

**CARACTERIZACIÓN DE PATRONES LOCOMOTORES ANORMALES RELACIONADOS  
CON LA ENFERMEDAD DE PARKINSON A PARTIR DE ARQUITECTURAS DE  
APRENDIZAJE PROFUNDO DEDICADAS A LA ESTIMACIÓN DE POSES**

**JEAN CARLOS PORTILLA MORA**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS  
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA  
BUCARAMANGA**

**2023**

**CARACTERIZACIÓN DE PATRONES LOCOMOTORES ANORMALES RELACIONADOS  
CON LA ENFERMEDAD DE PARKINSON A PARTIR DE ARQUITECTURAS DE  
APRENDIZAJE PROFUNDO DEDICADAS A LA ESTIMACIÓN DE POSES**

**JEAN CARLOS PORTILLA MORA**

**Tesis presentada en cumplimiento de los requisitos para el grado de:  
Ingeniero de Sistemas**

**Director:**

**Fabio Martínez Carrillo**

**Doctor en Ingeniería de Sistemas y Computación**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS  
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA  
BUCARAMANGA**

**2023**

## AGRADECIMIENTOS

Al profesor Fabio Martínez, al profesor Luis Carlos Guayacán y al profesor Edgar Rangel por su dedicación y todo el apoyo a la realización de este trabajo, brindando los mejores consejos y ajustes que me han servido de aprendizaje para la vida de siempre seguir para adelante y nunca darse por vencido sea cual sea la adversidad y motivarme a dar lo mejor de mi para explotar mis capacidades intelectuales y mejorar como persona para poder servir a la sociedad.

A mi familia en especial el apoyo de mis padres que siempre quieren lo mejor de mi y han sacrificado demasiado por mi futuro y yo hago el esfuerzo para que no sea en vano, también a compañeros y profesores con los que he tenido un trato muy respetuoso y amigable, que me ha ayudado a aprender cosas para la vida que apenas está empezando.

Al grupo de investigación *BIVL<sup>2</sup>ab* que mas que un grupo de investigación, es una familia que siempre me acogió y tenía siempre los brazos abiertos ante toda circunstancia, compañeros de trabajo que de corazón puedo considerar como amigos de los que aprendo y seguiré aprendiendo mucho para la vida.

A la Universidad Industrial de Santander junto a su escuela de Ingeniería de sistemas e informática por darme la oportunidad de ser un estudiante mas que quiere cumplir sus sueños y llegar lejos con los distintos apoyos al estudiante.

## DEDICATORIA

*Primero que todo a Dios por darme la sabiduría para afrontar todo en la vida, a mi familia por darme la vida que tengo, a mis padres por todos los apoyos que necesite en la vida con todo el cariño del mundo, mi hermanita que tanto quiero, mi nonita que amo con todo mi corazón, mis nonos que están en la eternidad, mis tíos con sus consejos, el grupo de investigación BIVL<sup>2</sup>ab que me abrió sus puertas en el momento que mas lo necesitaba e hice muchas amistades con seres humanos que te hacen sentir parte de su familia, a la escuela de ingeniería de sistemas e informática, por esas oportunidades que me ha brindado tanto de estudio como de trabajo que me ha permitido viajar a otros sitios del país, a todos los buenos amigos que he conocido en esta etapa la universidad como Nuri, Alemán, Santiago, Jofator, Pedro, Pardito, Daniel Duarte, Erwing, mi primo Juan Pablo, Daniel, Morita, William, Camilo, Edward, Brayan, Franklin, Mateo, Santi, Aleja, Pipe, Andrés, Jhon, Morón, Jurianny y Will de las clases italiano, compañeros de la pasantía en Ecopetrol, entre varios mas que quizás se me olvidan, que hoy también son profesionales en sus distintas carreras llenándome de orgullo y por ultimo y no menos importante a mi mascota Lulú que siempre me acompañó cuando mas lo necesitaba.*

**Jean Carlos Portilla Mora.**

## CONTENIDO

	<b>page</b>
<b>INTRODUCCIÓN</b> . . . . .	<b>11</b>
<b>1. Fundamentos y trabajos previos</b> . . . . .	<b>13</b>
1.1. Enfermedad de Parkinson y el análisis de la marcha . . . . .	13
1.2. Métodos computacionales para la representación postural . . . . .	15
1.3. Métodos computacionales para la enfermedad del Parkinson . . . . .	18
<b>2. Problema de Investigación</b> . . . . .	<b>23</b>
<b>3. Objetivos</b> . . . . .	<b>24</b>
<b>4. Método Propuesto</b> . . . . .	<b>25</b>
4.1. <i>OpenPose</i> : una arquitectura profunda para la generación de posturas. . . . .	25
4.1.1 Campo de afinidad entre articulaciones . . . . .	27
4.1.2 Mapas de confianza articulares . . . . .	29
4.1.3 Asociación de partes . . . . .	30
4.2. Red convolucional 3D para clasificar patrones parkinsonianos . . . . .	31
4.3. Descriptor de posturas basado en la covarianza . . . . .	33
<b>5. Diseño Experimental</b> . . . . .	<b>37</b>
5.1. Descripción de la base de datos . . . . .	37
5.2. Configuración de la metodología . . . . .	37
5.2.1 Configuración para la extracción de poses . . . . .	37
5.2.2 Configuración de la red convolucional 3D . . . . .	38
5.2.3 Descriptor de covarianza de posturas . . . . .	38

**6. Evaluación y Resultados . . . . . 40**

6.1. Caracterización de representaciones intermedias posturales y la red convolu-  
cional 3D . . . . . 40

6.2. Descriptor de covarianza para las posturas . . . . . 42

**7. Conclusiones y Perspectivas . . . . . 45**

**BIBLIOGRAFÍA . . . . . 47**

## LISTA DE FIGURAS

	<b>page</b>
Figura 1. Esqueleto obtenido usando <i>OpenPose</i> . . . . .	26
Figura 2. Arquitectura de <i>OpenPose</i> para la extracción de posturas . . . . .	27
Figura 3. Representación gráfica de un ejemplo de <i>PAF</i> . . . . .	28
Figura 4. Construcción de siluetas . . . . .	29
Figura 5. Construcción de las coordenadas de las extremidades . . . . .	30
Figura 6. Ejemplo de esqueletos extraídos con <i>OpenPose</i> . . . . .	31
Figura 7. Extracción de características profundas . . . . .	32
Figura 8. Caracterización de Patrones . . . . .	34
Figura 9. Representación de coordinación por medio de matriz de correlación . . . . .	36
Figura 10. Comparación clasificación de pacientes ( <i>PAF</i> vs <i>JCM</i> ) . . . . .	41
Figura 11. Comparación correlación entre pacientes . . . . .	44

## LISTA DE TABLAS

	<b>page</b>
Tabla 1. Comparación clasificación de nuestra propuesta con estado del arte . . . . .	41
Tabla 2. Comparación clasificación por covarianza de puntos de extremidades inferiores	42
Tabla 3. Comparación clasificación por covarianza de puntos en general . . . . .	43

## RESUMEN

**TÍTULO:** Caracterización de patrones locomotores anormales relacionados con la enfermedad de Parkinson a partir de arquitecturas de aprendizaje profundo dedicadas a la estimación de poses \*

**AUTOR:** Jean Carlos Portilla Mora \*\*

**PALABRAS CLAVE:** Enfermedad de Parkinson, aprendizaje profundo, análisis de la marcha, estimación de la postura, matriz de covarianza.

**DESCRIPCIÓN:** La enfermedad de Parkinson (EP) es uno de los trastornos neurodegenerativos más prevalentes en todo el mundo, con más de 6,2 millones de casos registrados a nivel mundial. El análisis de la marcha es crucial para cuantificar y comprender las anomalías motoras relacionadas con esta enfermedad. En este sentido, se utilizan tecnologías que integran dispositivos especializados que procesan datos de postura y movimiento. Sin embargo, estos sistemas basados en marcadores están limitados por su coste, complejidad y la necesidad de personal especializado para la localización de los sensores. Por otro lado, en la literatura se han explorado enfoques basados en el análisis de vídeo, los cuales están hoy en día limitados a realizar procesos globales de clasificación, perdiendo detalle en el análisis cinemático, durante la locomoción. En este trabajo, se desarrolló una estrategia sin marcadores para cuantificar patrones locomotores asociados al párkinson, teniendo como línea base una arquitectura de aprendizaje profundo dedicada a la estimación de poses. Para ello, en este trabajo se recuperan las características profundas aprendidas durante la estimación de poses. El conjunto de estas activaciones fue proyectada en representaciones convolucionales volumétricas y ajustadas de acuerdo a una tarea de discriminación con respecto a sujetos control. Adicionalmente, una caracterización de la marcha respecto a los movimientos posturales fueron codificados en matrices de covarianza, las cuales proporcionan una ventaja explicativa entre articulaciones de interés. Además, estas covarianzas fueron proyectadas en clasificadores para validar el desempeño discriminativo con respecto a sujetos control. Las aproximaciones propuestas lograron clasificar pacientes con párkinson con una exactitud de 98% usando los mapas volumétricos de activación y una exactitud de 71.5% usando las matrices de covarianza.

---

\* Trabajo de investigación

\*\* Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería de Sistemas e Informática. Director: Fabio Martínez, PhD en ingeniería de sistemas y computación, análisis de imágenes y análisis de video.

## ABSTRACT

**TITLE:** Characterization of abnormal locomotor patterns related to Parkinson's disease from deep learning architectures dedicated to pose estimation \*

**AUTHOR:** Jean Carlos Portilla Mora \*\*

**KEYWORDS:** Parkinson's Disease, deep learning, gait analysis, posture estimation, covariance matrix.

**DESCRIPTION:** Parkinson's disease (PD) is one of the most prevalent neurodegenerative disorders worldwide, with over 6.2 million cases reported globally. Gait analysis is crucial for quantifying and understanding motor abnormalities associated with this disease. In this regard, technologies integrating specialized devices are used to process posture and motion data. However, marker-based systems are limited by their cost, complexity, and the need for specialized personnel to locate points of interest. On the other hand, in the literature, video-based approaches have been explored, but they are currently limited to performing global classification processes, losing detail in kinematic analysis during locomotion. In this study, a markerless strategy was developed to quantify motor patterns associated with Parkinson's disease, using a deep learning architecture as the basis for representation. In this work, deep features learned during pose estimation were leveraged. The set of these activations was projected into volumetric convolutional representations and adapted for a discrimination task with respect to control subjects. In a second characterization of gait, postural movements were encoded into covariance matrices, which offer an explanatory advantage in terms of correlational relationships between relevant joints. Furthermore, these covariances were projected to classifiers to verify their discriminative nature with respect to control subjects. The proposed approaches achieved the classification of Parkinson's patients with an accuracy of 99% using volumetric activation maps and an accuracy of 76.1% using covariance matrices.

---

\* Research work

\*\* Faculty of Physics-Mechanics Engineering. School of Systems Engineering and Informatics. Advisor: Fabio Martínez Carrillo, PhD. Computer and systems engineering, medical image analysis and video analysis.

## INTRODUCCIÓN

La enfermedad de Parkinson (EP) es el segundo trastorno neurodegenerativo más común a nivel mundial. Para el año 2015, se reportaron más de 6.2 millones de casos.<sup>1</sup> Así mismo, durante las últimas tres décadas, se ha presentado un aumento significativo en la prevalencia, llegando a quintuplicarse<sup>2</sup>. Algunas proyecciones, estiman más de 17 millones de personas afectadas para el 2040.<sup>3</sup>

En la actualidad, el diagnóstico de esta enfermedad se basa principalmente en la evaluación de síntomas motores, por parte de especialistas médicos<sup>4</sup>. Por lo tanto, una metodología crucial en el análisis implica realizar un estudio de la marcha para cuantificar y comprender las anomalías motrices, llegando a facilitar su diagnóstico y pronóstico<sup>5</sup>. Para la caracterización de los patrones locomotores se usan sistemas basados en marcadores, colocados en puntos anatómicos claves del cuerpo<sup>6</sup>, los cuales permiten un análisis de los datos de postura y movimiento mediante técnicas basadas en modelos biomecánicos. Sin embargo, estos sistemas alteran el gesto natural del movimiento, junto a las aproximaciones

---

<sup>1</sup> Valery L FEIGIN et al. “Burden of neurological disorders across the US from 1990-2017: a global burden of disease study”. In: *JAMA neurology* 78.2 (2021), pp. 165–176.

<sup>2</sup> Eduardo TOLOSA et al. “Challenges in the diagnosis of Parkinson’s disease”. In: *The Lancet Neurology* 20.5 (2021), pp. 385–397.

<sup>3</sup> E DORSEY et al. “The emerging evidence of the Parkinson pandemic”. In: *Journal of Parkinson’s disease* 8.s1 (2018), S3–S8.

<sup>4</sup> Erika ROVINI; Carlo MAREMMANI, and Filippo CAVALLO. “How wearable sensors can support Parkinson’s disease diagnosis and treatment: a systematic review”. In: *Frontiers in neuroscience* 11 (2017), p. 555.

<sup>5</sup> Richard BAKER. “Gait analysis methods in rehabilitation”. In: *Journal of neuroengineering and rehabilitation* 3.1 (2006), pp. 1–10.

<sup>6</sup> Marco IOSA et al. “Wearable inertial sensors for human movement analysis”. In: *Expert review of medical devices* 13.7 (2016), pp. 641–659.

cinemáticas, que dependen solo de algunos movimientos articulares, llegando a limitar la caracterización de patrones parkinsonianos.

En la literatura se han propuesto diversas metodologías de visión por computador, basados en análisis de video, las cuales calculan descriptores espacio-temporales que pueden tener cierto grado de correlación con enfermedades locomotoras. Estos métodos sin marcadores, han permitido analizar secuencias de vídeo y clasificar los tipos de movimiento <sup>7</sup>. Estos métodos tienen la capacidad de aprender las diferencias entre los patrones motores de la EP y pacientes control, logrando predicciones automáticas para apoyar el diagnóstico médico a partir de una secuencia de vídeo. Sin embargo, los patrones aprendidos pueden no resultar clínicamente relevantes, debido a que las predicciones pueden carecer de información semántica a nivel anatómico y fisiológico utilizados durante la rutina clínica.

En este trabajo, se presenta una estrategia sin marcadores para cuantificar y clasificar patrones locomotores asociados al parkinson respecto a una población control. Este descriptor tiene como fundamento diferencial el uso de representaciones de aprendizaje profundo, y han sido entrenadas para la recuperación de características posturales durante la marcha. Para ello, se realizó una selección de un conjunto de datos que contuviera vídeos de marcha de pacientes diagnosticados con EP y de población control. Se implementó, como línea base, una arquitectura profunda dedicada a la extracción de posturas, mediante la estimación de puntos articulares aproximados sobre vídeos. Las activaciones posturales resultantes se proyectaron en una representación convolucional volumétrica, bajo un esquema de aprendizaje profundo supervisado, ajustándolo para realizar tareas de discriminación entre sujetos control y parkinson. En una segunda aproximación se tomaron las posturas generadas en cada ejercicio de locomoción y se obtuvo un descriptor de covarianza; Este descriptor es compacto, explicable y permite la clasificación de patrones parkinsonianos con respecto a una población control.

---

<sup>7</sup> The LANCET. *Artificial intelligence in health care: Within touching distance*. 2017.

## 1. Fundamentos y trabajos previos

### 1.1. Enfermedad de Parkinson y el análisis de la marcha

La enfermedad de Parkinson (EP) es la segunda enfermedad neurodegenerativa más frecuente a nivel mundial<sup>8</sup>. Se estima que 150 de cada 100.000 habitantes es diagnosticado con la enfermedad y las cifras aumentan conforme se incrementa la expectativa de vida<sup>9</sup>. Esta enfermedad no tiene cura, aunque si hay tratamientos para sobrellevar y controlar el trastorno. La EP presenta una gran variedad de síntomas que se pueden clasificar en síntomas motores y no motores.<sup>10</sup> Entre los síntomas no motores se encuentran los trastornos del sueño, los cognitivos, los del estado de ánimo, entre otros.<sup>11</sup> Entre los síntomas motores se destaca la presencia de temblores, inestabilidad postural y trastornos de la marcha<sup>12</sup>. La marcha es una actividad diaria fundamental y su alteración puede tener un impacto significativo en la calidad de vida de los pacientes. La marcha humana consiste en la ejecución de una compleja y armoniosa combinación de movimientos, involucrando una gran variedad de subsistemas biológicos. A través de su estudio pueden ser identificados los primeros sig-

---

<sup>8</sup> Juan Sebastián SAAVEDRA MORENO; Paula Andrea MILLÁN, and Omar Fredy BURITICÁ HENAO. “Introducción, epidemiología y diagnóstico de la enfermedad de Parkinson”. In: *Acta neurológica colombiana* 35 (2019), pp. 2–10.

<sup>9</sup> Lina M ARIZA-SERRANO et al. “Caracterización de pacientes con enfermedad de Parkinson en un centro de referencia de la ciudad de Bogotá, Colombia”. In: *Acta Neurológica Colombiana* 32.3 (2016), pp. 203–208.

<sup>10</sup> Jaime KULISEVSKY et al. “Enfermedad de Parkinson avanzada. Características clínicas y tratamiento (parte I)”. in: *Neurología* 28.8 (2013), pp. 503–521.

<sup>11</sup> JL W BOSBOOM; T CORONA, and WOLTERS E CH. “Psicosis en la enfermedad de Parkinson”. In: *Archivos de neurociencias (México, DF)* 9.1 (2004), pp. 25–33.

<sup>12</sup> K BERGANZO et al. “Síntomas no motores y motores en la enfermedad de Parkinson y su relación con la calidad de vida y los distintos subgrupos clínicos”. In: *Neurología* 31.9 (2016), pp. 585–591.

nos de la enfermedad, incluso antes de que aparezcan otros síntomas motores evidentes, y distinguir el Parkinson de otras afecciones neurológicas con síntomas similares<sup>13</sup>. Es por ello que el análisis de la marcha constituye una herramienta fundamental para la detección temprana de la EP; para realizar seguimiento de los patrones motores, así como también, es una alternativa para cuantificar el estadio de la EP. De hecho, desde el análisis de marcha se ofrecen métricas objetivas para evaluar la función motora y la eficacia del tratamiento. A continuación, se describen algunos síntomas característicos de la EP relacionados a patrones motores anormales que suelen ser detectados a través del análisis de la marcha.

**La bradicinesia** es la lentitud que presenta un paciente al momento de ejecutar movimientos voluntarios. Esto se traduce en una disminución de la espontaneidad gestual, escritura más lenta con letras más pequeñas (micrografía), dificultad para realizar tareas que requieren destreza fina y una reducción en el balanceo de los brazos al caminar. Los pacientes pueden adoptar una marcha con pasos cortos, arrastrando los pies y experimentar una ralentización generalizada de sus movimientos, lo que resulta en una prolongación del tiempo necesario para realizar actividades comunes<sup>14</sup>. La presencia de este síntoma constituye uno de los criterios más utilizados para la identificación de la EP. En un estudio realizado a 136 pacientes se obtuvo que un 80% de los pacientes presentaban este patrón<sup>15</sup>.

**La rigidez** también conocido como hipertoncicidad o incremento del tono muscular, es un síntoma observado en movimientos pasivos del paciente, tanto para músculos flexores como extensores. Se manifiesta como una resistencia anormal en los músculos y las articula-

---

<sup>13</sup> John TAPIA-NÚÑEZ and P CHANÁ-CUEVAS. “Diagnóstico de la enfermedad de Parkinson”. In: *Rev neurol* 38.1 (2004), pp. 61–67.

<sup>14</sup> Carolina LEÓN-JIMÉNEZ et al. “Síndrome Rígido Acinético”. In: *Revista de Medicina Clínica* 3.2 (2019), pp. 104–108.

<sup>15</sup> Sofía GARRIDO-ELUSTONDO et al. “Capacidad de detección de patología psiquiátrica por el médico de familia”. In: *Atención Primaria* 48.7 (2016), pp. 449–457.

ciones, lo que hace que los movimientos sean lentos y difíciles de iniciar. Se describe a menudo como "rigidez en rueda dentada" debido a la sensación de enganche o saltos al mover pasivamente las articulaciones. Se caracteriza por no ser suave y presentar fuertes cambios en la aceleración. Su identificación se centra en la observación de las dificultades que un paciente pueda tener en la realización de los siguientes movimientos: movilización de articulaciones, desplazamientos de muñecas y tobillos, movimientos de codos y rodillas, entre otros<sup>14</sup>. En cuanto al porcentaje de criterios de identificación de la enfermedad de Parkinson este posee un 70.1% en general y en el estudio de 136 pacientes, el 60% de los pacientes presentó este síntoma<sup>16</sup>.

**La inestabilidad postural** en la EP se refiere a la dificultad que enfrentan las personas afectadas para mantener un equilibrio y postura adecuados. Esto se manifiesta en problemas como una marcha inestable, con pasos cortos y dificultades para iniciar o detenerse, alteraciones posturales que pueden resultar en una postura inclinada, con la cabeza agachada y los hombros caídos, y dificultades en el equilibrio, lo que aumenta el riesgo de caídas<sup>16</sup>.

## 1.2. Métodos computacionales para la representación postural

La representación de la postura humana ha sido objeto de amplias investigaciones en campos como la medicina, la ciencia deportiva y la ingeniería biomédica. Los modelos biomecánicos, por ejemplo, posibilitan la estimación de la postura de un individuo a partir de la posición espacial de sus articulaciones en un momento específico, utilizando parámetros cinemáticos<sup>17</sup>. Uno de los métodos más ampliamente utilizados para la captura de la

---

<sup>16</sup> Nancy Bertado RAMÍREZ et al. "Datos clave para el diagnóstico clínico de enfermedad de Parkinson". In: *Revista Mexicana de Neurociencia* 10.5 (2009), pp. 340–343.

<sup>17</sup> Juan Camilo LOZANO CARRILLO. "Pose temporal estimation in markerless normal human gait integrating kinematic patterns and segmented video". In: *Departamento de Imágenes Diagnósticas* (2015).

postura humana es la tecnología Mocap o de captura de movimiento<sup>18</sup>. Estos métodos utilizan técnicas de grabación de movimiento del cuerpo humano, que recogen datos espacio-temporales para luego ser representados digitalmente. El desempeño de los sistemas Mocap depende en gran medida de la tecnología de captura de movimiento, es decir, del uso o no uso de marcadores o sensores de cámaras especializadas<sup>19</sup>. Estos sistemas, sin embargo, requieren de personal especializado para colocar correctamente los marcadores y protocolos de captura complejos en espacios y condiciones controladas. Adicionalmente, el proceso de colocación de marcadores es prolongado, tedioso, puede incomodar al paciente y alterar el gesto natural de la marcha<sup>20</sup>.

Otros sistemas de captura han mejorado en este sentido, incorporando técnicas que no requieren de marcadores. Por ejemplo, usando cámaras RGBD, las cuales integran información de profundidad a través del uso de sensores infrarrojos. Estos sistemas han sido usados en el área de investigación clínica para la estimación de poses atípicas y caracterización de enfermedades motoras<sup>21</sup>. Sin embargo, la fiabilidad de estos sistemas RGBD disminuye conforme aumenta la distancia entre el objeto de estudio y el sensor. Además, no funcionan adecuadamente en exteriores, debido a la interferencia de la señal infrarroja producida por la luz directa del sol<sup>22</sup>. Por lo que en aplicaciones clínicas y ambientes controlados, se han

---

<sup>18</sup> Fabián Vicente HORNA LÓPEZ and Luis Mifguel TARÍS RAMOS. "Diseño e implementaición de un sistema alternativo de captura de movimiento para efectos visuales. Caso práctico: Sacrilegio del 4 de mayo de 1897". B.S. thesis. 2013.

<sup>19</sup> Lesly Lisbeth GÓMEZ ECHEVERRY et al. "Sistemas de captura y análisis de movimiento cinemático humano: una revisión sistemática". In: *Prospectiva* 16.2 (2018), pp. 24–34.

<sup>20</sup> Mariana Hernández GONZÁLEZ-MONJE and Norberto MALPICA. "Sistemas basados en vídeo". In: *MANUAL SEN DE* (2021).

<sup>21</sup> Andrés David GIL MIRANDA. "Evaluación del movimiento en pacientes con parkinson utilizando técnicas computacionales para la automatización del protocolo UPDRS mediante el Kinect". In: (2019).

<sup>22</sup> Juan SALVATORE; Jorge OSIO, and Martín MORALES. "Detección de objetos utilizando el sensor Kinect". In: *Guayaquil, Ecuador, LACCEI* (2014).

evidenciado limitaciones para estimar las variaciones angulares de las articulaciones, con respecto a los métodos tradicionales de marcadores <sup>23</sup>.

Por otra parte, métodos basados en visión por computador han logrado estimar la postura humana por medio de cámaras convencionales RGB<sup>24</sup>. Por ejemplo, existen herramientas como *PoseNet*, desarrolladas en colaboración con *Google*, permiten la localización automática de puntos clave articulares. *PoseNet* permite realizar este proceso de manera sencilla y libre en navegadores web mediante algoritmos decodificadores diseñados específicamente para generar las poses <sup>25</sup>. Otro sistema similar es el proporcionado por el framework de *MediaPipe* llamado *MediaPipe Pose*, el cual ofrece la capacidad de identificar puntos clave en el cuerpo humano en imágenes de cámaras RGB utilizando técnicas de aprendizaje automático<sup>26</sup>. Sin embargo, estos métodos son poco robustos, debido a que funcionan a partir de modelos ligeros, pensados para resultados en tiempo real, por lo que son poco precisos e inviables para aplicaciones médicas.

En este sentido, una herramienta que se destaca principalmente por su robustez, confiabilidad y precisión es *OpenPose* <sup>27</sup>, un enfoque que busca emular un sistema de adquisición de datos posturales similar al de los marcadores, pero siendo mucho más económico, rápido y

---

<sup>23</sup> KM PÉREZ-ALBA; AN LEÓN-AGUILAR, and RA SALIDO-RUIZ. “Estudio comparativo de métodos para el análisis del movimiento en 2D: ventajas y desventajas del uso de marcadores”. In: *Memorias del Congreso Nacional de Ingeniería Biomédica*. Vol. 4. 1. 2017, pp. 294–297.

<sup>24</sup> Jesús HERRÁEZ SORIA et al. “Análisis de métodos de identificación personal basados en siluetas”. In: (2010).

<sup>25</sup> Lenin Germán AGUILAR SIGUENZA. “Diseño y desarrollo de un módulo para determinar la postura humana empleando técnicas de visión artificial y reconocimiento de patrones como herramienta de soporte en el desarrollo de la motricidad gruesa de niños con discapacidad”. MA thesis. 2020.

<sup>26</sup> Adriana Samira Jaspón MUTIS; Oscar Julián Perdomo CHARRY, and Juan Alberto Castillo MARTÍNEZ. “Caracterización de movimientos a través de imágenes y sensores inerciales para la prevención de lesiones de miembro superior durante actividades repetitivas”. In: (2023).

<sup>27</sup> Zhe CAO et al. “Realtime multi-person 2d pose estimation using part affinity fields”. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017, pp. 7291–7299.

cómodo. Aunque los resultados no son absolutamente precisos, se acercan notablemente a los obtenidos mediante marcadores, y ha demostrado un error de precisión menor a 30 mm en trabajos como el de Chaves et al.<sup>28</sup>.

La estrategia *OpenPose*<sup>27</sup> permite estimar posturas de múltiples personas, en tiempo real, e incluyendo la detección de cuerpo, pies, manos y expresiones faciales<sup>29</sup>.

### 1.3. Métodos computacionales para la enfermedad del Parkinson

El diagnóstico del Parkinson consiste, principalmente, en la evaluación de los síntomas motores<sup>4</sup> por medio de un análisis de la marcha que permita cuantificar y comprender las anomalías de movimiento con el fin de determinar un pronóstico apropiado<sup>5</sup>. Existen diversas técnicas que permiten evaluar el movimiento y sus alteraciones. Entre ellas, se encuentran distintos sensores que permiten medir parámetros cinemáticos<sup>30</sup>. Estos sensores pueden ayudar a estimar los efectos de los síntomas motores que podrían no ser tan evidentes durante las etapas iniciales de la enfermedad<sup>31</sup>, entre los cuales están los electrogoniómetros, que miden los movimientos angulares de las articulaciones; los sensores electromecánicos inerciales como los acelerómetros<sup>32</sup>, que se colocan en segmentos del cuerpo para medir sus aceleraciones lineales o angulares; o los giroscopios, que miden la velocidad angular o los ángulos de rotación. Todos estos instrumentos magnéticos, iner-

---

<sup>28</sup> Jorge Marquez CHAVEZ and Wei TANG. "A vision-based system for stage classification of parkinsonian gait using machine learning and synthetic data". In: *Sensors* 22.12 (2022), p. 4463.

<sup>29</sup> Estephanie MONTOYA MORALES. "Detección y seguimiento de personas en video". In: (2018).

<sup>30</sup> Rafael CALDAS et al. "A systematic review of gait analysis methods based on inertial sensors and adaptive algorithms". In: *Gait & posture* 57 (2017), pp. 204–210.

<sup>31</sup> Gian PAL and Christopher G GOETZ. "Assessing bradykinesia in parkinsonian disorders". In: *Frontiers in Neurology* 4 (2013), p. 54.

<sup>32</sup> Chia-Yu HSU et al. "Test-retest reliability of an automated infrared-assisted trunk accelerometer-based gait analysis system". In: *Sensors* 16.8 (2016), p. 1156.

ciales o electromecánicos, permiten obtener parámetros cinemáticos durante el movimiento de la persona<sup>33</sup>, sin embargo, su resultado depende del posicionamiento y la elección de la zona a investigar. Además estos sensores tienen la desventaja de ser costosos y complejos<sup>34</sup>, lo que limita su uso y viabilidad a la hora de tomar estos datos. Adicionalmente, su colocación puede alterar el gesto natural del movimiento y debe ser realizada por personal especializado<sup>35</sup>.

Un estudio como el de Balaji et al<sup>36</sup>, empleó una metodología de recopilación de datos mediante marcadores, que implicaba la captura de datos cinéticos a través de marcadores ubicados en las plantas de los pies de los pacientes durante el proceso de marcha. Los datos recopilados se utilizaron posteriormente para llevar a cabo la clasificación de los pacientes mediante algoritmos de clasificación como árboles de decisiones y máquinas de soporte vectorial<sup>36</sup>. A pesar de que los resultados obtenidos en este estudio son prometedores, es fundamental tener en cuenta que este enfoque se centra exclusivamente en los movimientos de los pies. Esto implica que los patrones de movimiento en otras partes del cuerpo podrían no considerarse al clasificar a los pacientes.

Por otra parte, los sistemas ópticos disponibles en la actualidad para la evaluación del Parkinson, se basan en la captura del movimiento mediante el uso de cámaras colocadas en el laboratorio<sup>5</sup>, con el fin de extraer métricas de la marcha, como la longitud del paso, la

---

<sup>33</sup> Danilo DEMARCHI; Rosita RABBITO, and Paolo BONATO. "Using Deep Learning-Based Pose Estimation Algorithms for Markerless Gait Analysis in Rehabilitation Medicine". In: (2021).

<sup>34</sup> Charence WONG et al. "Wearable sensing for solid biomechanics: A review". In: *IEEE Sensors Journal* 15.5 (2015), pp. 2747–2760.

<sup>35</sup> Antonio I CUESTA-VARGAS; Alejandro GALÁN-MERCANT, and Jonathan M WILLIAMS. "The use of inertial sensors system for human motion analysis". In: *Physical Therapy Reviews* 15.6 (2010), pp. 462–473.

<sup>36</sup> E BALAJI; D BRINDHA, and R BALAKRISHNAN. "Supervised machine learning based gait classification system for early detection and stage classification of Parkinson's disease". In: *Applied Soft Computing* 94 (2020), p. 106494.

fuerza de reacción al suelo y el ángulo del pie. Sin embargo, estos modelos tienen problemas similares a los sensores en términos de la complejidad en configurar los elementos en el laboratorio <sup>37</sup> y están sujetos a restricciones geométricas y visuales consideradas para la descripción de los movimientos. Recientemente, han surgido esquemas de aprendizaje automático y aprendizaje profundo que utilizan redes neuronales para extraer características de las imágenes y los vídeos <sup>38</sup>. Estos nuevos esquemas se pueden aplicar al seguimiento de los síntomas motores de la EP <sup>7</sup>. En Cho et al<sup>39</sup> se propone un marco de visión para identificar las características de la marcha de la EP y clasificar a los pacientes en controles sanos y personas con EP. En este algoritmo, se define el vídeo en una serie de imágenes que comprenden los movimientos de la marcha. Este sistema es mejorado por Cho et al <sup>39</sup>, en el cual se incluyen la estratificación de la EP, mediante la implementación de un algoritmo de regresión, sin embargo, estos patrones pueden carecer de claridad con respecto a referentes anatómicos y fisiológicos utilizados en la rutina clínica.

También se han propuesto métodos que utilizan sensores como *Kinect* para recopilar datos de la marcha de los pacientes con EP, como en Tupa et al<sup>40</sup> que se extraen las coordenadas del esqueleto para los datos obtenidos. No obstante, estos sistemas están restringidos al uso en interiores ya que son sistemas basados en luz infrarroja y a su vez tienen limitaciones para hacer un análisis de movimiento humano preciso. La estimación de la postura ha sido un campo activo en los últimos años y muchas investigaciones siguen en exploración, por lo cual, se pueden usar esquemas de aprendizaje con mayor elaboración; como es

---

<sup>37</sup> Fani DELIGIANNI et al. "A fusion framework to estimate plantar ground force distributions and ankle dynamics". In: *Information Fusion* 41 (2018), pp. 255–263.

<sup>38</sup> Junfeng GAO et al. *Computer vision in healthcare applications*. 2018.

<sup>39</sup> Chien-Wen CHO et al. "A vision-based analysis system for gait recognition in patients with Parkinson's disease". In: *Expert Systems with applications* 36.3 (2009), pp. 7033–7039.

<sup>40</sup> Ondřej ŤUPA et al. "Motion tracking and gait feature estimation for recognising Parkinson's disease using MS Kinect". In: *Biomedical engineering online* 14.1 (2015), pp. 1–20.

el caso de *OpenPose* <sup>41</sup>, que utiliza una red neuronal convolucional (CNN) para extraer la postura humana. A partir de la arquitectura de *OpenPose* se han propuesto análisis de marcha alternativos, como es el caso de Viswakumar et al <sup>41</sup>, en el cual se usa un enfoque sin marcadores y *OpenPose*, como sistema de estimación de la postura en 2D, para extraer los puntos de referencia anatómicos y calcular el ángulo de flexión/extensión de la rodilla. Sin embargo, en este método es limitado en cuanto a que su cuantificación se limita únicamente a descripciones locales anormal de ángulos mediante el producto vectorial entre puntos. Recientes esquemas proponen una CNN para la clasificación entre la marcha normal y anormal en enfermedades de la marcha a partir de la estimación de la postura humana realizada por *OpenPose*, pero con la desventaja de que no ofrece un análisis global elaborado sobre las anomalías en los pacientes en vídeo<sup>42</sup>.

También se han llevado a cabo estudios basados en metodologías de visión por computadora, como el trabajo de Guayacán et al.<sup>43</sup>. Este estudio aborda la identificación y cuantificación de patrones de marcha asociados con la enfermedad de Parkinson utilizando una Red Convolucional de Largo Plazo (LTC). La metodología adoptada comprende el análisis de secuencias de videos de individuos con enfermedad de Parkinson y sujetos sanos durante la marcha. A partir de estos datos, se aprenden características usando una red convolucional 3D <sup>44</sup>. Mediante el proceso de retropropagación, la red resalto los patrones de marcha característicos de la enfermedad de Parkinson y a distinguirlos de los patrones de marcha normales<sup>43</sup>. Sin embargo, en este estudio se realiza una caracterización de manera

---

<sup>41</sup> Aditya VISWAKUMAR et al. "Human gait analysis using OpenPose". In: *2019 fifth international conference on image information processing (ICIIP)*. IEEE. 2019, pp. 310–314.

<sup>42</sup> Ali ROHAN et al. "Human pose estimation-based real-time gait analysis using convolutional neural network". In: *IEEE Access* 8 (2020), pp. 191542–191550.

<sup>43</sup> Luis C GUAYACÁN and Fabio MARTÍNEZ. "Visualising and quantifying relevant parkinsonian gait patterns using 3D convolutional network". In: *Journal of biomedical informatics* 123 (2021), p. 103935.

<sup>44</sup> Gül VAROL; Ivan LAPTEV, and Cordelia SCHMID. "Long-term temporal convolutions for action recognition". In: *IEEE transactions on pattern analysis and machine intelligence* 40.6 (2017), pp. 1510–1517.

global, definiendo regiones en lugar de analizar individualmente cada una de las extremidades de los pacientes. Esto puede generar cierta confusión en el contexto médico, ya que no se proporciona una representación detallada y específica de estos patrones.

## **2. Problema de Investigación**

La enfermedad de Parkinson es un trastorno neurodegenerativo prevalente a nivel mundial, que afecta a más de 6 millones de personas, repercutiendo en las funcionalidades motoras de los pacientes y ocasionando algunos síntomas tales como temblores, rigidez, inestabilidad postural, entre otros. El análisis de la marcha constituye una de las principales fuentes de valoración de la enfermedad, permitiendo la cuantificación, clasificación de fenotipos y su consecuente seguimiento, según un procedimiento particular. Sin embargo, los sistemas actuales para el análisis de la marcha emplean tecnologías costosas y complejas tanto económicamente como computacional, como sensores y marcadores en puntos anatómicos clave del cuerpo. Estas tecnologías son ineficientes en términos de tiempo y requieren personal especializado para la colocación de marcadores. Por lo tanto, limita su uso y viabilidad en la adquisición y análisis de datos de la marcha. Adicionalmente, la colocación de los marcadores es compleja, altera el gesto natural de movimiento que se desea estudiar y debe ser realizada por personal especializado. Algunos trabajos computacionales emergentes han propuesto métodos sin marcadores basados en el análisis de vídeo y el aprendizaje profundo para detectar y clasificar enfermedades locomotoras como el Parkinson. Estos enfoques permiten analizar patrones de movimiento en secuencias de vídeo, lo que puede respaldar el diagnóstico médico. Sin embargo, estas metodologías a menudo carecen de información clínicamente relevante relacionada con marcadores anatómicos y fisiológicos utilizados en la práctica médica, lo que limita su utilidad en entornos clínicos al no ser fácilmente interpretables.

### **3. Objetivos**

#### **Objetivo General**

- Determinar patrones motores asociados al Parkinson desde una representación profunda dedicada a la cuantificación de posturas de marcha.

#### **Objetivo Específicos**

- Definir un conjunto de vídeos de marcha en una población con Parkinson y población control para realizar la caracterización postural durante la locomoción.
- Identificar una arquitectura profunda que tenga la capacidad de recuperar posturas durante la locomoción.
- Implementar una estrategia de clasificación de descriptores posturales para la caracterización de la enfermedad del Parkinson.
- Validar la estrategia de caracterización postural en cuanto a la capacidad de discriminar patrones asociados al Parkinson y a pacientes control.

## 4. Método Propuesto

En este trabajo se exploró la caracterización de patrones motores asociados a la enfermedad de Parkinson, a partir de puntos de interés articulares (posturas), calculados sin el uso de marcadores. Primero, se seleccionó e implementó una herramienta computacional para la generación de posturas e identificación de puntos clave corporales a partir de secuencias de vídeo. Posteriormente, se propusieron dos estrategias independientes para caracterizar la enfermedad de Parkinson. En la primera estrategia, se obtuvo una representación convolucional volumétrica analizando globalmente las características intermedias obtenidas por la red de generación de posturas. Para la segunda estrategia propuesta, se llevó a cabo un análisis de las posturas compactadas como descriptores de covarianza y correlación, lo que permitió medir las relaciones dinámicas y de coordinación asociadas a diferentes patrones relacionados a la enfermedad de Parkinson. En las siguientes subsecciones se presenta detalladamente las aproximaciones propuestas para la caracterización de patrones parkinsonianos desde un conjunto de posturas.

### 4.1. *OpenPose*: una arquitectura profunda para la generación de posturas.

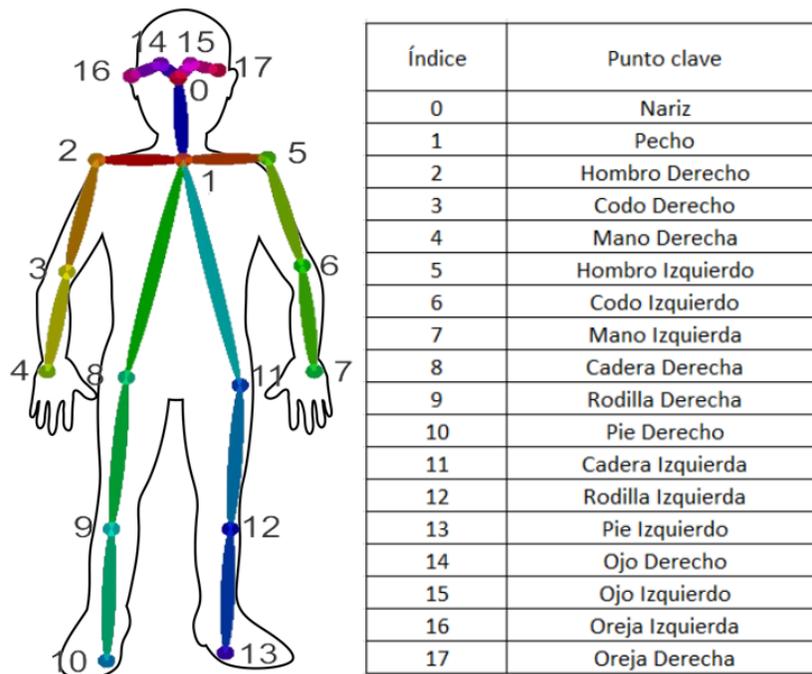
El primer objetivo de este trabajo consistió en la identificación de un método computacional, para la generación de posturas durante un ejercicio de locomoción, cabe destacar que una de las motivaciones es la de usar solo información de vídeo para no sufrir por marcadores externos, que alteren los patrones de locomoción. Con este propósito, se seleccionó *OpenPose*<sup>45</sup>, una arquitectura profunda, ampliamente usada en la literatura, para la estimación de puntos articulares de interés durante el movimiento y realización de acciones.

---

<sup>45</sup> Zhe CAO et al. "Openpose: Realtime multi-person 2d pose estimation using part affinity fields". In: *IEEE transactions on pattern analysis and machine intelligence* 43.1 (2021), pp. 172–186.

En la arquitectura de OpenPose se busca extraer una postura  $P \in \mathbb{N}^J$  (donde  $J \in \{j_1, j_2, \dots, j_n\}$  es el conjunto de  $n$  articulaciones capturadas) dada una imagen de entrada  $I \in \mathbb{R}^{w \times h}$  (es decir,  $I \rightarrow P$ ) y la pose  $P$  en este trabajo cuenta con 18 puntos articulares ( $|J| = 18$  como se ilustra en la figura 1). Estos puntos articulares permiten resumir la dinámica de un sujeto particular durante la locomoción. Particularmente, cada imagen de entrada  $I$  es procesada por capas convolucionales obteniendo un conjunto de activaciones profundas  $F$ , que son minimizadas con respecto a dos ramas de procesamiento: Campos de afinidad ( $L$ ) y mapas de confianza articular ( $S$ ). Una vez procesados los mapas de confianza y campos vectoriales, se debe encontrar coincidencias entre estos, para la asociación de los candidatos a partes del cuerpo<sup>45</sup>.

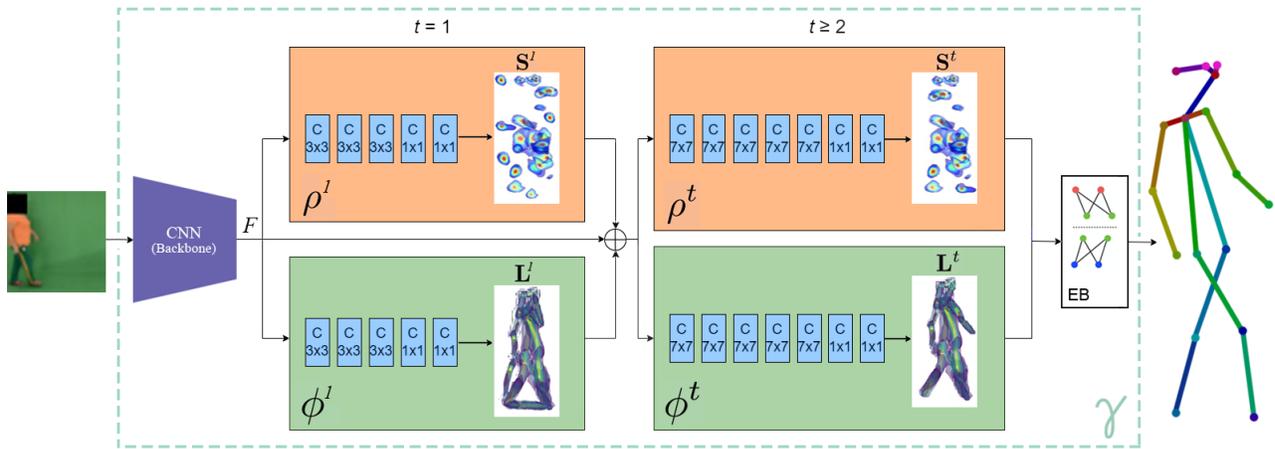
**Figura 1.** Ejemplo de estimación de postura con la respectiva descripción de cada punto y sus conexiones.



Este proceso se realiza iterativamente, a través de un esquema de refinamiento de la predicción por etapas  $t \in \{1, \dots, T\}$ . Como resultado se obtiene un conjunto de puntos sobre las ar-

ticulaciones principales del cuerpo. A continuación se detalla cada uno de los componentes de *OpenPose*. La Figura 2 ilustra las etapas clave del proceso, incluyendo la estimación iterativa de los mapas de confianza y los campos de afinidad, así como el emparejamiento de partes del cuerpo. El funcionamiento global de la red es representado matemáticamente como  $\gamma(I_n)$ .

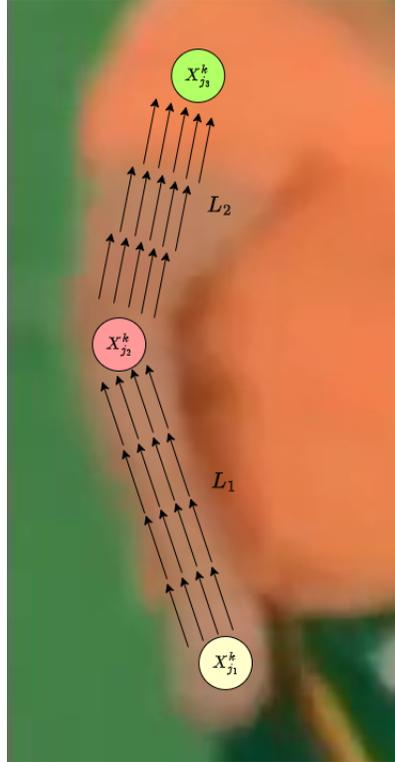
**Figura 2.** Representación gráfica del funcionamiento de *OpenPose*, desde la entrada de la imagen hasta la estimación de la postura correspondiente.



**4.1.1. Campo de afinidad entre articulaciones** Los Campos de Afinidad entre Partes (*PAF*, por sus siglas en inglés) son conjuntos de mapas de vectores 2D que se utilizan para modelar las relaciones espaciales y anatómicas entre pares de articulaciones del cuerpo. Formalmente se describen como un conjunto  $L = \{L_i\}_{i=1}^C$ , donde  $L_i \in \mathbb{R}^{w \times h \times 2}$ , y  $C$  es un hiperparámetro de los PAFs a encontrar. Cada píxel dentro del PAF contiene un vector que representa la dirección y la fuerza de la conexión entre el par de articulaciones correspondientes. La dirección del vector indica la orientación de la conexión, y la magnitud del vector representa la confianza en esa conexión, como se puede ver en la figura 3.

Inicialmente, la red genera un conjunto de *PAF*, representados como  $L^{t=1} = \phi^{t=1}(F)$ , donde  $\phi^{t=1}$  se refiere a las capas convolucionales utilizadas para el cálculo de los *PAF* en  $t = 1$ . Por

**Figura 3.** Representación de los *PAFs* originados entre los puntos de  $X_{j_1,k}^k$  hacia  $X_{j_2,k}^k$  y de este último hacia el punto de  $X_{j_3,k}^k$ .

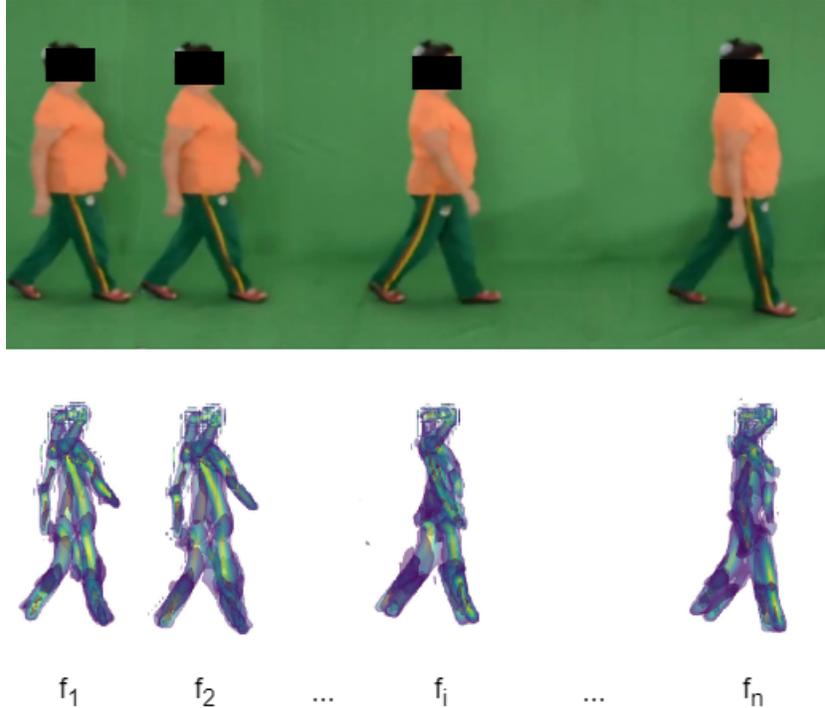


cada etapa de refinamiento subsiguiente, se utilizarán los *PAF* predichos en la etapa previa, las características originales  $F$ , y un conjunto de mapas de confianza articulares ( $S^{t-1}$ ) se combinan y se emplean para generar las predicciones refinadas:

$$L^t = \phi^t(F, S^{t-1}, L^{t-1}), \quad \text{para } t \geq 2. \quad (1)$$

Este enfoque permite el refinamiento progresivo de los *PAF*, contribuyendo al proceso de detección y asociación de las diversas partes del cuerpo. En la figura 4 se puede observar las activaciones resultantes de estos campos, los cuales son potenciales representaciones intermedias del proceso de locomoción, incluyendo las direcciones predominantes durante la locomoción.

**Figura 4.** Visualización de todos los campos de afinidad (*PAF*) obtenidos durante la marcha de un sujeto control.



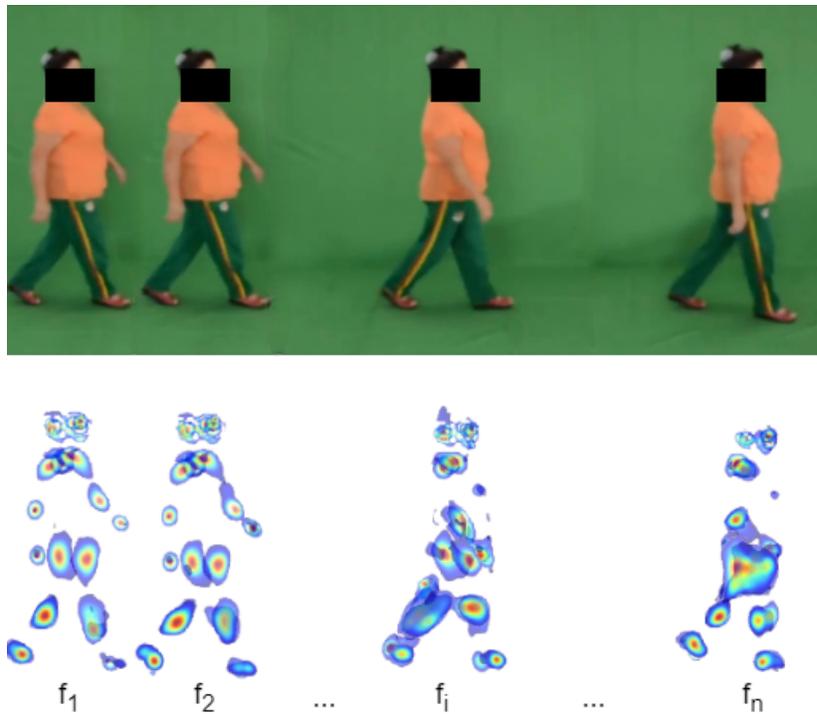
**4.1.2. Mapas de confianza articulares** En una rama paralela del procesamiento, otro banco de filtros convolucionales sirven como entrada para generar una representación probabilística de las poses. Particularmente, un mapa de confianza articular (*JCM*, por sus siglas en inglés) es una representación bidimensional que refleja la probabilidad de que una determinada parte del cuerpo pueda estar ubicada en algún píxel en específico. Formalmente se describen como un conjunto  $S = \{S_j\}_{j=1}^J$ , con  $S_j \in \mathbb{R}^{w \times h}$ , donde  $J \in \{j_1, j_2, \dots, j_n\}$  es la cantidad de partes del cuerpo (articulaciones). Cada píxel en  $S_j$  contiene un valor que representa la probabilidad de que la articulación  $j$  esté ubicada en esa posición de la imagen. En otras palabras, los *JCM* indican cuán seguro está el modelo de que una articulación específica se encuentra en cada píxel de la imagen.

De manera análoga a la generación de los *PAF* inicialmente, la red genera un conjunto de *JCM*, representados como  $S^{t=1} = \rho^{t=1}(F)$ , donde  $\rho^{t=1}$  se refiere al módulo convolucional

utilizado para el cálculo de los mapas en  $t = 1$ . En cada etapa de refinamiento subsiguiente, los  $JCM$  y  $PAF$  de la etapa previa, junto a las características  $F$  se combinan para generar las predicciones refinadas (ver Figura 5):

$$S^t = \rho^t(F, S^{t-1}, L^{t-1}), \quad \text{para } t \geq 2. \quad (2)$$

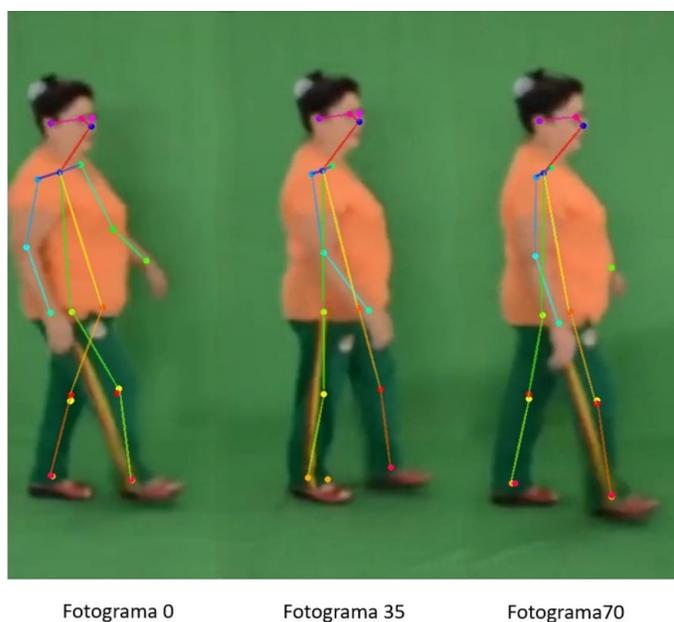
**Figura 5.** Visualización de todos los mapas de confianza ( $JCM$ ) obtenidos durante la marcha de un sujeto control.



**4.1.3. Asociación de partes** Una vez realizadas las  $T$  etapas de refinamiento, se ensamblan las partes candidatas siguiendo un proceso de emparejamiento bipartito (EB) de grafos. Formalmente, dado un par específico de partes del cuerpo,  $j_x$  y  $j_y$ , se busca encontrar la asociación óptima entre los candidatos detectados, luego, se crea un grafo bipartito donde sus nodos son los candidatos de detección ( $JCM$ ) de  $j_x$  y  $j_y$ , y las aristas son todas las posibles conexiones entre estos candidatos ( $PAF$ ). El objetivo es encontrar un empare-

amiento entre dos nodos que maximice el peso total de las aristas seleccionadas usando los JCM como ponderación de las aristas. Este emparejamiento garantiza que cada candidato de detección de  $j_x$  esté asociado con exactamente un candidato de detección de  $j_y$  y viceversa. Finalmente, utilizando el algoritmo <sup>46</sup> se encuentra el emparejamiento máximo en grafos bipartitos ponderados, entre las diferentes partes del cuerpo con sentido espacial y anatómico, como se observa en la figura 6.

**Figura 6.** Ejemplo de estimación de postura usando *OpenPose* para diferentes fotogramas de video.



## 4.2. Red convolucional 3D para clasificar patrones parkinsonianos

Una vez ajustada la arquitectura de *OpenPose* con videos de sujetos control y pacientes con Parkinson, se pueden obtener representaciones intermedias de la representación : los campos de afinidad entre articulaciones ( $L$ ) y los mapas de confianza articular ( $S$ ). Estas

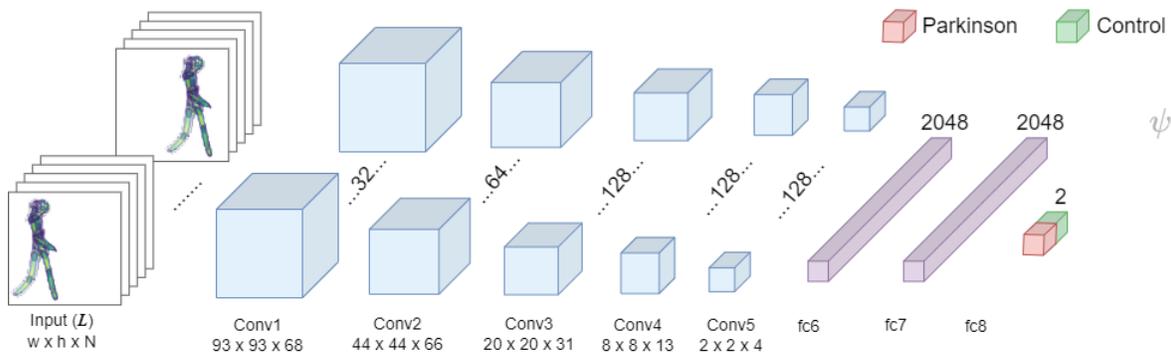
---

<sup>46</sup> Harold W KUHN. "The Hungarian method for the assignment problem". In: *Naval research logistics quarterly* 2.1-2 (1955), pp. 83–97.

representaciones intermedias son activaciones de *OpenPose*, que contienen información relevante sobre la cinemática durante la locomoción ( $L$ ) y la importancia articular en cada fotograma ( $S$ ).

Entonces como primer enfoque de clasificación, se propuso el uso de las representaciones profundas intermedias ( $L$  y  $S$ ), para la caracterización de patrones motores espacio-temporales relacionados a la enfermedad de Parkinson. Para ello, se diseñó y ajustó una red convolucional 3D, que permite aprender relaciones profundas considerando el carácter volumetrico de la información. La arquitectura convolucional 3D especializada en la extracción de características espacio-temporales, a partir de vídeos completos. Este tipo de arquitecturas volumetricas logra capturar patrones temporales a largo plazo en datos secuenciales. Esto es fundamental en el análisis de marcha parkinsoniana, ya que varios síntomas cardinales de la EP requieren una observación prolongada, a lo largo del ciclo de la marcha, para ser correctamente identificados. De hecho, estas representaciones volumétricas, con convoluciones 3D, han sido propuestas en la literatura para el análisis de video en diferentes tareas, como por ejemplo en el reconocimiento de acciones <sup>44</sup>.

**Figura 7.** Arquitectura de la red *LTC* utilizada para clasificar las secuencias de campos de afinidad generados con *OpenPose* y estimar la probabilidad de pertenecer a un paciente con EP.



Particularmente en este trabajo, se obtuvieron los *PAF*  $L$  de cada fotograma  $I_n$  de video de marcha durante la última etapa de refinamiento ( $t = T$ ), es decir  $L = \{L^T(I_n)\}_{n=1}^N$ , donde  $N$  corresponde al número total de fotogramas del video. Luego, el conjunto de *PAF* correspondiente a todos los fotogramas  $L$  fue ingresado a la arquitectura convolucional 3D. Esta

arquitectura considera convoluciones espacio-temporales para poder identificar los distintos patrones que se puedan presentar en un proceso de marcha para determinar la probabilidad de que estos correspondieran a un paciente con EP o a un sujeto control, como se muestra en la Figura 7. Formalmente, el funcionamiento de la red se puede expresar como  $P(EP|\mathbf{L}) = 1 - P(\text{control}|\mathbf{L}) = \psi(\mathbf{L})$ , donde  $\psi$  representa el conjunto de kernels, capas, funciones y operaciones que conforman al modelo.

Cabe resaltar que la representación intermedia de los *PAF*, contienen información direccional sobre el posicionamiento de las articulaciones, entonces se espera que a través de las convoluciones 3D, la arquitectura aprenda las cinemáticas con mayor carácter discriminativo entre los sujetos control y patrones Parkinsonianos. Del mismo modo, en este trabajo también se ajustó la arquitectura volumétrica con mapas de confianza articular, esperando que a través de las convoluciones, se logre aprender una coherencia temporal entre activaciones estructurales, que pueden ser a su vez discriminantes.

### **4.3. Descriptor de posturas basado en la covarianza**

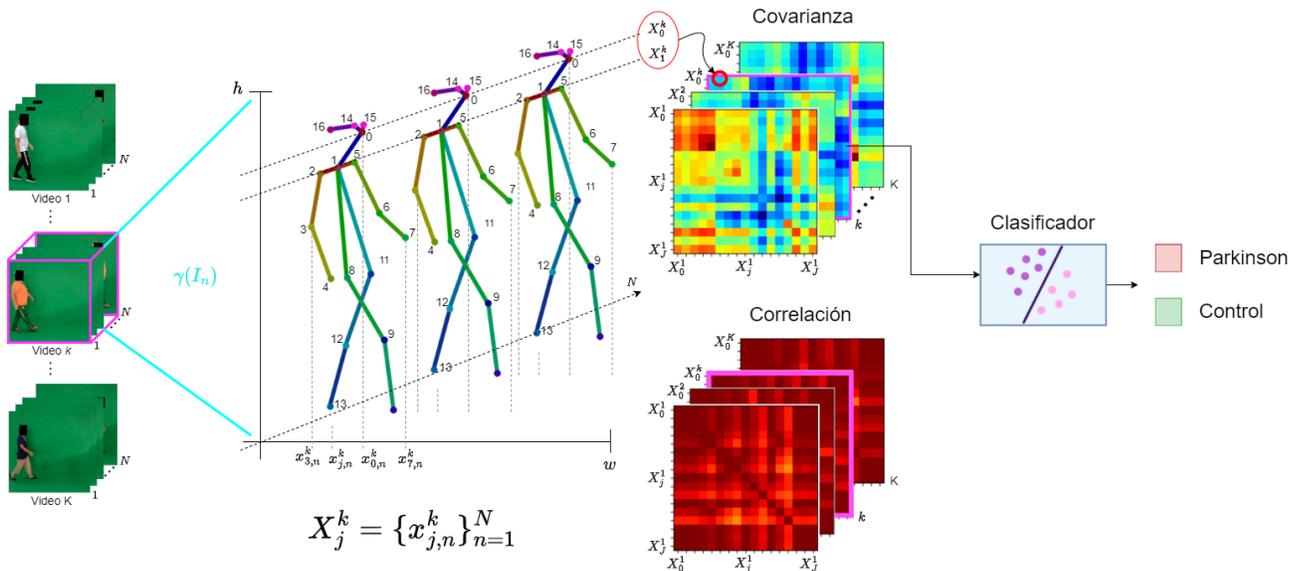
La marcha humana es producto de una compleja interacción de subsistemas corporales que permiten el movimiento eficiente y sincronizado de las diferentes extremidades, soportado por una postura normalmente erguida. En este sentido, la locomoción puede ser discretizada en un conjunto de puntos articulares, y analizada como la cinemática correspondiente a los movimientos de estos puntos articulares, así como las relaciones de sincronización entre ellos, durante los ejercicios de locomoción. Es por ello, que en este trabajo se usó un segundo enfoque de análisis basado en la caracterización y modelamiento de las posturas. Así, se propuso la utilización de los puntos clave obtenidos al final de la red *OpenPose*, resumiendo su dinámica en puntos en un descriptor de covarianza, que codifica la información en índices de segundo orden.

Teniendo en cuenta lo anterior, se contruyó una matriz de covarianza como descriptor compacto que resume la cinemática postural entre las trayectorias de las articulaciones. Este

descriptor ofrece información de la coordinación motora, una característica predominante en el análisis de marchas parkinsonianas. De hecho, en el caso de la EP, que afecta el control motor, se pueden observar movimientos menos armoniosos e identificar anomalías en la relación y la fuerza de dependencia entre dos partes del cuerpo. Además, estos descriptores permiten explicar las relaciones cinemáticas entre las articulaciones de interés, permitiendo la identificación de relaciones articulares relevantes.

Para la codificación de estos descriptores de segundo orden, primero se obtuvieron las coordenadas articulares  $\gamma(I_n)$  para cada uno de los  $N$  fotogramas del vídeo  $k$ . Luego, considerando que en la marcha predominan los desplazamientos articulares en el plano horizontal, se calcularon las matrices de covarianza usando exclusivamente las coordenadas horizontales  $X_j^k = \{x_{j,n}^k\}_{n=1}^N$  de la articulación  $j$ , donde  $x_{j,n}^k \in [0, w]$ . Una representación visual del enfoque propuesto se presenta en la Figura 8.

**Figura 8.** Esquema propuesto para la generación de matrices de covarianza y correlación a partir de los puntos clave articulares y su posterior clasificación.



Con estas trayectorias calculadas por cada punto articular de interés, se construyó una matriz de covarianza calculando la relación lineal entre cada par de puntos articulares  $(j_1, j_2)$  del

video  $k$  como se muestra en la ecuación (3).

$$Cov(j1, j2) = \frac{1}{N} \sum_{n=1}^N (X_{j1,n}^k - \bar{X}_{j1}^k)(X_{j2,n}^k - \bar{X}_{j2}^k) \quad (3)$$

El valor de la covarianza refleja la medida en que ambas coordenadas se distancian simultáneamente de su media. Un resultado positivo indica que los valores de  $j1$  e  $j2$  se desvían en la misma dirección de sus medias respectivas. Cuando el valor es cercano, la covarianza señala que no existe una relación lineal significativa entre  $j1$  y  $j2$ . Entonces, los cambios cinemáticos del conjunto de posturas durante un proceso de locomoción, son resumidos en un descriptor de covarianza  $C$ . Este descriptor de covarianza  $C$  permite interpretar de la relación entre las posiciones articulares, así como también permite encontrar patrones discriminativos entre la población de EP y los pacientes control <sup>47</sup>.

Estos descriptores covarianza  $C$  son entonces usados como descriptores para entrenar algoritmos supervisados de clasificación. Particularmente, estas covarianzas son matrices simétricas positivas y co-existen en un espacio cónico, denominado la variedad de Riemann. Entonces cada matriz de covarianza debe ser proyectada a un plano tangente, como  $\log C$ , permitiendo de esta forma operar con restricciones típicas de los algoritmos de clasificación. Entonces por cada muestra de video, se obtiene la tupla  $(\log C, y_i)$ , siendo  $y_i$  la etiqueta asociada al video, permitiendo modelar un problema supervisado.

Por otra parte, este descriptor de covarianza permite explicar la coordinación entre pares articulares. Para ello, se realiza una normalización con respecto a las varianzas de las variables, obteniendo así una matrix de correlación. Es decir, se obtiene una medida estandarizada que varía entre -1 y 1. Una correlación de 1 significa una relación lineal positiva perfecta, -1 significa una relación lineal negativa perfecta, y 0 significa que no hay relación lineal. Esta correlación se calcula entre cada par de puntos articulares  $(j1, j2)$  como se

---

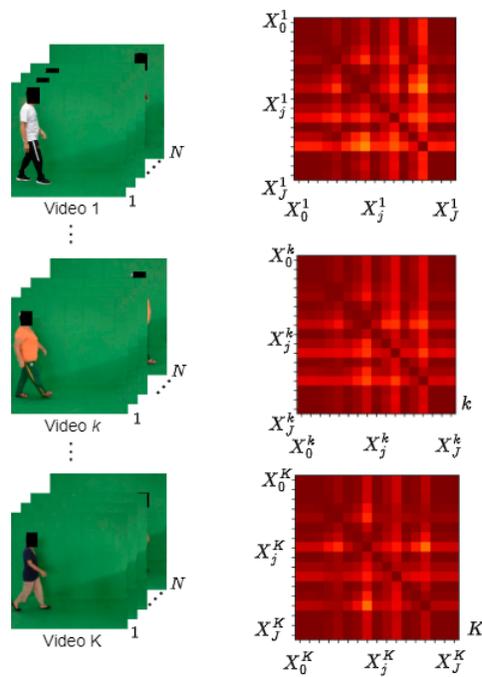
<sup>47</sup> Pedro CHANÁ and Daniela ALBURQUERQUE. "Enfermedad de parkinson". In: *Chile. Universidad de Santiago de Chile. CETRAM* (2010).

muestra en la ecuación (4).

$$Corr(j1, j2) = \frac{Cov(j1, j2)}{\sigma_{j1}\sigma_{j2}} \quad (4)$$

Esta matrix normalizada ofrece mayor interpretabilidad de los resultados, esto lo podemos evidenciar en la Figura 9. Es así, que estos descriptores también pueden resultar en herramientas útiles para el análisis observacional de la marcha, indicando directamente relaciones articulares con menor capacidad de coordinación. Así la herramienta puede ofrecer patrones distintivos para identificar anomalías tempranas asociadas con la EP.

**Figura 9.** Generación de matrices correlación a partir de los puntos clave articulares y caracterización de coordinación de movimiento en marcha.



## 5. Diseño Experimental

### 5.1. Descripción de la base de datos

La base de datos utilizada en este trabajo comprende una serie de videos RGB capturados sin marcadores, durante un ejercicio de locomoción. En este estudio se invitaron a participar a 30 sujetos, de los cuales 16 fueron sujetos control y 14 habían sido diagnosticados con EP. Los pacientes con EP se encontraban en etapas de la enfermedad entre 1.0 y 3.0, según la escala de Hoehn y Yahr. En total 8 pacientes estaban diagnosticados en el grado menor e igual a 2.5, y 6 pacientes entre el grado 2.5 a 3.0. Cada sujeto en el estudio fue grabado en ocho ocasiones mientras realizaba caminatas naturales sin marcadores, cuatro veces hacia la izquierda y cuatro veces hacia la derecha, para un total de 240 secuencias de video. Este conjunto de datos se encuentra balanceado por edad, con una edad promedio de  $70.4 \pm 5.38$  años para los pacientes de control y  $73 \pm 7.45$  años para los pacientes con EP. Todos los videos se grabaron en interiores, con una cámara estática y un fondo de color uniforme. La duración promedio de los videos es de 1 a 2 segundos. Todos los participantes proporcionaron su consentimiento informado y la investigación fue aprobada por el comité de ética de la Universidad Industrial de Santander.

### 5.2. Configuración de la metodología

**5.2.1. Configuración para la extracción de poses** De cada video, seleccionamos  $N = 70$  fotogramas intermedios (para cubrir aproximadamente un ciclo de marcha). En cada registro de video se asegura un ciclo completo de marcha, lo que garantiza una exposición completa de la cinemática durante la locomoción. Los videos se redimensionaron a un tamaño de  $95 \times 95$  píxeles ( $w \times h$ ). Cada fotograma se pasó individualmente a la red *OpenPose* para la estimación de la postura. Para la extracción de características convolu-

cionales se utilizó la red VGG19 <sup>48</sup>. Luego, estas características profundas se utilizaron para la generación de *PAF* y *JCM*; para esto se hizo uso de un numero de etapas  $t$  igual a 6.

**5.2.2. Configuración de la red convolucional 3D** La arquitectura convolucional propuesta para la clasificación de patrones parkinsonianos desde secuencias *PAF* y *JCM*, fue ajustada considerando diferentes niveles convolucionales y vectores embebidos. En este trabajo particularmente se validaron las configuraciones: 5 Conv3D 3 densas, 5 Conv3D 1 densas, 3 Conv3D 3 densas y 3 Conv3D 1 densa. Para nuestro modelos usamos 10 épocas de entrenamiento, una tasa de aprendizaje de  $1 \times 10^{-4}$ , un optimizador de tipo Adam y una función de pérdida de entropía cruzada.

Para la evaluación de cada una de las configuraciones se siguió un esquema de validación cruzada de *leave-one-patient-out*, en el que se realiza un modelo por cada paciente, teniendo las demás muestras para el entrenamiento del modelo. Además se realizó una validación con métricas de clasificación, como son exactitud, precisión, sensibilidad, f2-score y área bajo la curva "*AUC*".

**5.2.3. Descriptor de covarianza de posturas** Para la construcción de matrices de covarianza, se utilizaron las trayectorias de la coordenada  $X$  para cada uno de los puntos articulares generados por *OpenPose*. El tamaño total de cada descriptor es de  $17 \times 17$ , por cada uno de los videos registrados en la base de datos. Estas matrices de covarianza fueron validadas como descriptores para la clasificación entre Parkinson y sujetos control, usando algoritmos típicos de aprendizaje de máquina, tales como: Bosque aleatorio (*RF*), maquina de soporte vectorial (*SVM*), K-vecinos más cercanos (*K-NN*), clasificador bayesiano ingenuo (*NB*) y aumento de gradiente (*GB*). Además, se hicieron experimentos adicionales usando matrices de covarianza compactos, codificando únicamente los puntos articulares de la

---

<sup>48</sup> Karen SIMONYAN and Andrew ZISSERMAN. "Very deep convolutional networks for large-scale image recognition". In: *arXiv preprint arXiv:1409.1556* (2014).

parte superior e inferior, respectivamente. Para la validación de este descriptor también se utilizó una validación cruzada, bajo un esquema de *leave-one-patient-out*, obteniendo configuraciones por cada uno de los pacientes incluidos en el estudio, y utilizando las restantes muestras como entrenamiento.

## 6. Evaluación y Resultados

La metodología propuesta en este trabajo fue validada con respecto a las dos aproximaciones que utilizan la información resultante de la representación de posturas. A continuación se detallan los resultados logrados sobre estas aproximaciones.

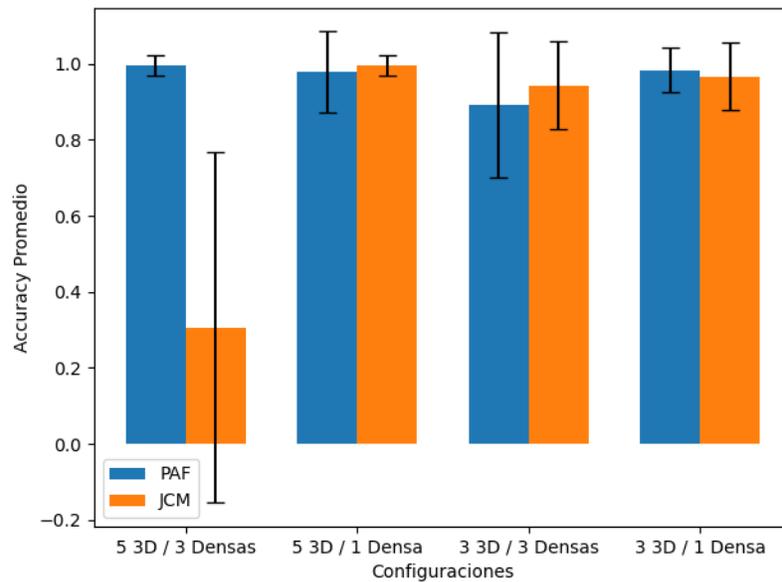
### 6.1. Caracterización de representaciones intermedias posturales y la red convolucional 3D

Para la validación de la capacidad de las representaciones intermedias de posturas, proyectamos las activaciones *PAF* y *JCM*, extraídas de la arquitectura *OpenPose*. Este bloque de activaciones fue proyectado a una arquitectura volumétrica convolucional para aprender representaciones discriminativas entre el Parkinson y una población control. Al mismo tiempo, se validó la representación convolucional que permitía mejor desempeño en la tarea de discriminación, determinando las diferentes capas convolucionales 3D, así como también los vectores embebidos asociados. La figura 10 muestra los resultados obtenidos para el conjunto total de 22 pacientes, teniendo como base de medida la exactitud en el proceso de clasificación.

Como se observa en la figura 10 la representación intermedia *PAF* reporta resultados coherentes y robustos frente a las diferentes configuraciones de la arquitectura entrenada. Los mapas vectoriales *PAF* pueden tener un impacto en las orientaciones de las posturas, lo cual puede ser un patron caracteristico que le permite a la red discriminar entre las dos poblaciones de estudio. Por otra parte, la representación *JCM* muestra un comportamiento inferior en la arquitectura con 3 capas densas, lo cual puede ser consecuencia de los limitados datos de entrenamiento, que en el caso particular de los mapas *JCM* exhiben información reducida de mapas de atención alrededor de las articulaciones.

En un segundo experimento, se realizó una comparación con una propuesta del estado

**Figura 10.** Comparación de exactitud de clasificación de pacientes control y Parkinson para distintas configuraciones, usando como entrada los *PAF* contra los *JCM*



**Tabla 1.** Comparación de métricas de clasificación de pacientes control y Parkinson entre nuestra propuesta con estado del arte

Métrica	RGB	OF	Propuesta (PAF)	Propuesta (JCM)
Exactitud (%)	94.89	84.66	99.43	99.43
Precisión	0.91	0.87	1	0.9887
Sensibilidad	1	0.78	0.9886	1
F2-Score	0.78	0.70	0.9909	0.9977
AUC	0.95	0.91	0.9987	1

del arte que propone la representación volumétrica, pero utilizando proyecciones de los videos crudos o mapeando la respuesta de un algoritmo de flujo óptico<sup>43</sup>. En la tabla1 se resumen los resultados obtenidos por el método del estado del arte, con una arquitectura de características similares (convoluciones 3d) sobre secuencias RGB y de flujo, así como las proyecciones usando las representaciones intermedias utilizando los mapas *PAF* y *JCM*. Como se observa, en general todas las proyecciones exhiben un comportamiento notable en las métricas de clasificación. Este resultado puede estar asociado al conjunto limitado de datos o también a los estadios de la población del Parkinson. Sin embargo, para los datos

**Tabla 2.** Comparación de métricas de clasificación de pacientes control y Parkinson por covarianzas de puntos de extremidades inferiores, no se muestra una buena clasificación entre los pacientes

<b>Métrica</b>	<b>RF</b>	<b>SVM</b>	<b>K-NN</b>	<b>NB</b>	<b>GB</b>
Exactitud (%)	53.41	43.75	48.86	46.59	48.86
Especificidad	0.5341	0.4773	0.6705	0.50	0.5227
Sensibilidad	0.5341	0.3977	0.3068	0.4310	0.4545

valorados los métodos logran un puntaje significativo en la clasificación. También cabe resaltar que las proyecciones intermedias logran una mejor representación de la información, clasificando correctamente las muestras de los videos mapeados (obteniendo una precisión, sensibilidad y *AUC* perfectos en alguna de las dos configuraciones). Cabe destacar además que el *AUC* reportado para los mapas intermedios, no solo lo hace robusto ante una clasificación binaria, sino que demuestra una alta separación entre las clases, lo cual puede ser determinante al extenderlo a estudios mas exhaustivos con casos adicionales. Por otra parte, estos mapas pueden tener un mayor carácter explicativo, descomponiendo la información cinemática en partes de la postura.

## 6.2. Descriptor de covarianza para las posturas

En un segundo análisis, se tomaron las posturas generadas por Openpose y se codificaron matrices de covarianza para determinar el carácter discriminatorio y explicativo entre la población de Parkinson y la población control. En un primer análisis, se construyeron matrices de covarianza utilizando únicamente los puntos articulares que corresponden a las extremidades inferiores. Esto, siguiendo los protocolos típicos de análisis que solo se detallan en la cinemática de las piernas durante la locomoción. Este descriptor fue proyectado a diferentes clasificadores típicos de aprendizaje de máquina para obtener una medida de caracterización del Parkinson. En la tabla 2 se resumen los resultados obtenidos con estos puntos articulares.

Como se puede observar, el mejor método de clasificación es el *Random forest*, logrando en promedio una exactitud del 53%. En este caso se puede evidenciar insuficiencia de la

**Tabla 3.** Comparación de métricas de clasificación de pacientes control y Parkinson por covarianzas de puntos en general, valores de exactitud entre el 66-76% en clasificación dando una mejora significativa respecto a la tabla anterior

<b>Métrica</b>	<b>RF</b>	<b>SVM</b>	<b>K-NN</b>	<b>NB</b>	<b>GB</b>
Exactitud (%)	71.59	68.18	74.43	76.14	66.48
Especificidad	0.6818	0.6932	0.7955	0.7841	0.6705
Sensibilidad	0.75	0.6705	0.6932	0.7386	0.6591

información postural para determinar patrones asociados al Parkinson. De hecho algunos patrones tienen una relación con la inclinación del tronco o coordinación entre miembros superiores e inferiores, que en este descriptor no se tiene en cuenta. Además, cabe destacar que estos resultados muestran una limitación típica de los protocolos en la clínica, al basarse únicamente la parte inferior del cuerpo para hacer una estimación cinemática durante la marcha.

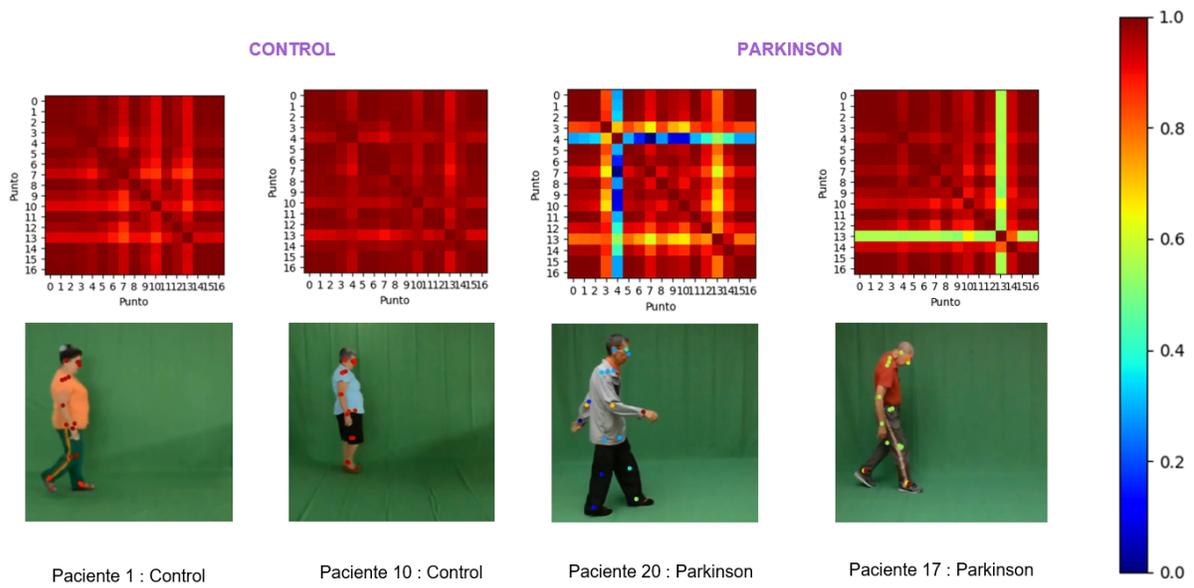
Teniendo en cuenta lo anterior, en un segundo experimento se decidió construir matrices de covarianza teniendo en cuenta todas las variables articulares brindadas por open-pose. Luego estas matrices fueron mapeadas a los clasificadores para obtener un puntaje de discriminación. En la tabla 3 se resumen los resultados obtenidos por estas matrices de covarianza utilizando diferentes clasificadores.

Como se puede observar, la inclusión de todos los puntos articulares demuestra un comportamiento destacable para la discriminación de las matrices. De hecho estos descriptores se componen únicamente de 17 valores escalares, logrando compactar la información de la locomoción e incluyendo patrones que pueden discriminar sujetos control de pacientes con la EP. En este caso, el método logró una exactitud del 71.5% utilizando un *Random forest*. Este descriptor puede ser utilizado como un esquema ágil para identificación de pacientes con la enfermedad, pero además como soporte en el diagnóstico y seguimiento de los pacientes.

De manera interesante, estos descriptores también pueden ser utilizados como herramientas de soporte observacional. Para ello, las matrices de covarianza fueron normalizadas y

expuestas como matrices de correlación, que permiten resaltar patrones de alta relación entre las articulaciones. Estos descriptores pueden ser indicadores de coordinación, lo cual facilitaría la labor de los profesionales en rehabilitación. En la Figura 11 podemos observar diferentes ejemplos para pacientes con la EP y sujetos control. Para esta visualización, los tonos azules indican una baja correlación mientras los tonos rojos indican una fuerte correlación o coordinación dinámica entre las articulaciones de interés. Resulta de bastante interés, como los pacientes con Parkinson muestran valores de baja coordinación entre la articulación que corresponde a mano derecha (punto 4) y pie izquierdo (punto 13). Esto resalta patrones parkinsonianos típicos.

**Figura 11.** Comparación de matrices de correlación de los movimientos entre dos pacientes control (izquierda) y dos pacientes parkinson (derecha)



## 7. Conclusiones y Perspectivas

En este trabajo se presentó una metodología para explotar representaciones articulares de la marcha, utilizando un framework sin marcadores, que permite discriminar entre una población diagnosticada con la EP y sujetos control. Para obtener una representación basada en posturas se utilizó la arquitectura de *OpenPose*, capturando no solo las configuraciones estructurales de las articulaciones, sino además obteniendo representaciones intermedias. Estas representaciones ofrecen información dominante de las posturas y pueden contener información estructural relevante para la clasificación.

En este estudio se seleccionó y acondicionó un conjunto de datos de pacientes con Parkinson y sujetos control, previamente capturados por el grupo de investigación *BIVL<sup>2</sup>ab*. Estos datos fueron mapeados a la red de *OpenPose* para obtener las posturas y las representaciones intermedias durante cada registro de locomoción. Una vez obtenidas las representaciones intermedias de la red generadora de posturas, se realizó un enfoque convolucional volumétrico para aprender patrones espacio-temporales, que fueran discriminativos y permitieran clasificar pacientes con Parkinson. Los resultados mostraron una alta capacidad en esta tarea, siendo estos índices potenciales indicadores de anomalías asociadas con la enfermedad, durante las tareas de locomoción.

Además, en este trabajo también se construyó un descriptor basado en la covarianza de las posturas que permitió codificar las relaciones de coordinación temporal entre diferentes puntos articulares, así como también ser usado como clasificador de pacientes con la EP. Este descriptor fue validado con diferentes métodos de clasificación, obteniendo resultados prometedores para vectores de descripción compactos. También estas matrices de covarianza fueron normalizadas y expuestas como una herramienta de soporte observacional, que puede apoyar a profesionales de la salud en la caracterización de pacientes.

En perspectiva, se plantea fortalecer significativamente la capacidad de clasificación a través de la implementación de la metodología de caracterización basada en matrices de covari-

anza. Estamos encaminados a alcanzar resultados que alcancen un nivel de competitividad superior, convirtiendo así nuestra herramienta en una valiosa contribución para la industria médica. Paralelamente, estamos entusiasmados por la perspectiva de fusionar ambos enfoques, buscando una sinergia que permita aprovechar al máximo las virtudes de cada esquema propuesto. Además, tenemos previsto extender nuestras pruebas a diversas bases de datos adicionales, dado que las actuales presentan limitaciones en cuanto a cantidad de datos de pacientes y no han sido capaces de abordar ciertos movimientos anómalos que podrían estar relacionados con la enfermedad de Parkinson en pacientes que no tenemos en cuenta aún.

## BIBLIOGRAFÍA

AGUILAR SIGUENZA, Lenin Germán. “Diseño y desarrollo de un módulo para determinar la postura humana empleando técnicas de visión artificial y reconocimiento de patrones como herramienta de soporte en el desarrollo de la motricidad gruesa de niños con discapacidad”. MA thesis. 2020 (cit. on p. 17).

ARIZA-SERRANO, Lina M et al. “Caracterización de pacientes con enfermedad de Parkinson en un centro de referencia de la ciudad de Bogotá, Colombia”. In: *Acta Neurológica Colombiana* 32.3 (2016), pp. 203–208 (cit. on p. 13).

BAKER, Richard. “Gait analysis methods in rehabilitation”. In: *Journal of neuroengineering and rehabilitation* 3.1 (2006), pp. 1–10 (cit. on pp. 11, 18, 19).

BALAJI, E; BRINDHA, D, and BALAKRISHNAN, R. “Supervised machine learning based gait classification system for early detection and stage classification of Parkinson’s disease”. In: *Applied Soft Computing* 94 (2020), p. 106494 (cit. on p. 19).

BERGANZO, K et al. “Síntomas no motores y motores en la enfermedad de Parkinson y su relación con la calidad de vida y los distintos subgrupos clínicos”. In: *Neurología* 31.9 (2016), pp. 585–591 (cit. on p. 13).

BOSBOOM, JL W; CORONA, T, and E CH, WOLTERS. “Psicosis en la enfermedad de Parkinson”. In: *Archivos de neurociencias (México, DF)* 9.1 (2004), pp. 25–33 (cit. on p. 13).

CALDAS, Rafael et al. “A systematic review of gait analysis methods based on inertial sensors and adaptive algorithms”. In: *Gait & posture* 57 (2017), pp. 204–210 (cit. on p. 18).

CAO, Zhe et al. “Openpose: Realtime multi-person 2d pose estimation using part affinity fields”. In: *IEEE transactions on pattern analysis and machine intelligence* 43.1 (2021), pp. 172–186 (cit. on pp. 25, 26).

CAO, Zhe et al. “Realtime multi-person 2d pose estimation using part affinity fields”. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017, pp. 7291–7299 (cit. on pp. 17, 18).

CHANÁ, Pedro and ALBURQUERQUE, Daniela. “Enfermedad de parkinson”. In: *Chile. Universidad de Santiago de Chile. CETRAM* (2010) (cit. on p. 35).

CHAVEZ, Jorge Marquez and TANG, Wei. “A vision-based system for stage classification of parkinsonian gait using machine learning and synthetic data”. In: *Sensors* 22.12 (2022), p. 4463 (cit. on p. 18).

CHO, Chien-Wen et al. “A vision-based analysis system for gait recognition in patients with Parkinson’s disease”. In: *Expert Systems with applications* 36.3 (2009), pp. 7033–7039 (cit. on p. 20).

CUESTA-VARGAS, Antonio I; GALÁN-MERCANT, Alejandro, and WILLIAMS, Jonathan M. “The use of inertial sensors system for human motion analysis”. In: *Physical Therapy Reviews* 15.6 (2010), pp. 462–473 (cit. on p. 19).

DELIGIANNI, Fani et al. “A fusion framework to estimate plantar ground force distributions and ankle dynamics”. In: *Information Fusion* 41 (2018), pp. 255–263 (cit. on p. 20).

DEMARCHI, Danilo; RABBITO, Rosita, and BONATO, Paolo. “Using Deep Learning-Based Pose Estimation Algorithms for Markerless Gait Analysis in Rehabilitation Medicine”. In: (2021) (cit. on p. 19).

DORSEY, E et al. “The emerging evidence of the Parkinson pandemic”. In: *Journal of Parkinson's disease* 8.s1 (2018), S3–S8 (cit. on p. 11).

FEIGIN, Valery L et al. “Burden of neurological disorders across the US from 1990-2017: a global burden of disease study”. In: *JAMA neurology* 78.2 (2021), pp. 165–176 (cit. on p. 11).

GAO, Junfeng et al. *Computer vision in healthcare applications*. 2018 (cit. on p. 20).

GARRIDO-ELUSTONDO, Sofía et al. “Capacidad de detección de patología psiquiátrica por el médico de familia”. In: *Atención Primaria* 48.7 (2016), pp. 449–457 (cit. on p. 14).

GIL MIRANDA, Andrés David. “Evaluación del movimiento en pacientes con parkinson utilizando técnicas computacionales para la automatización del protocolo UPDRS mediante el Kinect”. In: (2019) (cit. on p. 16).

GÓMEZ ECHEVERRY, Lesly Lisbeth et al. “Sistemas de captura y análisis de movimiento cinemático humano: una revisión sistemática”. In: *Prospectiva* 16.2 (2018), pp. 24–34 (cit. on p. 16).

GONZÁLEZ-MONJE, Mariana Hernández and MALPICA, Norberto. “Sistemas basados en vídeo”. In: *MANUAL SEN DE* (2021) (cit. on p. 16).

GUAYACÁN, Luis C and MARTÍNEZ, Fabio. “Visualising and quantifying relevant parkinsonian gait patterns using 3D convolutional network”. In: *Journal of biomedical informatics* 123 (2021), p. 103935 (cit. on pp. 21, 41).

HERRÁEZ SORIA, Jesús et al. “Análisis de métodos de identificación personal basados en siluetas”. In: (2010) (cit. on p. 17).

HORNA LÓPEZ, Fabián Vicente and TARÍS RAMOS, Luis Mifguel. “Diseño e implementación de un sistema alternativo de captura de movimiento para efectos visuales. Caso práctico: Sacrilegio del 4 de mayo de 1897”. B.S. thesis. 2013 (cit. on p. 16).

HSU, Chia-Yu et al. “Test-retest reliability of an automated infrared-assisted trunk accelerometer-based gait analysis system”. In: *Sensors* 16.8 (2016), p. 1156 (cit. on p. 18).

IOSA, Marco et al. “Wearable inertial sensors for human movement analysis”. In: *Expert review of medical devices* 13.7 (2016), pp. 641–659 (cit. on p. 11).

KUHN, Harold W. “The Hungarian method for the assignment problem”. In: *Naval research logistics quarterly* 2.1-2 (1955), pp. 83–97 (cit. on p. 31).

KULISEVSKY, Jaime et al. “Enfermedad de Parkinson avanzada. Características clínicas y tratamiento (parte I)”. In: *Neurología* 28.8 (2013), pp. 503–521 (cit. on p. 13).

LANCET, The. *Artificial intelligence in health care: Within touching distance*. 2017 (cit. on pp. 12, 20).

LEÓN-JIMÉNEZ, Carolina et al. “Síndrome Rígido Acinético”. In: *Revista de Medicina Clínica* 3.2 (2019), pp. 104–108 (cit. on pp. 14, 15).

LOZANO CARRILLO, Juan Camilo. “Pose temporal estimation in markerless normal human gait integrating kinematic patterns and segmented video”. In: *Departamento de Imágenes Diagnósticas* (2015) (cit. on p. 15).

MONTOYA MORALES, Estephanie. “Detección y seguimiento de personas en video”. In: (2018) (cit. on p. 18).

MUTIS, Adriana Samira Jaspón; CHARRY, Oscar Julián Perdomo, and MARTÍNEZ, Juan Alberto Castillo. “Caracterización de movimientos a través de imágenes y sensores inerciales para la prevención de lesiones de miembro superior durante actividades repetitivas”. In: (2023) (cit. on p. 17).

PAL, Gian and GOETZ, Christopher G. “Assessing bradykinesia in parkinsonian disorders”. In: *Frontiers in Neurology* 4 (2013), p. 54 (cit. on p. 18).

PÉREZ-ALBA, KM; LEÓN-AGUILAR, AN, and SALIDO-RUIZ, RA. “Estudio comparativo de métodos para el análisis del movimiento en 2D: ventajas y desventajas del uso de marcadores”. In: *Memorias del Congreso Nacional de Ingeniería Biomédica*. Vol. 4. 1. 2017, pp. 294–297 (cit. on p. 17).

RAMÍREZ, Nancy Bertado et al. “Datos clave para el diagnóstico clínico de enfermedad de Parkinson”. In: *Revista Mexicana de Neurociencia* 10.5 (2009), pp. 340–343 (cit. on p. 15).

ROHAN, Ali et al. “Human pose estimation-based real-time gait analysis using convolutional neural network”. In: *IEEE Access* 8 (2020), pp. 191542–191550 (cit. on p. 21).

ROVINI, Erika; MAREMMANI, Carlo, and CAVALLO, Filippo. “How wearable sensors can support Parkinson’s disease diagnosis and treatment: a systematic review”. In: *Frontiers in neuroscience* 11 (2017), p. 555 (cit. on pp. 11, 18).

SAAVEDRA MORENO, Juan Sebastián; MILLÁN, Paula Andrea, and BURITICÁ HENAO, Omar Fredy. “Introducción, epidemiología y diagnóstico de la enfermedad de Parkinson”. In: *Acta neurológica colombiana* 35 (2019), pp. 2–10 (cit. on p. 13).

SALVATORE, Juan; OSIO, Jorge, and MORALES, Martín. “Detección de objetos utilizando el sensor Kinect”. In: *Guayaquil, Ecuador, LACCEI* (2014) (cit. on p. 16).

SIMONYAN, Karen and ZISSERMAN, Andrew. “Very deep convolutional networks for large-scale image recognition”. In: *arXiv preprint arXiv:1409.1556* (2014) (cit. on p. 38).

TAPIA-NÚÑEZ, John and CHANÁ-CUEVAS, P. “Diagnóstico de la enfermedad de Parkinson”. In: *Rev neurol* 38.1 (2004), pp. 61–67 (cit. on p. 14).

TOLOSA, Eduardo et al. “Challenges in the diagnosis of Parkinson’s disease”. In: *The Lancet Neurology* 20.5 (2021), pp. 385–397 (cit. on p. 11).

ŤUPA, Ondřej et al. “Motion tracking and gait feature estimation for recognising Parkinson’s disease using MS Kinect”. In: *Biomedical engineering online* 14.1 (2015), pp. 1–20 (cit. on p. 20).

VAROL, Gül; LAPTEV, Ivan, and SCHMID, Cordelia. “Long-term temporal convolutions for action recognition”. In: *IEEE transactions on pattern analysis and machine intelligence* 40.6 (2017), pp. 1510–1517 (cit. on pp. 21, 32).

VISWAKUMAR, Aditya et al. “Human gait analysis using OpenPose”. In: *2019 fifth international conference on image information processing (ICIIP)*. IEEE. 2019, pp. 310–314 (cit. on p. 21).

WONG, Charence et al. “Wearable sensing for solid biomechanics: A review”. In: *IEEE Sensors Journal* 15.5 (2015), pp. 2747–2760 (cit. on p. 19).