



UNIVERSIDAD DE CUENCA

Facultad de Ingeniería

**Carrera de
Electrónica y Telecomunicaciones**

**Generación de la biomecánica del
movimiento de extremidades inferiores.**

*Trabajo de titulación previo a la
obtención del título de Ingeniero en
Electrónica y Telecomunicaciones.*

Autores:

Stalin Javier Benenaula Armijos
stamben1996@gmail.com

C.I: 010564342-3

Milton Damian Trelles Peralta
trelles.damian1d@gmail.com

C.I: 010497609-7

Director:

Ing. Luis Ismael Minchala Ávila, PhD

C.I: 030145348-6

Co-Director:

Lcda. Luz Maria Ayavaca Tapia, Mg

C.I: 010481499-1

**Cuenca - Ecuador
23 de abril de 2021**



Resumen

El ser humano en su búsqueda de mejorar la calidad de vida en personas que sufren alteraciones de la marcha, ha desarrollado tecnologías capaces de identificar patrones y características de las diferentes afecciones que deterioran la movilidad. Si bien algunos estudios exploran métodos invasivos como la electromiografía, el uso de sensores y/o marcadores para el análisis y evaluación de marchas patológicas, es todavía escasa la investigación que abordan métodos que no invadan el cuerpo en vista de que en tiempos actuales es un enfoque imprescindible.

El propósito de este estudio es desarrollar un sistema no invasivo, basado en técnicas de visión e inteligencia artificial con capacidad de generar parámetros espacio-temporales de la biomecánica del movimiento de las extremidades inferiores a partir de marchas normales o patológicas como la hemiparética y paraparética, así como el análisis y clasificación de dichas marchas.

La metodología utilizada consiste en la captura de imágenes [Red Green Blue \(RGB\)](#) en personas que realizan varios ciclos de dichas marchas, estas imágenes se procesan mediante el uso de modelos como OpenPose y PoseNet para estimar la pose. Luego, se aplican técnicas de corte, sincronización, filtrado, normalización y análisis en 2D, además de nuevos enfoques como el [Skeleton Gait Energy Image \(SGEI\)](#) para caracterizar la marcha. Finalmente mediante algoritmos como [Convolutional Neural Network \(CNN\)](#) o [Support Vector Machine \(SVM\)](#), se entrena al sistema para clasificar las marchas analizadas.

Como resultado, se generan los parámetros de longitud de paso, cadencia, amplitud de paso, tiempo de paso, velocidad de marcha, inclinación de la postura corporal frontal y ángulos de las extremidades inferiores del cuerpo humano de las 3 marchas utilizando un sistema con un enfoque no invasivo, adicionalmente los resultados experimentales muestran alta eficiencia en la clasificación de las marchas con un 98.57 % para OpenPose y 98.15 % con PoseNet.

Palabras clave : Biomecánica. Marcha. OpenPose. PoseNet. Clasificación



Abstract

Human beings, in their quest to improve the quality of life in people who suffer from gait disturbances, have developed technologies capable of identifying patterns and characteristics of different conditions that deteriorate mobility. Although, some studies explore invasive methods such as electromyography, the use of sensors and/or markers for the analysis and evaluation of pathological gaits, there is still little research that addresses methods that do not invade the body, given that in current times it is an essential approach.

The purpose of this study is to develop a non-invasive system, based on vision techniques and artificial intelligence capable of generating spatio-temporal parameters of the biomechanics of movement of the lower extremities from normal or pathological gaits such as hemiparetic and paraparetic, as well as the analysis and classification of these gaits.

The methodology used consists of capturing RGB images in people who perform several cycles of the normal, hemiparetic and paraparetic gaits. These images are processed by using models like OpenPose and PoseNet to estimate the pose. Then, cutting, synchronization, filtering, normalization and 2D analysis techniques are applied, as well as new approaches such as Skeleton Gait Energy Image (SGEI) to characterize the gait. Finally, through algorithms such as Convolutional Neural Network (CNN) or Support Vector Machine (SVM), the system is trained to classify the analyzed gaits.

As a result, it is possible to generate the parameters of stride length, cadence, stride width, step time, gait speed, front body posture inclination and angles of the lower extremities of the human body of the 3 gaits using a non-invasive system approach, additionally experimental results show high efficiency in the classification of the gaits with a 98.57 % using OpenPose and a 98.15 % with PoseNet.

Keywords : Biomechanics. Gaits. OpenPose. PoseNet. Classification



Índice general

Resumen	1
Abstract	2
Índice general	3
Índice de figuras	6
Índice de tablas	8
Cláusula de Propiedad Intelectual	9
Cláusula de Propiedad Intelectual	10
Cláusula de licencia y autorización para publicación en el Repositorio Institucional	11
Cláusula de licencia y autorización para publicación en el Repositorio Institucional	12
Certifico	13
Certifico	14
Dedicatoria	15
Dedicatoria	16
Agradecimientos	17
Abreviaciones y acrónimos	18
1. Introducción	19
1.1. Identificación del problema	19
1.2. Justificación	20
1.3. Alcance	20
1.4. Objetivos	20
1.4.1. Objetivo general	20
1.4.2. Objetivos específicos	21



2. Marco teórico y estado del arte	22
2.1. Bases conceptuales de la marcha humana	22
2.1.1. Ciclo de la marcha humana	22
2.1.1.a. Divisiones del ciclo de marcha humana	23
2.1.1.b. Fases del ciclo de la marcha	23
2.1.2. Parámetros de la marcha humana	23
2.1.3. Evaluación de la marcha humana	24
2.1.4. Evaluación instrumental	24
2.1.4.a. Captura de movimiento o Fotogrametría	24
2.2. Marchas patológicas	26
2.2.1. Marcha hemiparética	26
2.2.2. Marcha paraparética	26
2.3. Modelos de estimación de pose	27
2.3.1. PoseNet	28
2.3.2. OpenPose	30
2.4. Preprocesamiento de imágenes	31
2.4.1. Ventana de Hanning	31
2.4.2. Distancia euclidiana	31
2.4.3. Imagen de energía de la marcha (GEI)	32
2.5. Algoritmos de clasificación	33
2.5.1. Redes neuronales convolucionales	33
2.5.1.a. Modelo VGG-19	33
2.5.2. Máquinas de vector soporte	34
2.6. Herramientas para evaluar el desempeño de algoritmos de clasificación	35
2.6.1. Matriz de confusión	35
2.6.2. Curva ROC	35
2.7. Estado del arte y trabajos relacionados	36
3. Metodología	39
3.1. Descripción de equipos	39
3.1.1. Cámaras y accesorios	39
3.1.2. Requerimientos de hardware	39
3.2. Instalación y configuración de software	40
3.3. Descripción del ambiente y procedimiento de toma de datos	40
3.4. Pre-procesamiento de imágenes	41
3.4.1. Corte y sincronización	41
3.4.2. Extracción de pose	41
3.4.3. Suavizado	43
3.4.4. Normalizar la posición del esqueleto en el plano frontal y sagital	43
3.4.5. Identificación de los ciclos de la marcha	44
3.4.6. Cálculo de las imágenes de energía de marcha esquelética	44
3.4.7. Cálculos biomecánicos de la marcha	46
3.4.7.a. Goniometría digital	46
3.4.7.b. Análisis en 2D	48



3.5. Extracción de características y clasificación	48
3.5.1. Redes neuronales convolucionales	48
3.5.2. Características biomecánicas y máquinas de vector soporte	49
4. Resultados	50
4.1. Análisis de la biomecánica de la marcha	50
4.1.1. Parámetros espacio temporales y goniometría digital	50
4.1.2. Generación de ángulos del tren inferior del cuerpo humano	53
4.1.2.a. OpenPose	53
4.1.2.b. PoseNet	56
4.2. Precisión de los clasificadores	59
4.2.1. Ajustes de parámetros CNN y precisión	59
4.2.1.a. OpenPose	60
4.2.1.b. PoseNet	61
4.2.2. Ajustes de parámetros SVM y precisión	62
4.2.2.a. OpenPose	62
4.2.2.b. PoseNet	63
5. Conclusiones y Recomendaciones	64
5.1. Conclusiones	64
5.2. Recomendaciones	65
5.3. Trabajos futuros	65
A. Apendice A	66
A.1. Modelo de consentimiento informado	66
A.2. Registro de Firmas	66
B. Apendice B	69
B.1. Instalación y configuración de OpenPose	69
B.2. Instalación y configuración de PoseNet	70
B.3. Interfaz gráfica del sistema desarrollado	70
Bibliografía	72



Índice de figuras

2.1. Periodos, fases y divisiones de la marcha [14]	23
2.2. Fases del ciclo de la marcha [15]	23
2.3. Patrón de marcha de persona de prueba analizado en el plano sagital frente al patrón de marcha normalizado [18]	25
2.4. Ciclograma de la marcha: Representación gráfica de las fases de la marcha [19]	26
2.5. Marcha hemiparética [3]	27
2.6. Marcha paraparética	27
2.7. Estimación de pose mediante PoseNet [9]	29
2.8. Imagen de entrada y resolución de la red [24]	29
2.9. Estimación de pose mediante OpenPose con formato BODY_25 [25]	31
2.10. Ventana de Hanning [29]	32
2.11. Siluetas binarias de la marcha condensada en Gait Energy Image (GEI) [32]	32
2.12. Filtro kernel usado en las CNN [34]	33
2.13. Modelo VGG-19 [36]	34
2.14. Clasificador SVM [39]	35
2.15. Curva Receiver Operating Characteristic (ROC)	36
3.1. Toma de datos en ambiente	40
3.2. Diagrama implementado para el pre-procesamiento	41
3.3. Ejemplo de estimación de pose vista sagital	42
3.4. Ejemplo de estimación de pose vista frontal	42
3.5. Suavizado de coordenadas y extracción de ángulo de rodilla antes y después de usar Hanning	43
3.6. Normalización vista frontal	44
3.7. Normalización vista sagital	44
3.8. Distancia entre el tobillo izquierdo y derecho de dos ciclos de la marcha	45
3.9. Fotogramas correspondientes a 1 ciclo de la marcha OpenPose	45
3.10. SGEI OpenPose	46
3.11. Ángulos calculados	47
3.12. Longitudes de paso y zancada	48
3.13. Arquitectura de la variación del modelo VGG-19	49
4.1. Flexión Cadera OpenPose	54
4.2. Flexión Rodilla OpenPose	55
4.3. Flexión Tobillo OpenPose	56



4.4. Flexión Cadera PoseNet	57
4.5. Flexión Rodilla PoseNet	58
4.6. Flexión Tobillo PoseNet	59
4.7. Curvas de entrenamiento OpenPose	60
4.8. Herramientas de evaluación OpenPose	61
4.9. Curvas de entrenamiento PoseNet	61
4.10. Herramientas de evaluación PoseNet	62
4.11. Herramientas de evaluación OpenPose	63
4.12. Herramientas de evaluación PoseNet	63
A.1. Registro de firmas primera parte	67
A.2. Registro de firmas segunda parte	68
B.1. Interfaz gráfica del sistema desarrollado	71



Índice de tablas

2.1. Asignación de ID de puntos clave de las articulaciones en PoseNet	28
2.2. Asignación de ID de puntos clave de las articulaciones en OpenPose	30
2.3. Matriz de Confusión de 2 clases	35
3.1. Ángulos calculados	47
4.1. Parámetros espacio-temporales OpenPose	51
4.2. Parámetros espacio-temporales PoseNet	52



Cláusula de Propiedad Intelectual

Yo, Stalin Javier Benenaula Armijos, autor de la tesis “Generación de la biomecánica del movimiento de extremidades inferiores”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 23 de abril de 2021

Stalin Javier Benenaula Armijos

010564342-3



Cláusula de Propiedad Intelectual

Yo, Milton Damian Trelles Peralta, autor de la tesis “Generación de la biomecánica del movimiento de extremidades inferiores”, certifico que todas las ideas, opiniones y contenidos expuestos en la presente investigación son de exclusiva responsabilidad de su autor.

Cuenca, 23 de abril de 2021

Milton Damian Trelles Peralta

010497609-7



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Yo, Stalin Javier Benenaula Armijos en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación “Generación de la biomecánica del movimiento de extremidades inferiores”, de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos. Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 23 de abril de 2021

Stalin Javier Benenaula Armijos

010564342-3



Cláusula de licencia y autorización para publicación en el Repositorio Institucional

Yo, Milton Damian Trelles Peralta en calidad de autor y titular de los derechos morales y patrimoniales del trabajo de titulación “Generación de la biomecánica del movimiento de extremidades inferiores”, de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN reconozco a favor de la Universidad de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos. Asimismo, autorizo a la Universidad de Cuenca para que realice la publicación de este trabajo de titulación en el repositorio institucional, de conformidad a lo dispuesto en el Art. 144 de la Ley Orgánica de Educación Superior.

Cuenca, 23 de abril de 2021

Milton Damian Trelles Peralta

010497609-7



Certifico

Que el presente proyecto de tesis: Generación de la biomecánica del movimiento de extremidades inferiores, fue dirigido y revisado por mi persona.

Ing. Luis Ismael Minchala Ávila, PhD
Director



Certifico

Que el presente proyecto de tesis: Generación de la biomecánica del movimiento de extremidades inferiores, fue dirigido y revisado por mi persona.

Lcda. Luz Maria Ayavaca Tapia, Mg
Co-director



Dedicatoria

A mi Padre

Por el incondicional apoyo y ser un pilar fundamental en mi vida, gracias por cada consejo y siempre desearme lo mejor. Le dedico esta tesis en agradecimiento a todo lo que hace por mi.

Stalin Javier Benenaula Armijos



Dedicatoria

“A todas las personas que hicieron posible que llegara a cumplir esta meta”.

Milton Damian Trelles Peralta



Agradecimientos

A nuestros directores

Por su tiempo y apoyo incondicional, que fueron parte fundamental para desarrollar de manera exitosa este trabajo. Gracias por su tutoría, consejos y motivación brindada.

A la facultad de Ingeniería

Por ofrecernos los conocimientos necesarios para lograr nuestro objetivo. Gracias por permitirnos ser mejores personas y unos excelentes profesionales.

A nuestra familia

Por ofrecernos ese amor incondicional que nos motivó a no rendirnos en el transcurso de la carrera. ¡Gracias a Ustedes!

LOS AUTORES



Abreviaciones y Acrónimos

CNN Convolutional Neural Network. [1](#), [6](#), [33](#), [48](#), [59](#)

DCT Discrete Cosine Transform. [37](#)

GEI Gait Energy Image. [6](#), [32](#), [38](#), [41](#)

ILSVRC ImageNet Large Scale Visual Recognition Challenge. [33](#)

RBF Radial Basis Function. [34](#), [35](#), [49](#), [62](#)

RGB Red Green Blue. [1](#), [20](#), [29](#), [37](#)

RGB-D Red Green Blue-Depth. [20](#), [37](#)

ROC Receiver Operating Characteristic. [6](#), [35](#), [36](#)

SGEI Skeleton Gait Energy Image. [1](#), [41](#), [43](#), [44](#), [49](#), [60](#), [61](#)

SVM Support Vector Machine. [1](#), [6](#), [34](#), [35](#), [49](#), [59](#), [62](#)



Introducción

1.1. Identificación del problema

En la actualidad, constituye una gran preocupación de la ciencia moderna el estudio de afecciones que deterioran la movilidad del sistema esquelético-muscular alterando el desplazamiento normal y determinando la aparición de marchas patológicas. Se requiere dar un seguimiento, control y reconocimiento pertinente para orientar la mejora terapéutica de recuperación de la salud de la persona. Entre las opciones que permiten abordar estas problemáticas, se encuentran las tecnologías multimedia para obtener una interpretación con valoración técnica que beneficia el diagnóstico clínico y la recuperación de la salud integral.

En el ámbito tecnológico, existen variedad de metodologías de análisis y evaluación de la marcha del individuo, tanto de la normalidad como de los estados patológicos. Son orientados a guiar procesos de identificación, reconocimiento y diagnóstico asertivo que posteriormente permitan un tratamiento eficaz de dichas patologías. Entre estos métodos técnicos están la electromiografía, la videogrametría y dinamometría que han servido en la práctica clínica como técnicas de análisis, limitadas a dar un estudio dinámico y cinemático de la marcha utilizando en su mayoría herramientas invasivas para el cuerpo humano [1], que en tiempos actuales no son idóneos.

Actualmente, existen proyectos que buscan identificar patrones y características de las marchas patológicas, el seguimiento y tratamiento respectivo. Por ejemplo, en [2] utilizan un sistema basado en sensores para determinar características de la marcha relacionada a enfermedades neurodegenerativas, condiciones que han impulsado el desarrollo de estudios científicos, que evalúen y analicen ciertas marchas patológicas como la hemiparética [3] y paraparética [4].

Estas marchas pueden ser analizadas con sistemas basados en videogrametría apoyados en la visión artificial para procesar los datos [5], siendo por tanto, aplicables en el ámbito de la salud para incentivar el emprendimiento de investigaciones de las causas más comunes de alteraciones de la marcha, que involucran al daño cerebral recibido y las lesiones de origen traumático. Estas alteraciones suponen un deterioro importante en la fortaleza y calidad de vida de las personas afectadas y el entorno familiar [3], resultando que, la tecnología y el mejor uso de la misma en el área de la salud beneficia al individuo en particular y a la sociedad en general.

Por lo expuesto, es urgente desarrollar sistemas competentes de detección e identificación de marchas

patológicas específicas. Así como el análisis de la biomecánica de las mismas basados estrictamente en la visión e inteligencia artificial, utilizando videos RGB y equipos de acceso factible para el uso.

1.2. Justificación

En el campo científico, las investigaciones tecnológicas están enfocadas en el análisis y evaluación de la marcha humana para identificar anomalías e identificar un tipo específico de marcha patológica. Por esta razón, se utilizan mecanismos de videografía apoyada con inteligencia artificial y el uso de marcadores [1] o sin la necesidad de los mismos, pero con la asistencia de sensores Red Green Blue-Depth (RGB-D) [6, 7] que permiten obtener una proyección 3D de las imágenes de la marcha. Estos enfoques centran el interés en el registro de la información acerca de las marchas patológicas de enfermedades neurodegenerativas como el Parkinson [5], neuropatías o enfermedades como el de Huntington [2], que afectan el desplazamiento de las personas y modifican las condiciones de la movilidad individual.

En este contexto, este trabajo utiliza modelos como OpenPose y PoseNet en conjunto con sistemas basados en visión artificial y videos que capturan imágenes en dos dimensiones que se focalizan específicamente en el análisis y evaluación de los parámetros espacio-temporales biomecánicos. También, en la identificación y clasificación de marchas patológicas causadas por daño cerebral adquirido como la hemiparética o por lesiones de origen traumático como la paraparética, en contraste con la marcha de una persona sana. Por tanto este estudio de investigación científica se desarrolla con el fin de realizar un sistema que genere información de parámetros espacio-temporales de la marcha y permita identificar las patologías abordadas.

1.3. Alcance

Esta investigación implementa y desarrolla un sistema de visión e inteligencia artificial no invasivo que permite generar parámetros espacio temporales de la biomecánica de la marcha humana, detecta e identifica marchas patológicas específicas como la hemiparética y la paraparética en comparación con la marcha de una persona sana. Este sistema puede constituir un apoyo diagnóstico y una guía en el tratamiento de enfermedades derivadas de dichas anomalías. Para lograr este cometido, se utiliza modelos computacionales capaces de estimar la pose del cuerpo humano como OpenPose [8] y PoseNet [9], alcanzando resultados que faciliten comparar y distinguir modelos y a la vez, proporcionen un mayor grado de relevancia tanto en la generación de parámetros espacio-temporales como en la clasificación de las marchas.

Finalmente, se realizan varias tomas de video a personas que realizan estas marchas, se capturan imágenes con teléfonos móviles mediante cámaras RGB situadas en un ambiente controlado. Estos videos permiten extraer, mediante visión artificial los parámetros biomecánicos esenciales de la marcha y analizarlos [10], caracterizando los datos para entrenar mediante algoritmos de clasificación e identificación cada una de las marchas humanas normal, hemiparética y paraparética.

1.4. Objetivos

1.4.1. Objetivo general

Implementar un sistema de visión artificial no invasivo para generar la biomecánica del movimiento de extremidades inferiores en personas con marcha normal, hemiparética y paraparética.



1.4.2. Objetivos específicos

El presente trabajo tiene los siguientes objetivos específicos:

- Identificar y desarrollar una solución técnica no invasiva para la correcta adquisición de datos obtenidos de la marcha humana.
- Incluir funcionalidades al sistema de visión artificial como la detección de ángulos y el análisis de parámetros espacio-temporales de la marcha de un individuo.
- Definir un enfoque que permita extraer características de la marcha que proporcionen mayor información al clasificador.
- Clasificar mediante técnicas de inteligencia artificial las marchas patológicas hemiparética y paraparética en referencia a la marcha humana normal.



Marco teórico y estado del arte

El presente capítulo está dividido en siete secciones. La Sección 2.1 presenta una visión general de la marcha humana, define los distintos conceptos de análisis, métodos de evaluación y parámetros de la marcha, en la Sección 2.2 se revisan y definen alteraciones patológicas de la marcha como la hemiparética y la paraparética. En la Sección 2.3 se presentan dos modelos de estimación de pose PoseNet y OpenPose utilizados para abstraer mediante coordenadas en dos dimensiones el movimiento de una persona. Además, se usan varias técnicas de visión artificial para procesar las coordenadas y permitir un mejor desempeño del sistema así como enfoques para caracterizar la marcha, lo cual está descrito en la Sección 2.4. En la Sección 2.5 se describen los algoritmos utilizados para realizar la clasificación de las marchas, mientras que en la Sección 2.6 se presentan las herramientas para evaluar el desempeño de dichos algoritmos. En la Sección 2.7 se detalla el estado del arte y los trabajos relacionados con esta investigación.

2.1. Bases conceptuales de la marcha humana

La marcha humana consiste en una secuencia repetitiva de movimiento de los miembros inferiores que, balancean el cuerpo hacia adelante mientras se mantiene un equilibrio postural. Es importante describir el ciclo de la marcha normal, las fases y ciertas variables que la definen desde un punto de vista cinemático y cinético [11]. Por lo tanto este proceso es cíclico, tiene una sucesión de pasos con acciones y movimientos que se producen entre el choque de talón de un pie y el choque de talón del pie contralateral.

2.1.1. Ciclo de la marcha humana

El desplazamiento del cuerpo humano, precisa de la marcha que es un proceso conformado por la repetición de ciclos continuos. Se inicia en un miembro inferior el cual proporciona soporte, estabilidad y propulsión, mientras que el otro avanza hacia adelante, y de forma cíclica se invierten los papeles produciendo un ciclo de la marcha humana que es una repetición de una serie de eventos por cada miembro inferior [12].

2.1.1.a. Divisiones del ciclo de marcha humana

El ciclo de la marcha humana se especifica en dos periodos uno de apoyo y otro de oscilación como se muestra en la Figura 2.1. En referencia al periodo de apoyo, se advierte que es el momento en el que el pie está en contacto con el suelo, en tres intervalos, un doble apoyo inicial y uno final, y un apoyo unipodal. La duración de este intervalo es un indicador de la capacidad del soporte de los miembros inferiores, por lo que es útil para identificar anomalías en la marcha humana. Mientras que, el período de oscilación se comprende como el instante en el cual el pie está en el aire y avanza hacia adelante con un apoyo unipodal, tiene la misma duración que el periodo de oscilación de la otra extremidad y la relación de duración de estos momentos es de 60 y 40 % respectivamente [13].




Figura 2.1: Periodos, fases y divisiones de la marcha [14]

2.1.1.b. Fases del ciclo de la marcha

El ciclo de la marcha humana tiene fases comprendidos desde el apoyo, que implica dos instancias diferentes tal como se muestra en la Figura 2.2. En la de doble apoyo está el período de contacto inicial y de respuesta a la carga, mientras que en la de apoyo unipodal están las instancias de apoyo medio, apoyo terminal y pre-oscilación. En el periodo de oscilación, se determina el avance de la extremidad, con oscilación inicial, media y final.




Figura 2.2: Fases del ciclo de la marcha [15]

2.1.2. Parámetros de la marcha humana

En la marcha humana [16] se usan términos de parámetros espacio-temporales del campo de la cinemática, que incluyen momentos articulares, potencias articulares, fuerzas de reacción del suelo y electromiografía, así

como las variables de edad, sexo, la longitud de los miembros inferiores que hacen complejo establecer un patrón común.

Al referirse a los parámetros espacio-temporales, en [10] los que más destacan para este análisis son: la cadencia, que incorpora al número de pasos por unidad de tiempo representada por pasos por minuto; la longitud del paso, que concentra la distancia media entre dos puntos de apoyo de ambos pies mientras están en el suelo; seguidamente la longitud de la zancada, que refiere a dos choques de talón consecutivos realizados por un mismo pie y finalmente, la velocidad de la marcha, es la distancia que recorre el cuerpo hacia adelante durante la unidad de tiempo y se expresa en metros por segundo.

Como se menciona en [17], una estimación correcta de la cinemática de la marcha se obtiene calculando la posición espacial del centro de masa del cuerpo y los centros de giro de cada una de las articulaciones de cadera, rodilla y tobillo que intervienen durante el movimiento, siendo necesario acotar que la electromiografía también es un parámetro elegible cuando se requiere analizar el movimiento de la marcha y determinar las anomalías.

En la Figura 2.3 se muestra los gráficos de las posiciones angulares vs ciclo % correspondiente al patrón de marcha en el plano sagital de las articulaciones de la cadera, rodilla y tobillo. Estos movimientos se conocen como flexo/extensión y su valor de referencia en una persona saludable corresponden a la (franja gris), mientras que, los valores de las franjas (verde, roja y azul) pertenecen a las alteraciones producidas por pacientes con una enfermedad neurodegenerativa, la cual muestra mínima flexión tanto del tobillo como en la rodilla derecha.

2.1.3. Evaluación de la marcha humana

El análisis observacional proporciona una estimación de la cinemática de la marcha, debido a su bajo coste y aplicabilidad se convierte en la aproximación más frecuente. Dicho análisis se basa en la evaluación del desplazamiento articular y de los componentes espacio-temporales. Este método comprende 5 fases: La primera se refiere a la preparación previa de todas las partes involucradas en el desarrollo de la prueba, como el profesional y equipo de salud, el paciente, entre otros. La segunda fase comprende la grabación y registro fotográfico. La tercera fase hace referencia a la elaboración de los cinegramas y ciclogramas, es decir la división de la marcha en ciclos. La cuarta corresponde al análisis cualitativo y cuantitativo de la marcha, la quinta fase define las conclusiones y recomendaciones [19].

2.1.4. Evaluación instrumental

Un estudio cuantitativo de la marcha permite dar un análisis más objetivo del comportamiento biomecánico del ser humano mientras se desarrolla la misma, utilizando herramientas capaces de procesar y medir objetivamente patrones de movimiento y de detectar anomalías. A continuación, se expone el sistema de fotogrametría :

2.1.4.a. Captura de movimiento o Fotogrametría

Existen diferentes métodos de evaluación que determinan patrones de la marcha y pueden llegar a determinar anomalías presentes en la misma. Una de ellas es el análisis mediante plataformas dinamométricas que registran las fuerzas externas e internas que actúan en el movimiento. Otra es la electromiografía de superficie que estudia las señales eléctricas proveniente de electrodos ubicados en la superficie corporal del paciente mediante videografía, fotogrametría y captura de movimiento.

Este método de evaluación instrumental sirve para obtener información bidimensional o tridimensional del movimiento a partir de imágenes planas que crean un modelo biomecánico para simplificar el cuerpo que se va a




Figura 2.3: Patrón de marcha de persona de prueba analizado en el plano sagital frente al patrón de marcha normalizado [18]

analizar. Esta simplificación está compuesta por puntos corporales que unidos forman diferentes segmentos y ángulos entre ellos, como se muestra en la Figura 2.4. El procedimiento para capturar el movimiento depende del sistema y colocación de marcadores en puntos anatómicos [14]. Los datos adquiridos por el sistema corresponden a cada punto de la simplificación del cuerpo representados en un sistema cartesiano (x, y, z), de esta manera se tiene la posición lineal de los puntos y más variables que se derivan de esta primera como la velocidad, aceleración angular y lineal.




Figura 2.4: Ciclograma de la marcha: Representación gráfica de las fases de la marcha [19]

2.2. Marchas patológicas

Las alteraciones básicas de la marcha debido a patologías se pueden clasificar en deformidad, debilidad muscular, dolor y control neurológico deficitario [20]. Una deformidad resulta cuando los tejidos no permiten una movilidad pasiva suficiente e imposibilita una marcha normal. Una debilidad muscular puede deberse a una atrofia muscular, lesiones neurológicas, etc. De esta forma hay imposibilidad de identificar los niveles máximos de fuerza muscular para una marcha normal. El dolor resulta en reacciones fisiológicas que derivan de las dos alteraciones indicadas anteriormente. Y por último, un control neurológico deficitario se produce cuando hay patologías en el sistema nervioso, que dan lugar a alteraciones durante la marcha como espasticidad, alteraciones de la coordinación, patrones reflejos primitivos, alteraciones de la secuencia de la actuación muscular y alteración de la propiocepción.

2.2.1. Marcha hemiparética

Esta se produce como consecuencia de la lesión unilateral de la corteza motora o de la vía corticoespinal. En relación con las alteraciones espacio-temporales, en pacientes hemipléjicos es posible observar una disminución de la velocidad, la cadencia y la longitud del paso, con pasos más cortos y breves. La marcha hemipléjica o hemiparética se caracteriza por ser asimétrica tanto espacial como temporalmente, además tiende a tener reacciones de equilibrio con mayores latencias e interrumpidas. De esta forma el paciente camina dibujando un semicírculo a cada paso tal y como se muestra en la Figura 2.5, este evento se lo conoce como la marcha de segador. La extensión de las articulaciones del tren inferior se ven alteradas en los dos periodos de la marcha, tanto en fase de apoyo como de oscilación.

2.2.2. Marcha paraparética

En la marcha paraparética, las piernas suelen estar ligeramente flexionadas en la cadera y en posición de aducción. Las rodillas están extendidas o ligeramente flexionadas y los pies en posición de flexión plantar, es



Figura 2.5: Marcha hemiparética [3]

decir, los pies forman un ángulo mayor a 90 grados con la tibia. Esta postura requiere la circunducción de las piernas al caminar, formando círculos hacia el exterior del cuerpo. La marcha puede parecer rígida e insegura tal y como muestra en la Figura 2.6. En la marcha paraparética, cada pierna parece estar arrastrada hacia adelante [4].




Figura 2.6: Marcha paraparética

2.3. Modelos de estimación de pose

La estimación de la pose humana descubre la ubicación y orientación de las diversas articulaciones y partes del cuerpo humano en una imagen o video. Las partes del cuerpo detectadas normalmente se figuran como las coordenadas en 2D y 3D de valiosas articulaciones esqueléticas [21]. En este trabajo, se utiliza la estimación

de pose para extraer fotograma a fotograma coordenadas con el fin de usarlas como entradas para analizar y clasificar la marcha normal, hemiparética y paraparética. En la Sección 2.3.1 y 2.3.2 se revisan los modelos de estimación de pose PoseNet y OpenPose respectivamente.

2.3.1. PoseNet

PoseNet utiliza un modelo de *machine learning* lanzado por Google que utiliza la biblioteca de Tensor Flow [22]. Estima la pose de una persona a partir de una imagen o un video mediante el cálculo de las ubicaciones espaciales de las articulaciones corporales clave (puntos clave). Estimar la pose se refiere a técnicas de visión artificial para determinar por ejemplo las articulaciones del cuerpo humano [9].

Las diversas articulaciones corporales detectadas por el modelo PoseNet se muestran en la Tabla 2.1.

Tabla 2.1: Asignación de ID de puntos clave de las articulaciones en PoseNet

ID	Parte	ID	Parte	ID	Parte
0	Nariz	6	Hombro Derecho	12	Cadera Derecha
1	Ojo Izquierdo	7	Codo Izquierdo	13	Rodilla Izquierda
2	Ojo Derecho	8	Codo Derecho	14	Rodilla Derecha
3	Oreja Izquierda	9	Muñeca Izquierda	15	Tobillo Izquierdo
4	Oreja Derecha	10	Muñeca Derecha	16	Tobillo Derecho
5	Hombro Izquierdo	11	Cadera Izquierda		

De lo anterior se desprende que, PoseNet puede ser usado para estimar una o múltiples poses dando como resultado coordenadas (x, y) de los puntos clave en el espacio de la imagen de entrada, su exactitud y velocidad de procesamiento dependen del modelo de red utilizado, sea Mobilenet o ResNet caracterizados por su alta velocidad-baja exactitud y baja velocidad-alta exactitud, respectivamente [23]. La Figura 2.7 muestra un ejemplo de los puntos del cuerpo mapeados en la imagen de entrada y procesada mediante PoseNet.




Figura 2.7: Estimación de pose mediante PoseNet [9]

La estimación realizada por PoseNet ocurre en dos fases, como se muestra en la Figura 2.8. Primero, una imagen RGB alimenta la entrada de una red neuronal convolucional. Luego, se utiliza un algoritmo de decodificación de poses, puntajes de confianza de pose, posiciones de puntos clave y puntajes de confianza de puntos clave de las salidas del modelo [24]. Cabe resaltar que PoseNet procesa la imagen de entrada de cualquier tamaño, pero la exactitud de predicción depende del tamaño de la red, el tipo de la red y por supuesto, del rendimiento del procesador que esté ejecutando dicho algoritmo.




Figura 2.8: Imagen de entrada y resolución de la red [24]

2.3.2. OpenPose

OpenPose utiliza un modelo de software libre lanzado por CMU Perceptual Computing Lab. Este modelo puede tomar una imagen de una o varias personas como entrada y estimar un conjunto de coordenadas 2D correspondientes a un máximo de 135 partes diferentes del cuerpo humano [8]. Este modelo puede estimar los puntos clave de la cara, cuerpo y manos, dando como resultado diferentes formatos de salida como:

- Cuerpo BODY_25: contiene 25 puntos clave
- Cuerpo COCO: contiene 18 puntos clave
- Cara: contiene 70 puntos clave
- Mano: contiene 21 puntos clave

Basado en el trabajo [21], el formato más eficaz para clasificar marchas que aplica este trabajo, corresponde a Cuerpo BODY_25. La Tabla 2.2 muestra cada parte del cuerpo indexada a su ID correspondiente y la Figura 2.9 muestra un ejemplo del esqueleto resultante con sus 25 puntos clave mapeados y unidos en la imagen de entrada que fue procesada mediante OpenPose.

Tabla 2.2: Asignación de ID de puntos clave de las articulaciones en OpenPose

ID	Parte	ID	Parte	ID	Parte
0	Nariz	9	Cadera Derecha	18	Oreja Izquierda
1	Cuello	10	Rodilla Derecha	19	Pie: Dedo Grande Izquierdo
2	Hombro Derecho	11	Tobillo Derecho	20	Pie: Dedo Pequeño Izquierdo
3	Codo Derecho	12	Cadera Izquierda	21	Talón Izquierdo
4	Muñeca Derecha	13	Rodilla Izquierda	22	Pie: Dedo Grande Derecho
5	Hombro Izquierdo	14	Tobillo Izquierdo	23	Pie: Dedo Pequeño Derecho
6	Codo Izquierdo	15	Ojo Derecho	24	Talón Derecho
7	Muñeca Izquierda	16	Ojo Izquierdo		
8	Cadera Media	17	Oreja Derecha		

Tal como se indica en [26], la información de la ubicación dentro del frame actual para cada articulación o punto clave del esqueleto se representa por valores de coordenadas horizontales, verticales (x, y) y por el valor de precisión obtenido en el instante del frame actual.




Figura 2.9: Estimación de pose mediante OpenPose con formato BODY_25 [25]

2.4. Preprocesamiento de imágenes

La etapa de preprocesamiento permite utilizar diferentes técnicas aplicadas a las imágenes digitales para mejorar la calidad, y facilitar la búsqueda de información. En este trabajo, se utilizan técnicas de filtrado como la ventana de Hanning, también soluciones como la distancia euclidiana para hallar la longitud entre 2 puntos o técnicas que condensan la información dinámica de la marcha como el Gait Energy Image, que se referencian en las secciones 2.4.1, 2.4.2 y 2.4.3.

2.4.1. Ventana de Hanning

La ventana de Hanning fue nombrada por Julius von Hann, un meteorólogo austriaco. Esta ventana tiene un efecto en el dominio del tiempo y de la frecuencia. En el dominio del tiempo, disminuye la amplitud de la señal cerca de los bordes de la ventana, que ayuda a eliminar las discontinuidades [27]. La ventana de Hanning está definida como:

$$w(n) = 0.5 - \cos\left(\frac{2\pi n}{M-1}\right) \quad 0 \leq n \leq M-1 \quad (2.1)$$

Uno de los procesos digitales más comunes es el proceso de suavizado de la información para reducir el ruido de las altas frecuencias. Este ruido se puede deber al movimiento de artefactos, error de cuantización, entre otros [28]. Una forma sencilla de reducir este ruido es promediar puntos que se encuentran cerca mediante la ventana de Hanning que se muestra a continuación en la Figura 2.10.

2.4.2. Distancia euclidiana

A lo largo de la historia, el matemático llamado Euclides propone la solución para encontrar la distancia entre 2 puntos en un espacio euclideo, el cual es deducido a partir del teorema de Pitágoras [30]. En un espacio




Figura 2.10: Ventana de Hanning [29]

de 2 dimensiones, la distancia euclidiana entre 2 puntos P1 y P2, de coordenadas cartesianas (x_1, y_1) y (x_2, y_2) respectivamente es:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (2.2)$$

2.4.3. Imagen de energía de la marcha (GEI)

El GEI se calcula tomando la imagen media de las imágenes de silueta binaria que componen un ciclo de marcha completo, alineadas horizontalmente por el centroide de su tronco superior. Además de representar visualmente información relevante, como la simetría de la marcha, la amplitud del movimiento y la postura corporal, también es resistente a las imperfecciones que puedan existir en las siluetas binarias, ya que se atenúan en el cálculo medio. Puede usarse directamente en métodos de clasificación o para extraer características adicionales [31].

El resultado final del GEI es una imagen que representa la marcha [32], condensa la información dinámica de la marcha de las siluetas capturadas durante un ciclo en una sola imagen y calculada mediante la expresión :

$$GEI = \frac{1}{a + N} \sum_{t=a}^N I_t(x, y) \quad (2.3)$$

Siendo a el primer fotograma, N el número total de fotogramas por cada ciclo de la marcha e I_t las imágenes de las siluetas binarias. En la Figura 2.11 se muestra un ejemplo del cálculo de un GEI.



Figura 2.11: Siluetas binarias de la marcha condensada en GEI [32]

2.5. Algoritmos de clasificación

Los algoritmos de clasificación son útiles cuando la respuesta al problema cae dentro de un conjunto finito de resultados posibles. En este trabajo se clasifican 3 tipos de marcha humana y se utilizan las redes neuronales convolucionales y máquinas de vector soporte para su clasificación. En la Sección 2.5.1 y 2.5.2 se profundiza en estos clasificadores.

2.5.1. Redes neuronales convolucionales

Las redes neuronales convolucionales por sus siglas en inglés **CNN**, han alcanzado renombre como método moderno de reconocimiento de imágenes. La **CNN** es una red neuronal profunda estructurada en capas paralelas que utilizan filtros convolucionales para detectar características en imágenes. Las primeras capas detectan formas básicas, como bordes y curvas, mientras que en las capas posteriores las características se vuelven más abstractas, permitiendo la detección de estructuras más complejas en la imagen [31]. Una de las estructuraciones de capas mas utilizada para clasificar imágenes, es la arquitectura VGG-19 desarrollada y aplicada desde el 2014, la cual ganó el concurso **ImageNet Large Scale Visual Recognition Challenge (ILSVRC)** de ImageNet [33]. En la Sección 2.5.1.a se abordará la configuración de capas de esta arquitectura.

Estas redes neuronales se desarrollan en torno a cuatro conceptos: conexiones locales, pesos compartidos, agrupación y el uso de múltiples capas, de esta forma se reduce el tiempo de cómputo y uso de memoria. Esta reducción se debe principalmente a que, en estas redes cada elemento de la capa oculta se asigna a un área específica de la entrada, generando un número menor pero suficiente de parámetros con conciencia espacial.

En cuestión, una **CNN** reduce la información mirando las regiones individuales de los datos y recuperando características importantes utilizando filtros llamados kernels. Un ejemplo de esto se muestra en la Figura 2.12, una matriz de 5×5 representa la imagen a ser tratada como un conjunto de píxeles en dos dimensiones, esta matriz es multiplicada por un kernel cuyo uso depende del efecto que se desee dar. El filtro examina cada píxel de la imagen y multiplica este valor con el de sus 8 circundante por el valor correspondiente del filtro. Por lo tanto el píxel inicial se regula con el valor resultante final.




Figura 2.12: Filtro kernel usado en las **CNN** [34]

2.5.1.a. Modelo VGG-19

El modelo VGG19 mostrado en la Figura 2.13, fue creado por Simonyan y Zisserman en la Universidad de Oxford con arquitectura **CNN**, con 16 capas convolucionales y 3 capas totalmente conectadas [35]. La entrada del modelo es una imagen de 224×224 píxeles que pasa por varias capas de bloques convolucionales compuestos por filtros de 3×3 . El paso y relleno están a 1 pixel. La agrupación espacial después de cada bloque convolucional se realiza con agrupación máxima en una ventana de 2×2 píxeles y un paso de 2. El extremo de

la red se compone de tres capas completamente conectadas, de modo que, las dos primeras tienen 4096 canales y la tercera, realiza la clasificación junto a una capa soft-max de 1000 canales.




Figura 2.13: Modelo VGG-19 [36]

2.5.2. Máquinas de vector soporte

Las máquinas de vector soporte **SVM** originalmente estaban pensadas para resolver problemas de clasificación binaria, actualmente también se manejan para multi clasificación. Han sido utilizadas con éxito en visión artificial, categorización de texto o análisis de series temporales. Las **SVM** pertenecen a la categoría de clasificadores lineales que inducen separadores lineales o también llamados hiperplanos, si estos no son linealmente separables se hará uso de la funciones kernel [37].

Generalmente las funciones kernel lineales son un caso específico del kernel función radial base **Radial Basis Function (RBF)**, el cual es no lineal y contrario al kernel lineal, puede manejar casos en los que la relación entre clases y sus atributos no son lineales. En la Figura 2.14a se muestra la superficie de decisión para SVMs con kernel lineal y en la Figura 2.14b con el kernel **RBF** [38]. Las **SVM** radican en la minimización del denominado riesgo estructural, la idea, es seleccionar un hiperplano de separación que equidista de los ejemplos más cercanos de cada clase para conseguir un denominado margen máximo a cada lado del hiperplano. Desde un punto de vista práctico, el hiperplano separador de margen máximo ha demostrado tener una buena capacidad de generalización, evitando en gran medida el problema del sobre-entrenamiento.




Figura 2.14: Clasificador SVM [39]

2.6. Herramientas para evaluar el desempeño de algoritmos de clasificación

Las herramientas para evaluar el desempeño permiten cuantificar qué tan bueno es un clasificador, en este trabajo se utiliza la matriz de confusión y la curva ROC revisados en la Sección 2.6.1 y 2.6.2 respectivamente.

2.6.1. Matriz de confusión

Se puede definir a la matriz de confusión como una tabla de contingencia, que sirve como herramienta estadística para el análisis de observaciones emparejadas. Además, es la forma más usual y estándar de informar sobre la exactitud temática de productos derivados de la clasificación de datos procedentes de imágenes [40].

De esta manera se forma una matriz cuadrada de $M \times M$, donde M es el número de clases que se consideran y cada uno de los M^2 elementos de la matriz se denominan celdas. De esta forma, las celdas de la diagonal de la matriz de confusión tienen la cantidad correspondiente de ítems bien clasificados llamadas celdas coincidencia, mientras que las celdas que no pertenecen a la diagonal contienen las confusiones, errores u omisiones y se denominan celdas error.

Tabla 2.3: Matriz de Confusión de 2 clases

	Clase 1	Clase 2
Clase 1	TP	FN
Clase 2	FP	TN

En la Tabla 2.3, las celdas TP de Verdaderos Positivos y TN de Verdaderos Negativos corresponden a la diagonal y por tanto, son celdas coincidencia, mientras que FN y FP que son Falsos Negativos y Falsos Positivos respectivamente son celdas error.

2.6.2. Curva ROC

Una curva de característica operativa del receptor o curva ROC, es un gráfico que indica el rendimiento de un modelo de clasificación en todos los umbrales de clasificación como muestra la Figura 2.15. Se representan

dos parámetros importantes en esta curva: la tasa de verdaderos positivos y la tasa de falsos positivos. Por lo general, la curva ROC tiene una tasa positiva real en el eje Y , y una tasa de falsos positivos en el eje X , por lo que en la esquina superior izquierda de la gráfica es el punto ideal, una tasa de falsos positivos de cero y una tasa positiva verdadera de uno. Cabe destacar además que, esta curva es un conjunto de puntos en un espacio cuadrado de $[0, 1]$ [41].




Figura 2.15: Curva ROC

2.7. Estado del arte y trabajos relacionados

En una visión general el ser humano durante el desarrollo de su vida necesita desplazarse y ejecutar las diferentes actividades esenciales, complementarias y muy diversas que debe cumplir en el diario vivir para subsistir y perpetuar la especie. Por lo tanto, camina con paso bípedo característico de la raza humana que lo identifica como un sujeto que imprime y revela aspectos y parámetros individuales de la condición de salud física, psicológica y social.

En la actualidad, [42] indica que, los procesos de adquisición de datos ejecutados en un entorno de laboratorio obtienen una adecuada captura del movimiento humano para un ciclo de marcha normal. Esto permite identificar variaciones y modificaciones en los análisis de la cinemática humana y las posibles alteraciones en el funcionamiento muscular.

En este contexto, diseñar y aplicar programas computacionales en estudios de la marcha humana de un individuo previamente seleccionado, concede establecer rutinas de entrenamiento y rehabilitación que fomentan la mejora del estado de salud. También, sirven de guías para la óptima fabricación de dispositivos protésicos, otorgando una visión completa del funcionamiento de las extremidades humanas [43].

Por tanto, en concordancia con [44], en el estudio de la cinemática de los miembros inferiores de las personas, una valoración objetiva y eficaz requiere de métodos que relacionan el movimiento con los elementos de interpretación mediante la técnica de inteligencia artificial. Se busca disminuir la subjetividad utilizando

software, que valide algoritmos para segmentar y clasificar los ciclos de la marcha de las extremidades inferiores del ser humano. De esta forma determinar ciclos atípicos que no coinciden con la secuencia estándar de las fases y subfases de la marcha presentes en las diferentes patologías.

En el momento actual, el manejo de la visión artificial es fundamental para efectuar procesos no intrusivos en campos de la salud como la fisioterapia. Este enfoque propicia un aumento en las investigaciones, las aplicaciones y el uso de modelos como PoseNet y OpenPose, desarrollados para estimar la pose humana. Estos modelos pueden ser utilizados en pacientes con marcha hemiparética y paraparética, generando información con datos reales que permiten identificar el padecimiento y orientar la guía terapéutica profesional.

En cuanto al beneficio de OpenPose en el campo de la salud en [45], se comprueba que este modelo estima eficientemente varios parámetros como tiempo de paso, distancia de paso y ángulos sagitales comparado con la captura de movimientos tridimensionales. Además, observa que mediciones promedio de participantes individuales son más exactas que tomadas pasó a paso. En [46] se valida el modelo PoseNet, referente al uso en aplicaciones de la salud humana, establecen una propuesta para utilizar este modelo en procesos de estimación de pose y seguimiento corporal con una cámara web, los pacientes cumplen un programa de entrenamiento y evaluación con la capacidad de obtener retroalimentación cercana al tiempo real.

Continuando, el análisis de la biomecánica de la marcha ya viene siendo estudiado varios años, en [47] se analiza los parámetros espacio temporales, cinemática y cinética de la marcha en pacientes con alteración del equilibrio sagital, asimismo la información es recopilada y analizada mediante el uso de marcadores y un software especializado respectivamente. En el presente trabajo se plantea un enfoque no invasivo para adquirir los datos mediante el uso de cámaras celulares y modelos de estimación de pose como OpenPose y PoseNet. De este modo se podrá analizar los parámetros espacio temporales de las alteraciones de la marcha como la hemiparética, paraparética y utilizar estos parámetros para clasificar estas alteraciones.

En relación a este campo del quehacer científico, un trabajo relacionado con marchas patológicas [48] recopila videos de 5 voluntarios sanos de diferente forma corporal, simulan marchas anormales como la asimétrica a la derecha o la encorvada, consecuencia del dolor en la rodilla y en la espalda baja respectivamente. Por otro lado, en [49] se extrae videos de 10 voluntarios sanos que aplican una guía de entrenamiento previo a la simulación de 5 marchas patológicas. Análogo a estos enfoques en el presente estudio, el proceso de obtención de datos se apoya en la supervisión profesional de personal médico calificado.

Además, en los estudios acerca de este tema, [31] realiza la toma de datos con un abordaje en un plano sagital, de modo que, en cada una de las marchas la persona camina paralelamente al plano de una cámara RGB, una vez de izquierda a derecha y otra de derecha a izquierda, con un mínimo de 2 ciclos completos de la marcha capturados en cada dirección. También, [50] emplea 2 dispositivos Kinect RGB-D en un plano semi frontal para obtener la marcha hacia adelante y hacia atrás de pacientes con Parkinson. En base a esto se ha planteado incluir un plano frontal y sagital a la marcha en la recolección de datos utilizando una cámara RGB.

Al obtener videos en un plano frontal, el tamaño del esqueleto aumenta conforme el sujeto camina hacia la cámara, en [51] se propone un procedimiento para caracterizar el esqueleto independiente de la posición en la que se encuentre. También, proponen un método de filtrado para remover el ruido de la trayectoria del esqueleto mediante la transformación al dominio Discrete Cosine Transform (DCT) y reconstruirla solo con el primer 50 % de los coeficientes, que se obtiene por medio de un filtro pasabajo. En [52] se propone utilizar un filtro paso bajo Butterworth de cuarto orden sin retardo y encontrar la frecuencia de corte mediante un análisis residual. En el presente planteamiento, se sigue la dirección de normalizar el tamaño del esqueleto mientras que en el otro apartado se opta por usar el método de suavizado hanning.

Las características extraídas de la caminata de una persona juegan un papel muy importante en la clasificación



de patologías, en [53] introducen una representación invariante al ciclo de la marcha, utilizan las trayectorias de movimiento de las articulaciones de un esqueleto humano en 3D capturado por un sensor Kinect y es caracterizada mediante una matriz de covarianza. Incluso señalan que la mejor información para clasificar patologías como la hemiplejia proviene de los miembros inferiores del cuerpo. En [54] proponen un método de caracterización basado en el ángulo de inclinación del cuerpo y el ángulo que se produce entre los dedos del pie y su talón. Otro trabajo que presenta un método para representar la marcha es [31], emplea el GEI extraído de un ciclo de la marcha con la silueta corporal. En base a lo expuesto se ha planteado utilizar una variante del GEI obtenida del esqueleto de la persona y producida por los modelos de OpenPose y PoseNet en lugar de su silueta corporal y utilizar parámetros espacio temporales como otro método de caracterización de la marcha.

Trabajos como el de [31] o [53] utilizan redes neuronales convolucionales y máquinas de vector soporte respectivamente para la clasificación de marchas diplegicas, neuropática o parkinsoniana, alcanzando excelentes resultados del 89.6 % y 91.1 %. Análogo a estos enfoques en este trabajo se utilizan los mismos algoritmos clasificadores, con ligeros cambios en su arquitectura.

De forma similar a lo expuesto en el presente trabajo, el proceso de obtención de datos será apoyado bajo la supervisión profesional de personal médico calificado. También, se utilizará un plano sagital para grabar los vídeos incluyendo un plano frontal para aprovechar la mayor información proveniente de la marcha. Otro de los aspectos importantes es utilizar métodos de normalización de tamaño y filtrado de errores, lo que permitirá mejorar la eficiencia del sistema implementado. En cuanto a las diferencias con otros trabajos, se propone una etapa de corte y sincronización para reducir el tiempo de procesamiento, una etapa de extracción de pose con los modelos PoseNet y OpenPose para evitar usar dispositivos invasivos para el cuerpo y difíciles de conseguir. De igual manera, utilizar una variante del GEI, utilizando una silueta esqueletica como nuestro enfoque de caracterización de la marcha para brindar una mejor descripción del movimiento. Esta metodología permitirá analizar, evaluar y clasificar marchas patológicas como la hemiparética y paraparética en contraste con la marcha de una persona sana.



Metodología

Este capítulo presenta la metodología aplicada para obtener los parámetros espacio-temporales, caracterización y clasificación de la marcha. La Sección 3.1 presenta los equipos y hardware necesario para implementar el sistema de análisis de la marcha, en la Sección 3.2 se describe el proceso para la instalación y configuración de los modelos de estimación de pose OpenPose y PoseNet, utilizados para estimar las coordenadas de las diferentes partes del cuerpo de personas que realizan la marcha normal, hemiparética, paraparética y adquiridas en un ambiente controlado el cual es descrito en la Sección 3.3. La Sección 3.4 se enfoca en simplificar, mejorar y normalizar los datos obtenidos a partir de las marchas realizadas, así como el proceso para computar los parámetros espacio-temporales del movimiento de las extremidades inferiores de la marcha. La Sección 3.5 propone diferentes métodos para la extracción de características de la marcha y su clasificación.

3.1. Descripción de equipos

En este punto, se describen los equipos utilizados durante la adquisición de datos, el pre-procesamiento de imágenes y el entrenamiento. Primero, se da una breve descripción de las cámaras y accesorios en la Sección 3.1.1, y luego, en la Sección 3.1.2, se aborda las computadoras que procesan los datos en etapas de pre-procesamiento y entrenamiento para las pruebas de clasificación.

3.1.1. Cámaras y accesorios

Se utilizan 2 cámaras posteriores de celular con resolución HD 720p a 30 fotogramas por segundo con apertura f/1.8 pertenecientes a las marcas Huawei [55] y Xiaomi [56], además de 2 trípode para dar estabilidad en la grabación de video, cuenta con un soporte para celular incluyendo un brazo móvil para regular la altura con 1.7 metros de margen.

3.1.2. Requerimientos de hardware

Los requisitos de hardware que deben cumplir las computadoras van ligadas a la capacidad de cómputo necesarias para el buen funcionamiento de PoseNet [9] y OpenPose [8]. Para procesar los datos usando PoseNet se utiliza una computadora portátil con CPU IntelCore i7 de 5ta generación, 8 GB de RAM y una tarjeta gráfica

Nvidia GeForce 760 de 2GB. Adicionalmente se utiliza computación en la nube que permite reducir el tiempo de ejecución en la etapa de pre-procesamiento de imágenes y entrenamiento. Google Colab [57] brinda estas características, se obtiene procesamiento mediante GPU de Google Compute Engine [58] que proporciona una capacidad acorde a la requerida y para OpenPose es la mejor opción. Si se cumple con estos requisitos mínimos, la configuración y el sistema tienen un rendimiento equilibrado [59].

3.2. Instalación y configuración de software

El modelo PoseNet fue desarrollado en javascript para aplicaciones web, por lo que es necesario realizar la transformación para acoplarse al lenguaje de programación Python que es más robusto, de alto nivel y es la mejor opción para cumplir los objetivos de este estudio [60]. De igual manera, el modelo OpenPose desarrollado en lenguaje C++, se instala y configura como una API de Python por su facilidad de uso y para mantener una equivalencia en la programación de ambos modelos. En el Apéndice B, se detalla la instalación y configuración de los 2 modelos.

3.3. Descripción del ambiente y procedimiento de toma de datos

En esta investigación se realiza la generación de modelos biomecánicos y clasificación de 3 tipos de marcha: normal, hemiparética y paraparética. Estas marchas se obtienen en un ambiente controlado con suficiente luz artificial, sin ningún tipo de obstáculo que pueda causar alteraciones en las mismas. El lugar que se asigna para la toma de video es de 7.15 metros de largo y 4.5 metros de ancho, se ubican 2 cámaras con trípode de forma lateral y frontal a la marcha del sujeto de prueba a una altura de 1.27 metros como se muestra en la Figura 3.1. Con estas indicaciones se garantiza que los 2 planos obtenidos sagital y frontal pueden captar todo el cuerpo de la persona y su movimiento al realizar la marcha.




Figura 3.1: Toma de datos en ambiente

Un total de 15 personas (9 hombres y 6 mujeres) en el rango de 20-50 años de edad son voluntarios que firman un Consentimiento Informado (Apéndice A) que, permite el uso de estos videos para propósitos de investigación. Cada uno simula 4 secuencias de marcha por cada patología incluyendo la marcha normal, que recopila 48 videos por persona y un total de 720 videos. En cada una de las secuencias las personas caminan de forma paralela y frontal a las cámaras empezando con el pie derecho, con un mínimo de 2 ciclos completos (5 pasos) obteniendo los videos en formato MP4, codificación por defecto H.264 y una resolución de 720p.

3.4. Pre-procesamiento de imágenes

A continuación de la adquisición de video, las imágenes tienen que pasar por una etapa de procesamiento para simplificar la representación de los datos, mientras se mantiene la información relevante que se va a usar en las etapas de generación de la biomecánica y extracción de las características para la clasificación, y crear nuevas formas de imágenes que se van a usar como entrada en las etapas antes mencionadas. En este trabajo, se utiliza una variación del GEI [32], que está basada en las siluetas binarias de una pose y su cambio resulta en obtener una imagen con las mismas características en forma de esqueleto adquirida por los modelos PoseNet y OpenPose llamada SGEI. El proceso para obtener estas imágenes se muestra en el diagrama de la Figura 3.2




Figura 3.2: Diagrama implementado para el pre-procesamiento

3.4.1. Corte y sincronización

En el proceso de corte, se recortan los videos de la base de datos momentos antes que la marcha sea iniciada, de igual manera momentos posteriores a la misma, es decir, cuando el sujeto de prueba ha cumplido con los 3.7 metros de marcha designados. Este paso permite reducir considerablemente el tiempo de procesamiento en la etapa de extracción de pose, porque los modelos PoseNet y OpenPose desechan las imágenes innecesarias para el análisis de este trabajo.

En el proceso de sincronización, se iguala en tiempo los videos adquiridos de forma lateral y frontal a la marcha del sujeto, esto permite al igual que en el proceso de corte, reducir el tiempo de procesamiento e identificar el comienzo y final de los ciclos de la marcha de los videos con vista frontal. Los ciclos de la marcha pueden ser identificados solamente en los videos con vista sagital mediante un proceso presentado en la Sección 3.4.5, al realizar la sincronización, los videos con vista frontal también pueden ser evaluados correctamente.

3.4.2. Extracción de pose

Para la generación de la biomecánica de la marcha y deducción del SGEI, se necesita calcular la información de los puntos clave del cuerpo humano de los vídeos adquiridos en la etapa de toma de datos. Esto se realiza utilizando los modelos PoseNet y OpenPose. Estos modelos pueden tomar videos de personas caminando como entrada y devolver un conjunto de coordenadas 2D por cada fotograma, correspondientes a las diferentes partes del cuerpo humano. Los 2 modelos son capaces de detectar las poses de múltiples personas de forma simultánea, no obstante, este trabajo requiere la detección de 1 persona por video, esto evita posibles errores de los modelos ante confusiones de 2 o más poses en un mismo video. Una vez obtenido el conjunto de coordenadas de cada fotograma por video, se utiliza la librería OpenCV [59] para dibujar y unir los puntos mediante líneas conectando las coordenadas de cada punto clave del cuerpo. En la Figura 3.3 y 3.4, se indica la salida de los modelos PoseNet y OpenPose después de dar como entrada una imagen con vista sagital y frontal.




Figura 3.3: Ejemplo de estimación de pose vista sagital




Figura 3.4: Ejemplo de estimación de pose vista frontal

3.4.3. Suavizado

La salida de los modelos PoseNet y OpenPose presentan ciertas variaciones de coordenadas en la salida de los modelos, generalmente son errores mínimos que se obtienen y que pueden ser suprimidos mediante el uso de funciones de interpolación y con una ventana de Hanning [29], referida en la Sección 2.4.1. Esta ventana recorre el conjunto de coordenadas de los puntos clave del cuerpo y las suaviza, permitiendo que el error de medición de una pose se minimice considerablemente. En la Figura 3.5, se muestra los ángulos de la rodilla derecha medidos a una persona que camina por 6 segundos, antes y después de usar Hanning.





Figura 3.5: Suavizado de coordenadas y extracción de ángulo de rodilla antes y después de usar Hanning

3.4.4. Normalizar la posición del esqueleto en el plano frontal y sagital


En el plano frontal, el tamaño del esqueleto aumenta conforme el sujeto camina hacia la cámara causando que las medidas de longitud sean muy variables, en [51] se propone un procedimiento para caracterizar el esqueleto independiente de la posición en la que se encuentre. Este mismo concepto se utiliza en este trabajo, los datos tomados en la Sección 3.3 incluyen planos frontales donde el sujeto se acerca y se aleja de la cámara. Utilizar dicho procedimiento normaliza la posición del esqueleto y da la impresión que está caminando en su propio terreno, lo cual también es aplicado al plano sagital convenientemente para el cálculo del SGEI. En la Figura 3.6a, se visualiza el esqueleto con plano frontal de algunos frames de la marcha usando el modelo OpenPose sin normalización y en 3.6b, está normalizado. Asimismo, en la Figura 3.7a, se muestra el esqueleto con plano sagital de ciertos frames sin normalizar y en 3.7b, está normalizado. El mismo procedimiento es aplicado para PoseNet.



(a) Sin normalizar

(b) Normalizada

Figura 3.6: Normalización vista frontal



(a) Sin normalizar

(b) Normalizada

Figura 3.7: Normalización vista sagital

3.4.5. Identificación de los ciclos de la marcha

Antes de realizar el cálculo del **SGEI** y obtener los parámetros de la marcha para generar la biomecánica, es necesario identificar cada ciclo completo de la marcha, de esta manera se elimina los datos innecesarios y se utiliza solamente los ciclos completos que contiene cada video. El cálculo matemático que se utiliza para identificar los ciclos de la marcha es la distancia euclidiana [30] presentada en la Sección 2.4.2. La Figura 3.8 muestra esta distancia entre el tobillo izquierdo y derecho de dos ciclos de la marcha de una persona sana. Los picos de esta señal corresponden al momento en el que los 2 tobillos están más alejados uno de otro, tras cada paso, y un ciclo completo de la marcha corresponde a cada 2 ocurrencias de estos picos.

3.4.6. Cálculo de las imágenes de energía de marcha esquelética

Luego de normalizar la posición de los esqueletos y obtener una imagen por cada fotograma del video correspondiente a un ciclo de la marcha, las imágenes son recortadas mediante un cuadro delimitador tomando como centro el punto medio de la cadera. La altura y ancho es redimensionado a 224x224 píxeles como se muestra en la Figura 3.9. Finalmente, el **SGEI** es calculado mediante el proceso y la expresión presentada en la Sección 2.4.3, con la diferencia que se aplica las siluetas del esqueleto de los modelos PoseNet y OpenPose en lugar de las siluetas de todo el cuerpo. Un ejemplo de una imagen que contiene un ciclo completo de la marcha de izquierda a derecha usando el modelo OpenPose y su correspondiente **SGEI** se muestra en la Figura 3.10. El **SGEI**, permite tener una representación compacta del movimiento a lo largo de un ciclo de marcha centrada más en el aspecto de movimiento de las secuencias, lo que admite una mejor descripción de los diferentes tipos de marcha anormal, y este mismo procedimiento es aplicado para PoseNet.




Figura 3.8: Distancia entre el tobillo izquierdo y derecho de dos ciclos de la marcha





Figura 3.9: Fotogramas correspondientes a 1 ciclo de la marcha OpenPose



(a) Vista Frontal

(b) Vista Sagital

Figura 3.10: SGEI OpenPose

3.4.7. Cálculos biomecánicos de la marcha

Existen varios métodos de estudio de la marcha, este trabajo se centra en la cinemática, que describe los movimientos producidos por el cuerpo humano. Ciertos parámetros espacio-temporales son de principal interés y se usan como base para generar la biomecánica de la marcha normal, hemiparética y paraparética. Se calculan parámetros usados en el ámbito clínico como: longitud de paso, cadencia, amplitud de paso, tiempo de paso, ángulos formados por los miembros del cuerpo humano, velocidad de marcha e inclinación de la postura corporal frontal. Para este análisis de la marcha se usa la goniometría digital, que mide la posición angular en cualquier instante de tiempo y el análisis en 2D, que permite digitalizar el cuerpo humano como un sistema de segmentos unido por puntos. Algunas características relevantes de la marcha se transforman en características computables.

3.4.7.a. Goniometría digital

Mediante las coordenadas de los puntos clave obtenidos como salida de los modelos vistos en la Sección 2.3, se calcula los ángulos de las articulaciones de los miembros inferiores por cada fotograma de cada ciclo de la marcha. En la Figura 3.11 se visualizan estos ángulos calculados tanto en el plano sagital como en el frontal junto a su etiqueta correspondiente.




Figura 3.11: Ángulos calculados

En la Tabla 3.1 se presentan los ángulos calculados para OpenPose y PoseNet incluyendo los puntos claves involucrados en cada modelo. Las proyecciones son puntos construidos en base a coordenadas de otros puntos clave que facilitan la medición de ángulos que no son posibles de cuantificar con los datos predeterminados.

Tabla 3.1: Ángulos calculados

Id de etiqueta	Nombre de ángulo	Puntos clave OpenPose	Puntos clave PoseNet
a	Tobillo Derecho	10-11-Proyección	14-16-Proyección
b	Rodilla Derecha	9-10-11	12-14-16
c	Cadera Derecha	2-9-10	6-12-14
d	Sagital	8-10-13	Proyección-13-14
e	Rodilla Izquierda	12-13-14	11-13-15
f	Tobillo Izquierdo	13-14-Proyección	13-15-Proyección
g	Cadera Izquierda	5-12-13	5-11-13
h	Inclinación hacia la Izquierda	1-8-Proyección	3 Proyecciones
i	Inclinación hacia la Derecha	1-8- Proyección	3 Proyecciones
j	Codo Izquierdo	5-6-7	5-7-9
k	Codo Derecho	2-3-4	6-8-10
l	Cadera Frontal Izquierda	8-12-13	Proyección-11-13
m	Cadera Frontal Derecha	8-9-10	Proyección-12-14

3.4.7.b. Análisis en 2D

Los parámetros de la marcha humana como la longitud de paso, cadencia, amplitud de paso, tiempo de paso y velocidad son calculados usando como punto de partida la distancia euclidiana vista en la Sección 3.4.5 y se normaliza para obtener una distancia real e identificar los ciclos de la marcha. A continuación se indica el proceso de cálculo de los parámetros antes mencionados:

- **Longitud de paso:** Se calcula usando cada ocurrencia de pico porque representa la distancia más alejada del pie izquierdo respecto al derecho.
- **Longitud de zancada:** Se calcula usando el doble de la longitud de paso.
- **Amplitud de paso:** Se aplica el mismo proceso para calcular la longitud de paso pero usando la vista frontal.
- **Tiempo de paso:** Se calcula restando el número de cuadro en el cual existe una ocurrencia de pico con su contiguo inmediato, siendo que los videos fueron tomados a 30 cuadros por segundo se divide para esta cantidad.
- **Velocidad de marcha:** Se calcula usando la distancia total caminada entre el primer y último pico dividida para el tiempo que se tarda en completar dicha distancia.
- **Cadencia:** Se calcula usando el número total de picos ocurrentes porque cada uno representa un paso, dividido para el tiempo en minutos en el que fue desarrollado dichos pasos.

Los parámetros de longitud de paso y zancada, Figura 3.12, son calculados tanto para el pie izquierdo como para el derecho, debido a que en las marchas hemiparética y paraparética la distancia recorrida por cada uno de los pies suelen diferir.




Figura 3.12: Longitudes de paso y zancada

3.5. Extracción de características y clasificación

3.5.1. Redes neuronales convolucionales

Luego de efectuar el pre-procesamiento de imágenes y obtener la salida deseada, el siguiente paso es la extracción de características realizada por una CNN [31] en orden para obtener un vector de características para cada una de las imágenes de entrada. El modelo escogido para la tarea de extracción de características y clasificación es la VGG-19 [35] vista en la Sección 2.5.1, implementada en Python empleando una librería

de Tensorflow llamada Keras [61]. VGG-19 se escoge por su rapidez de convergencia y su simplicidad para entrenar e implementar. Por lo que, generalmente es la mejor solución para la extracción de características [19]. Tiene como entrada imágenes [SGEI](#) en planos sagitales y frontales, posteriormente pasan por varios bloques de capas convolucionales compuestas por filtros pequeños. Originalmente esta arquitectura en su último bloque de capas permiten 1000 canales para clasificar, no obstante se modifica a 3 canales correspondientes a las 3 clases de marchas: normal, hemiparética y paraparética. La arquitectura VGG-19 utilizada se presenta en la Figura 3.13



Figura 3.13: Arquitectura de la variación del modelo VGG-19

Debido a que la base de datos disponible es reducida, es impráctico entrenar nuevamente toda la red, en vista de posibles problemas con el sobreajuste. En consecuencia, se hace uso de la transferencia de aprendizaje [62], empleando una versión de VGG-19 anteriormente entrenada con la base de datos de Imagenet [33], análogo al trabajo en [31]. Las primeras capas de la arquitectura mantienen sus pesos porque son las encargadas de detectar las formas comunes básicas en las imágenes, mientras que las capas posteriores se adecuan con precisión empleando la base de datos obtenida en la Sección 3.3, con el fin de que aprendan propiedades que son más propias a los objetivos de este trabajo.

3.5.2. Características biomecánicas y máquinas de vector soporte

Otro método para clasificar, proviene de usar los parámetros de la marcha calculados en la Sección 3.4.7, los cuales son una base para extraer las características que alimentan al algoritmo de aprendizaje supervisado [SVM](#) visto en la Sección 2.5.2. Un total de 28 variables conforman el vector de características incluyendo los 6 parámetros de la marcha de la Sección 3.4.7-Análisis en 2D, más 2 variables debido a que la longitud de paso y zancada es separada en pie izquierdo y derecho conformando un total de 8 variables. El análisis goniométrico digital aporta con 20 variables, las Ids de etiqueta de ángulos desde la **a** hasta la **g** incorporan tanto el ángulo máximo como el mínimo que se producen en la marcha, mientras que desde la **h** hasta la **m** solamente se utiliza el ángulo máximo. Cabe recalcar que la mayoría de las variables son promediadas por cada ciclo que realiza el sujeto, en vista de que, en la marcha se efectúa más de un ciclo completo. Finalmente, este conjunto de datos es la entrada del algoritmo [SVM](#) utilizado con el kernel [RBF](#) análogo al empleado en [53], que ofrece resultados prometedores.



Resultados

Para esta sección se analiza y procesa la información de las 15 personas voluntarias que participaron en este estudio que están referenciados en la Sección 3.3. En este capítulo se presentan los resultados obtenidos de la generación de la biomecánica de la marcha utilizando parámetros espacio-temporales y estimados mediante los modelos de OpenPose y PoseNet, así como los resultados finales con los diferentes métodos de clasificación propuestos.

El 7-8 % del total de información procesada, se descarta, en razón de que, los modelos presentan variaciones en las estimaciones de pose cuando una persona esta vestida con prendas de color negro y una diferencia del 3 % de información adicional entre el modelo PoseNet respecto a OpenPose.

4.1. Análisis de la biomecánica de la marcha

A continuación se presenta los resultados concernientes a la generación de la biomecánica del movimiento de extremidades inferiores, en la Sección 4.1.1 se muestra los valores de los parámetros espacio-temporales generados y en la Sección 4.1.2 se visualiza los patrones de los ángulos del tren inferior del cuerpo humano.

4.1.1. Parámetros espacio temporales y goniometría digital

En las Tablas 4.1 y 4.2 se muestra el promedio de los parámetros espacio-temporales y su desviación estándar obtenidos a partir del modelo OpenPose y PoseNet respectivamente, extraídos de las imágenes capturadas y procesadas de 15 voluntarios que ejecutan la marcha hemiparética, normal, paraparética y el análisis de la movilidad del miembro inferior derecho (D) e izquierdo (I).

Existe similitud entre los resultados de los parámetros obtenidos de la marcha normal en concordancia con los trabajos realizados por [10, 16, 17, 63–65] dando validez a los datos obtenidos por este sistema. Los valores de Longitud de paso D (0.52 m) e I (0.53 m) así como la Inclinação del cuerpo D (2.88 grad) e I (3.84 grad) para ambas piernas son semejantes, lo cual indica que el cuerpo se mantiene estable y los pasos dados son coherentes entre si. En cuanto a los valores de velocidad de caminata (1.14 m/s) y cadencia (98.17 pasos/min) muestran que la marcha normal es más rápida respecto a las otras dos, implicando un recorrido con menos pasos en una misma distancia. Además los ángulos mínimos de la cadera D (158.77 grad) e I (160.65 grad), rodilla D (124.17 grad) e

I (127.22 grad) y tobillo D (43.61 grad) e I (43.52 grad), demuestran que existe una flexión mayor en la fase inicial de oscilación respecto a las otras dos marchas. Se debe tomar en cuenta que la altura de los participantes influye en los resultados.

Como se vió en la Sección 2.2. La marcha hemiparética se caracteriza por ser asimétrica tanto espacial como temporalmente, así lo demuestra el parámetro de inclinación hacia la derecha y hacia la izquierda con valores de 5.37 y 10.67 grados, respectivamente. El parámetro de Longitud de paso D (0.32 m) e I (0.24) indica que la pierna derecha da un paso mas grande que la pierna izquierda.

Tabla 4.1: Parámetros espacio-temporales OpenPose

Parámetros	Hemiparética	Normal	Paraparética
Longitud de paso D (m)	0.34 $\pm$ 0,05	0.52 $\pm$ 0,06	0.32 $\pm$ 0,08
Longitud de paso I (m)	0.24 $\pm$ 0,07	0.53 $\pm$ 0,07	0.29 $\pm$ 0,08
Longitud de zancada D (m)	0.58 $\pm$ 0,10	1.04 $\pm$ 0,13	0.60 $\pm$ 0,14
Longitud de zancada I (m)	0.58 $\pm$ 0,10	1.06 $\pm$ 0,12	0.60 $\pm$ 0,14
Amplitud de paso (m)	0.25 $\pm$ 0,05	0.15 $\pm$ 0,08	0.32 $\pm$ 0,08
Tiempo de paso (s)	0.79 $\pm$ 0,12	0.61 $\pm$ 0,04	1.01 $\pm$ 0,30
Velocidad de caminata (m/s)	0.44 $\pm$ 0,14	1.14 $\pm$ 0,16	0.36 $\pm$ 0,10
Cadencia (pasos/min)	77.73 $\pm$ 11,27	98.17 $\pm$ 6,67	64.22 $\pm$ 17,01
Sagital D (grad)	25.68 $\pm$ 6,73	39.42 $\pm$ 9,41	27.69 $\pm$ 7,70
Sagital I (grad)	25.74 $\pm$ 8,85	38.36 $\pm$ 9,80	24.17 $\pm$ 8,38
Inclinación hacia la D (grad)	5.37 $\pm$ 3,91	2.88 $\pm$ 1,43	9.83 $\pm$ 4,18
Inclinación hacia la I (grad)	10.67 $\pm$ 3,99	3.84 $\pm$ 2,05	10.92 $\pm$ 4,41
Max Cadera Frontal D (grad)	96.43 $\pm$ 3,00	90.68 $\pm$ 2,21	99.64 $\pm$ 3,63
Max Cadera Frontal I (grad)	97.61 $\pm$ 3,18	91.75 $\pm$ 2,68	99.95 $\pm$ 3,75
Max Rodilla D (grad)	182.59 $\pm$ 3,26	181.14 $\pm$ 12,43	182.36 $\pm$ 3,81
Min Rodilla D (grad)	169.46 $\pm$ 7,08	124.17 $\pm$ 14,44	164.17 $\pm$ 6,12
Max Cadera D (grad)	186.09 $\pm$ 6,33	191.37 $\pm$ 5,65	187.66 $\pm$ 7,57
Min Cadera D (grad)	167.10 $\pm$ 8,92	158.77 $\pm$ 3,93	164.44 $\pm$ 8,09
Max Tobillo D (grad)	102.51 $\pm$ 4,65	109.61 $\pm$ 6,99	98.39 $\pm$ 5,72
Min Tobillo D (grad)	74.54 $\pm$ 7,12	43.61 $\pm$ 7,79	65.67 $\pm$ 5,12
Max Rodilla I (grad)	178.80 $\pm$ 9,04	180.83 $\pm$ 12,34	181.51 $\pm$ 6,12
Min Rodilla I (grad)	139.58 $\pm$ 12,90	127.22 $\pm$ 14,36	158.21 $\pm$ 9,25
Max Cadera I (grad)	188.39 $\pm$ 7,23	192.72 $\pm$ 5,09	188.83 $\pm$ 6,43
Min Cadera I (grad)	161.35 $\pm$ 7,62	160.65 $\pm$ 3,63	165.48 $\pm$ 7,14
Max Tobillo I (grad)	94.26 $\pm$ 7,80	109.65 $\pm$ 6,98	96.79 $\pm$ 6,38
Min Tobillo I (grad)	55.27 $\pm$ 7,14	43.52 $\pm$ 8,04	61.35 $\pm$ 5,44

Continuando, en la Tabla 4.1, los ángulos formados respecto a la vertical D (5.54 grad) e I (11.13 grad) indican que el cuerpo está más inclinado hacia la izquierda, de igual manera la mínima flexión producida por la rodilla D (166.63 grad) e I (140.02 grad) señalan una asimetría debido a que la pierna derecha dibuja un semicírculo provocando la inclinación excesiva a un solo lado, denotando que la afección se encuentra en la parte derecha del cuerpo.

En cuanto a la marcha paraparética, resulta ser rígida e insegura y así lo demuestran los resultados de parámetros muy característicos de esta patología, como la velocidad de caminata (0.36 m/s), tiempo de paso (1.01 s) o cadencia (64.22 pasos/min) que son más bajos comparado con la marcha normal o la hemiparética, de igual manera la mínima flexión de las rodillas D (164.17 grad) e I (158.21 grad) es notoria. La inclinación respecto a la vertical D (9.83 grad) e I (10.92 grad) revelan que la alteración en la caminata y la afección se manifiesta en ambas piernas.

Los parámetros espacio-temporales obtenidos mediante el modelos PoseNet se muestran en la Tabla 4.2, comparando los valores con la Tabla 4.1 se puede sostener que el promedio de los 26 parámetros difieren en **2.98 %** respecto a lo calculado con el modelo OpenPose, lo cual indica una mínima divergencia entre los resultados de las dos tablas.

Tabla 4.2: Parámetros espacio-temporales PoseNet

Parámetros	Hemiparética	Normal	Paraparética
Longitud de paso D (m)	0.32 $\pm$ 0,05	0.50 $\pm$ 0,06	0.31 $\pm$ 0,08
Longitud de paso I (m)	0.24 $\pm$ 0,07	0.49 $\pm$ 0,06	0.28 $\pm$ 0,08
Longitud de zancada D (m)	0.56 $\pm$ 0,09	0.99 $\pm$ 0,10	0.57 $\pm$ 0,13
Longitud de zancada I (m)	0.56 $\pm$ 0,09	1.00 $\pm$ 0,10	0.58 $\pm$ 0,13
Amplitud de paso (m)	0.27 $\pm$ 0,05	0.16 $\pm$ 0,03	0.36 $\pm$ 0,08
Tiempo de paso (s)	0.78 $\pm$ 0,12	0.62 $\pm$ 0,05	1.01 $\pm$ 0,30
Velocidad de caminata (m/s)	0.43 $\pm$ 0,14	1.15 $\pm$ 0,17	0.36 $\pm$ 0,10
Cadencia (pasos/min)	78.58 $\pm$ 12,28	97.88 $\pm$ 7,02	64.77 $\pm$ 18,24
Sagital D (grad)	24.65 $\pm$ 6,05	40.05 $\pm$ 7,18	25.38 $\pm$ 7,82
Sagital I (grad)	25.95 $\pm$ 8,88	37.98 $\pm$ 7,21	23.64 $\pm$ 8,67
Inclinación hacia la D (grad)	5.54 $\pm$ 4,16	3.50 $\pm$ 1,98	9.84 $\pm$ 4,06
Inclinación hacia la I (grad)	11.13 $\pm$ 4,38	4.36 $\pm$ 1,56	11.17 $\pm$ 4,67
Max Cadera Frontal D (grad)	104.073 $\pm$ 5,00	96.73 $\pm$ 7,71	107.37 $\pm$ 6,44
Max Cadera Frontal I (grad)	108.60 $\pm$ 7,03	97.07 $\pm$ 11,15	105.90 $\pm$ 5,87
Max Rodilla D (grad)	180.99 $\pm$ 3,47	177.37 $\pm$ 3,79	181.76 $\pm$ 4,08
Min Rodilla D (grad)	166.63 $\pm$ 7,18	124.59 $\pm$ 6,63	162.18 $\pm$ 6,51
Max Cadera D (grad)	185.13 $\pm$ 6,04	191.65 $\pm$ 5,62	187.59 $\pm$ 6,44
Min Cadera D (grad)	164.90 $\pm$ 8,50	157.52 $\pm$ 3,37	164.02 $\pm$ 7,25
Max Tobillo D(grad)	101.98 $\pm$ 5,69	107.31 $\pm$ 4,47	98.02 $\pm$ 5,66
Min Tobillo D (grad)	72.60 $\pm$ 6,82	44.56 $\pm$ 4,81	64.25 $\pm$ 5,49
Max Rodilla I (grad)	177.29 $\pm$ 4,40	176.78 $\pm$ 3,50	180.76 $\pm$ 5,66
Min Rodilla I (grad)	140.02 $\pm$ 9,81	126.10 $\pm$ 7,15	156.75 $\pm$ 8,16
Max Cadera I (grad)	190.28 $\pm$ 5,98	195.00 $\pm$ 5,59	190.18 $\pm$ 6,01
Min Cadera I (grad)	160.97 $\pm$ 7,54	159.87 $\pm$ 4,77	165.15 $\pm$ 7,17
Max Tobillo I (grad)	92.62 $\pm$ 5,67	109.29 $\pm$ 5,70	95.63 $\pm$ 6,40
Min Tobillo I (grad)	55.54 $\pm$ 5,16	43.10 $\pm$ 4,88	60.08 $\pm$ 5,60



4.1.2. Generación de ángulos del tren inferior del cuerpo humano

A continuación se indican las gráficas Ángulo vs % Ciclo de la marcha obtenidos a partir de la flexión realizada en vista sagital por la cadera, rodilla y el tobillo derecho pertenecientes al tren inferior del cuerpo humano para los modelos OpenPose y PoseNet.

4.1.2.a. OpenPose

En la Figura 4.1 correspondiente a la flexión realizada por la cadera derecha se muestra los patrones generados de las 3 marchas, la región de color verde representa las variaciones de ángulos producidas por los 15 voluntarios y la curva de color azul su promedio. Las Figuras 4.2 y 4.3 mantienen el mismo esquema pero con colores diferentes, rojo oscuro para rodilla derecha y celeste para tobillo derecho. Se evalúan únicamente las posiciones angulares del plano sagital derecho debido a que el izquierdo es un espejo invertido del derecho.

Las diferencias entre el patrón de marcha normal respecto a los patológicos es notorio, tanto la fase de apoyo (60 % del ciclo) como la de oscilación (40 % restante) se ven alterados. En la Figura 4.1 se puede visualizar que en el 50 % del ciclo de la marcha normal se produce un pico mas definido con un valor máximo de 200 grados mientras que, en la hemiparética el patrón esta mas llano, en cambio en la paraparetica el pico se traslada al 65 % del ciclo y sus margenes empiezan desde los 150 grados.




Figura 4.1: Flexión Cadera OpenPose

En la Figura 4.2 se distingue un patrón bien definido en los ángulos articulares de la rodilla perteneciente a la marcha normal, el 15 % del ciclo corresponde a la fase de amortiguación es decir, el peso del cuerpo esta apoyada en la pierna derecha provocando una ligera flexión, mientras que desde el 60 % hasta el 90 % del ciclo comienza la etapa de oscilación donde la pierna esta en el aire y la rodilla realiza su flexión máxima. El ultimo 10 % es concerniente a la fase final de oscilación con la pierna regresando a su estado inicial de apoyo.

Tanto en la marcha hemiparética como en la paraparética acorde con la Sección 2.2, los resultados obtenidos muestran patrones con tendencia a ser planos excepto en el 65 % del ciclo de la marcha, donde la flexión de la rodilla es leve.




Figura 4.2: Flexión Rodilla OpenPose

En la Figura 4.3 se presenta el patrón generado por el ángulo del tobillo respecto a la horizontal, se puede mencionar que 40 grados es el pico del ángulo flexionado entre el 60 % y el 80 % para la marcha normal formando un patrón en forma de V, mientras que las otras dos marchas muestran una flexión aplanada con un pico de aproximadamente en los 60 grados y solo diferenciadas por una pequeña alteración en el 90 % del ciclo de la marcha hemiparética.






Figura 4.3: Flexión Tobillo OpenPose

4.1.2.b. PoseNet


En las Figuras 4.4, 4.5 y 4.6 se muestran las flexiones de cadera, rodilla y tobillo utilizando el modelo PoseNet. Los patrones de este modelo son muy semejantes a los obtenidos con el modelos OpenPose, por lo que análisis de las gráficas se omiten.



(a) Normal




(b) Hemiparética




(c) Paraparética


Figura 4.4: Flexión Cadera PoseNet



(a) Normal



(b) Hemiparética



(c) Paraparética

Figura 4.5: Flexión Rodilla PoseNet




Figura 4.6: Flexión Tobillo PoseNet

4.2. Precisión de los clasificadores

En la Sección 4.2.1 y 4.2.2 se muestran los resultados de clasificación para CNN y SVM respectivamente con los modelos OpenPose y PoseNet, utilizando herramientas para evaluar la precisión de los clasificadores como son la matriz de confusión y la curva ROC utilizadas con las 3 marchas identificadas numéricamente como hemiparética (id=1), normal (id=2) y paraparética (id=3).

4.2.1. Ajustes de parámetros CNN y precisión

Como se mencionó en la Sección 3.5.1 la arquitectura CNN escogida para caracterizar y clasificar las marchas es la VGG-19, los pesos de la arquitectura son reutilizados y solo la última capa totalmente conectada es entrenada. Durante el ajuste de los parámetros se seleccionó un *batch size* máximo de 32 permitiendo que el modelo converja más rápido puesto que, más imágenes serían usadas en cada época de entrenamiento. El número de épocas fue establecido en 10 y se utiliza la función de pérdidas *categorical cross entropy*, que es fijada por defecto para clasificaciones multiclase, además, se emplea el optimizador descenso de gradiente estocástico (SGD, en inglés Stochastic Gradient Descent) otorgando iteraciones más rápidas, finalmente la tasa

de aprendizaje de SGD se fija en 0.0002. Los mejores resultados se dan utilizando los ajustes anteriores, tanto para OpenPose como para PoseNet.

4.2.1.a. OpenPose

Un total de 2794 imágenes SGEI fueron obtenidas utilizando OpenPose, 1138 de la marcha hemiparética, 546 de la normal y 1110 de la paraparética. El 70 % de cada marcha se utiliza para entrenamiento, 15 % para validación y el 15 % restante para pruebas. En la Figura 4.7 se muestra la evolución de las curvas de entrenamiento para precisión y pérdidas, en la curva de precisión se alcanza rápidamente una convergencia cercana al 100 % lo que indica que el número de épocas utilizada es suficiente; en cuanto a la Figura 4.7a, la curva de pérdidas se acerca al 0 constatando el uso de un bajo número de épocas para evitar sobre entrenamiento.




Figura 4.7: Curvas de entrenamiento OpenPose

Un conjunto de 421 imágenes SGEI pertenecientes al 15 % de las 3 marchas fueron evaluadas mediante una matriz de confusión y curvas ROC, 171 de la hemiparética, 83 de la normal y 167 de la paraparética. Los resultados de la matriz de confusión y las curvas ROC se muestran en las Figuras 4.8a y 4.8b respectivamente, indicando una precisión del **98.57 %** y un área bajo la curva cercana a **1** lo cual denota un excelente desempeño en la clasificación.




Figura 4.8: Herramientas de evaluación OpenPose

4.2.1.b. PoseNet

Un total de 2880 imágenes SGEI fueron obtenidas utilizando PoseNet (3 % más que OpenPose debido a que el modelo es un poco más robusto con prendas de color negro), 1188 de la marcha hemiparética, 544 de la normal y 1148 de la paraparética. Al igual que con OpenPose El 70 % de cada marcha se utiliza para entrenamiento, 15 % para validación y el 15 % restante para pruebas. En la Figura 4.9 se muestran resultados similares a las curvas de entrenamiento de OpenPose con la diferencia que utilizando los SGEI de PoseNet converge mucho mas lento que OpenPose




Figura 4.9: Curvas de entrenamiento PoseNet

Un conjunto de 433 imágenes SGEI pertenecientes a las 3 marchas fueron evaluadas mediante una matriz de confusión, 179 de la hemiparética, 82 de la normal y 172 de la paraparética. Los resultados de la matriz de confusión y las curvas ROC se muestran en las Figuras 4.10a y 4.10b respectivamente, indicando una precisión del **98.15 %** denotando un 0.42 % menor en relación a OpenPose.




Figura 4.10: Herramientas de evaluación PoseNet

4.2.2. Ajustes de parámetros SVM y precisión

Como se manifiesta en la Sección 3.5.2, el algoritmo de clasificación SVM utiliza como entrada los parámetros espacio temporales extraídos de los 15 participantes obteniendo un total de 28 variables por cada marcha realizada. El algoritmo SVM utiliza el kernel RBF con los ajustes por defecto debido a que los resultados son los más favorables utilizando esta configuración. A continuación se muestran los resultados utilizando los Modelos de OpenPose y PoseNet.

4.2.2.a. OpenPose

Se procesan 319 vectores de datos, 104 correspondientes a la marcha hemiparética, 111 de la normal y 104 de la paraparética. El 70 % de la información es utilizada para entrenamiento y el 30 % restante para pruebas. Un conjunto de 96 vectores cada uno con 28 variables pertenecientes a las 3 marchas fueron evaluadas mediante una matriz de confusión y curvas ROC, 36 de la hemiparética, 35 de la normal y 25 de la paraparética. Los resultados de la matriz de confusión indican una precisión del **96.87 %** y un área bajo la curva cercana a **1** mostradas en la Figura 4.11, aunque el porcentaje es menor en 1.7 % respecto a si se usa el método con imágenes SGEI y el clasificador CNN para el modelo OpenPose, de igual manera se denota un excelente desempeño en la clasificación de marchas.




Figura 4.11: Herramientas de evaluación OpenPose

4.2.2.b. PoseNet

Se procesan 329 vectores de datos, 106 correspondientes a la marcha hemiparética, 111 de la normal y 112 de la paraparética. El 70 % de la información es utilizada para entrenamiento y el 30 % restante para pruebas. Un conjunto de 99 vectores cada uno con 28 variables pertenecientes a las 3 marchas fueron evaluadas mediante una matriz de confusión, 33 de la hemiparética, 31 de la normal y 35 de la paraparética. Los resultados de la matriz de confusión indican una precisión del **94.94 %** y un área bajo la curva cercana a **1** mostradas en la Figura 4.12, el porcentaje de precisión es menor en 3.21 % respecto a si se usa el método con imágenes SGEI y el clasificador CNN para el modelo PoseNet.




Figura 4.12: Herramientas de evaluación PoseNet



Conclusiones y Recomendaciones

5.1. Conclusiones

Los resultados obtenidos de los parámetros de longitud de paso, cadencia, amplitud de paso, tiempo de paso, velocidad de marcha, inclinación de la postura corporal frontal y ángulos de las extremidades inferiores del cuerpo humano de las 3 marchas, son consistentes con la bibliografía y con las diferentes evaluaciones de las marchas, lo que nos indica que el sistema implementado utilizando ambos modelos son útiles para el apoyo diagnóstico y puede ser una guía en el tratamiento de marchas patológicas como las analizadas en este estudio.

El análisis de la marcha mediante modelos no invasivos como OpenPose y PoseNet desempeñan un papel fundamental en el seguimiento de pacientes que no puedan acudir a un centro especializado, mediante un vídeo tomado por un teléfono celular se estima la pose a lo largo de la marcha y es suficiente para poder generar parámetros espacio-temporales, permitiendo a un profesional de la salud poder evaluar de manera objetiva las alteraciones de la marcha.

En este estudio se propuso identificar y clasificar la marcha normal, hemiparética y paraparética utilizando datos generados a partir de vídeos en 2 dimensiones y estimados por los modelos de OpenPose y PoseNet. Los experimentos realizados utilizando el enfoque para la extracción de características de la marcha SGEI y el algoritmo de clasificación CNN junto a una arquitectura VGG-19, así como el uso de las 28 variables espacio-temporales con el algoritmo SVM, presentaron una mejoría relevante en la precisión de clasificación. Se llega a obtener un máximo de 98.57 % de precisión utilizando el enfoque SGEI-CNN, mientras que con otros enfoques presentados en el estado del arte llegan a un máximo de 91.1 %.

En base a los resultados el modelo OpenPose es 0.42 % y 3.21 % más robusto que PoseNet utilizando los algoritmos de clasificación CNN y SVM respectivamente. También se puede definir que utilizar OpenPose requiere de mayor capacidad computacional que el otro modelo.

Finalmente, este trabajo investigativo implementa un sistema de visión artificial no invasivo generando la biomecánica del movimiento de extremidades inferiores en personas con marcha normal, hemiparética, paraparética y con exactitud clasifica mediante técnicas de inteligencia artificial estas marchas patológicas, la interfaz gráfica de la herramienta desarrollada se presenta en el Apéndice B.3.



5.2. Recomendaciones

Los modelos OpenPose y PoseNet presentan errores de estimación de pose cuando la persona utiliza prendas de color negro o muy holgada, por lo que se recomienda descartar este tipo de vestimenta, de igual manera el uso de trípodes es imprescindible cuando se realiza la adquisición de video en vista de que da estabilidad y permite que los modelos obtengan la pose con una mejor precisión.

Cuando se desee utilizar el sistema de visión artificial para analizar la marcha de una persona mediante computadoras de gama media o que no cuenten con una GPU de al menos 4 GB, es recomendable utilizar el modelo PoseNet, en cambio si se cuenta con un equipo con altas prestaciones en la GPU, se debe utilizar el modelo OpenPose debido a que procesa la información mas rápido que el otro modelo.

5.3. Trabajos futuros

Una posible extensión de este trabajo es la importancia de utilizar una base de datos que contenga una mayor cantidad de voluntarios que realicen las marchas, así como expandir el número de marchas patológicas que afectan la movilidad humana. Esto podrá permitir dar una mayor generalidad y evitar problemas como el sobre entrenamiento.

Los recursos computacionales desempeñan un papel fundamental en la precisión de los modelos de estimación de pose, influyendo en los resultados del análisis de la marcha. En el caso de no contar con una computadora de gama media/alta que brinde la precisión necesaria, se puede aplicar la misma metodología de este trabajo para desarrollar aplicaciones web junto a la computación orientada a la nube que permita al usuario abstraerse del hardware.



Apendice A

A.1. Modelo de consentimiento informado

Yo , con C.I en fecha de 2021, acepto participar en la adquisición de video como parte del proyecto de Investigación “Generación de la biomecánica del movimiento de extremidades inferiores” realizado por investigadores de la Universidad de Cuenca, que servirá para evaluar patrones normales y anormales de la marcha; del cual declaro conocer sus finalidades y forma de realización del procedimiento, que implica:

- Obtener medidas de altura y edad.
- Caminar frente a 2 cámaras ubicadas sagital y frontalmente.
- Caminar simulando anomalías de la marcha.
- Observación directa de los patrones de marcha.
- Procesamiento de video mediante visión artificial.
- Duración del estudio aproximadamente 1 hora.

Se guardará la confidencialidad de la información.

.....
Firma

A.2. Registro de Firmas






Nombres	Cedula	Edad	Altura	Firma
Gabriel Barros	0609704521	25	1.80	
Daniel Zúñiga	0104585740	22	1.86	
Ricardo Vazquez	0106380793	22	1.61	
Yuleidy Zambrano	0706082377	21	1.69	
Karla Paguay	0940591571	26	1.52	
Elian Trelles	0105776769	20	1.70	
Ximena Albornoz	0107270910	22	1.65	
Milton Trelles	0103056065	50	1.65	

Figura A.1: Registro de firmas primera parte


Christian Quinde	0105320386	24	1.77	
Paul Astudillo	0105708457	24	1.79	
Narcisa Minchalo	0102857133	50	1.65	
Giselle Soto	0104268974	23	1.6	
Damián Trelles	0104976097	24	1.69	
Stalin Benenaula	0105643423	24	1.8	
Karina Peralta	0103161998	49	1.55	

Figura A.2: Registro de firmas segunda parte



Apendice B

B.1. Instalación y configuración de OpenPose

```
1 import os
2 from os.path import exists, join, basename, splitext
3
4 ##### Instalación #####
5
6 git_repo_url = 'https://github.com/CMU-Perceptual-Computing-Lab/openpose.git'
7 project_name = splitext(basename(git_repo_url))[0]
8 if not exists(project_name):
9     # see: https://github.com/CMU-Perceptual-Computing-Lab/openpose/issues/949
10    # install new CMake because of CUDA10
11    !wget -q https://cmake.org/files/v3.13/cmake-3.13.0-Linux-x86_64.tar.gz
12    !tar xzf cmake-3.13.0-Linux-x86_64.tar.gz --strip-components=1 -C /usr/local
13    # clone openpose
14    !git clone -q --depth 1 $git_repo_url
15    !sed -i 's/execute_process(COMMAND git checkout master WORKING_DIRECTORY ${
16        CMAKE_SOURCE_DIR}\3rdparty\caffe)/execute_process(COMMAND git checkout
17        f019d0dfe86f49d1140961f8c7dec22130c83154 WORKING_DIRECTORY ${CMAKE_SOURCE_DIR
18        }\3rdparty\caffe)/g' openpose/CMakeLists.txt
19    # install system dependencies
20    !apt-get -qq install -y libatlas-base-dev libprotobuf-dev libleveldb-dev libsnappy-dev libhdf5-serial-
21        dev protobuf-compiler libgflags-dev libgoogle-glog-dev liblmdb-dev opencv-headers ocl-icd-
22        opencv-dev libviennacl-dev
23    # build openpose
24    !cd openpose && rm -rf build || true && mkdir build && cd build && cmake .. && make -j`nproc`
25    #####
```



```
21 |
22 | ##### Configuración #####
23 | !cd openpose && ./build/examples/openpose/openpose.bin --video ../drive/MyDrive/video.mp4 --
    | render_pose 0 --display 0 --number_people_max=1 --net_resolution "-1x720" --write_json ../
    | drive/MyDrive/keypoints
24 | #####
```

Listado B.1: Este código permite instalar y configurar OpenPose en Google Colab

B.2. Instalación y configuración de PoseNet

```
1 | ##### Instalación #####
2 |
3 | !git clone https://github.com/atomicbits/posenet-python
4 | !pip install matplotlib
5 | !pip install tensorflow
6 | !pip install opencv-python
7 | !pip install tfjs-graph-converter
8 | !pip install scipy
9 | !pip install pandas
10 | !pip install tfjs-graph-converter
11 | #####
12 |
13 | ##### Configuración #####
14 |
15 | model = 'resnet50' # mobilenet resnet50
16 | stride = 16 # 8, 16, 32 (max 16 for mobilenet, min 16 for resnet50)
17 | quant_bytes = 4 # float
18 | multiplier = 1.0 # only for mobilenet
19 | posenet = load_model(model, stride, quant_bytes, multiplier)
20 |
21 | #####
```

Listado B.2: Este código permite instalar y configurar PoseNet en Google Colab

B.3. Interfaz gráfica del sistema desarrollado




Figura B.1: Interfaz gráfica del sistema desarrollado



Bibliografía

- [1] C. Pava, F. Bernal, G. Hernandez, R. Gonzalez, R. Raya, y S. Menaught, “Metodología para la evaluación de la marcha normal y patológica con correlación digital de imágenes,” *Ciencia e Ingeniería*, pp. 39–46, 2018.
- [2] H. Gaßner, D. Jensen, F. Marxreiter, A. Kletsch, S. Bohlen, R. Schubert, L. Muratori, B. Eskofier, J. Klucken, J. Winkler, R. Reilmann, y Z. Kohl, “Gait variability as digital biomarker of disease severity in Huntington’s disease,” *Neurology*, num. 267, p. 1594–1601, 2020.
- [3] F. Molina y M. Carratalá, *La marcha humana*. Médica Panamericana S.A, 2020.
- [4] W. Pirker y R. Katzenschlager, “Gait disorders in adults and the elderly : A clinical guide,” *Wiener klinische Wochenschrift*, num. 129, p. 81–95, 2016.
- [5] S. Shetty y Y. Rao, “SVM based machine learning approach to identify Parkinson’s disease using gait analysis,” *International Conference on Inventive Computation Technologies (ICICT)*, p. 1–5, 2016.
- [6] N. Nobuyasu, S. Tetsuro, U. Kazuhiro, O. Leon, A. Kimura, I. Yoichi, F. Senshi, y Y. Shinsuke, “Evaluation of 3D Markerless Motion Capture Accuracy Using OpenPose With Multiple Video Cameras,” *Frontiers in Sports and Active Living*, num. 2, 2020.
- [7] L. Qiannan, W. Yafang, S. Andrei, C. Ya, T. Changhe, C. Baoquan, y Y. Shengyuan, “Classification of gait anomalies from kinect,” *The Visual Computer*, num. 34, p. 1–13, 2018.
- [8] G. Hidalgo, “Openpose: Whole-body pose estimation,” Master’s thesis, Carnegie Mellon University, Pittsburgh, Pennsylvania, 4 2019.
- [9] D. Oved, “Estimation in the browser with tensorflow.js.” [En línea]. Disponible: <https://medium.com/tensorflow/real-time-human-pose-estimation-in-the-browser-with-tensorflow-js-7dd0bc881cd5>
- [10] A. Mendoza, A. B. Santamaria, T. G. Urrego, y J. Z. García, “Marcha: descripción, métodos, herramientas de evaluación y parámetros de normalidad reportados en la literatura,” *ES Movimiento y Salud*, p. 29–43, 2013.
- [11] R. Cano de la Cuerda, R. Martínez Piédrola, y J. Miangolarra Page, *Control y aprendizaje motor: fundamentos, desarrollo y reeducación del movimiento humano*. Médica Panamericana S.A, 2017.
- [12] J. Cámara, “Análisis de la marcha: sus fases y variables espacio-temporales,” *Fisiología del ejercicio*, num. 1, pp. 160–173, 2011.
- [13] U. C. de Chile, “Marcha normal y patológica.” [En línea]. Disponible: <http://www.docencia traumatologia.uc.cl/marcha-normal-y-patologica/>



- [14] R. G. Figuera, J. Vilaseca, y B. Müller, “Técnicas instrumentales de diagnóstico y evaluación en rehabilitación,” *Revista de la Sociedad Española de Rehabilitación y Medicina Física*, pp. 305–314, 2005.
- [15] M. G. Jiménez, “Análisis de la marcha: Evaluación de un exoesqueleto aplicado a la marcha asistida,” Ph.D. dissertation, Universidad Politécnica de Madrid, Madrid, España, 2016.
- [16] A. H. Larrea, “Estudio de los parámetros espaciales de la marcha en la población anciana española y su asociación con resultados adversos a la salud,” Ph.D. dissertation, Universidad Internacional de Cataluña, Barcelona, España, 2017.
- [17] F. Martínez y E. Romero, “Análisis de vídeo para estimación del movimiento humano: Una Revisión,” *Revista Med*, num. 17, pp. 95–106, 2009.
- [18] F. Romero y J. Barrios, “El análisis biomecánico de la marcha en personas con discapacidad motora,” *Educación Física y Deportes*, num. 230, 2017.
- [19] J. D. Lesmes, *Evaluación clínico-funcional del movimiento corporal humano*. Médica Panamericana S.A, 2007.
- [20] C. M. Sanz, “Marcha Patológica,” *Revista del Pie y Tobillo*, num. 1, pp. 44–54, 2003.
- [21] M. Pearson, “Automatic gait recognition,” Master’s thesis, Linköping University, Linköping, Suecia, 7 2020.
- [22] G. Group, “Tensorflow.” [En línea]. Disponible: https://www.tensorflow.org/lite/models/pose_estimation/overview
- [23] —, “Posenet.” [En línea]. Disponible: <https://github.com/tensorflow/tfjs-models/tree/master/posenet>
- [24] L. A. Siguenza, “Diseño y desarrollo de un módulo para determinar la postura humana empleando técnicas de visión artificial y reconocimiento de patrones como herramientas de soporte en el desarrollo de la motricidad gruesa de niños con discapacidad,” Master’s thesis, Universidad Politécnica Salesiana, Cuenca, Ecuador, 2020.
- [25] G. Hidalgo, Z. Cao, T. Simon, S. Wei, Y. Raaj, H. Joo, y Y. Sheikh, “Cmu-perceptual-computing-lab / openpose.” [En línea]. Disponible: <https://github.com/CMU-Perceptual-Computing-Lab/openpose>
- [26] W. Chen, Z. Jiang, H. Guo, y X. Ni, “Fall Detection Based on Key Points of Human-Skeleton Using OpenPose,” *Symmetry*, 2020.
- [27] D. Guffanti, “Control remoto por voz del robot móvil pionner p3-dx,” Master’s thesis, Universidad ESPE, Sangolquí, Ecuador, 2013.
- [28] F. Robles, “Detección automática de cambios abruptos de dinámica en señales electrocardiográficas basados en test estadísticos,” Master’s thesis, Universidad Austral de Chile, Valdivia, Chile, 2012.
- [29] N. Group, “hanning.” [En línea]. Disponible: https://numpy.org/doc/stable/_images/numpy-hanning-1_00_00.png
- [30] G. García y G. González, “Reconocimiento de imágenes dactilares por medio de la transformada de wavelet daubechies y distancias euclidianas,” Master’s thesis, Instituto Politécnico Nacional, México DF, México, 2015.

- [31] J. Santos, “Using deep learning for gait abnormality classification,” Master’s thesis, department of Electrical and Computer Engineering, University Lisboa, Lisboa, Portugal, 2019.
- [32] J. Han y B. Bhanu, “Individual recognition using gait energy image,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, num. 28(2), 2006.
- [33] ImageNet, “Imagenet large scale visual recognition competition.” [En línea]. Disponible: <http://image-net.org/challenges/LSVRC/>
- [34] A. D. Marti, “Desarrollo de un sistema de detección y predicción de la pose 3d de objetos en la escena mediante técnicas de deep learning,” Master’s thesis, Universidad de Alicante, Alicante, España, 2019.
- [35] S. K y Zisserman., “Very Deep Convolutional Networks for Large-Scale Image Recognition,” *arXiv*, num. 28(2), 2014.
- [36] Y. Zheng, C. Yang, y A. Merkulov, “Breast cancer screening using convolutional neural network and follow-up digital mammography,” *arXiv*, num. 4, 2018.
- [37] E. Carmona, “Tutorial sobre Máquinas de Vectores Soporte (SVM),” *arXiv*, 11 2016.
- [38] V. Apostolidis-Afentoulis, “Svm classification with linear and rbf kernels,” 07 2015.
- [39] S. learn Group, “Scikit-learn.” [En línea]. Disponible: https://scikit-learn.org/stable/auto_examples/svm/plot_iris_svc.html
- [40] J. Ariza-López F. and Rodríguez-Avi y V. Alba-Fernández, “Control estricto de matrices de confusión por medio de distribuciones multinomiales,” *GeoFocus*, num. 21, 2018.
- [41] F. Abad, “Curva roc.” [En línea]. Disponible: <https://freddy-abadl.medium.com/curva-roc-d8c638894f49>
- [42] B. .M, R. R, y A. R, “Comparación de dos sistemas de captura de movimiento por medio de las trayectorias articulares de marcha,” *Ingeniería Biomédica*, num. 2, pp. 149–160, 2016.
- [43] F. Valencia-Aguirre, C. Mejía-Echeverría, y V. Erazo-Arteaga, “Desarrollo de una prótesis de rodilla para amputaciones transfemorales usando herramientas computacionales,” *Revista UIS Ingenierías*, 2017.
- [44] P. Liendo y U. Rafael, “Clasificación de la marcha hemipléjica utilizando las características difusas de los indicadores cinemáticos en tobillo, rodilla y cadera,” *Interciencia*, num. 41(9), pp. 633–638, 2016.
- [45] J. Stenum, C. Rossi, y R. Roemmich, “Two-dimensional video-based analysis of human gait using pose estimation,” *bioRxiv*, 2020.
- [46] S. Rick, S. Bhaskaran, Y. Sun, S. McEwen, y N. Weibel, “Neuropose: geriatric rehabilitation in the home using a webcam and pose estimation,” *Interciencia*, pp. 105–106, 2019.
- [47] P. Gonzalez, “Análisis biomecánico de la marcha mediante un modelo analítico de dinámica inversa en pacientes con alteración del equilibrio sagital del raquis,” Master’s thesis, Universidad Autonoma de Barcelona, Barcelona, España, 2017.
- [48] T. Nguyen, H. Huynh, y J. Meunier, “Skeleton-based abnormal gait detection,” *Sensors*, num. 16(11), p. 1792, 2016.



- [49] K. Jun, Y. Lee, S. Lee, D. Lee, y M. Kim, "Pathological gait classification using kinect v2 and gated recurrent neural networks," *IEEE Access*, num. 8, pp. 139 881–139 891, 2020.
- [50] L. Dranca, L. de Abetxuko Ruiz de Mendarozketa, y A. Goñi, "Using kinect to classify parkinson's disease stages related to severity of gait impairment," *BMC Bioinformatics*, 2018.
- [51] M. Kumar y R. Babu, "Human gait recognition using depth camera: a covariance based approach," *Proceedings of the 8th Indian Conference on Computer Vision, Graphics and Image Processing*, p. 20, 2012.
- [52] N. Nakano, T. Sakura, K. Ueda, L. Omura, K. Arata, Y. Iino, S. Fukushima, y S. Yoshioka, "Evaluation of 3d markerless motion capture accuracy using openpose with multiple video cameras," *Frontiers in Sports and Active Living*, 2020.
- [53] Q. Li, Y. Wang, A. Sharf, Y. Cao, C. Tu, B. Chen, y S. Yu, "Classification of gait anomalies from kinect," *The Visual Computer*, num. 34, pp. 1–13, 2018.
- [54] B. Mallikarjuna, R. Viswanathan, y B. Naib, "Feedback-based gait identification using deep neural network classification," 2020.
- [55] H. Group, "Huawei mate 20 lite." [En línea]. Disponible: <https://consumer.huawei.com/latin/phones/mate20-lite/>
- [56] X. Group, "Xiaomi mi 9t." [En línea]. Disponible: <https://www.mi.com/es/mi-9-t/>
- [57] G. Group, "Google colab." [En línea]. Disponible: <https://colab.research.google.com/notebooks/intro.ipynb>
- [58] —, "Google cloud." [En línea]. Disponible: <https://cloud.google.com/compute>
- [59] Z.Cao, G. Martinez, T. Simon, S. Wei, y Y. A. Sheikh, "Openpose: Realtime multi-person 2d pose estimation using part affinity fields" *IEEE transactions on pattern analysis and machine intelligence*, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019.
- [60] P. Group, "Python." [En línea]. Disponible: <https://www.python.org/about/>
- [61] K. Group, "Keras." [En línea]. Disponible: <https://keras.io/api/>
- [62] L. Pratt, J. Mostow, y C. Kamm, "Transfer of learned information among neural networks," *AAAI-91 Proceedings*, pp. 584–589, 1991.
- [63] A.-O. Saud, W. James, A.-Y. Alia, y A.-G. Muneera, "Basic gait parameters: A comparison of reference data for normal subjects 20 to 29 years of age from kuwait and scandinavia," *Rehabilitation Research Development*, num. 4, 2003.
- [64] T. Diana, C. Andrea, P. Elisa, A. Laura, M. Anat, M. H. Jeffrey, y C. Ugo Della, "Estimation of step-by-step spatio-temporal parameters of normal and impaired gait using shank-mounted magneto-inertial sensors: application to elderly, hemiparetic, parkinsonian and choreic gait," *Journal of Neuro Engineering and Rehabilitation*, 2014.
- [65] Y. Stephania, "Estudio comparativo de sistemas de análisis de marcha basados en sensores inerciales y cámaras infrarrojas," Master's thesis, Universidad de Concepción, Concepción, Chile, 2018.