorde al proceso que se buscaba realizar, principalmente utilizando la propiedad de “Condición” para separar a la clase sana y con esguince.

Por otra parte, también se utilizó una la base de datos Gaitrec mencionada en la sección 7.5.2 con el fin de validar el comportamiento de los modelos de ML. Ya que la información de la base de datos propia puede ser limitada y contener bias durante el proceso de muestreo o por el desbalance de poblaciones, por lo que se pueden presentar incertidumbre en la eficiencia de las propuestas de modelos de ML. De esta base de datos pública se tomaron 761 muestras en estado sano y 601 muestras con esguince, con los cuales se estructuró una base de datos en SQL independiente, la cual cuenta con una estructura más simple como se muestra en la Fig. 8.14.

Metadata	
PK	ID
	No. Sesión
	Etiqueta de clase
	Etiqueta detallada
	Sexo
	Edad
	Altura (m)
	Peso (Kg)
	Índice de masa corporal
	Lado afectado
	Uso de ortopédico
	Fecha

Señales GRF	
FK	ID
PK	No. sesión
	No. prueba
	Presión en el eje X (%Masa corporal)
	Presión en el eje Y (%Masa corporal)
	Presión en el eje Z (%Masa corporal)

Fig. 8.14.- Tablas relacionales en SQL con base de datos GaitRec.

Esta base de datos estaría siendo utilizada para la validación del funcionamiento de las estructuras de los modelos, al contar con una mayor cantidad de información y un mejor balance entre las clases. Sin embargo, esta base de datos también cuenta con ciertas limitantes, como una estructura más simple donde solo se utiliza un indicador y el desconocimiento de la eficiencia del tratamiento obtenido.

8.4. Modelado de Stacked AutoEncoder (SAE)

Para el desarrollo de modelos de SAE se cumplió con lo establecido en la sección 7.4.1, por lo que se consideró el diseño de un solo modelo que pudiera ser utilizado para la obtención de indicadores de alto nivel, los cuales serán utilizados también con un clasificador en secciones posteriores, y para la obtención del MSE, que facilite la detección de anomalías en las muestras. Por lo tanto, se estableció como condición base los casos sanos al utilizar únicamente los indicadores extraídos de esta población para las etapas de entrenamiento y validación. Permitiendo que la evaluación de muestras ajenas a esta condición destaque a causa de las anormalidades presentes en su marcha, siendo el caso de toda la población con esguince de tobillo.

Para establecer la estructura del SAE se consideraron diferentes composiciones, utilizando diferentes tipos de capas para identificar cuales presentaban un mayor rendimiento con el tipo de información utilizada, tal como se estableció en la sección 7.4.1. Por lo cual se utilizó tres composiciones de SAE utilizando únicamente capas densas, LSTM o convolucionales, sin realizar combinaciones de estas para evitar el incremento de la complejidad del modelo. Como métrica del rendimiento se le dio mayor peso al MSE, ya que en las tareas de reconstrucción la precisión y la exactitud tienden a presentar rendimiento pobre, lo cual se explicó a detalle en la sección 7.4.3. Las estructuras fueron construidas en Python 9.10 utilizando la librería Keras, la cual es una API dedicada a la gestión e implementación de las herramientas de Tensorflow. Donde se utilizaron estructuras funcionales para la construcción de los modelos presentados en la Tabla 3, donde el '*' es utilizado para denotar un número indefinido de muestras.

Tabla 3.- Estructura de los modelos de SAE utilizados

Etapa	SAE-Denso		SAE-LSTM		SAE-Convolucional	
	Tipo	Forma	Tipo	Forma	Tipo	Forma
Entrada	Input layer	(*,78,60)	Input layer	(*,78,60)	Input layer	(*,60,78)
Encoder	Dense	(*,78,60)	LSTM	(*,78,60)	Conv 1D	(*,30,60)
	Dense	(*,78,30)	LSTM	(*,78,30)	Conv1D	(*,15,30)
	Dense	(*,78,15)	LSTM	(*,78,15)	Conv 1D	(*,8,15)
Indicadores de alto nivel	Dense	(*,78,10)	LSTM	(*,78,10)	Conv 1D	(*,10,78)
	Dense	(*,78,15)	LSTM	(*,78,15)	Conv 1D	(*,20,15)
Decoder	Dense	(*,78,30)	LSTM	(*,78,30)	Conv 1D	(*,40,30)
	Dense	(*,78,60)	Time distributed	(*,78,60)	Conv 1D	(*,80,60)
	---	---	---	---	Conv 1D	(*,160,78)
	Output layer	(*,78,60)	Output layer	(*,78,60)	Output layer	(*,60,78)
Salida						

Para evaluar la eficiencia de cada modelo se consideró utilizar 64 muestras de pruebas de voluntarios sanos, de los cuales se tomaron todos los indicadores cinemáticos y se les aplicó una normalización para minimizar el bias. De esta muestra se tomó el 80% para la tarea de entrenamiento y validación, utilizando una división (split) de 0.2, durante 300 épocas con un batch size de 60. El resto de las muestras fueron utilizadas para la realización de los modelos entrenados, resultando en el rendimiento reportado en la Tabla 4.

Tabla 4.- Rendimiento de los modelos de SAE con muestras sanas

Métrica	SAE-Denso	SAE-LSTM	SAE-Convolucional
	Tipo	Tipo	Tipo
MSE entrenamiento	0.0062	0.0035	0.0045
MSE validación	0.0064	0.0037	0.0046
MSE prueba	0.0061	0.0038	0.0044

El resultado obtenido muestra una clara diferencia al utilizar LSTM, ya que los indicadores a base de patrones con formas específicas para cada acción los cuales se ven afectados ante la presencia de anomalías, tal como se mencionó en la sección 6.4.1. Con base a estos resultados se consideró el uso de este modelo para los procesos subsecuentes. Al modelo final se le incorporó como proceso de regularización el uso de capas de dropout, para minimizar el riesgo de overfitting, resultando en el modelo presentado en la Fig. 8.15, donde tanto el encoder como el decoder son tratados como modelos independientes y se toma como salidas del modelo tanto el MSE, siendo el error de reconstrucción, como la salida del encoder, siendo los indicadores de alto nivel.

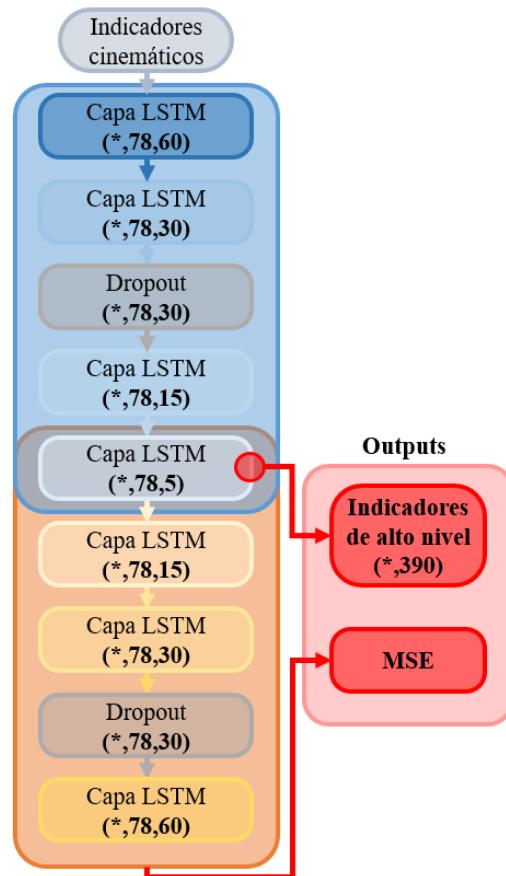


Fig. 8.15.- Estructura del modelo final del modelo SAE.

8.5. Clasificador

El clasificador normalmente solo cuenta con la tarea de inferir a que clase pertenece cada clase; sin embargo, en esta ocasión se consideró que el puntaje puede ser utilizado para cuantificar el progreso de recuperación de una lesión de esguince, tal como se desarrolla en la sección 7.6.2. Por lo tanto, era necesario que el clasificador contara con un alto rendimiento en la separación de ambas poblaciones, utilizando un proceso de muestreo no estadístico para la selección cuidadosa de muestras particulares donde se tuviera una certeza del 100% de pertenencia a la clase. Esto se debe principalmente a los casos con esguince, ya que sus muestras son tomadas en diferentes puntos de su recuperación y es difícil indicar con certeza el momento donde su marcha pasa a tener más similitudes con una marcha sana. Para evitar estas ambigüedades solo se tomaron las pruebas realizadas en las primeras dos sesiones. Por lo tanto, para el desarrollo del clasificador se trabajó con una población de 64 muestras sanas y 24 muestras con esguince, tomando 80% para entrenamiento y validación y 20% para pruebas. La información de la que estaría compuesta cada muestra serían tanto los indicadores espacio temporales como los cinemáticos, estos últimos pasarían por el modelo de SAE generado en la sección 8.5, para convertir las series de tiempo con forma en un vector de 390 indicadores de alto nivel. A estos se les anexarían los indicadores espacio temporales, resultando en un total de 407 indicadores por muestra.

Para el desarrollo del clasificador se utiliza nuevamente keras, donde únicamente se consideró un modelo NN con una capa de softmax como salida para la toma de inferencias, con el fin de mantener un modelo de baja complejidad que pueda ser fácilmente ajustado. Considerando esto se automatizó la realización de pruebas de ablación donde se modificaban el número de capas, el número de neuronas por capa, la aplicación de regularización con dropout, la tasa de aprendizaje y el batch size. La selección y variación de cada uno de los parámetros que serían modificados en cada iteración de clasificador fueron seleccionados mediante keras tuner, donde se utilizaron 100 individuos a lo largo de 50 generaciones para maximizar la precisión. Los resultados obtenidos de los 5 mejores modelos se presentan en la Tabla 5, donde el número de neuronas es representado como un arreglo para simbolizar el número en cada capa.

Tabla 5.- Modelos más destacados de la prueba de ablación

Parámetro	Clasificador 1	Clasificador 2	Clasificador 3	Clasificador 4	Clasificador 5
No. de capas	3	3	3	3	3
No. de neuronas	[62,45,19]	[90,36,24]	[61,44,25]	[88,48,15]	[92,58,22]
Regularización	True	True	True	True	True
Porcentaje de dropout	0.16	0.5	0.86	0.68	0.29
Bach size	127	111	161	126	174
Precisión	99.00	97.15	88.83	88.28	95.47
Exactitud	96.66	97.00	88.66	90.33	94.00
Recall	96.15	98.55	95.67	98.49	95.47
F1-score	97.56	97.85	92.12	93.11	95.47

De los resultados obtenidos se puede apreciar que el nivel de complejidad relacionado al número de capas se mantiene constante entre los modelos más destacados, ya que tienden a ser factores que incentivan el overfitting (Huyen, 2022). El cual es minimizado mediante el uso de regularización, tal como se presenta en todos los clasificadores obtenidos al implementar Dropout. Finalmente, el rendimiento del clasificador 2 presentan un mayor F1-score, lo cual indica un mejor balance entre la precisión y el recall, lo cual es recomendable en los casos donde se tiene un desbalance de clases, tal como es el caso. Sin embargo, se realizó una consideración adicional donde se incorporó el MSE de los indicadores cinematográficos como un nuevo indicador, siendo un total de 408 por muestra, con el fin de identificar si este puede tener un efecto positivo en el rendimiento del clasificador. Por lo tanto, en la Tabla 6 muestra los cambios que se presentan al incluir el MSE como indicador, donde el modelo utiliza la misma estructura y condiciones del clasificador 2.

Tabla 6.- Incorporación del MSE como indicador.

Parámetro	Sin MSE	Con MSE
Precisión	97.15	98.48
Exactitud	97.00	97.66
Recall	98.55	97.98
F1-score	97.85	98.23

Los resultados obtenidos sugieren que el MSE pueden tener un impacto positivo sobre el rendimiento del modelo, aunque queda a debate si estos son significativos al no superar el 1% en el F1-score. Aun así, se consideró mantener su incorporación para los procesos subsecuentes.

8.6. Cuantificación del grado de recuperación

El grado de recuperación es el medio por el cual se busca identificar el impacto que está teniendo el tratamiento sobre la condición de los pacientes con esguince de tobillo, por ello se le ha dado especial importancia al monitoreo de los pacientes en cada una de sus consultas. Hasta el momento solo se logró recopilar en su totalidad la información de 2 voluntarios para la base de datos propia, por lo cual la metodología planteada en la sección 7.5 no ha presentado resultados confiables a causa de la limitada información; sin embargo, si fue posible utilizar la información recopilada para realizar una comparativa entre ambas poblaciones con el fin de validar las diferencias en la mecánica de la marcha planteadas en la sección 6.3.1. Para hacer esto se dividió por semanas la información recabada de los voluntarios con esguince, buscando que en cada etapa de su recuperación se pudieran apreciar cambios considerables en sus indicadores. Uno de los indicadores que tuvo mayor relevancia sobre la comparativa fue el periodo de duración de una zancada, en donde los resultados se alinearon con la literatura, la cual establece que al presentarse una lesión de esguince de tobillo por inversión las personas tienden a reducir la velocidad de caminado en la búsqueda de incrementar su estabilidad. La realización de esta comparativa se puede apreciar en la Fig. 8.16, en donde se resalta con azul la silueta ideal de una marcha sana durante un ciclo, así como la trayectoria promedio realizada por la población sana, mientras que con tonos rojos se resalta la trayectoria promedio de un ciclo de la marcha durante cada semana de tratamiento. El resultado de esto son variaciones de la longitud de zancada (ΔL), las cuales cuentan con una variación inicial de hasta un 80% y se ven reducidas de forma progresiva alcanzando un 20% al finalizar el tratamiento. Si bien esto no puede utilizarse directamente como una cuantificación de la recuperación del paciente, ya que no se llega a obtener un patrón dentro de los límites de la condición sana, si representa un impacto del tratamiento sobre el comportamiento de la marcha.

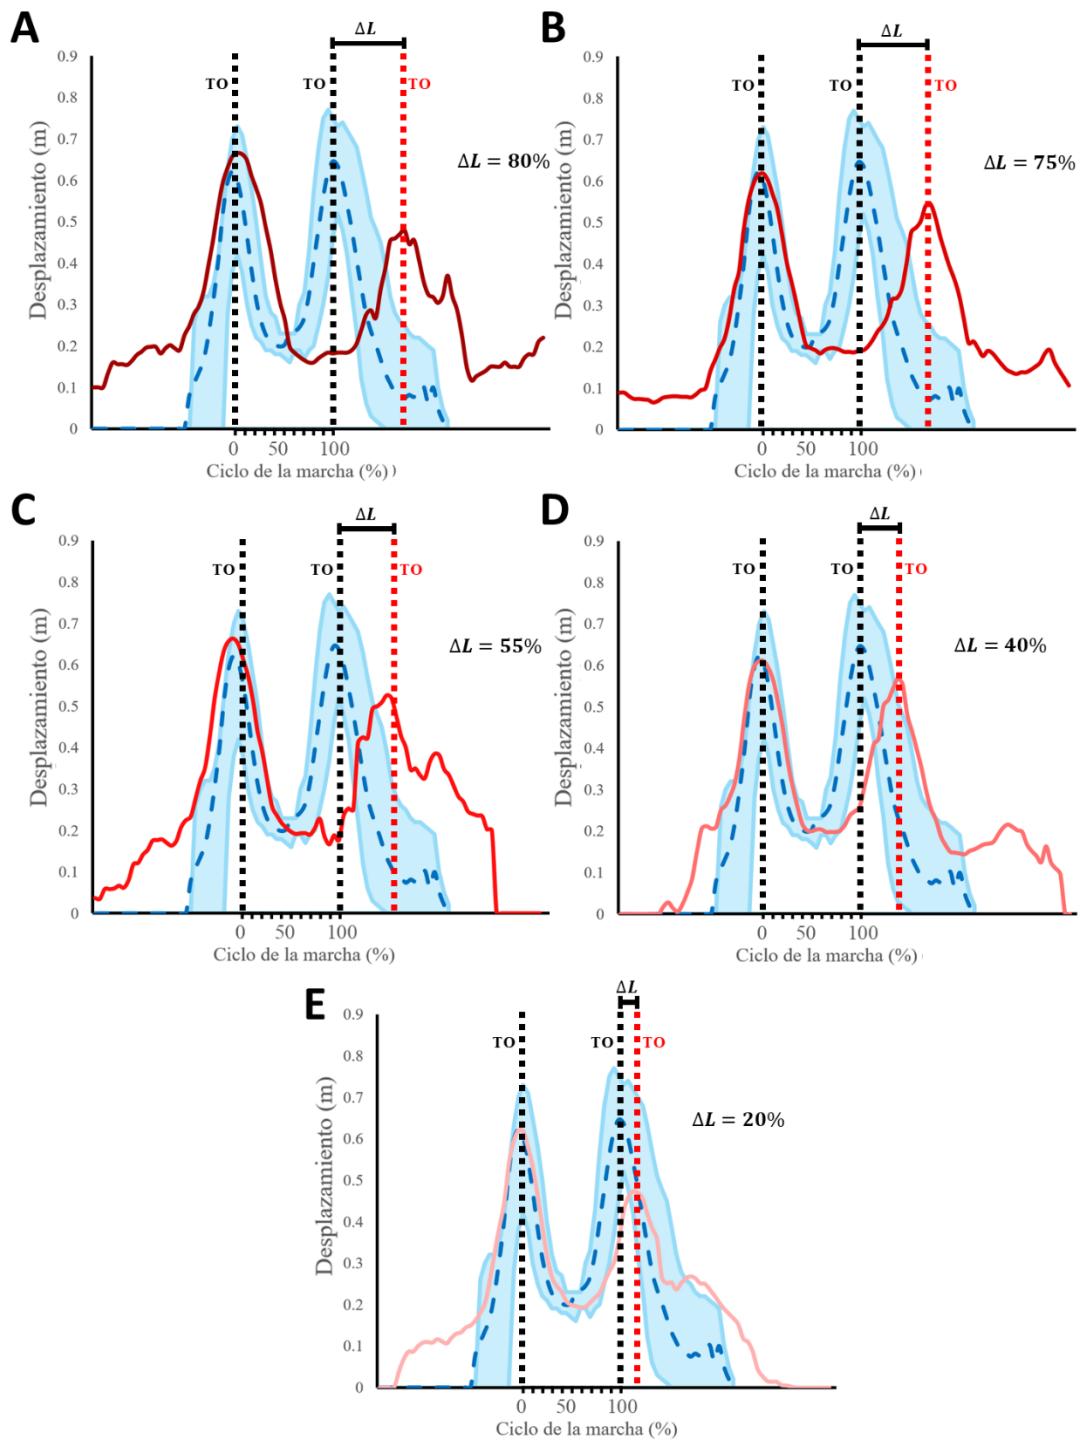


Fig. 8.16.- Comparativa de la marcha en estado sano contra la marcha con esguince de tobillo por inversión. A. Primera semana. B. Segunda semana. C. Tercera semana. D. Cuarta semana. E. Quinta semana.

Ante los resultados obtenidos se optó por comparar todos los indicadores extraídos en la sección 8.2. Presentando una comparativa de las variaciones en la Tabla 7, donde se buscó caracterizar el estado sano de la marcha al identificar el valor promedio obtenido por la población sana, así como sus rangos mínimos y máximos utilizando la desviación estándar, los cuales podrían ser interpretados como los criterios que debe cumplir una marcha sana. Lo mismo se realizó para los casos con esguince de tobillo, remarcando aquellos indicadores en donde se presentaron variaciones considerables fuera de los rangos establecidos por la condición sana. Sin embargo, se considera que estos no pueden ser tomados por completo como una caracterización de la condición debido a la cantidad reducida de población, por lo cual se podría contar con bias en la información.

Tabla 7.- Caracterización de los indicadores de cada población

Indicadores	Población sana			Población con esguince		
	Promedio	Min	Max	Promedio	Min	Max
Longitud de zancada (m)	1.17	1.1	1.24	1.14	1.05	1.22
Periodo (s)	1.11	1.06	1.17	1.61	1.35	1.86
Cadencia (pasos/min)	107.89	102.9	112.87	76.71	63.37	90.04
Tiempo de soporte de pierna derecha (s)	0.62	0.52	0.72	0.87	0.62	1.12
Tiempo de balance de pierna derecha (s)	0.51	0.4	0.62	0.75	0.42	1.09
Tiempo de soporte de pierna izquierda (s)	0.61	0.47	0.76	0.96	0.71	1.21
Tiempo de balance de pierna izquierda (s)	0.51	0.38	0.63	0.7	0.48	0.92
Rotación máxima en cadera derecha (°)	204.41	197.54	211.28	209.4	202.91	215.89
Rotación mínima en cadera derecha (°)	145.14	138.92	151.37	148.77	143.67	153.87
Rotación máxima en rodilla derecha (°)	178.25	172.7	180.00	177.63	173.55	180.00
Rotación mínima en rodilla derecha (°)	119.17	113.95	124.39	117.71	110.51	124.9

Rotación máxima en tobillo derecho (°)	119.59	112.45	126.73	116.15	112.86	119.45
Rotación mínima en tobillo derecho (°)	39.6	32.93	46.28	40.1	34.28	45.91
Rotación máxima en cadera izquierda (°)	206.54	202.28	210.8	211.29	208.24	214.34
Rotación mínima en cadera izquierda (°)	144.72	138.48	150.96	150.33	144.86	155.8
Rotación máxima en rodilla izquierda (°)	180.00	172.6	180.00	180.00	175.63	180.00
Rotación mínima en rodilla izquierda (°)	122.61	112.15	133.06	119.19	111.18	127.19
Rotación máxima en tobillo izquierdo (°)	123.32	117.02	129.62	118.22	114.82	121.61
Rotación mínima en tobillo izquierdo (°)	41.76	37.74	45.78	43.53	40.76	46.3

Al revisar las diferencias entre ambas poblaciones, hay indicadores que inmediatamente se encuentran fuera de los rangos establecidos por el estado sano, como la cadencia y los tiempos de soporte y balanceo, mientras que otros indicadores tienden a tener traslapos, como los rangos de rotación, y en algunos casos están completamente dentro del rango, como es el caso de la longitud de zancada. Por estos últimos casos, es difícil definir un solo indicador que pueda reflejar el grado de recuperación.

A pesar de que la base de datos propia se vio limitada en la cuantificación del grado de recuperación, fue posible realizar las pruebas de la metodología planteada en la sección 7.5 pero utilizando la base de datos publica, ya que esta contiene una mayor extensión de voluntarios para ambas poblaciones. Primeramente, se decidió realizar una comparativa de la información recabada de ambas poblaciones, tal como se realizó para la base de datos propia, donde se caracterizará el comportamiento del estado sano y fuera posible visualizar una diferencia con los casos con esguince de tobillo. Los resultados obtenidos se pueden apreciar en la Fig. 8.17, en donde únicamente se visualiza una zona azul que caracteriza a una marcha sana, así como una trayectoria promedio de ambos estados. En este caso se puede

observar una diferencia de duración del 6% del tiempo de soporte, entre el golpe de talón y el despegue; sin embargo, existe un traslape considerable del comportamiento de ambas poblaciones, por lo cual no se puede dar una respuesta concluyente de los cambios presentados en la marcha como resultado del tratamiento.

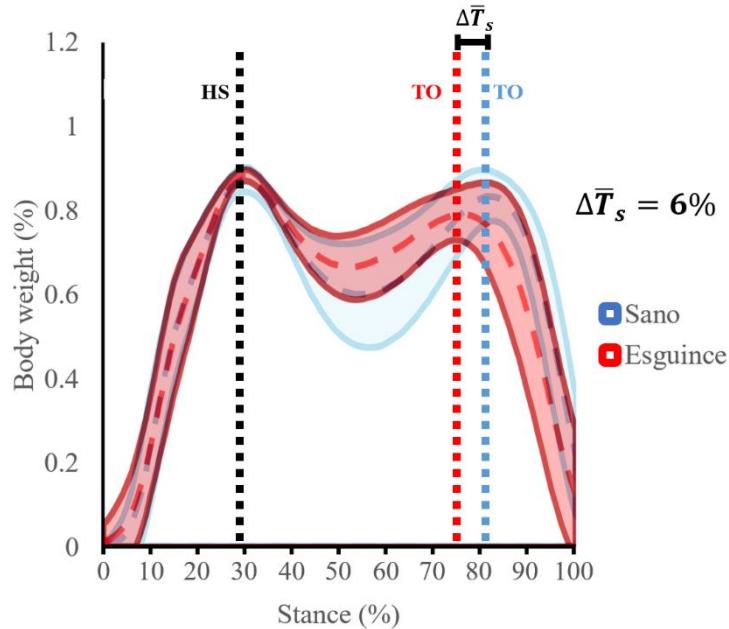


Fig. 8.17.- Comparativa de la caracterización del estado sano y con esguince de la base de datos pública.

Considerando la ambigüedad que se puede tener al comparar ambos casos, resulta en la situación ideal donde se puede aplicar la metodología para la obtención del grado de recuperación. Por lo tanto, fue necesario repetir los procesos realizados con la base de datos propia para generar un SAE y un clasificador ajustados a la estructura de la información de la base de datos publica, resultando en la estructura de la Fig. 8.18.

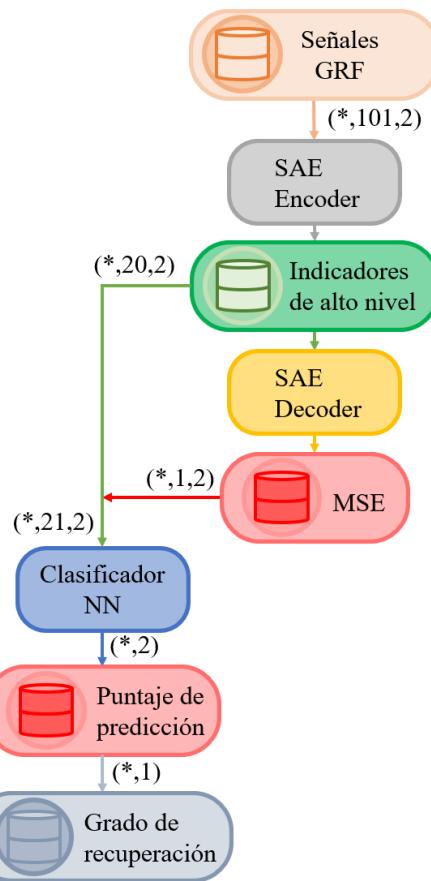


Fig. 8.18.- Pipeline para el cálculo del grado de recuperación.

Donde de igual manera que con la base de datos propia, se utiliza un SAE para la extracción de indicadores de alto nivel, entrenado únicamente con señales de la población sana. Al trabajar con señales GRF estas se encuentran en un formato de series de tiempo, de la cuales se reduce su dimensionalidad para trabajar con 20 indicadores por muestra, más el MSE obtenido del error de reconstrucción. El modelo utilizado fue el mismo seleccionado en la sección 8.4 a base de LSTM, cuyo desempeño se describe en la Tabla 8.

Tabla 8.- Rendimiento de los modelos de SAE con muestras sanas para base de datos publica

Métrica	SAE-LSTM
	Tipo
MSE entrenamiento	0.0025
MSE validación	0.0028
MSE prueba	0.0030

Para el clasificador, de igual manera se utiliza el mismo modelo seleccionado en la sección 8.5, únicamente se adapta la capa de entrada para que coincida con el formato de la información obtenida del SAE. El desempeño del clasificador se describe a través de la Tabla 9, donde se utilizó una muestra de 1094 muestras de ambas poblaciones.

Tabla 9.- Rendimiento del clasificador
para base de datos publica

Parámetro	Con MSE
Precisión	97.59
Exactitud	97.18
Recall	98.09
F1-score	97.84

Una vez que se validó el funcionamiento del clasificador se optó por utilizar la igualdad propuesta en la sección 7.5.1 con la ecuación 44 para cuantificar el grado de recuperación, utilizando el puntaje de pertenencia a la clase sana para identificar el impacto del tratamiento sobre la marcha. Para su implementación se agruparon por sesiones las muestras tomadas de la población con esguince de tobillo, compuesta por 13 voluntarios con seguimiento completo, las cuales fueron evaluadas con el modelo de la Fig. 8.18 para tomar únicamente su pertenencia al estado sano. El resultado se despliega en forma de la gráfica de cajas mostrada en la Fig. 8.19, en donde se puede apreciar un incremento del grado de recuperación conforme se tiene un progreso en el tratamiento, tiendiendo al valor de 1, el cual representa el estado sano, además de que se muestra una menor variabilidad de los datos al reducirse el tamaño de la caja.

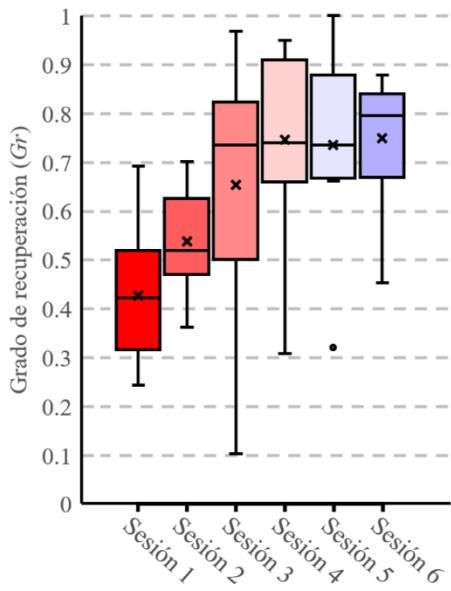


Fig. 8.19.- Progreso de la recuperación de la población con esguince de tobillo.

Partiendo de los resultados obtenidos se puede considerar que el método propuesto tiene la capacidad de identificar las diferencias en la recuperación presentadas entre cada una de las sesiones; sin embargo, a pesar de haber utilizado la base de datos publica aún se tiene una cantidad limitada de datos que podría no representar de forma confiable el impacto del tratamiento en todos los casos. Aun así, se considera que tiene el potencial de ser utilizado durante la realización de diagnósticos y seguimientos por parte de especialistas y la cual podría mejorar su confiabilidad mediante el incremento de la población.

8.7. Proyección del grado de recuperación

Una de las tareas más complicadas durante la evaluación y seguimiento de una condición es la realización de predicciones de como la lesión va a reaccionar al tratamiento y la capacidad de identificar anomalías durante el proceso de recuperación. Por lo cual se buscó utilizar la metodología planteada en la sección 7.6 para utilizar los indicadores como base para realizar la estimación ideal del progreso que debe presentarse durante el tratamiento mediante la estimación del Gr de las próximas sesiones. Por lo tanto, esto se basa en los resultados obtenidos en la sección 8.6, por lo cual todos los resultados mostrados fueron obtenidos utilizando la base de datos pública.

Para estimar el progreso de la condición, primeramente, se planteó la caracterización del comportamiento del Gr durante el periodo de tratamiento, para lo cual se utilizó la información de los 13 voluntarios que llevaron un tratamiento completo. Similar a la sección anterior, se dividió la información obtenida por sesiones para obtener los valores promedio, así como una silueta que delimita el comportamiento de la recuperación con base a la información disponible, los cuales son mostrados en la Fig. 8.20.

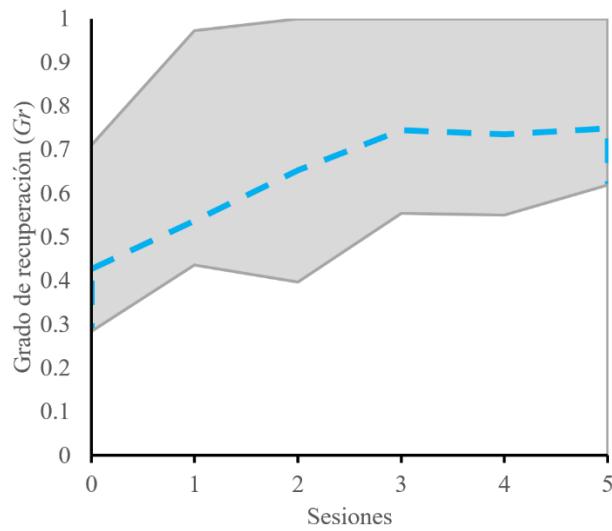


Fig. 8.20.- Caracterización del progreso del grado de recuperación durante el tratamiento.

Mediante esta caracterización se pudo validar que durante el periodo de recuperación se presenta una tendencia hacia el valor unitario en el comportamiento del Gr obtenido, por lo tanto, se consideró que era factible su uso para realizar una proyección de su desarrollo mediante un modelo de regresión. Para esto se utilizó la metodología planteada en la sección 7.6, para generar un conjunto de modelos de regresión, los cuales puedan ser utilizados en cascada para obtener el desarrollo de Gr de hasta las próximas 5 sesiones. Para esto se opta por un modelo de regresión compuesto por una capa de LSTM, con el fin de identificar patrones, y por una capa densa para calcular el próximo Gr , esto continúa repitiéndose tal como se aprecia en la Fig. 8.21.

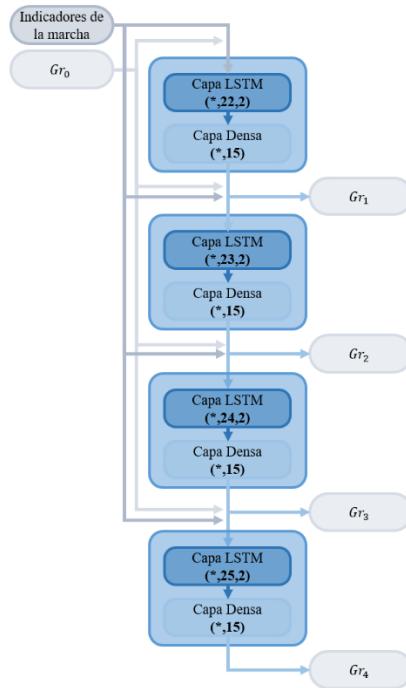


Fig. 8.21.- Estructura en cascada de modelos de regresión.

Cada uno de los modelos fue entrenado de forma individual con los valores de Gr obtenidos de la evaluación con el modelo de la sección 8.6, donde se obtuvieron los desempeños mostrados en la Tabla 10.

Tabla 10.- Desempeño de modelos de regresión

Métrica	Regresión LSTM			
	Modelo sesión 2	Modelo sesión 3	Modelo sesión 4	Modelo sesión 5
MSE entrenamiento	0.0063	0.0067	0.0072	0.0071
MSE validación	0.0120	0.0112	0.0135	0.0151
MSE prueba	0.0205	0.0195	0.0199	0.0214

El modelo obtenido mostró un buen desempeño para estimar el progreso del Gr para los casos donde se tuvo un seguimiento adecuado de su tratamiento. Sin embargo, algo importante es considerar como reaccionaría ante los casos donde se presentaron anomalías en su seguimiento, para lo cual se tomaron 11 casos de la base de datos que presentaron esguince

de tobillo que no finalizaron su tratamiento o que presentaron interrupciones. En los cuales al ser evaluado se presentaron variaciones entre el progreso real y su predicción, lo cual se muestra por medio del ejemplo en la Fig. 8.22, en donde se toma el caso de un paciente que mantuvo un seguimiento semanal de su tratamiento; sin embargo, este se vio suspendido por las siguientes dos semanas. Al evaluar sus pruebas con el modelo desarrollado se presentó un comportamiento anormal, el cual es presentado en la Fig. 8.22 en las diferentes etapas de comparativa entre el progreso real y el progreso esperado. Primeramente, en la Fig. 8.22^a se aprecia la predicción realizada a partir de las evaluaciones de las primeras sesiones, en la Fig. 8.22B se aprecia el ajuste de la predicción con base en el desarrollo real, y finalmente se muestra la presencia de una variación entre el progreso real, la predicción anterior y la predicción corregida, Fig. 8.22C.

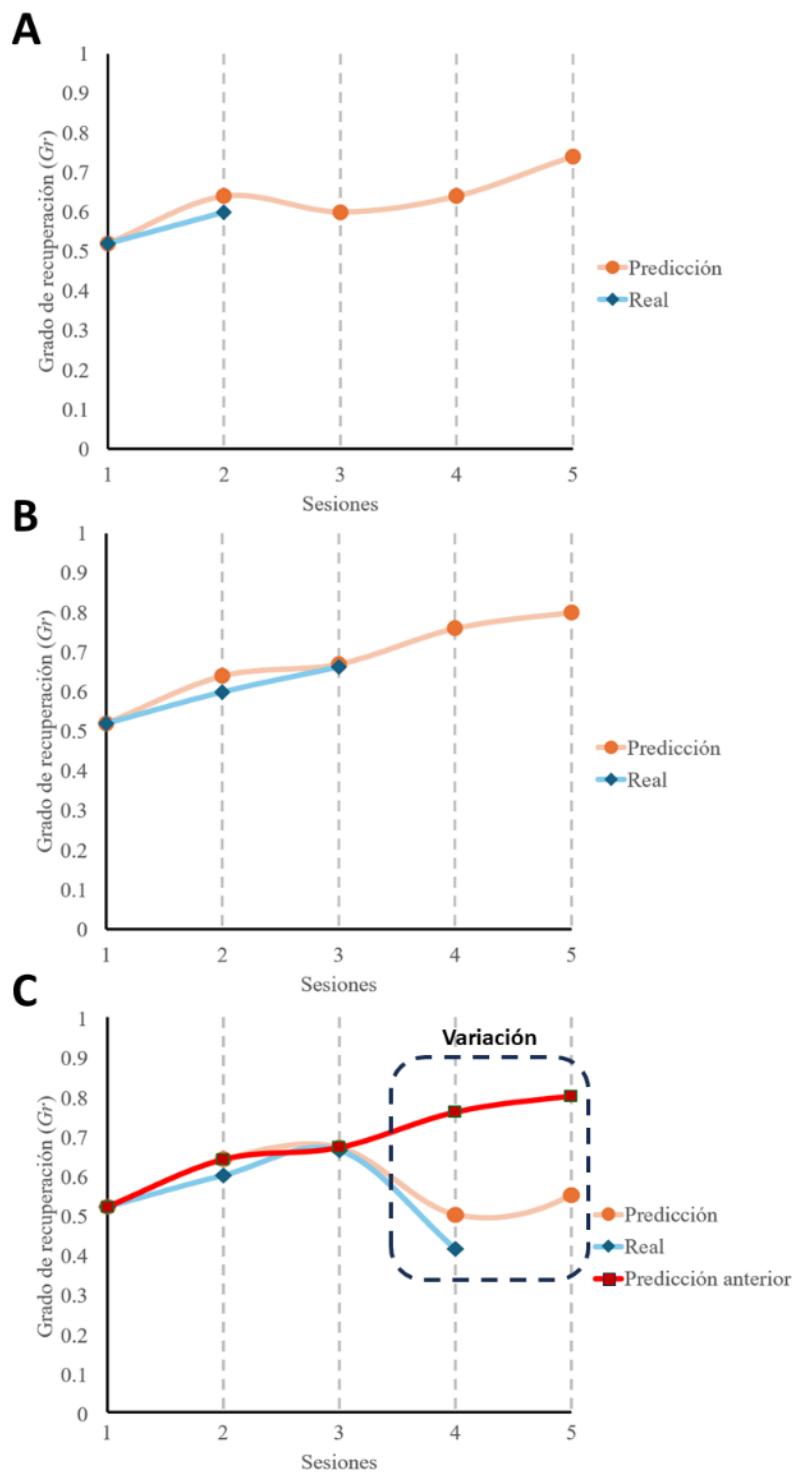


Fig. 8.22.- Evaluación de una muestra con mal seguimiento del tratamiento. A. Predicción con base a 1 sesión, B. Ajuste de predicción con base en la segunda sesión. C. Variación entre la recuperación real y la predicción anterior.

Como resultado se puede observar que, al evaluar este tipo de casos, se presentan variaciones en las predicciones y la realidad, lo cual puede alertar a los especialistas que se ha presentado un cambio inesperado en el progreso de recuperación. Aunque estos datos aún se vean limitados en su cantidad se puede visualizar las ventajas que puede brindar la incorporación de este tipo de análisis para fundamentar los ajustes de los especialistas al tratamiento.

8.8. Sistema de visión artificial embebido

Los modelos desarrollados en las secciones anteriores tuvieron como objetivo en todo momento el ser una fuente de información confiable que permita el sustento de los diagnósticos del especialista en fisioterapia. Por lo cual también es necesario su integración en un sistema que le permita utilizarlo de forma constante durante la realización de evaluaciones y seguimientos, por ello se había planteado en la sección 7.7 el desarrollo de un sistema de visión artificial embebido. Para la implementación de esta fue necesario definir de manera clara los componentes de hardware, software, herramientas, tareas y el pipeline de la información.

8.8.1. Desarrollo de hardware

Para la construcción del sistema embebido se siguieron las características propuestas en la sección 7.7.2, ajustando el diseño y las medidas para albergar los componentes reales, teniendo las consideraciones adicionales como los puertos de conexión y la alimentación. Resultando en el prototipo de carcaza que se presenta en la Fig. 8.23, considerando el uso de una pantalla táctil, un microcontrolador, un conjunto de baterías y reguladores para la alimentación y la incorporación de una cámara, bajo la consideración de que la segunda cámara se colocaría de forma independiente al sistema embebido para cumplir con la distribución planteada en la sección 8.1.1.3.

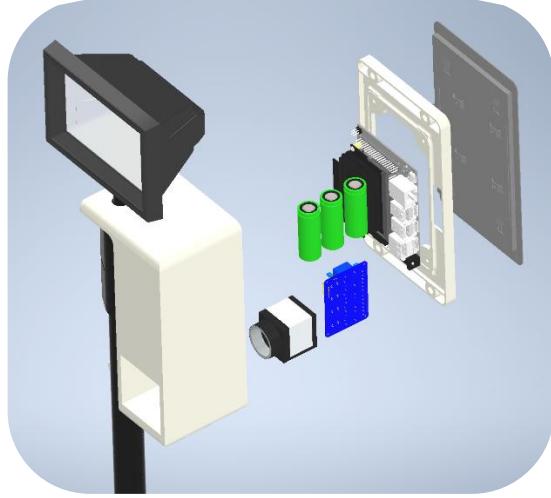


Fig. 8.23.- Prototipo del sistema de visión embebido.

Los componentes utilizados para la construcción del sistema embebido y sus características se presentan en la Tabla 11.

Tabla 11.- Componentes de hardware del sistema embebido.

Componente	Características	Cantidad
Cámara UI-3130CP Rev. 2	<ul style="list-style-type: none"> - Marca: IDS - Tipo: Monocromático - Resolución: 0.5 MP (800x600) - Obturador: Global - Lente: 3 mm 	1
Cámara acA1440-220um	<ul style="list-style-type: none"> - Marca: Basler - Tipo: Monocromático - Resolución: 1.6 MP (1400 x 1080) - Obturador: Global - Lente: 3 mm 	1
Jetson Nano	<ul style="list-style-type: none"> - Marca: NVIDIA - Modelo: 945-13450-0000-100 - RAM: 2048 MB - Memoria: 4 GB 	1
Pantalla táctil	<ul style="list-style-type: none"> - Marca: Ingcool - Tamaño: 7'' - Resolución: 1024x600 	1

Modulo Wifi	<ul style="list-style-type: none"> - Marca: Waveshare - Modelo: AC8265 - Bandas: 2.4GHz / 5GHz - Velocidad: 300Mbps / 867Mbps 	1
Fuente de alimentación	<ul style="list-style-type: none"> - Entrada: 110~220 V - Salida: 12 V - Corriente: 6.4 A - Potencia: 80 W 	1
Tripie tipo C	<ul style="list-style-type: none"> - Rango de altura: 75-175 cm 	2

De los componentes finales contra los propuestos, se tuvo que realizar el cambio de la alimentación del sistema embebido, pasando del uso de baterías recargables a una fuente de alimentación. Esto fue a causa de una alta demanda de corriente de parte de los componentes, la cual no podía ser suministrada de forma estable por las baterías, disparando las protecciones de algunos dispositivos. El agrupamiento final de los componentes y sus conexiones es representado en el diagrama de la Fig. 8.24.

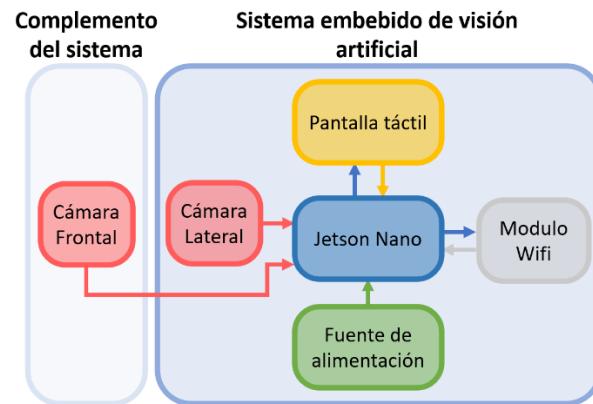


Fig. 8.24.- Conexión de componentes del sistema embebido.

El modelo planteado también fue modificado para simplificar su impresión en diferentes partes, optimizando la realización de modificaciones y el gasto de material. El modelo resultante impreso en 3D con filamento PLA se muestra en la Fig. 8.25.

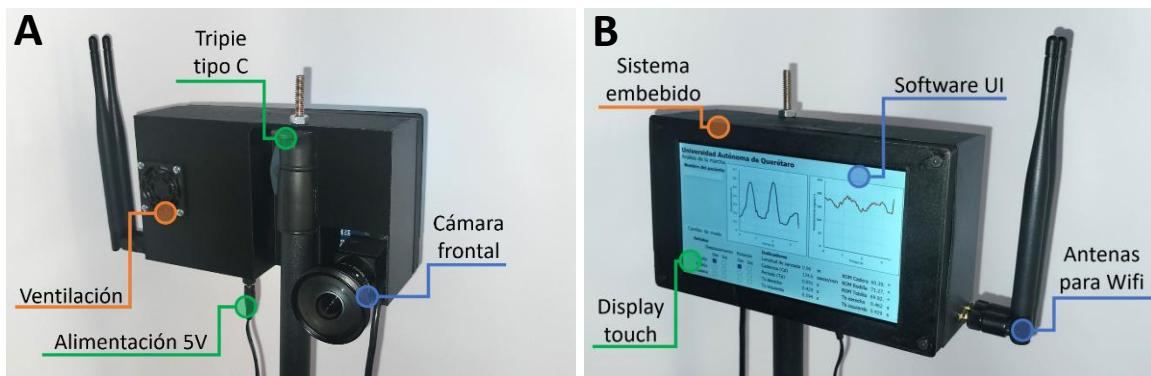


Fig. 8.25.- Ensamble final del sistema embebido de visión artificial. A. Vista frontal. B. Vista trasera.

8.8.2. Desarrollo de software

Para el desarrollo de software se consideró una implementación estructurada a base del microcontrolador Jetson Nano, el cual cuenta con un sistema operativo Ubuntu 18 especializado llamado Jetpack. En este se opta por el uso de lenguaje Python 3.10.5 el cual cuenta con una amplia cantidad de recursos como librerías open-source, soporte técnico y foros. Haciendo uso de estos recursos, se estructuró el diseño de un software encargado de la gestión de todos los aspectos del sistema embebido, los cuales fueron segmentados acorde a la tarea y las herramientas utilizadas, tal como se describe en la Fig. 8.26.

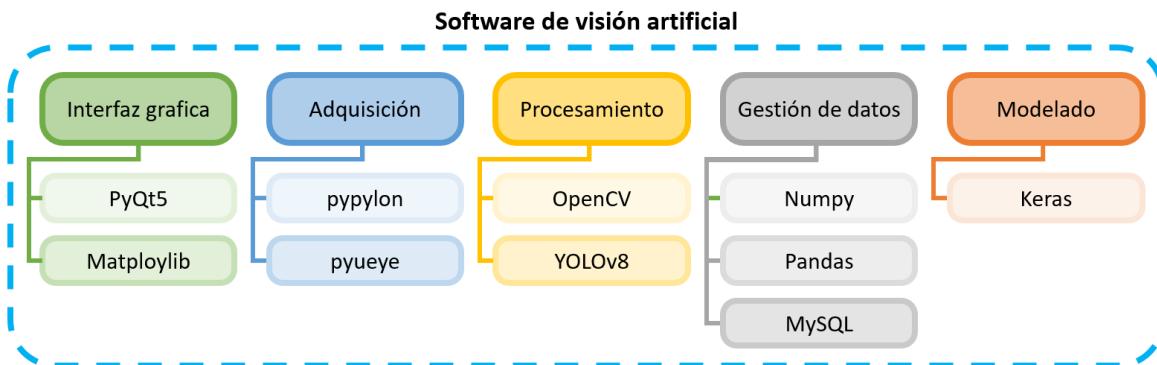


Fig. 8.26.- División de las tareas realizadas por el software de visión artificial con sus respectivas herramientas.

Interfaz gráfica (UI):

La interfaz se enfoca en un diseño minimalista que le provea al usuario con las herramientas para gestionar todos los procesos sin la necesidad de requerir de un conocimiento técnico en el área de programación, visión artificial o machine learning. Esta interfaz se realizó por medio de PyQt5, la cual es una librería open-source de Python especializada en el desarrollo de UI. Esta facilita la implementación de cualquier código previamente realizado utilizando un entorno orientado a objetos.

Para agilizar su desarrollo se utiliza la herramienta integrada de la librería llamada QtDesigner, que presenta un entorno libre de código, tal como se visualiza en la Fig. 8.27.

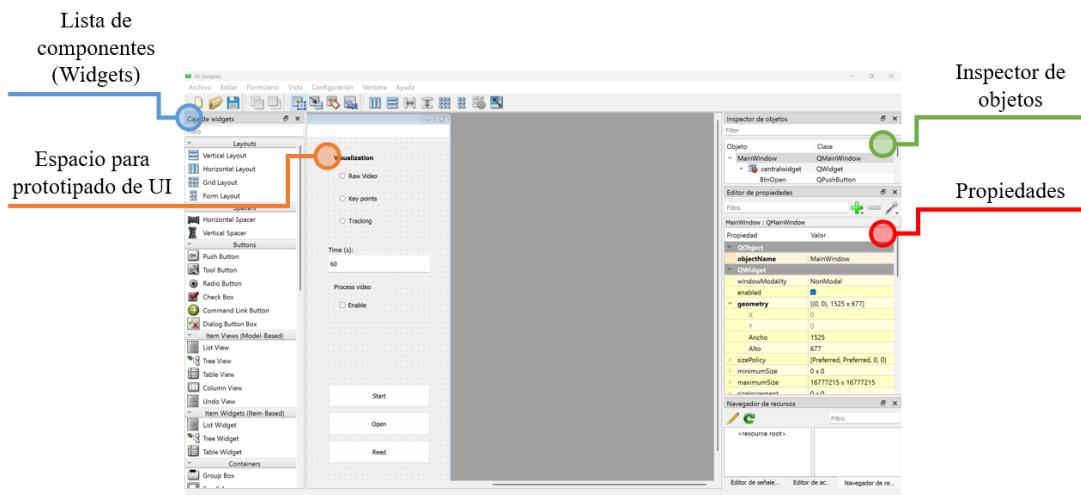


Fig. 8.27.- Diseño de UI mediante QtDesigner.

El diseño resultante para la UI posteriormente se pasa a código de Python mediante la librería `pyuic5`, generando código editable con los mismos elementos y distribución establecidos en la plataforma de QtDesigner y teniendo completa compatibilidad con las herramientas de PyQt5.

Adquisición:

La adquisición de videos es gestionada mediante las librerías `pypylon` y `pyueye`, utilizados para la gestión de cámaras de la marca Basler e IDS, respectivamente, ya que cada una cuenta con protocolos específicos para conexión, lectura, ajuste de parámetros y drivers. Estos se ajustan para que ambos videos sean en formato “.avi”, en escala de grises y a una frecuencia

fija de 20 fps. Esto último se consideración crucial, ya que ambos videos deben estar sincronizados para poder realizar la reconstrucción precisa de los movimientos de la marcha.

Procesamiento:

El procesamiento de los videos se realiza cuadro a cuadro utilizando el proceso descrito a detalle en la sección 8.1.2. Esto se realiza mediante OpenCV, para la lectura de videos y de cuadros, así como la modificación de características de las imágenes, como resolución, contraste, formato de color, en caso de ser necesario.

Por otra parte, también se realiza la detección de pose mediante YOLOv8, tal como se desarrolló en la sección 8.2. Automatizando todos los procesos para el procesamiento y extracción de indicadores cinemáticos y espaciotemporales.

Gestión de datos:

La gestión de datos comprende desde la estructuración de los arreglos de indicadores, operaciones, limpieza y almacenamiento, por lo que forma parte de cada instancia donde es necesario el manejo de datos del sistema embebido. La herramienta numpy es utilizado para agilizar la realización de operaciones en arreglos matriciales, permitiendo realizar tareas como concatenar, borrar y separar filas y columnas, trasformar el formato y forma del arreglo, creación de nuevos arreglos y el cálculo de parámetros estadísticos como máximo, mínimo, media, mediana y moda, por mencionar algunos.

Mientras tanto las herramientas de pandas y SQL son utilizadas principalmente para la lectura y almacenamiento de los datos extraídos de las pruebas en forma de bases de datos, permitiendo tener la información en un ambiente estructurado que simplifica el proceso de acceso y filtrado de la información, como se describió en la sección 8.3.3.

Modelado:

El modelado de algoritmos de ML se realiza mediante la API de Keras, la cual se basa en Tensorflow, para el diseño, entrenamiento y validación de todos los modelos utilizados. Por medio de estas se realizaron los modelos de clasificador de condiciones, propuestos en la sección 8.5, la extracción de indicadores de alto nivel con SAE, descrito en la sección 8.4, y la predicción del grado de recuperación, explicados a detalle en las secciones 8.6 y 8.7.

Minimizando la intervención del usuario a las tareas de selección de datos y su etiquetado. Los cuales son simplificados mediante una UI acondicionada para ser utilizada por cualquier persona con el conocimiento técnico mínimo, permitiendo la capacitación del personal de clínica y proporcionando cierto grado de flexibilidad para el ajuste o rediseño de los modelos.

8.8.3. Implementación de software

Durante el desarrollo del proyecto se consideró una división del software, una dedicada para el uso de los especialistas para la gestión completa del sistema de visión artificial y otra para la gestión del diseño de modelos de ML, con el fin de que las tareas que requieran de un conocimiento más técnico no interfieran en la realización de pruebas por parte de los especialistas. La división de tareas de cada software se puede visualizar en el diagrama de la Fig. 8.28.

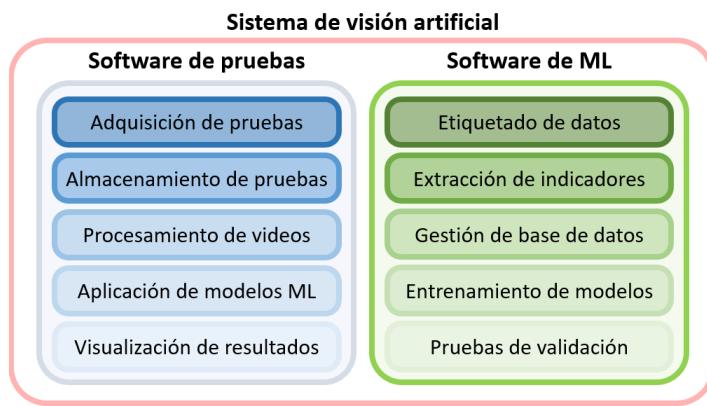


Fig. 8.28.- Distribución de tareas entre softwares.

8.8.3.1. Software de pruebas

Para el desarrollo de la interfaz de pruebas se optó por un diseño minimalista, que le presente al usuario únicamente los parámetros relevantes para la realización de pruebas y su registro. Para este último, simplemente se utiliza el nombre completo del paciente o voluntario, a partir del cual el propio programa verifica si se tienen registros previos. De ser el caso se genera un nuevo registro marcándolo como una nueva sesión o prueba, de lo contrario se genera un registro nuevo de paciente. Estos registros son almacenados localmente bajo la estructura mostrada en la Fig. 8.29.

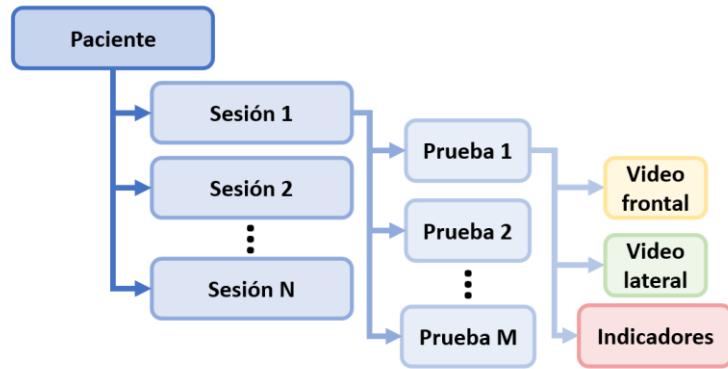


Fig. 8.29.- Estructura para el registro de pruebas.

En cuanto a los parámetros de las pruebas, únicamente se permite el ajuste del tiempo total de la grabación, la cual se puede modificar en caso de buscar realizar más pruebas o se esté utilizando una metodología diferente para la realización de pruebas. Además, se permite el cambio de la distancia de las cámaras, en caso de que el tipo de prueba o el espacio modifique la distribución del sistema de visión en el área de trabajo.

El UI para la realización de pruebas cuenta con múltiples elementos que le permitan al usuario monitorear el desempeño del paciente o voluntario en la prueba, por lo cual se incorporan dos displays, uno para la vista frontal y otro para la lateral. También se incorpora la capacidad de visualizar los resultados del procesamiento de imágenes en tiempo real obtenido por la detección de pose con YOLOv8. Posterior a la realización de las pruebas, se incorporan gráficas en las cuales el usuario pueda visualizar la información adquirida de la marcha, así como los resultados de la extracción de indicadores y las inferencias realizadas por los modelos de ML. La UI resultante se muestra en la Fig. 8.30, donde se puede apreciar la distribución de los componentes de la interfaz.

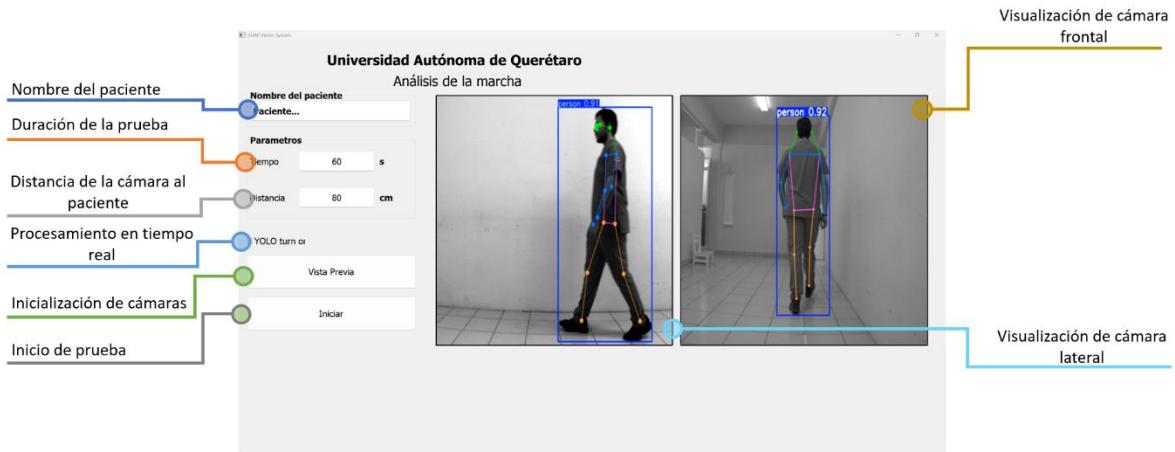


Fig. 8.30.- UI del software de pruebas para el sistema embebido.

Esta misma interfaz es modificada posterior a la evaluación de las pruebas, con tal de proveer al usuario de la información extraída del análisis de la marcha. Los indicadores obtenidos son desplegados de dos maneras, por un lado, los indicadores espacio temporales son representados en forma de valores constantes, siendo el promedio obtenido durante la evaluación de la o las pruebas. Mientras que, para los indicadores cinemáticos, estos son información representadas en series de tiempo, por lo cual se reutilizan los display para la visualización de gráficas, en donde utilizando un panel de control se puede seleccionar cuales señales se quieren visualizar, utilizando el primer display para la visualización de desplazamientos lineales y el segundo para la visualización de desplazamientos angulares, tal como se muestra en la Fig. 8.31.

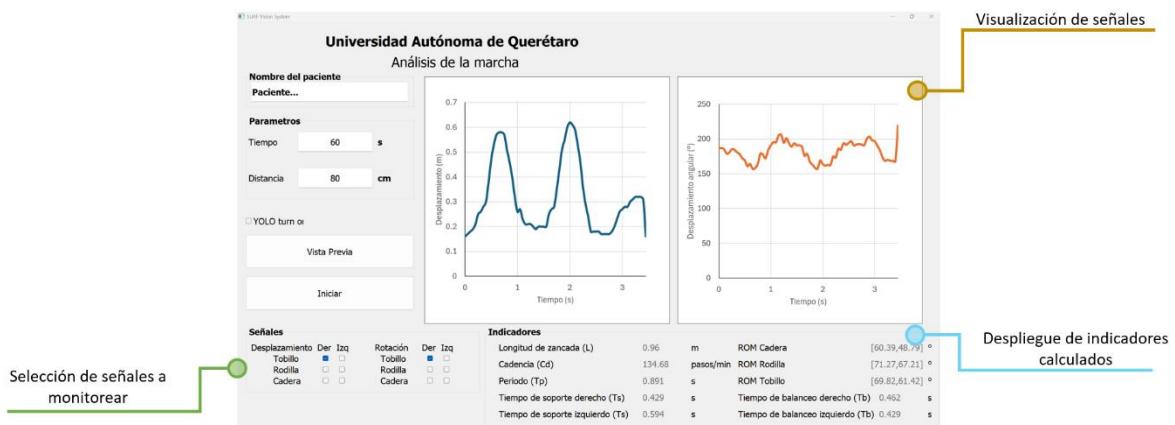


Fig. 8.31.- Despliegue de resultados de la extracción de indicadores.

8.8.3.2. Software de ML

En cuanto al UI enfocada a ML, esta también cuenta con un diseño simple, ya que no se busca reestructurar el modelo, sino que está enfocado a la realización de los procesos de procesamiento, etiquetado y entrenamiento de modelos de ML. La interfaz resultante permite la gestión de cada etapa tal como se muestra en la Fig. 8.32, donde se puede especificar si se busca trabajarlos como procesos independientes o en conjunto.

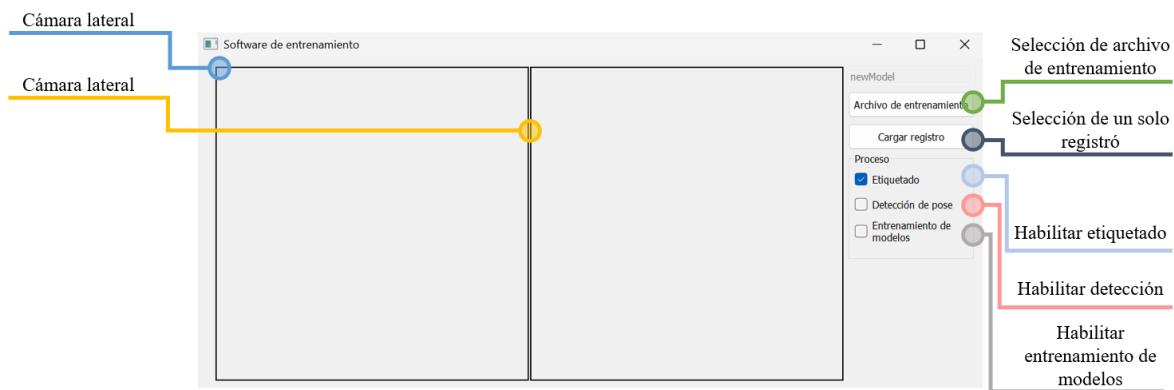


Fig. 8.32.- UI del software de ML para el sistema embebido.

Para la creación de algoritmos de ML es necesario especificar qué información será utilizada para sustentar las tareas de entrenamiento y validación, y debido a que se está trabajando para la identificación de casos específicos, es necesario que se identifique qué información puede ser anexada o excluida para tener el mayor impacto en el desempeño de los modelos. Para esto se utiliza un archivo de entrenamiento de tipo .csv, en donde se especificar la lista de registros de los casos relevantes para la creación de modelos de ML. Esto no es desarrollado mediante SQL ya que se espera que pueda ser fácilmente modificado por cualquier usuario que tenga una orientación básica en el uso del sistema.

Posteriormente, se desarrolla un pipeline que automatiza en su gran mayoría el proceso de entrenamiento de los modelos de ML. Iniciando por la extracción de indicadores, en donde se toman los videos obtenidos de cada registro incluido en el archivo de entrenamiento, y se realiza la reconstrucción de la biomecánica en cada fotograma con el modelo más robusto de YOLOv8. A la información extraída se le aplican los filtros para la eliminación de datos

nulos y la reducción del ruido, para posteriormente realizar la extracción de los indicadores espaciotemporales y cinemáticos. Los resultados obtenidos son almacenados tanto localmente como en una base de datos de SQL, con el fin de que se puedan reutilizar en otros procesos de entrenamiento.

El etiquetado de datos es únicamente necesario para las tareas de clasificación, por lo cual se incorporaron opciones para realizarlo tanto de forma automática como de forma manual. La primera opción sería la más común, ya que los registros o pertenecen a un voluntario sano o a un voluntario con lesión, pero se provee una alternativa en caso de que se busque realizar modificaciones a futuro en la metodología.

Por último, el entrenamiento y validación son desarrollados completamente de forma automática, ya que la estructura y parámetros del modelo se encuentran preestablecidos con base al objetivo del sistema, y la realización de cambios requeriría de un nivel técnico avanzado. En este proceso se generan los modelos de SAE y un clasificador para seguir las metodologías establecidas en la sección 7.6, los cuales son validados y se provee al usuario de los resultados del desempeño de cada modelo. Estos modelos son almacenados localmente para su implementación por el software de pruebas.

IX. CONCLUSIONES

El desarrollo de una metodología para la extracción de la biomecánica de la marcha resultó tener potencial, al permitir un amplio rango de flexibilidad en cuanto a las condiciones de prueba y una facilidad para el procesamiento de datos, en donde utilizando las mismas mediciones de la cinemática fue posible identificar eventos como el HS o el TO, que permitieron el cálculo de los indicadores espacio temporales como la cadencia o longitud de zancada. Por lo cual el proceso de adquisición se vuelve intuitivo y puede ser realizado sin la necesidad de tener conocimiento técnico o el realizar un procesamiento manual de la información.

Al contar con registros detallados del progreso de condiciones fue posible generar modelos de ML que pudieran identificar los patrones y tendencias en los indicadores, con lo cual incluso fue posible comprimir la información hasta en un 90% en forma de indicadores de alto nivel sin perder la relación entre los datos, así como generar clasificadores que pudieran distinguir las diferencias entre ambas poblaciones con una precisión de 98.48%, exactitud de 97.66%, recall de 97.98% y un F1 score de 98.23%. Lo cual es remarcable considerando que estadísticamente se presentaban similitudes entre las poblaciones que puede causar confusión en su interpretación por parte de especialistas.

La cuantificación del grado de recuperación fue uno de los procesos más complejos al no existir una metodología definida que se sustentara en información cuantitativa, por lo tanto, se optó por el uso de las variaciones en el MSE del SAE y el puntaje de un clasificador NN. Lo cual demostró tener un buen desempeño al mostrar un valor que variaba en correlación al progreso del tratamiento e incluso presentaba una reacción inmediata ante casos con un tratamiento inconsistente o incompleto. Lo cual se pudo comprobar por medio de la base de datos publica, en donde se contaba con una mayor cantidad de casos incompletos o en donde se había registrado alguna problemática durante el proceso de seguimiento.

Utilizando los mismos resultados obtenidos para la cuantificación del grado de recuperación, se caracterizó la tendencia que presentan los casos que llevan un seguimiento apropiado de su tratamiento, permitiendo el desarrollo de modelos de regresión con ML. Los cuales a partir de los indicadores y la cuantificación del primer grado de recuperación fueron capaces de

realizar predicciones apropiadas del proceso de recuperación ideal del paciente, alcanzando un error de reconstrucción del 0.003. De igual manera al utilizar el modelo generado para la evaluación de casos con tratamiento incompleto, se presentaron variaciones entre el desarrollo ideal y el real, las cuales tienen el potencial para informar a los especialistas de anomalías en el proceso de recuperación lo cual pueda ser utilizado para sustentar la necesidad de realizar ajustes oportunos de los tratamientos.

Finalmente, todos los procesos fueron incorporados en un solo sistema embebido, el cual pudiera ser utilizado para el análisis y recopilación de datos de la marcha de futuros pacientes y voluntarios. Resultando en un sistema de visión embebido, que elimina múltiples limitantes de un sistema de visión tradicional, evitando el acondicionamiento estricto del área de trabajo o la necesidad de utilizar sensores o marcadores, que puedan interferir con el desempeño de los voluntarios durante las pruebas. Lo cual permite que el sistema pueda extraer indicadores de una marcha realizada bajo condiciones de la vida cotidiana, que puedan ser proporcionados al especialista para su análisis e interpretación. Permitiendo que los diagnósticos y la toma de decisiones durante el tratamiento, se encuentren fundamentados de forma más objetiva y provea la capacidad de llevar un seguimiento más detallado del progreso de la condición. Además de esto, la incorporación de los modelos de ML en un sistema embebido amplia la flexibilidad para su incorporación en diferentes protocolos de adquisición y análisis, lo cual incluso ha sido utilizado para desarrollo de investigaciones alternas y futuras como las mostradas en el Anexo C y D.

Como principal prospectiva quedaría el incremento de la base de datos propia, ya que, a pesar de haber demostrado un buen rendimiento en su caracterización y su clasificación, el cálculo del grado de recuperación resultaba inconsistente y con variaciones que no corresponden con el diagnóstico provisto por los especialistas, por lo cual se consideró que la cantidad limitada de información generaba bias y evitan que se presenta una tendencia clara del progreso. Por lo cual se buscará que en investigaciones futuras se pueda seguir el protocolo de adquisición planteado para caracterizar con mayor precisión las diferentes poblaciones y sus diferencias.

X. REFERENCIAS BIBLIOGRÁFICAS

1. Alcado García, V. D., Flores Aguilar, S., & Pérez Hernández, J. (2017). *Guía de práctica clínica GPC Diagnóstico y Tratamiento de las lesiones ligamentarias traumáticas en rodilla*. Instituto Mexicano del Seguro Social. <http://www.imss.gob.mx/profesionales-salud/gpc>
2. Alcocer, W., Vela, L., Blanco, A., Gonzales, J., & Oliver, M. (2012). Major Trends in the Development of Ankle Rehabilitation Devices. *Dyna*, 176, 45–55. <http://www.scielo.org.co/pdf/dyna/v79n176/v79n176a06.pdf>
3. Alpaydin, E. (2014). *Introduction to Machine Learning*. The MIT Press.
4. Anandacoomarasamy, A., & Barnsley, L. (2005). Long term outcomes of inversion ankle injuries. *British Journal of Sports Medicine*, 39(3). <https://doi.org/10.1136/bjsm.2004.011676>
5. Attenborough, A. S., Hiller, C. E., Smith, R. M., Stuelcken, M., Greene, A., & Sinclair, P. J. (2014). Chronic Ankle Instability in Sporting Populations. In *Sports Medicine* (Vol. 44, Issue 11, pp. 1545–1556). Springer International Publishing. <https://doi.org/10.1007/s40279-014-0218-2>
6. Bleakley, C. M., O'Connor, S. R., Tully, M. A., Rocke, L. G., MacAuley, D. C., Bradbury, I., Keegan, S., & McDonough, S. M. (2010). Effect of accelerated rehabilitation on function after ankle sprain: Randomised controlled trial. *BMJ (Online)*, 340(7756), 1122. <https://doi.org/10.1136/bmj.c1964>
7. Cavazos, G. J. Jr., & Harkless, L. B. (2021). The epidemiology, evaluation, and assessment of lateral ankle sprains in athletes. *Journal of Sports Medicine and Therapy*, 6(2), 008–017. <https://doi.org/10.29328/journal.jsmt.1001052>
8. Chakraborty, J., Upadhyay, S., & Nandy, A. (2022). Musculoskeletal Injury Recovery Assessment using Gait Analysis with Ground Reaction Force Sensor. *Medical Engineering & Physics*, 103(October 2021), 103788. <https://doi.org/10.1016/j.medengphy.2022.103788>
9. Chaudhari, A. M. W., Briant, P. L., Bevill, S. L., Koo, S., & Andriacchi, T. P. (2008). Knee kinematics, cartilage morphology, and osteoarthritis after ACL injury.

In *Medicine and Science in Sports and Exercise* (Vol. 40, Issue 2, pp. 215–222).
<https://doi.org/10.1249/mss.0b013e31815cbb0e>

10. Chen, Y., Fan, Y., Lin, T., & Zhou, Q. (2023). *Effects of low-level laser therapy and functional exercises in the treatment of chronic ankle sprain: A randomized controlled trial*. <https://doi.org/10.21203/rs.3.rs-3677006/v1>
11. Connaboy, C., Eagle, S. R., Johnson, C. D., Flanagan, S. D., Mi, Q., & Nindl, B. C. (2019). Using Machine Learning to Predict Lower-Extremity Injury in US Special Forces. In *Medicine and Science in Sports and Exercise* (Vol. 51, Issue 5). <https://doi.org/10.1249/MSS.0000000000001881>
12. Di Raimondo, G., Willems, M., Killen, B. A., Havashinezhadian, S., Turcot, K., Vanwanseele, B., & Jonkers, I. (2023). Peak Tibiofemoral Contact Forces Estimated Using IMU-Based Approaches Are Not Significantly Different from Motion Capture-Based Estimations in Patients with Knee Osteoarthritis. *Sensors*, 23(9). <https://doi.org/10.3390/s23094484>
13. Doherty, C., Bleakley, C., Hertel, J., Caulfield, B., Ryan, J., & Delahunt, E. (2015). Lower extremity function during gait in participants with first time acute lateral ankle sprain compared to controls. *Journal of Electromyography and Kinesiology*, 25(1), 182–192. <https://doi.org/10.1016/j.jelekin.2014.09.004>
14. Drakos, M. C., Domb, B., Starkey, C., Callahan, L., & Allen, A. A. (2010). Injury in the National Basketball Association: A 17-year overview. In *Sports Health* (Vol. 2, Issue 4, pp. 284–290). <https://doi.org/10.1177/1941738109357303>
15. Gazit, E., Buchman, A. S., Dawe, R., Curran, T. A., Mirelman, A., Giladi, N., & Hausdorff, J. M. (2020). What happens before the first step? A New Approach to Quantifying Gait Initiation Using a Wearable Sensor. *Gait and Posture*, 76, 128–135. <https://doi.org/10.1016/j.gaitpost.2019.11.007>
16. Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference Library* (Vol. 172, pp. 519–567). Springer. https://doi.org/10.1007/978-3-030-32644-9_36
17. Gisondi, M. A. (2008). *Emergency Medicine* (J. G. Adams, E. Barton, J. Collings, P. Deblieux, M. A. Gisondi, & E. Nadel, Eds.). Saunders,Elsevier.

18. Golanó, P., Vega, J., de Leeuw, P. A. J., Malagelada, F., Manzanares, M. C., Götzens, V., & van Dijk, C. N. (2010). Anatomy of the ankle ligaments: A pictorial essay. *Knee Surgery, Sports Traumatology, Arthroscopy*, 18(5), 557–569. <https://doi.org/10.1007/s00167-010-1100-x>
19. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
20. Gribble, P. A., Bleakley, C. M., Caulfield, B. M., Docherty, C. L., Fourchet, F., Fong, D. T. P., Hertel, J., Hiller, C. E., Kaminski, T. W., McKeon, P. O., Refshauge, K. M., Verhagen, E. A., Vicenzino, B. T., Wikstrom, E. A., & Delahunt, E. (2016). 2016 consensus statement of the International Ankle Consortium: Prevalence, impact and long-term consequences of lateral ankle sprains. *British Journal of Sports Medicine*, 50(24), 1493–1495. <https://doi.org/10.1136/bjsports-2016-096188>
21. Griffin, L. Y., Agel, J., Albohm, M. J., Arendt, E. A., Dick, R. W., Garrett, W. E., Garrick, J. G., Hewett, T. E., Huston, L., Ireland, M. L., Johnson, R. J., Kibler, W. B., Lephart, S., Lewis, J. L., Lindenfeld, T. N., Mandelbaum, B. R., Marchak, P., Teitz, C. C., & Wojtys, E. M. (2000). Noncontact Anterior Cruciate Ligament Injuries: Risk Factors and Prevention Strategies. *Journal of the American Academy of Orthopaedic Surgeons*, 8(3), 141–150. <https://doi.org/10.5435/00124635-200005000-00001>
22. Guo, Z., Li, Y., Wang, Y., Liu, H., Guo, R., Ma, J., Wu, X., Jiang, D., & Ren, T. (2025). Intelligent Diagnosis and Predictive Rehabilitation Assessment of Chronic Ankle Instability Using Shoe-integrated Sensor System. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. <https://doi.org/10.1109/TNSRE.2025.3563924>
23. Harrison, R. F., & Kennedy, R. L. (2005). *Artificial Neural Network Models for Prediction of Acute Coronary Syndromes Using Clinical Data From the Time of Presentation*. 46(5), 431–439. <https://doi.org/10.1016/j.annemergmed.2004.09.012>

24. Hassebrock, J. D., Gulbrandsen, M. T., Asprey, W. L., Makovicka, J. L., & Chhabra, A. (2020). *Knee Ligament Anatomy and Biomechanics*. www.sportsmedarthro.com
25. Hertel, J., & Corbett, R. O. (2019). An updated model of chronic ankle instability. *Journal of Athletic Training*, 54(6), 572–588. <https://doi.org/10.4085/1062-6050-344-18>
26. Herzog, M. M., Kerr, Z. Y., Marshall, S. W., & Wikstrom, E. A. (2019). Epidemiology of ankle sprains and chronic ankle instability. *Journal of Athletic Training*, 54(6), 603–610. <https://doi.org/10.4085/1062-6050-447-17>
27. Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313(5786), 504–507. <https://doi.org/10.1126/science.1129198>
28. Horsak, B., Slijepcevic, D., Raberger, A. M., Schwab, C., Worisch, M., & Zeppelzauer, M. (2020). GaitRec, a large-scale ground reaction force dataset of healthy and impaired gait. *Scientific Data*, 7(1). <https://doi.org/10.1038/s41597-020-0481-z>
29. Hsu, Y. L., Chung, P. C., Wang, W. H., Pai, M. C., Wang, C. Y., Lin, C. W., Wu, H. L., & Wang, J. S. (2014). Gait and balance analysis for patients with Alzheimer's disease using an inertial-sensor-based wearable instrument. *IEEE Journal of Biomedical and Health Informatics*, 18(6), 1822–1830. <https://doi.org/10.1109/JBHI.2014.2325413>
30. Huyen, C. (2022). *Designing Machine Learning Systems An Iterative Process for Production-Ready Applications*. <http://oreilly.com>
31. Hwang, U., Kwon, O., Kim, J., & Gwak, G. (2025). Machine learning for classifying chronic ankle instability based on ankle strength, range of motion, postural control and anatomical deformities in delivery service workers with a history of lateral ankle sprains. *Musculoskeletal Science and Practice*, 75, 103230. <https://doi.org/10.1016/j.msksp.2024.103230>
32. Ivins, D. (2006). Acute ankle sprain: An update. *American Family Physician*, 74(10).

33. Jakhar, D., & Kaur, I. (2020). Artificial intelligence, machine learning and deep learning: definitions and differences. *Clinical and Experimental Dermatology*, 45(1), 131–132. <https://doi.org/10.1111/ced.14029>
34. Jasmine Yohan Putri, A., Aziza Kusuma, R., & Nur Alpiah, D. (2024). *EFFECTIVENESS OF ULTRASOUND MODALITY IN ANKLE SPRAIN* (Vol. 2, Issue 2).
35. Kaminski, T. W., Hertel, J., Amendola, N., Docherty, C. L., Dolan, M. G., Hopkins, J. T., Nussbaum, E., Poppy, W., & Richie, D. (2013). National athletic trainers' association position statement: Conservative management and prevention of ankle sprains in athletes. *Journal of Athletic Training*, 48(4), 528–545. <https://doi.org/10.4085/1062-6050-48.4.02>
36. Koldenhoven, R. M., Hart, J., Saliba, S., Abel, M. F., & Hertel, J. (2019). Gait kinematics & kinetics at three walking speeds in individuals with chronic ankle instability and ankle sprain copers. *Gait and Posture*, 74, 169–175. <https://doi.org/10.1016/j.gaitpost.2019.09.010>
37. Kong, D., & Yan, X. (2020). Adaptive parameter tuning stacked autoencoders for process monitoring. *Soft Computing*, 24(17), 12937–12951. <https://doi.org/10.1007/s00500-020-04717-x>
38. Li, J., Lu, L., Zhao, L., Wang, C., & Li, J. (2021). An integrated approach for robotic Sit-To-Stand assistance: Control framework design and human intention recognition. *Control Engineering Practice*, 107. <https://doi.org/10.1016/j.conengprac.2020.104680>
39. Lippert, L. S. (2011). *Clinical kinesiology and anatomy* (5th ed.). F.A. Davis Company.
40. Lomelí-Rivas, Á., Rivero-Garduño, M. E., Rovelo-Wegener, Y., & Rocío Herrada-Chávez, C. (2014). Perfil epidemiológico del Servicio de Medicina de Rehabilitación de Médica Sur. In *Rev Invest Med Sur Mex* (Vol. 21, Issue 2).
41. Long, J. T., & Krzak, J. J. (2023). Kinematics and Kinetics of the Foot and Ankle during Gait. In *Foot and Ankle Biomechanics* (pp. 77–88). Elsevier. <https://doi.org/10.1016/B978-0-12-815449-6.00020-2>

42. Lorenz, E. A., Su, X., & Skjærret-Maroni, N. (2024). A review of combined functional neuroimaging and motion capture for motor rehabilitation. In *Journal of NeuroEngineering and Rehabilitation* (Vol. 21, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/s12984-023-01294-6>
43. Lorenzo Galván, M. G., Anzaldo Campos, M. C., & Saavedra Escalona, J. L. (2017). *Prevalencia de inestabilidad crónica posterior a esguince de tobillo en pacientes atendidos en el servicio de medicina física y rehabilitación en primer nivel de atención* [Universidad Autónoma de Baja California]. <https://repositorioinstitucional.uabc.mx/server/api/core/bitstreams/cb856fd2-0f06-4ecd-9b2a-c83aa286c44c/content#:~:text=Resultados:%20Se%20incluyeron%20un%20total,el%2029.6%25%20de%20los%20casos>.
44. Malik, O. A. (2021). Deep autoencoder for identification of abnormal gait patterns based on multimodal biosignals. *International Journal of Computing and Digital Systems*, 10(1), 1–8. <https://doi.org/10.12785/ijcds/100101>
45. Maura, R. M., Rueda Parra, S., Stevens, R. E., Weeks, D. L., Wolbrecht, E. T., & Perry, J. C. (2023). Literature review of stroke assessment for upper-extremity physical function via EEG, EMG, kinematic, and kinetic measurements and their reliability. In *Journal of NeuroEngineering and Rehabilitation* (Vol. 20, Issue 1). BioMed Central Ltd. <https://doi.org/10.1186/s12984-023-01142-7>
46. Noor, M. H. M., Nazir, A., Wahab, M. N. A., & Ling, J. O. Y. (2021). Detection of Freezing of Gait Using Unsupervised Convolutional Denoising Autoencoder. *IEEE Access*, 9, 115700–115709. <https://doi.org/10.1109/ACCESS.2021.3104975>
47. Okut, H. (2021). *Deep Learning for Subtyping and Prediction of Diseases: Long-Short Term Memory*. www.intechopen.com
48. Ordóñez-Flores, A. R., Rivera-Sánchez, J. J., Jiménez-Baez, M. V., Rojano-Mejía, D., Moreno-Tovar, M. G., & Guerrero-Martínez, A. I. (2024). Comparing costs and timing of ankle sprain care in two first-tier care systems. *Cirugia y Cirujanos*, 92(6), 751–757. <https://doi.org/10.24875/CIRU.23000024>

49. Pang, C. C. C., Upton, A. R. M., Shine, G., & Kamath, M. V. (2003). A comparison of algorithms for detection of spikes in the electroencephalogram. *IEEE Transactions on Biomedical Engineering*, 50(4), 521–526. <https://doi.org/10.1109/TBME.2003.809479>
50. Punt, I. M., Ziltener, J. L., Laidet, M., Armand, S., & Allet, L. (2015). Gait and physical impairments in patients with acute ankle sprains who did not receive physical therapy. *PM and R*, 7(1), 34–41. <https://doi.org/10.1016/j.pmrj.2014.06.014>
51. Shan, W., Lu, H., Wang, S., Zhang, X., & Gao, W. (2021). Improving Robustness and Accuracy via Relative Information Encoding in 3D Human Pose Estimation. *Proceedings of the 29th ACM International Conference on Multimedia*, 3446–3454. <https://doi.org/10.1145/3474085.3475504>
52. Sukru, D., Sefa, K., Mehmet, B., Turker, T., Sengul, D., Samir, B. B., Ahmet, K. P., & Murat, G. (2022). Automated knee ligament injuries classification method based on exemplar pyramid local binary pattern feature extraction and hybrid iterative feature selection. *Biomedical Signal Processing and Control*, 71. <https://doi.org/10.1016/j.bspc.2021.103191>
53. Suo, X., Tang, W., Mao, L., & Li, Z. (2024). Digital human and embodied intelligence for sports science: advancements, opportunities and prospects. In *Visual Computer*. Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s00371-024-03547-4>
54. Terven, J., Córdova-Esparza, D. M., & Romero-González, J. A. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. In *Machine Learning and Knowledge Extraction* (Vol. 5, Issue 4, pp. 1680–1716). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/make5040083>
55. Trew, M., & Everett, T. (2006). *Fundamentos del movimiento humano* (Masson, Ed.; 5th ed.). Elsevier.
56. Ultralytics. (2016). *YOLO vision*. <https://docs.ultralytics.com/es/>

57. Villa M., A., Gutiérrez G., E., & Pérez M., J. C. (2008). Consideraciones para el análisis de la marcha humana. Técnicas de videogrametría, electromiografía y dinamometría. *Revista Ingeniería Biomédica*, 2(3), 16–26.
58. Wexler, R. K. (1998). The Injured Ankle. *Am Fam Physician*, 3(57), 474–480.
59. Winter, D. A. (2009). Biomechanics and Motor Control of Human Movement: Fourth Edition. In *Biomechanics and Motor Control of Human Movement: Fourth Edition*. <https://doi.org/10.1002/9780470549148>
60. Wolfe, M. W., Mattacola, C. G., & McCluskey, L. C. (2001). Management of ankle sprains. *Am Fam Physician*, 63(1), 93–104. [https://doi.org/10.1016/S1060-1872\(10\)80009-7](https://doi.org/10.1016/S1060-1872(10)80009-7)
61. Yang, Y., Wu, Y., & Zhu, W. (2024). Recent advances in the management of chronic ankle instability. In *Chinese Journal of Traumatology - English Edition*. Elsevier B.V. <https://doi.org/10.1016/j.cjtee.2024.07.011>
62. Yin, R., Chen, H., Wang, C., Qin, C., Tao, T., Hao, Y., Wu, R., Jiang, Y., & Gui, J. (2025). Transformer-Based Multilabel Deep Learning Model Is Efficient for Detecting Ankle Lateral and Medial Ligament Injuries on Magnetic Resonance Imaging and Improving Clinicians' Diagnostic Accuracy for Rotational Chronic Ankle Instability. *Arthroscopy: The Journal of Arthroscopic & Related Surgery*, 41(3), 574-584.e4. <https://doi.org/10.1016/j.arthro.2024.05.027>
63. Yunas, S. U., & Ozanyan, K. B. (2021). Gait Activity Classification Using Multi-Modality Sensor Fusion: A Deep Learning Approach. *IEEE Sensors Journal*, 21(15), 16870–16879. <https://doi.org/10.1109/JSEN.2021.3077698>

Anexos

Anexo A



Universidad Autónoma de Querétaro
Facultad de ingeniería
Doctorado en Mecatrónica



Querétaro, Querétaro, ____ de _____ del 2025

Acuerdo de confidencialidad de participantes

Yo, Rogelio Cedeño Moreno identificado como estudiante del doctorado en mecatrónica y asesorado por el Dr. Irving Armando Cruz Albarrán director del proyecto “**Sistema inteligente de pronóstico para la rehabilitación de pacientes con lesiones de extremidades inferiores**” presentado como método de titulación de la maestría en ciencias mecatrónica de la Universidad Autónoma de Querétaro, manifiesto que:

- Entiendo que información confidencial es toda aquella, ya sea técnica, financiera, comercial o de cualquier otro carácter que sea suministrada o revelada por cualquiera de las partes. La cual se guardará con estricta confidencialidad y en donde todo dato obtenido como producto de la participación de los voluntarios será utilizado únicamente con fines académicos y no contará con ninguna relación directa hacia los participantes.
- Que me comprometo a restringir el acceso a la información confidencial sólo a aquellas personas vinculadas al proyecto en calidad de investigadores o auxiliares de investigación y que tengan necesidad de conocerla para el desarrollo del proyecto; y por lo tanto a mantener en la más estricta confidencialidad y no revelar a otras personas físicas o jurídicas cualquier información confidencial, en cualquier formato ni con otros fines distintos al proyecto.
- Que la confidencialidad se mantendrá permanentemente desde la recepción de la información y será almacenada en equipos de la universidad, dentro de las instalaciones.

M. en C. Rogelio Cedeño Moreno

Dr. Irving Armando Cruz Albarrán

Anexo B



Universidad Autónoma de Querétaro

Facultad de ingeniería

Doctorado en Mecatrónica



CARTA DE CONSENTIMIENTO INFORMADO

Mediante el siguiente formulario se acepta de manera voluntaria que se me incluya como sujeto de estudio en el proyecto de investigación denominado **“Sistema inteligente de pronóstico para la rehabilitación de pacientes con lesiones de extremidades inferiores”**, luego de haber conocido y comprendido en su totalidad, la información sobre dicho proyecto, riesgos si los hubiera y beneficios directos e indirectos de su participación en el estudio.

- Se me ha explicado la metodología básica de las pruebas que se realizarán y el cómo se busca utilizar la información para caracterizar la evolución de una lesión con el fin de predecir el cómo se comportara con nuevos pacientes.
- Se me han dado a conocer las herramientas que se utilizarán y se me ha asegurado que estas no representan ningún peligro para mi ser.
- Se me dio a conocer que los resultados obtenidos son con el fin de desarrollar una herramienta enfocada al apoyo de pacientes que se encuentren en pleno periodo de rehabilitación.
- Puedo retirarme del proyecto si lo considero conveniente a mis intereses, aun cuando el investigador responsable no lo solicite, informando mis razones para tal decisión en la Carta de Revocación respectiva si lo considero pertinente; pudiendo si así lo deseó, recuperar toda la información obtenida de mi participación.
- No haré ningún gasto, ni recibiré remuneración alguna por la participación en el estudio.
- Se guardará estricta confidencialidad sobre los datos obtenidos producto de mi participación, con un número de clave que ocultará mi identidad.
- Puedo solicitar, en el transcurso del estudio información actualizada sobre el mismo, al investigador responsable.

Lugar y Fecha: _____

Nombre y firma del participante

Nombre y firma de quien proporcionó la información para fines de consentimiento

Anexo C



Article

Computer Vision System Based on the Analysis of Gait Features for Fall Risk Assessment in Elderly People

Rogelio Cedeno-Moreno ¹, Diana L. Malagon-Barillas ², Luis A. Morales-Hernandez ^{1,2}, Mayra P. Gonzalez-Hernandez ² and Irving A. Cruz-Albarran ^{1,3,*}

¹ Laboratory of Artificial Vision and Thermography/Mechatronics, Faculty of Engineering, Autonomous University of Queretaro, Campus San Juan del Rio, San Juan del Rio 76807, Mexico

² University Physiotherapy Care System, Faculty of Nursing, Autonomous University of Queretaro, Campus Corregidora, Santiago de Queretaro 76912, Mexico

³ Artificial Intelligence Systems Applied to Biomedical and Mechanical Models, Faculty of Engineering, Autonomous University of Queretaro, Campus San Juan del Rio, San Juan del Rio 76807, Mexico

* Correspondence: irving.cruz@uq.mx

Abstract: Up to 30% of people over the age of 60 are at high risk of falling, which can cause injury, aggravation of pre-existing conditions, or even death, with up to 684,000 fatal falls reported annually. This is due to the difficult task of establishing a preventive system for the care of the elderly, both in the hospital environment and at home. Therefore, this work proposes the development of an intelligent vision system that uses a novel methodology to infer fall risk from the analysis of kinetic and spatiotemporal gait parameters. In general, each patient is assessed using the Tinetti scale. Then, the computer vision system estimates the biomechanics of walking and obtains gait features, such as stride length, cadence, period, and range of motion. Subsequently, this information serves as input to an artificial neural network that diagnoses the risk of falling. Ninety-six participants took part in the study. The system's performance was 99.1% accuracy, 94.4% precision, 96.9% recall, 99.4% specificity, and 95.5% F1-Score. Thus, the proposed system can evaluate the fall risk assessment, which could benefit clinics, hospitals, and even homes by allowing them to assess in real time whether a person is at high risk of falling to provide timely assistance.

Keywords: fall risk; machine learning; gait assessment; computer vision; physiotherapy; biomechanics; elderly



Citation: Cedeno-Moreno, R.; Malagon-Barillas, D.L.; Morales-Hernandez, L.A.; Gonzalez-Hernandez, M.P.; Cruz-Albarran, I.A. Computer Vision System Based on the Analysis of Gait Features for Fall Risk Assessment in Elderly People. *Appl. Sci.* **2024**, *14*, 3867. <https://doi.org/10.3390/app14093867>

Academic Editor: Lingfeng Shi

Received: 5 April 2024

Revised: 25 April 2024

Accepted: 25 April 2024

Published: 30 April 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

A fall is defined as an event in which a person is unintentionally thrown to the ground. It is the second leading cause of unintentional injury death with 684,000 fatal falls per year, primarily in adults over the age of 60 [1]. In addition, it has been observed that more than 30% of older adults suffer a fall each year, with 14% of these falls being recurrent [2], resulting in disability, loss of independence, limitation of activities of daily living, and functional impairment [3]. This is often associated with the natural degeneration of the gait due to the physiological changes associated with aging. For example, 10% of people between the ages of 60 and 69 have gait disorders, and more than 60% of people over the age of 80 have gait disorders [4]. Gait disorders occur in 10% of people between the ages of 60 and 69 and up to 60% of people over the age of 80 [4]. Gait disorders can have a significant impact on the quality of life of older adults and their participation in social activities, and a strong association has been observed with an increased risk of falls [5]. Therefore, worldwide guidelines for the prevention of falls in the elderly have recommended the use of devices that can measure the risk of falling, with the use of gait speed as one of the most important indicators [6].

To meet these needs, machine learning (ML) algorithms have been implemented in recent years. These are based on a structure inspired by the human brain for analyzing com-

Anexo D



A stacked autoencoder-based aid system for severity degree classification of knee ligament rupture

Rogelio Cedeno-Moreno^a, Luis A. Morales-Hernandez^a, Irving A. Cruz-Albarran^{a,b,*}

^a Laboratory of Artificial Vision and Thermography/Mechatronics, Faculty of Engineering, Autonomous University of Queretaro, Campus San Juan del Rio, 76807, Queretaro, Mexico

^b Artificial Intelligence Systems Applied to Biomedical and Mechanical Models, Faculty of Engineering, Autonomous University of Queretaro, Campus San Juan del Rio, 76807, Queretaro, Mexico

ARTICLE INFO

Keywords:

Musculoskeletal injuries
Knee ligament rupture
Severity prediction
Gait analysis
Stacked auto encoder
Ground reaction force

ABSTRACT

Background: Knee ligament rupture is one of the most common injuries, but the diagnosis of its severity tends to require the use of complex methods and analyses that are not always available to patients.

Aim: The objective of this research is the investigation and development of a diagnostic aid system to analyze and determine patterns that characterize the presence of the injury and its degree of severity.

Methods: Implement a novel proposal of a framework based on stacked auto-encoder (SAE) for ground reaction force (GRF) signals analysis, coming from the GaitRec database. Analysis of the raw data is used to determine the main features that allow us to diagnose the presence of a knee ligament rupture and classify its severity as high, mid or mild.

Results: The process is divided into two stages to determine the presence of the lesion and, if necessary, evaluate variations in features to classify the degree of severity as high, mid, and mild. The framework presents an accuracy of 87 % and a F1-Score of 90 % for detecting ligament rupture and an accuracy of 86.5 % and a F1-Score of 87 % for classifying severity.

Conclusion: This new methodology aims to demonstrate the potential of SAE in physiotherapy applications as an evaluation and diagnostic tool, identifying irregularities associated with ligament rupture and its degree of severity, thus providing updated information to the specialist during the rehabilitation process.

1. Introduction

The purpose of a healthy knee is to generate motion, maintain stability, and distribute the forces generated during static and dynamic activities. This is achieved through a combination of actions between the bones, muscles, menisci and ligaments. The latter are responsible for establishing the biomechanics of the knee, defining the axes of rotation, the range of motion and the overall structure of all the components of the knee. However, as the primary limiter of motion, when an abnormal movement generates high loads, it is common to suffer a ligament rupture, with more than 80,000 cases reported annually [1]. Directly affecting the locomotion and stability of the injured limb, resulting in an alteration of the biomechanics of the knee, unable to withstand the efforts generated during static or dynamic activities. And consequently, increase the load and stress applied to the other limb to avoid resting its

own weight in the affected limb, altering the symmetry of the ground reaction forces generated during walking [2]. This is commonly diagnosis with the Lachman test, anterior drawer tests, or pivot shift tests [3]. However, these are not always conclusive, and an arthroscopic exploration or magnetic resonance imaging is necessary, which is not within the reach of every patient or clinic and can be a very invasive method [4]. To minimize its use, new tools are implemented to facilitate the extraction of information from the biomechanics of the injury, to define a clear picture of how it should be evaluated, treated and followed up [2]. Obtaining optimal results through detailed information for decision making, timely interventions and treatments tailored to the condition, which reduces the short-term presence of biomechanical deficiencies that may promote the development of diseases such as osteoarthritis [5]. Some of the new tools are based on artificial intelligence (AI), for the reconstruction of the biomechanics of the patient and

* Corresponding author. Laboratory of Artificial Vision and Thermography/Mechatronics, Faculty of Engineering, Autonomous University of Queretaro, Campus San Juan del Rio, San Juan del Rio, 76807, Mexico.

E-mail address: irving.cruz@uq.mx (I.A. Cruz-Albarran).

<https://doi.org/10.1016/j.combiomed.2024.108983>

Received 18 October 2023; Received in revised form 1 August 2024; Accepted 2 August 2024
0010-4825/© 2024 Elsevier Ltd. All rights are reserved, including those for text and data mining, AI training, and similar technologies.