



Universidad Autónoma de Querétaro
Facultad de ingeniería
Maestría en ciencias mecatrónica
Campus San Juan del Río



Tesis:

“Análisis de la marcha a través de machine learning para la clasificación de alteraciones óseas y musculares”

Que como parte de los requisitos para obtener el título de Maestro en ciencias del área de mecatrónica

Presenta:

Ing. Rogelio Cedeño Moreno

Director:

Dr. Luis Alberto Morales Hernández

San Juan del Río, Qro., a 16 de abril del 2021



Universidad Autónoma de Querétaro
Facultad de ingeniería
Maestría en ciencias mecatrónica
Campus San Juan del Río



Tesis:

“Análisis de la marcha a través de machine learning para la clasificación de alteraciones óseas y musculares”

Que como parte de los requisitos para obtener el título de Maestro en ciencias del área de mecatrónica

Presenta:

Ing. Rogelio Cedeño Moreno

Director:

Dr. Luis Alberto Morales Hernández

Dr. Luis Alberto Morales Hernández

Presidente

Dr. Irving Armando Cruz Albarrán

Secretario

A large, stylized handwritten signature in blue ink, likely belonging to the President or Secretary.

A smaller handwritten signature in blue ink, possibly a second signature or a date.

A handwritten signature in black ink, possibly a date or a second signature.

Dr. Roque Alfredo Osornio Ríos

Vocal

Dr. Juan José Saucedo Dorantes

Suplente

Dr. Aurelio Domínguez González

Suplente

Dirección General de Bibliotecas de la UAQ

Resumen

En el trabajo presente se propuso la idea de desarrollar un sistema de bajo costo para el análisis y diagnóstico de alteraciones de la marcha, principalmente aquellas que afectan los sistemas óseo y muscular, causando problemas motrices que van degenerando la marcha con el tiempo pero que rara vez son detectados o atendidos hasta que la degeneración está muy avanzada. Para lograr esto se consideró la obtención de información cuantificable de la marcha, para lo cual se diseñó e implementó un sistema de visión artificial a base del protocolo Davis y un conjunto de sensores montables. De esta manera se determinan diferentes indicadores, como lo son la longitud de zancada, la cadencia, rango de movimiento, etc. Con esta información se construyó una base de datos donde se cuente con casos etiquetados de los indicadores de personas en estado sano, con problemas musculares y con problemas óseos, de tal manera que es utilizada para el entrenamiento de un algoritmo de Support Vector Machine (SVM) con el fin de que sea capaz de evaluar y clasificar nuevos casos, en donde no se conozca el estado de un paciente, de tal manera que pueda ser una herramienta de diagnóstico y apoyo para el especialista.

Abstract

In the present work, the idea of developing a low-cost system for the analysis and diagnosis of gait disturbances was proposed, mainly those that affect the bone and muscular systems, causing motor problems that degenerate over time but are rarely detected or treated until the degeneration is very advanced. To achieve this, it was considered to obtain quantifiable gait information, for which an artificial vision system based on the Davis protocol and a set of mountable sensors was designed and implemented. In this way indicators are determined, such as stride length, cadence, range of motion, etc. With this information, a database was built where there are labeled cases of the indicators of people in a healthy state, with muscular problems and with bone problems, in such way that it's used for the training of a Support Vector Machine (SVM) algorithm in order to evaluate and classify new cases, where the state of a patient is unknown, so that it can be a diagnostic and support tool for the specialist.

Agradecimientos

Para empezar, me gustaría dar un agradecimiento especial a mi familia, la cual en todo momento me ha brindado su apoyo y que siempre me han hecho saber lo orgullosos que están de mí, pero aún más orgulloso estoy yo de la familia que me acompaña y me cuida.

También quiero agradecer a todos los profesores que me han apoyado compartiendo sus conocimientos en las materias y con el desarrollo del presente trabajo, en especial a mi director de tesis el Dr. Luis Alberto Morales Hernández, al Dr. Irving Armando Cruz Albarrán, al Dr. Roque Alfredo Osornio Ríos y a todos los sinodales que me han apoyado día y noche con las revisiones y observaciones. Además, un agradecimiento especial a la maestra Arely Guadalupe Morales Hernández, quien me ha apoyado con la realización de pruebas y con la retroalimentación de la metodología.

El estudiar este posgrado me dio muchas oportunidades y experiencias, me permitió compartir un poco más de tiempo con mis amigos más cercanos los cuales no quisiera perder nunca, me dio nuevas experiencia y retos, me permitió conocer a más gente, hacer nuevos amigos que siempre recordare e incluso me permitió enamorarme. Cuando me pongo a pensar en el momento que me dieron esta oportunidad de continuar estudiando nunca me imaginé lo mucho que significaría para mí y cuan agradecido estaría de haber aceptado, porque me hubiera perdido de momentos que ahora atesorare siempre.

No sé qué tan buen profesionalista sea ahora que he cursado la maestría, tal vez no haya mejorado mucho y aun cargue muchos de mis errores, pero lo que si se es que soy una mejor persona.

Índice

Índice de imágenes	vii
Índice de tablas	ix
Capítulo 1	1
1.1. Introducción	1
1.2. Antecedentes	4
1.3. Justificación	7
1.4. Descripción del problema	8
1.5. Objetivo general	9
1.6. Planteamiento general	10
Capítulo 2. Fundamentación teórica	11
2.1. Sistema óseo	11
2.2. Sistema muscular	12
2.3. Marcha	12
2.4. Ciclo de la marcha	13
2.5. Fase de apoyo	13
2.6. Fase de balanceo	14
2.7. Variables espaciotemporales	14
2.7.1. Cadencia	15
2.7.2. Longitud de paso y longitud de zancada	16
2.7.3. Angulo del pie	16
2.7.4. Anchura de la zancada	16
2.8. Actividad articular	16
2.8.1. Rango de movimiento	17
2.9. Miopatías	18
2.10. Distrofias musculares	19
2.11. Patologías óseas	20
2.11.1. Displasia ósea	20
2.11.2. Osteodistrofia	20
2.11.3. Disostosis	20
2.12. Biomecánica	21

2.13.	Protocolo de adquisición Davis	22
2.13.1.	Sistema de coordenadas fijo al cuerpo	23
2.14.	Cinemática del movimiento	24
2.14.1.	Desplazamiento.....	24
2.14.2.	Ángulos de los segmentos de extremidades.....	26
2.14.3.	Ángulos de articulaciones	27
2.14.4.	Velocidad lineal y angular	27
2.14.5.	Aceleración lineal y angular	28
2.15.	Cinética.....	28
2.16.	Visión artificial.....	29
2.17.	Machine learning	29
2.18.	Support Vector Machine	30
2.18.1.	Datos de entrenamiento	31
2.18.2.	Semejanza	31
2.18.3.	Reconocimiento de patrones.....	32
2.18.4.	Hiperplano.....	35
2.19.	Funciones de Kernel	39
Capítulo 3. Metodología		42
3.1.	Población de pacientes	44
3.2.	Realización de pruebas físicas por los participantes.....	44
3.2.1.	Preparación del sujeto	44
3.2.2.	Entorno de las pruebas	45
3.2.3.	Sistema de adquisición por visión artificial.....	45
3.2.4.	Sensores de inercia montables	52
3.3.	Adquisición de variables cinéticas y espaciotemporales	54
3.3.1.	Detección de los marcadores y reconstrucción del esqueleto	54
3.3.2.	Cálculos de ángulos.....	56
3.3.3.	Cálculo del desplazamiento	57
3.3.4.	Cálculos derivados de velocidad lineal y angular.....	58
3.3.5.	Procesamiento de las señales del sensor inercial.....	59
3.3.6.	Cálculo de indicadores de la marcha	59
3.3.6.1.	Longitud de zancada	60

3.3.6.2.	Tiempo de soporte.....	61
3.3.6.3.	Tiempo de balanceo.....	63
3.3.6.4.	Tiempo de doble soporte.....	63
3.3.6.5.	Ángulos de rodilla y tobillo durante golpe de talón y despegue.....	64
3.3.6.6.	Velocidad angular de rodilla y tobillo.....	65
3.3.6.7.	Ángulos de los pies.....	66
3.3.6.8.	Amplitud de movimiento articular.....	67
3.3.6.9.	Cadencia.....	67
3.3.6.10.	Velocidad de caminado.....	68
3.4.	Etapa de entrenamiento.....	68
3.4.1.	Pre-procesamiento de los datos.....	68
3.4.2.	Selección del Kernel.....	69
3.4.3.	Etiquetado de datos.....	70
3.4.4.	Entrenamiento y validación.....	70
Capítulo 4.	Resultados.....	72
4.1.	Sistema de visión artificial.....	72
4.2.	Sensor montable.....	72
4.3.	Área de trabajo.....	73
4.4.	Pruebas físicas.....	74
4.5.	Desarrollo de interfaz de usuario.....	76
4.6.	Adquisición de video.....	77
4.7.	Procesamiento de imágenes.....	78
4.8.	Indicadores de la marcha a través de visión artificial.....	80
4.9.	Support Vector Machine.....	82
4.10.	Etapa de entrenamiento y cross-validation.....	83
Capítulo 5.	Prospectivas.....	89
Capítulo 6.	Conclusión.....	90
Capítulo 7.	Referencias bibliográficas.....	92

Índice de figuras

Fig. 1.1 Diagrama a bloques del planteamiento general.	10
Fig. 2.1 Vista superior de la vértebra cervical (Testut & Latarjet, 2014).	11
Fig. 2.2 Ciclo de la marcha con sus diferentes etapas (Lippert & Hurrell, 2006).	13
Fig. 2.3 Representación de las variables espaciotemporales (Trew & Everett, 2006).	15
Fig. 2.4 Patrones de movimientos articulares durante la marcha. A) Articulación de cadera. B) Articulación de rodilla. C) Articulación de tobillo (Trew & Everett, 2006).	17
Fig. 2.5.- Representación del rango de movimiento de la articulación de la rodilla (imagen basada en Winter, 2009)	18
Fig. 2.6 Representación gráfica del movimiento registrado durante la marcha (Winter, 2009).	21
Fig. 2.7 Configuración de marcadores para las extremidades inferiores (Davis et al., 1991).	22
Fig. 2.8 Traslación de un objeto en un plano x-y (basado en Hibbeler, 2010).	25
Fig. 2.9 Localización de marcadores en la pierna utilizando un protocolo definido (Winter, 2009).	26
Fig. 2.10 Representación gráfica del reconocimiento de patrones (Scholkopf & Smola, 2001).	33
Fig. 2.11.- Ejemplos de implementación de los hiperplanos. A) Hiperplano con un error de clasificación alto. B) Hiperplano con un error de clasificación ideal. C) Hiperplano sin error de clasificación (Scholkopf & Smola, 2001).	36
Fig. 2.12 Separación de datos con hiperplanos. A) Posibles hiperplanos. B) Hiperplano óptimo (Begg & Kamruzzaman, 2005).	38
Fig. 2.13.- Representación del truco de Kernel. A) Conjunto de datos no linealmente separables. B) Espacio de indicadores usando Kernel. C) Datos separados en su espacio original (Verplancke et al., 2008).	40
Fig. 3.1.- Diagrama de la metodología	43
Fig. 3.2.- Representación del campo de visión de una cámara	46
Fig. 3.3.- Espacio de captura para la calibración de la cámara	46
Fig. 3.4.- Errores de proyección	47
Fig. 3.5.- Recreación del espacio de captura	47
Fig. 3.6.- Esquema del mecanismo Hoeken en conjunto con un pantógrafo.	49
Fig. 3.7.- Trayectoria generada por el mecanismo Hoeken en el punto j	49
Fig. 3.8 Captura de los marcadores reflejantes con luz infrarroja (Hafer et al., 2015).	52
Fig. 3.9.- Diagrama de conexión entre los componentes	53
Fig. 3.10.- Umbralización de la imagen y detección de los marcadores. A) Imagen original en blanco y negro durante una prueba. B) Segmentación de los marcadores, detección del centroide y etiquetado.	55
Fig. 3.11.- Traslación del origen	56
Fig. 3.12.- Numeración de los puntos de interés	56
Fig. 3.13.- Resultado de la medición de velocidad derivada de la posición. A) Desplazamiento resultante del talón. B) Velocidad derivada del desplazamiento del talón.	58
Fig. 3.14.- Grafica de la velocidad con filtro de media móvil. A) Medición de velocidad sin filtro. B) Medición de la velocidad filtrada.	59
Fig. 3.15.- Detección de picos y valles de la señal de desplazamiento.	60

Fig. 3.16.- Obtención del tiempo de soporte a través de máximos y mínimos.	61
Fig. 3.17.- Obtención del tiempo de soporte sin transiciones. A) Datos originales del ángulo del talón. B) Varianza de los datos del talón.	62
Fig. 3.18.- Obtención del tiempo de balanceo a través de máximos y mínimos.	63
Fig. 3.19.- Representación de la etapa de doble soporte	64
Fig. 3.20.- Obtención de los ángulos de la rodilla durante los golpes de talón y los despegues.	65
Fig. 3.21.- Velocidad angular durante el golpe de talón y el despegue. A) Grafica del desplazamiento angular de la rodilla. B) Grafica de la velocidad angular obtenida a partir del desplazamiento.	66
Fig. 3.22.- Representación de la amplitud de movimiento de la rodilla.	67
Fig. 4.1.- Visualización de los marcadores con el sistema de visión artificial.	72
Fig. 4.2.- Modelo físico de los sensores montables.	72
Fig. 4.3.- Colocación de los sensores en el calzado.	73
Fig. 4.4.- Área de trabajo para la realización de pruebas.	74
Fig. 4.5.- Muestra de la población de participantes que realizaron la prueba.	75
Fig. 4.6.- Interfaz de usuario del sistema de monitoreo.	77
Fig. 4.7.- Segmentación de un fotograma. A) Imagen monocromática original. B) Imagen resultante del procesamiento.	79
Fig. 4.8.- Comparación entre las mediciones de dos participantes, donde los datos del participante A se presentan en azul y los del participante B en naranja.	84
Fig. 4.9.- Datos de entrenamiento normalizados obtenidos del software.	¡Error! Marcador no definido.
Fig. 4.10.- Datos de validación normalizados a partir de los datos de entrenamiento	¡Error! Marcador no definido.
Fig. 4.11.- Resultados de precisión de cada uno de los SVM generados con cross-validation.	¡Error! Marcador no definido.
Fig. 4.12.- Resultados obtenidos de los SVM para clasificación de velocidad utilizando cross-validation.	¡Error! Marcador no definido.

Índice de tablas

Tabla 2-1.- Funciones de Kernels	41
Tabla 3-1 Parámetros intrínsecos de la cámara.....	48
Tabla 3-2.- Dimensiones de los eslabones del mecanismo Hoeken y el pantógrafo.....	50
Tabla 3-3.- Comparación entre mediciones del Sistema real y el simulado.....	51
Tabla 3-4.- Medidas ideales del acelerómetro y giroscopio	54
Tabla 3-5.- Indicadores utilizados para el entrenamiento de la SVM.....	60
Tabla 4-1.- Archivos generados por el software	80
Tabla 4-2.- Presentación de indicadores para el usuario.....	81
Tabla 4-3.- Datos generales de dos participantes.....	83
Tabla 4-4.- Base de datos generada a partir de los indicadores para la identificación de la marcha.	85
Tabla 4-5.- Base de datos normalizada para la clasificación de velocidad	87

Capítulo 1

1.1. Introducción

Durante siglos el ser humano se ha visto fascinado por la estructura y funcionamiento de su propio cuerpo, de las complejas conexiones y mecanismos del sistema musculoesquelético y por la multitud de tareas que son posibles de realizar, como lo son correr, saltar, sentarse y muchas más. Este interés impulsó el desarrollo de la investigación del cuerpo humano, aunque de manera empírica y, en muchos casos, solo lo que podía ser perceptible con la vista. Lo cual, por supuesto creó las bases de lo que son la anatomía y la fisiología; sin embargo, se quedaban demasiado limitadas. No fue que hasta con el paso de los años se comenzó a formalizar el estudio del cuerpo humano, lo cual principalmente se logró a través de la disección y el análisis de cuerpos, permitiendo realizar la descripción del sistema óseo como estructura principal, el sistema muscular como el motor principal de casi todo movimiento y el sistema nervioso como vía de comunicación con el cerebro. Lo cual permitió que se desarrollaran otras ramas de la medicina como lo es la biomecánica.

Conforme se establecían los conocimientos del cuerpo humano, también se comenzó a dirigir la atención en las personas que contaban con limitantes motrices y que por lo tanto les era imposible realizar algunas tareas. El estudio de estos desperfectos dio como resultado la conclusión de que se debían a alteraciones fisiológicas, como malformaciones óseas, subdesarrollo de los músculos, un sistema nervioso atrofiado, entre muchos otros problemas. Algunos comenzaron a ser diagnosticados a través de métodos de observación, en donde una persona con un gran conocimiento empírico y mucha experiencia lograba distinguir sutiles alteraciones en el movimiento del paciente, con lo cual se le podría suministrar algún tipo de tratamiento. Sin embargo, este tipo de diagnósticos resultaban imprecisos y en muchos casos terminaban en un diagnóstico incorrecto.

Con el avance de la tecnología se comenzaron a implementar diferentes metodologías para el análisis del movimiento, como el uso del goniómetro para la medición de ángulos entre extremidades, la aplicación de tinta en las plantas de los pies para la medición del ángulo de

la pisada, entre otras. Aunque también se comenzaron a realizar a realizar estudios del tipo químico, a través de análisis de sangre e histoquímicos, permitiendo la detección de algunas patologías. Como resultado de estos cambios en las metodologías del análisis del movimiento, se obtuvo una mayor certidumbre para la realización de diagnósticos, por lo que se comenzaron a desarrollar técnicas que permitieran obtener información más específica de la condición del paciente, como la estructura de los huesos y sus deformaciones, el estado del tejido muscular, el desgaste del cartílago, etc. Lo cual fue posible obtener a través de las radiografías y otros métodos de tipo invasivo.

A pesar del éxito que se ha logrado tener para la detección y reconocimiento de patologías motrices, la realización de los diagnósticos puede llegar a generar un gran consumo de tiempo y recursos por parte del especialista y el paciente. Es por ello en la actualidad se ha buscado el desarrollo de sistemas que sean capaces de realizar la adquisición de variables cinéticas, cinemáticas y temporales de los movimientos, con el fin de reconstruir la biomecánica del cuerpo y determinar en qué puntos existen anomalías, lo cual permite que el especialista pueda evaluar al paciente de manera más objetiva. Sin embargo, estos sistemas han continuado en desarrollo, lo cual ha llevado a la implementación de algoritmos de machine learning para llevar a cabo la detección de patrones que pueden llegar a definir algún problema en específico, de esta manera los sistemas de medición pasaban de ser simples sistemas de evaluación a sistemas de diagnóstico. Aunque aún no se pueda depender por completo de estos sistemas sirven como una buena guía para el especialista y principalmente si este carece de suficiente experiencia. Estos sistemas se han vuelto populares para el diagnóstico de diferentes padecimientos; sin embargo, estos cuentan con dos limitantes, la primera es la cantidad de información con la cual se lleva a cabo el aprendizaje ya que se recomienda tener la mayor cantidad de muestras ya que cada una podría diferir mucho de la otra a pesar de que sea la misma condición, por lo tanto, si se llegan a utilizar pocas muestras se pueden obtener resultados imprecisos. Por otra parte, es la especialización del sistema, esto se debe a la cantidad tan variada de padecimientos y factores que afectan al movimiento, por lo que se tiende a concentrar el desarrollo del sistema a la identificación de un solo problema o patología.

Con base a la información presente es posible comprender por qué los sistemas de diagnóstico pueden ser beneficiosos, pero también que presentan un reto ya que los sistemas tienden a enfocarse en una sola tarea y dependen de la calidad de las mediciones para realizar un diagnóstico fiable. En base a esto se propone el sistema a desarrollar en el trabajo presente, el cual a través de machine learning, visión artificial y sensores montables logre clasificar a los pacientes con patologías de origen muscular o de origen óseo.

Dirección General de Bibliotecas de la UAG

1.2. Antecedentes

Con el paso del tiempo los seres humanos se han vuelto conscientes de las acciones físicas que son capaces de realizar con su cuerpo, como correr, saltar, sentarse, entre otras. Lo que progresivamente comenzó a generar un gran interés en cuanto a los límites de estas acciones, es decir, que tanto pueden ser desarrolladas o aún más importante porque algunas acciones no pueden ser desarrolladas por ciertas personas. Con base en este interés se comenzó a estudiar el movimiento humano de manera más objetiva llegando al nacimiento de ramas de la medicina como la anatomía, biomecánica, fisiología y muchas otras derivadas (Trew & Everett, 2006).

Para poder conocer las causas que llegan a limitar el movimiento es necesario llevar a cabo el análisis del movimiento del cuerpo humano lo cual se vuelve sumamente complejo. Tomando como ejemplo la caminata o marcha, que siendo una de las acciones más importantes también es una de las más complejas ya que existe una multitud de interacciones entre factores internos y externos entre los cuales se pueden encontrar factores anatómicos, fisiológicos, biomecánicos, psicológicos, sociológicos y ambientales (Trew & Everett, 2006). Esto dio comienzo al desarrollo del estudio de la marcha en donde se buscaba evaluar y diagnosticar las alteraciones existentes en la marcha, lo cual se realizó a base de observaciones y mediciones de esta con el fin de comprender que factores influían, diagnosticar si existía una patología neuro-musculo-esqueléticas y como se podía dar un tratamiento adecuado (Haro, 2014). Sin embargo, a causa de la infinidad de factores que pueden influir en la marcha y de las compensaciones que puede llegar a realizar el paciente, se convierte en una tarea que requiere un alto grado de conocimiento y experiencia por parte de un especialista y aun así puede llegar a ser subjetiva e imprecisa (Turani et al., 2004). Por ello se han buscado desarrollar herramientas que realicen una evaluación cuantitativa del estado de un ser humano a base de mediciones y el análisis de estas (Winter, 2009).

En la necesidad de realizar mediciones del movimiento humano, se han desarrollado múltiples herramientas para la adquisición de dicha información siendo los más comunes los sensores montables (Hsu et al., 2014) y los sistemas de visión artificial (Wang et al., 2013), a través de los cuales es posible llevar a cabo la descripción de un movimiento de manera

cuantitativa, eliminando así la subjetividad del proceso. Cada uno de estos métodos de adquisición cuentan con sus ventajas, por parte de los sistemas de visión artificial se cuenta con un sensor que simula la vista humana, a través de la cual se puede adquirir una amplia gama de información cuya adquisición no sería igual de sencilla a través de otros sensores (Pajares & M. de la Cruz, 2002). Esta cualidad convierte a los sistemas de visión artificial en una herramienta de gran versatilidad que puede ser adaptada para diferentes tareas, dando paso al desarrollo de diferentes áreas de la visión artificial. Una de estas áreas es conocida como la videogrametría, en donde se lleva a cabo la medición de diferentes parámetros espaciotemporales, cinéticos, cinemáticos o complementarios de la marcha (Villa M. et al., 2008). Esta herramienta se ha implementado en el estudio de personas con diferentes condiciones como lesiones en la médula espinal (Iucksch et al., 2013), Parkinson (Cho et al., 2009), desgaste por edad (Byrne et al., 2002), entre otros. Por otra parte, también han destacado los sensores montables en el estudio de condiciones, como en la evaluación de la espasticidad de los músculos en personas con parálisis cerebral (Van Den Noort et al., 2013), cálculo del riesgo de caída (Shany et al., 2012) y, de igual manera que con los sistemas de visión, el análisis del Parkinson (Jeon et al., 2017). Gracias a los resultados obtenidos en la realización de estos trabajos se ha logrado confirmar el potencial que tienen los sistemas de visión artificial como apoyo fiable para el diagnóstico de la marcha. Sin embargo, estos sistemas por sí solos aún son dependientes del análisis de un especialista por lo que se quedan limitados como herramientas de evaluación mas no de diagnóstico (Davis et al., 1991). Es por ello que se ha propuesto la implementación de otras tecnologías como lo son los algoritmos de machine learning, los cuales a través de amplias bases de datos les es posible determinar patrones, los cuales pueden ser utilizados para que un sistema se adapte a la realización de una tarea (Mitchell, 1997). La implementación de este tipo de algoritmos en el área del análisis del movimiento llevo al desarrollo de sistemas inteligentes en donde se utilizan los sistemas de visión artificial y los sensores montables como una etapa de adquisición y a los algoritmos de machine learning como intérpretes de los indicadores de la marcha, como lo son la longitud de zancada, longitud de paso, velocidad media del centro de gravedad, entre otras (Hageman & Blanke, 1986), con el fin de diagnosticar la presencia de alguna condición en específico. La capacidad y eficiencia de este tipo de sistemas de

diagnóstico se puede apreciar en los trabajos como el de Begg & Kamruzzaman, 2005 en donde se utilizó un algoritmo de machine learning conocido como support vector machine (SVM) para realizar la clasificación de mujeres jóvenes y mayores a base de las variaciones de la marcha obtenidas a través de un sistema de visión artificial, para posteriormente generar sugerencias de posibles tratamientos. De igual manera en el trabajo de Zhu et al., 2007 desarrollaron un sistema que permitía determinar si un paciente contaba con la capacidad de recibir rehabilitación, esto a través de un conjunto de cámaras distribuidas en una sala y la implementación del SVM. Por otra parte, también se han logrado buenos resultados en la utilización de sensores montables como es el caso de Hsu et al., 2014 en donde se decidió prescindir de sistemas de visión y se optó por la implementación de un sensor de inercia de fabricación propia, con el cual se realizó la evaluación del balance y la marcha de pacientes con Alzheimer. También se encuentra el trabajo de Van Den Noort et al., 2013 en donde se llevó a cabo el análisis de la marcha utilizando un conjunto de sensores inerciales y magnéticos, a la vez que se implementaba un nuevo protocolo de adquisición de desarrollo propio.

Este tipo de sistemas de diagnóstico han generado soluciones a múltiples condiciones, sin embargo, a causa de la gran variedad de factores que intervienen en la marcha se vuelve necesario generar un sistema especializado para cada condición. En el trabajo presente se buscará realizar la detección y clasificación de patologías musculares y esqueléticas en personas que no cuenten con un diagnóstico formal de alguna patología neuro-musculo-esquelética. Esto se realizará a través del análisis de su marcha con un sistema de visión artificial, en complemento con sensores inerciales para la adquisición de variables espaciotemporales, cinéticas y cinemáticas y el algoritmo SVM para la interpretación de los datos.

1.3. Justificación

La detección de anomalías en el movimiento humano y sus causas se han convertido en un factor importante a considerar en el desarrollo de las áreas de fisioterapia, ortopedia e incluso para la creación de equipos deportivos y prótesis. Sin embargo, aún existen muchos casos en donde la identificación de estas anomalías y de su la determinación de su origen se realizan de manera subjetiva, esto se debe principalmente al método utilizado para la medición del movimiento. Lo más habitual es que se realicen las mediciones de manera visual por parte de un experto, sin embargo, esta es una tarea que puede desafiar a cualquiera ya que ninguna persona es igual y por lo tanto no se pueden realizar comparaciones directas. A causa de esto es muy común que se produzcan errores de diagnóstico, los cuales pueden oscilar entre 15% y 13% o incluso en el peor de los casos del 47%, ya que todo depende de la capacitación y experiencia del especialista (Wray & Friedland, 1983) y puede traer como resultado la aplicación de tratamientos que no sean óptimos para el paciente o que puedan llegar a causar un mayor daño. Por lo tanto, para asegurar un mejor diagnóstico se pueden llegar a aplicar pruebas de laboratorio como el análisis de la sangre, toma de radiografías, artroscopia, etc. Las cuales pueden llegar a tomar cierto tiempo en dar resultados, pero también pueden representar un gran gasto de recursos por parte del paciente, lo cual no siempre es factible y mucho menos si no se cuenta con ningún indicio de cuál podría ser el problema, ya que podría ser necesario realizar una gran serie de pruebas. Por esta razón se ha considerado la realización de diagnósticos utilizando la identificación de patrones en el movimiento, para esto se han optado por tecnologías como lo es machine learning, el cual no solo se ha implementado para la medición sino también para la evaluación de diferentes condiciones, lo cual representa un apoyo para el especialista que permite reducir la subjetividad del proceso (Winter, 2009). Sin embargo, aún existen muchas condiciones en las cuales no se han implementado estas técnicas, por lo cual es necesario el desarrollo de este tipo de sistemas.

1.4. Descripción del problema

El primer problema que se busca resolver en el trabajo presente es el de la subjetividad de la medición de la marcha, a causa de las técnicas que comúnmente se utilizan para su medición. Una de las más comunes es la aplicación de tinta en la planta de los pies para que el paciente camine por una superficie de papel, lo cual permite realizar la medición del ángulo del pie (Jasuja et al., 1997). Como esta técnica existen muchas otras; sin embargo, tienden a ser tediosas en su realización e incluso pueden llegar a incomodar al paciente, lo cual puede tener repercusiones en su desempeño. Es por esta razón que muchos especialistas optan por un análisis visual, el cual es dependiente de su conocimiento empírico. De aquí surge el segundo problema a trabajar, en donde a causa de esta subjetividad en la medición fácilmente se puede llegar a un diagnóstico erróneo lo cual pueda perjudicar la rehabilitación de un paciente (Winter, 2009). Uno de los errores más comunes es al momento de diagnosticar por primera vez si un paciente cuenta con una patología neuro-musculo-esquelética, la problemática se encuentra en identificar si su padecimiento es de naturaleza muscular u ósea, esto se debe a las similitudes que se pueden llegar a presenciar durante el análisis de la marcha, para lo cual si el especialista no cuenta con la suficiente experiencia puede realizar error en el diagnóstico y causar que el tratamiento que se le dé al paciente solamente evite el desarrollo del malestar pero no la completa recuperación. Este error puede ser corregido a través de la realización de pruebas físicas, pruebas de laboratorio, toma de radiografías y otros métodos de capturas de imagen de tipo invasivo, como lo son la gammagrafía ósea o la artroscopia (Villa-forte & Clinic, 2017). Sin embargo, esto conlleva a una inversión de tiempo y dinero. Es por estas problemáticas que se propone el desarrollo de un sistema que realice mediciones cuantitativas a través de un sistema de visión artificial y sensores montables, que además pueda ser capaz de procesar la información utilizando algoritmos de machine learning para detectar si el padecimiento es muscular u óseo.

1.5. Objetivo general

Desarrollar un sistema basado en machine learning, que a través de un sistema de visión artificial y sensores inerciales identifique alteraciones en parámetros cinemáticos y cinéticos de la marcha, con el fin de determinar si una persona, que no ha sido diagnosticada, se encuentra en estado sano o cuenta con una patología del tipo ósea o muscular.

1.5.1. Objetivos específicos

- Revisar el estado del arte de la cinemática y cinética de la marcha para determinar cuáles parámetros son relevantes con el apoyo de un experto.
- Generar un sistema de visión artificial para monitorear la marcha del paciente a través de marcadores colocados en las principales articulaciones e implementar los sensores montables.
- Identificar los parámetros cinemáticos y cinéticos para llevar a cabo su medición a través de procesamiento de imágenes.
- Comparar los parámetros de la marcha con un patrón predefinido de una marcha regular para estimar las posibles alteraciones.
- Realizar pruebas de la marcha con pacientes previamente diagnosticados como sanos, con daño muscular o con daño óseo para generar una base de datos.
- Entrenar un algoritmo de machine learning utilizando una base de datos para que identifique las diferencias entre los casos musculares y óseos.
- Verificar la exactitud de clasificación de datos del algoritmo utilizando la base de datos original.
- Comprobar el funcionamiento del algoritmo entrenado en pruebas con nuevos pacientes para conocer su estado y proporcionar un diagnóstico.

1.6. Planteamiento general

El trabajo presente tiene como enfoque el análisis de la marcha y la detección de irregularidades para la clasificación de patologías de naturaleza muscular u ósea, con el fin de generar un diagnóstico objetivo. Esta tarea no es sencilla ya que se encuentra directamente ligada a la información que se esté obteniendo durante la evaluación física y a la calidad de esta; sin embargo, esta información tiende a ser imprecisa a causa del método de adquisición ya que es común que se adquieran de forma visual por el especialista, aunque también se llegan a utilizar otros métodos como la aplicación de goniómetro o la medición de huellas de tinta.

Para el desarrollo del trabajo presente se buscará generar un sistema de adquisición y diagnóstico a base de C#. Para la adquisición de la información se utilizarían sensores montables, los cuales se encuentran equipados con acelerómetros, y una cámara de alta velocidad, la cual detectará marcadores que se habrán colocado previamente en el paciente. A través de una serie de pruebas físicas se obtendrá información de la cual se podrán calcular parámetros cinéticos, cinemáticos y temporales de la marcha, con los cuales se calcularán indicadores estadísticos que serán utilizados para el entrenamiento de un algoritmo de machine learning conocido como Support Vector Machine (SVM), el cual finalmente será evaluado para definir su confiabilidad. El proceso mencionado se puede apreciar en la Fig. 1.1.



Fig. 1.1 Diagrama a bloques del planteamiento general.

Capítulo 2. Fundamentación teórica

2.1. Sistema óseo

El sistema óseo representa una parte fundamental de la anatomía ya que cumple con tareas relacionadas con el movimiento y protección. A través de su forma y su configuración el sistema óseo define la base estructural de la anatomía del ser humano, lo cual le brinda una rigidez al cuerpo y a diferencia de un ser invertebrado, la capacidad de manipular el entorno. El sistema óseo también es el encargado de definir los tipos de movimientos que los seres humanos pueden realizar y sus limitantes, esto se debe a las articulaciones, las cuales proporcionan una unión flexible y estable entre huesos (Trew & Everett, 2006).

Los huesos juegan un papel importante en la mecánica del movimiento, esto se debe que a través de las protuberancias y apófisis se proporcionan superficies en las cuales los tejidos blandos se pueden insertar definiendo la línea de fuerza de los músculos y los tendones (Trew & Everett, 2006).

En la Fig. 2.1 es posible observar las apófisis de la vértebra cervical las cuales son pequeñas protuberancias en donde se insertan tejidos blandos o músculos.

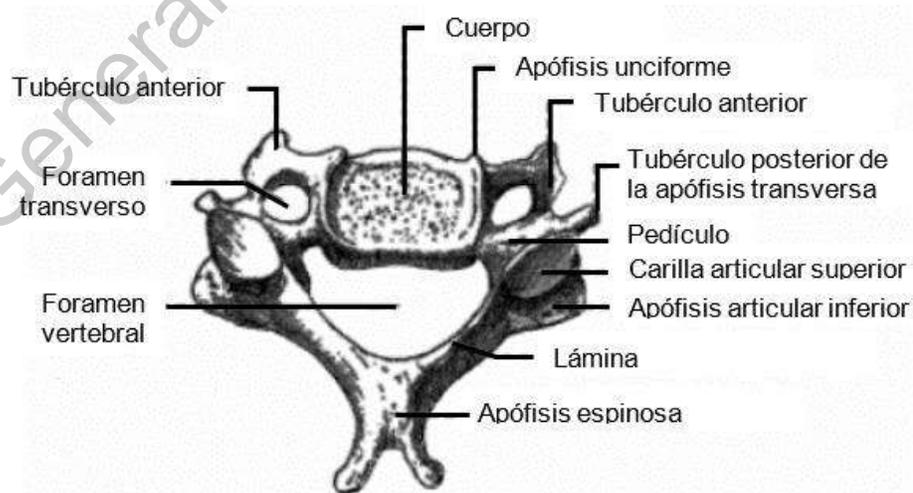


Fig. 2.1 Vista superior de la vértebra cervical (Testut & Latarjet, 2014).

2.2. Sistema muscular

El sistema muscular tiene un gran papel en la realización del movimiento del cuerpo humano, ya que su función principal es proporcionar la fuerza y el control para la realización de movimientos. Estos pueden llegar a ser utilizados de manera voluntaria o por reflejo, sin embargo, en algunos casos su funcionamiento se realiza de manera inconsciente, lo cual se presenta en los músculos de tipo cardíaco y liso. Por otra parte, se encuentran los músculos de tipo esquelético, como su nombre lo dice, se encuentran ligados al sistema óseo y permiten la realización de movimiento, la reacción a fuerzas externas y el control de la postura y el balance (Trew & Everett, 2006).

2.3. Marcha

El caminado humano, también conocido como marcha, es el medio a través del cual los seres humanos son capaces de realizar un desplazamiento de la manera más eficiente. Sin embargo, esta no es tarea fácil ya que requiere de la realización de movimientos coordinados en los cuales se ven involucrados un gran número de músculos y articulaciones, estos deben cumplir con la tarea de realizar movimientos precisos y alternantes en donde se debe mantener una postura estable. Esta actividad puede llegar a ser descrita como un balanceo, en donde a través del desplazamiento del centro de gravedad se genera una caída controlada la cual se recupera inmediatamente por el movimiento de una de las extremidades inferiores de modo que el centro de gravedad se vuelve a alinear con los pies, posteriormente se aprovecha la inercia obtenida para continuar el movimiento (Trew & Everett, 2006).

Para que la marcha pueda ser eficiente se requiere del desarrollo y la interacción de diferentes sistemas uno de estos es el sistema nervioso central, encargado de la coordinación de los movimientos, el sistema óseo, en donde las apófisis son utilizadas como palancas para la generación de fuerza, y finalmente el sistema muscular el cual desempeña la tarea de proporcionar la fuerza para la realización de movimientos (Haro, 2014).

2.4. Ciclo de la marcha

El ciclo de la marcha consiste en una serie de movimientos los cuales son de naturaleza rítmica en donde se ven implicadas todas las articulaciones de los miembros inferiores y la cual se puede dividir en diferentes fases. La primera es la fase de apoyo seguida de una fase de balanceo, lo cual se aplica para ambas extremidades. Durante el ciclo de la marcha cada una de las extremidades se encuentra el 60% del tiempo en la fase de apoyo y 40% del tiempo en la fase de balanceo, durante la transición de una fase a otra se genera una fase de doble apoyo en donde ambas extremidades se encuentran en contacto con el suelo (Trew & Everett, 2006). En la Fig. 2.2 se puede apreciar de manera visual del ciclo del caminado y sus distintas fases.

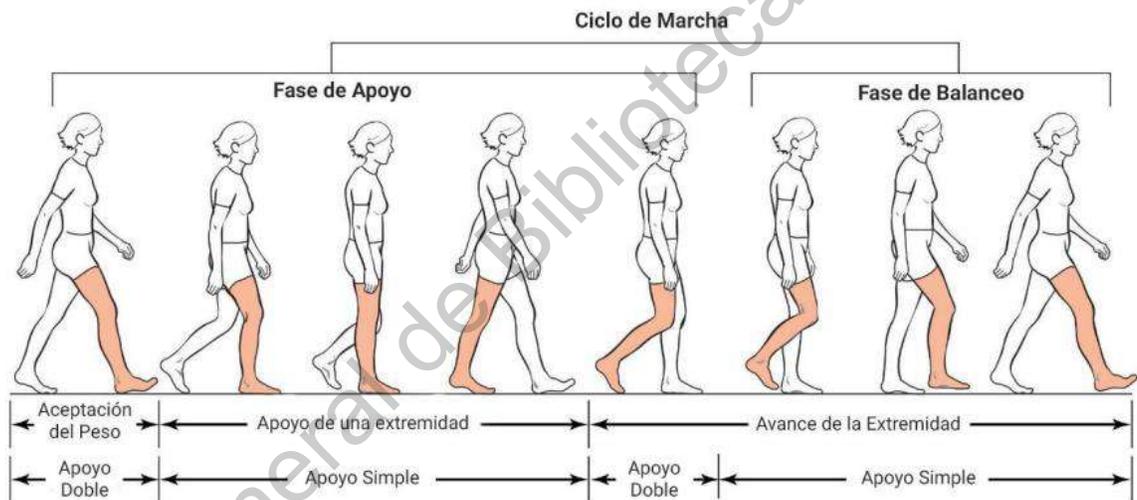


Fig. 2.2 Ciclo de la marcha con sus diferentes etapas (Lippert & Hurrell, 2006).

2.5. Fase de apoyo

Se dice que la fase de apoyo comienza en el momento en que el talón de una de las extremidades inferiores hace contacto con el suelo, lo que se conoce como golpe de talón, en esta fase es necesario que la extremidad genere un apoyo semirrígido y estable con el fin de que el otro miembro pueda realizar un balanceo. Esta fase se puede subdividir en varios pasos comenzando con la fase de golpe de talón, en la cual se establece el primer contacto con la superficie, seguido de la fase de pie plano o de carga, en donde la extremidad debe convertirse en el soporte principal del cuerpo aunque aún se cuenta con un apoyo por parte de la otra

extremidad, posteriormente es la fase de apoyo intermedia, en donde se convierte en el único soporte del cuerpo mientras la otra extremidad se encuentra en un balanceo, y finalmente se llega a la fase de separación del talón, despegue y separación de los dedos del pie mejor conocida como fase de propulsión, en donde la extremidad comienza a separarse de la superficie mientras la extremidad opuesta toma la tarea de soporte (Trew & Everett, 2006).

2.6. Fase de balanceo

La fase de balanceo consiste en la separación de una de las extremidades inferiores, la cual se desplaza hasta posicionarse por delante de la de la otra extremidad generando la acción de dar un paso. Un factor importante durante esta fase es la separación que se lleva a cabo, la cual debe ser aproximadamente de 2 cm para evitar cualquier obstáculo menor o irregularidad del terreno y generar un bajo consumo de energía. De igual manera se puede subdividir en tres fases, la primera es la fase de aceleración en donde a través de la cadera se realiza una aceleración en el movimiento de la extremidad en dirección anterior. Posteriormente se encuentra la fase de balanceo intermedio, la cual corresponde con la fase de apoyo intermedia de la otra extremidad y por lo tanto la extremidad en balanceo no se encuentra en contacto con el suelo. Finalmente, se encuentra la fase de desaceleración en donde a través de la acción muscular se busca desacelerar el miembro y prepararlo para comenzar la fase de apoyo (Trew & Everett, 2006).

2.7. Variables espaciotemporales

Existen múltiples variables espaciotemporales las cuales caracterizan a la marcha de cada persona y pueden ser medidas a través de diferentes métodos ya sea de manera empírica, utilizando únicamente la vista y conocimientos del especialista, o de manera cuantitativa, utilizando sensores de presión, sensores montables o sistemas de visión artificial. La medición de estas variables aporta información relevante para el diagnóstico de un paciente (Trew & Everett, 2006). Algunas de estas variables son la longitud de zancada, longitud de paso, ancho de paso y el ángulo del pie, se pueden observar en la Fig. 2.3.

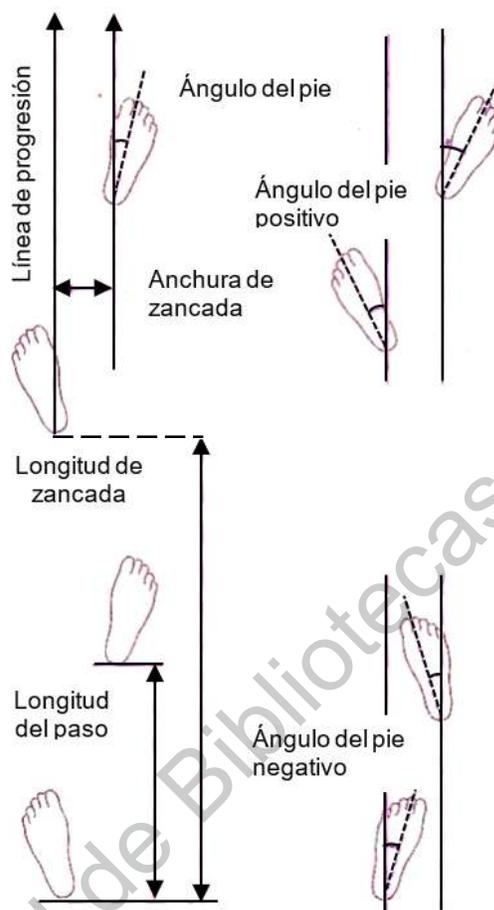


Fig. 2.3 Representación de las variables espaciotemporales (Trew & Everett, 2006).

2.7.1. Cadencia

Es el término utilizado para definir la velocidad de la marcha, este se mide en pasos por minuto y se cuenta con rangos establecidos para determinar los tipos de marcha. A partir de los 40 pasos/min se puede decir que es una marcha lenta, una marcha moderada se encuentra a partir de los 110 pasos/min y superior a esto llega a convertir a carrera. La capacidad que tiene el paciente para controlar su cadencia puede llegar a ser un indicador de su estado (Trew & Everett, 2006).

2.7.2. Longitud de paso y longitud de zancada

La longitud de paso es la distancia entre el punto en donde se dio el golpe de talón de la pierna derecha y el punto en donde se realizó el golpe de talón de la pierna izquierda. Por otra parte, se encuentra la longitud de zancada hace referencia a la separación entre dos puntos en donde se haya realizado el golpe de talón con la misma pierna, esto se puede interpretar en que una zancada consiste en dos pasos. Ambas variables se ven influenciadas por la longitud de los miembros inferiores, la edad de la persona, su cadencia y otros factores (Trew & Everett, 2006).

2.7.3. Angulo del pie

El ángulo del pie directamente se refiere al grado de giro que puede llegar a tener el pie al momento de realizar un paso, este puede ser interior o exterior los cuales son denominados negativos o positivos respectivamente. El análisis de este factor puede ayudar a determinar, en los casos que haya irregularidades en la marcha, cuales músculos se encuentran subdesarrollados, es decir, que no cuentan con la fuerza para desempeñar un movimiento en específico (Trew & Everett, 2006).

2.7.4. Anchura de la zancada

Se puede describir como la separación entre ambas extremidades (Trew & Everett, 2006). Esta puede llegarse a alterar con la edad a causa de que las personas buscan desarrollar una marcha más estable lo cual se ve reflejado como un incremento en la anchura de zancada (Hageman & Blanke, 1986).

2.8. Actividad articular

Para lo que respecta a la marcha y a las extremidades inferiores, se ha determinado un perfil de movimiento que describe los ángulos de rotación de los ángulos de la cadera, rodilla y el tobillo durante un ciclo de la marcha. Estos describen los momentos en los que la articulación genera una flexión o una extensión y a que ángulo se debería de realizar. Un ejemplo de estos patrones se puede visualizar en la Fig. 2.4 el cual corresponde a un ciclo de marcha a 35 km/h (Trew & Everett, 2006).

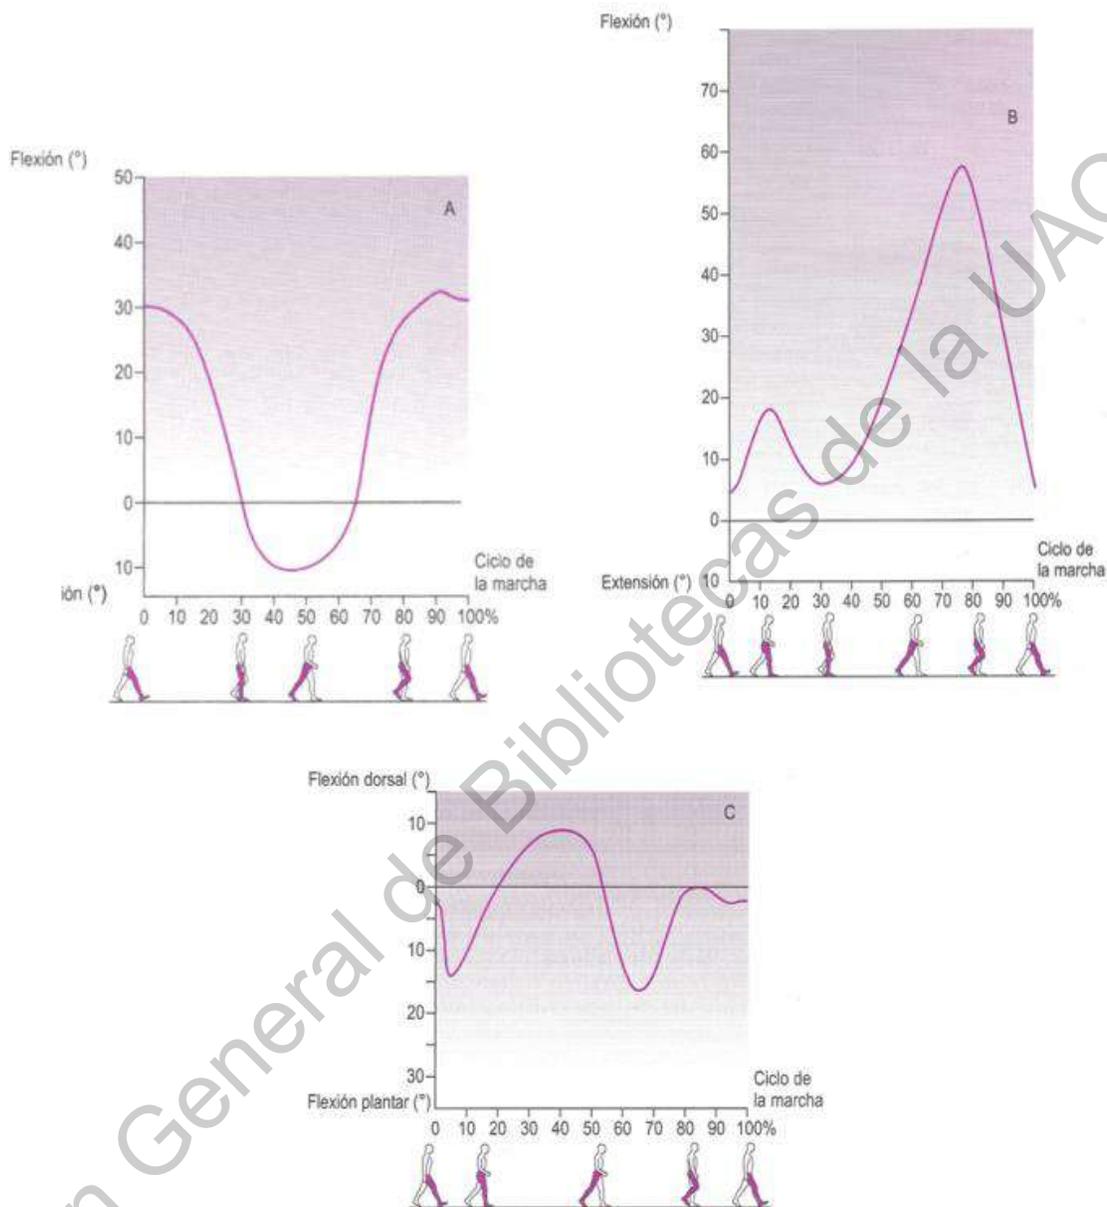


Fig. 2.4 Patrones de movimientos articulares durante la marcha. A) Articulación de cadera. B) Articulación de rodilla. C) Articulación de tobillo (Trew & Everett, 2006).

2.8.1. Rango de movimiento

También conocido como ROM por sus siglas en inglés (Range of motion), se enfoca en el análisis de las posiciones y movimientos que toman las articulaciones uniaxiales, biaxiales y

mutiaxiales durante la realización de una actividad en específico. Por ejemplo, el rango de movimiento de una rodilla no necesariamente deberá ser el máximo que puede realizar, sino el rango en grados en el que se ve a flexionar y extender durante la realización de una actividad como una caminata, subir escalones, saltar, etc. En la Fig. 2.5 se puede apreciar la medición del rango de movimiento, en donde la rodilla se encuentra en 180° cuando se encuentra completamente extendida y a 110° cuando se flexiona, lo cual puede variar dependiendo la edad, su estado de salud y la actividad realizada, por lo que se podría decir que en este ejemplo su ROM es de 180 a 110 o de 0 a 60 grados (Trew & Everett, 2006).

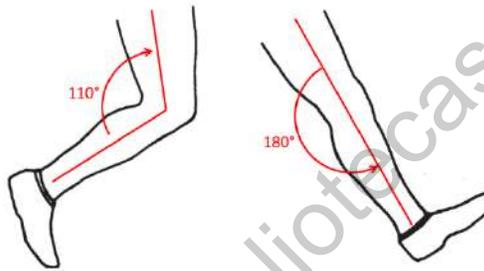


Fig. 2.5.- Representación del rango de movimiento de la articulación de la rodilla (imagen basada en Winter, 2009)

2.9. Miopatías

Las miopatías son patologías de origen genético que afectan directamente al músculo esquelético, lo cual puede verse reflejado en una deficiencia en la ejecución de movimientos, ya que se pueden presentar contracturas, calambres, dolor, debilidad, rigidez o fatiga en el músculo afectado (López Longo, 2008).

Las miopatías pueden ser de naturaleza adquirida o hereditaria, esta última conlleva un mayor riesgo, ya que puede causar un deterioro más rápido y afectar las funciones respiratorias y cardíacas en los primeros años de vida. Sin embargo, en la vida adulta el deterioro es lento y tiende a estabilizarse. Este tipo de patologías se ven caracterizadas por las variaciones que presentan en el análisis histoquímico, siendo las reacciones químicas presentes en el tejido, y los cambios ultraestructurales, que son las estructuras de los organismos que únicamente son visibles con un microscopio (Taratuto, 2010).

Ambos tipos de miopatías pueden ser tratadas a través de implementación de medicamentos específicos para la miopatía que se padece, acompañado de sesiones de rehabilitación y terapia física (López Longo, 2008).

Algunas de las miopatías más comunes son la miopatía nemalítica, descomposición congénita de tipos de fibras (GFTD), miopatías centrocélulares, miopatía miotubular, miopatía centrocélular, miopatías por cores, centralcore y multiminicore (Taratuto, 2010).

2.10. Distrofias musculares

Las distrofias musculares son patologías de naturaleza hereditaria, las cuales afectan directamente a grupos musculares causando debilidad muscular, lo cual repercute en la capacidad de movimiento de la persona. Las distrofias musculares se caracterizan por causar alteraciones en el tejido muscular como el redondeo de contornos, degeneración, necrosis, macrofagia, regeneración y fibrosis endomisial y perimisial (Taratuto, 2010).

La integridad de la fibra muscular se debe en gran medida a una membrana conocida como sarcolema, compuesta por un conjunto de proteínas conocidas como sarcolemales y subsarcolemales. Por lo tanto, la ruptura de dicha membrana puede llevar a la liberación de enzimas musculares causando la destrucción de la fibra muscular, lo cual da paso al desarrollo de una distrofia muscular (Erazo-Torricelli, 2004).

Uno de los grupos mayoritarios de las distrofias musculares causa debilidad en los músculos de la cintura escapular y pelviana, aunque también pueden causar afectaciones funcionales en los codos y tobillos (Erazo-Torricelli, 2004).

El tratamiento de estas patologías es variado a causa de los diferentes síntomas que presenta cada distrofia, estos pueden incluir tratamientos genéticos, terapia farmacológica, puede incluso ser necesaria cirugía. Pero el tratamiento que siempre será fundamental es la terapia física ya que permitirá mantener las funciones musculares, evitando la aparición de contracturas y escoliosis (Erazo-Torricelli, 2004).

Para la clasificación de distrofias musculares se agrupan en diferentes grupos, estos grupos son las distrofinopatías (distrofia de Duchenne y Becker), distrofia facioescapulohumeral

(DFEH), distrofias de cinturas (LGMD), distrofia de Emery-Dreifuss (DMED), distrofias musculares congénitas (DMC), distrofia distal y distrofia oculofaríngea (Erazo-Torricelli, 2004).

2.11. Patologías óseas

La estructura ósea del ser humano puede llegar a ser afectada por múltiples patologías que afectan su forma o su desarrollo, estas pueden ser clasificadas en tres grupos importantes displacia ósea, osteodistrofia y disostosis. Todas estas causan irregularidades en los huesos y por lo tanto pueden llegar a ser confundidas con facilidad (Clavel et al., 1973).

2.11.1. Displasia ósea

También conocida como osteodisplasia es de origen genético y causa problemas relacionados con las enzimas, lo cual se ve reflejado en una afectación de la formación y modelado de los huesos. Un factor característico es que el daño se propaga por toda la estructura ósea, deformando cada hueso, aunque en distintas intensidades (Clavel et al., 1973).

2.11.2. Osteodistrofia

Es un desorden causado por perturbaciones extrínsecas a los huesos como las alteraciones metabólicas, hormonales o vitamínicas. La dispersión del daño es irregular y depende mucho de la etapa de crecimiento en la que se encuentre la persona, por lo cual el daño puede o no esparcir (Clavel et al., 1973).

2.11.3. Disostosis

Es una malformación de origen hereditario la cual afecta a una región de la estructura ósea, esta no corre riesgos de esparcir el daño más allá del original (Clavel et al., 1973).

2.12. Biomecánica

La biomecánica es una disciplina que se creó a base de los conocimientos en física, química, matemáticas, fisiología y anatomía con el propósito de describir, analizar y evaluar el movimiento humano. Esta se ha convertido en una disciplina fundamental para el análisis del movimiento humano ya que se enfoca en la obtención de información significativa y de manera objetiva, permitiendo la detección de problemas o irregularidades en el movimiento, lo cual puede llevar a la detección de padecimientos. Esto se debe a que la información obtenida representa la misma mecánica del sistema musculoesquelético la cual puede ser analizada por un especialista para determinar de manera más objetiva el estado del paciente (Winter, 2009). En la Fig. 2.6 se puede apreciar el cómo se representa gráficamente la marcha a través de un mecanismo simple de cinco eslabones.

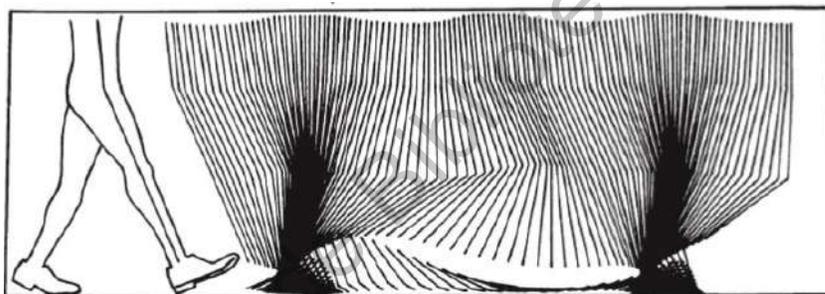


Fig. 2.6 Representación gráfica del movimiento registrado durante la marcha (Winter, 2009).

2.13. Protocolo de adquisición Davis

El protocolo Davis es una metodología para la adquisición y evaluación de la marcha humana, la cual trabaja a base de dos cámaras, una en el plano sagital y otra en el plano frontal, las cuales se encargan de la adquisición de información del movimiento. Para simplificar la tarea de adquisición se opta por el uso de marcadores reflejantes a los cuales se les proyectará una luz infrarroja, esto causará que los marcadores resalten en las capturas de las cámaras. En cuanto a la colocación de los marcadores, se debe realizar de manera muy cuidadosa ya que, en la realización de movimientos existen puntos en los cuales si se coloca un marcador se pueden generar errores, esto se debe a los movimientos que generan los propios músculos o los pliegues de la piel. Para esto el protocolo Davis propone la distribución que se muestra en la Fig. 2.7 en la cual los marcadores son colocados en puntos específicos de las articulaciones, procurando de esta manera el menor desplazamiento (Davis et al., 1991).

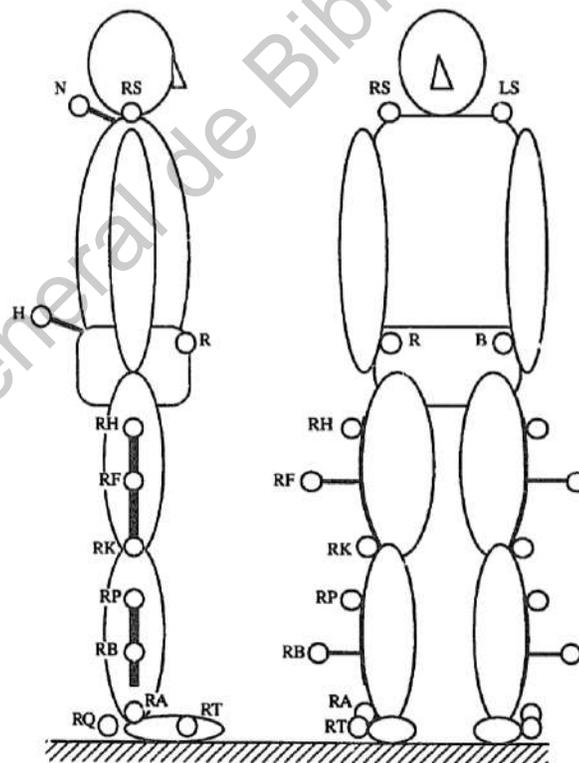


Fig. 2.7 Configuración de marcadores para las extremidades inferiores (Davis et al., 1991).

Para la colocación adecuada de los marcadores se deben identificar puntos exactos entre articulaciones. Para los marcadores 'R' y 'B' se debe de identificar la espina iliaca anterior superior y colocar los marcadores en la parte derecha e izquierda respectivamente y se puede colocar un marcador 'H' en la espina iliaca posterior superior. En los muslos se debe de palpar el epicóndilo medial y lateral del húmero en donde se deben de colocar los marcadores de tal forma que se encuentren alineados con el eje epicondular, se deben colocar los marcadores 'RK', 'RF' y 'RH' de manera alineada, con la mayor separación posible y una buena sujeción para evitar movimientos a causa de la piel. Para las espinillas se deben de colocar los marcadores de forma que se mantenga la alineación con el eje epicondular, el marcador 'RA' se debe de colocar a nivel del maléolo en la parte lateral, mientras que los marcadores 'RB' y 'RP' deben linearse de tal forma que se encuentren sobre el mismo eje de los marcadores del muslo. En el pie se coloca el marcador 'RT' en la parte lateral en la cabeza del quinto metatarso, este va acompañado de 'RQ' el cual es utilizado para obtener una línea que sea paralela a la planta del pie. Otros marcadores pueden ser utilizados solo para alguna tarea específica, como es el caso de 'RS', 'LS' y 'N' los cuales son utilizados para generar un plano que sea paralelo a la columna vertebral (Davis et al., 1991).

2.13.1. Sistema de coordenadas fijo al cuerpo

Un sistema de coordenadas fijas al cuerpo permite establecer un marco de referencia homogéneo para la realización de mediciones. Este se puede definir a partir de cualquier segmento del cuerpo que cuente con 3 marcadores no colineales. Uno de los puntos que se puede tomar es la pelvis en donde se genera un sistema de coordenadas a base de los marcadores 'R', 'B' y 'H', a base de estos se generan los vectores β_1 y β_2 utilizando las ecuaciones 2-1 y 2-2 respectivamente (Davis et al., 1991).

$$\beta_1 = 0.5(R + B) - H \quad (2-1)$$

$$\beta_2 = B - R \quad (2-2)$$

Posteriormente se normaliza β_2 para generar el vector unitario e_{py} con el cual se implementa el método de Gram-Schmidt, lo cual se representa en la ecuación 2-3.

$$\beta_3 = \beta_1 - (\beta_1 \cdot e_{py})e_{py} \quad (2-3)$$

Finalmente β_3 es normalizado para obtener e_{px} al cual se le aplica producto cruz para obtener e_{pz} . Esto puede ser utilizado en cualquier otro segmento del cuerpo (Davis et al., 1991).

2.14. Cinemática del movimiento

La cinemática de los movimientos biológicos se enfoca en las variables que definen el movimiento y no tanto en su origen. En esta tarea se toman en cuenta todos los desplazamientos generados durante un movimiento y con ellos su velocidad ya sea lineal o angular. Estos son representados a través de vectores en un espacio de coordenadas el cual puede ser bidimensional o tridimensional, en donde se puede contar con un marco de referencia absoluto o relativo. Últimamente es una herramienta que permite definir un movimiento, como la marchar, en términos cuantitativos, los cuales pueden ser analizados por un especialista (Winter, 2009). La cinemática cuenta con algunas variables que representan información relevante para el estudio de la marcha como lo son el desplazamiento de las extremidades inferiores, los ángulos de rotación de las articulaciones y las velocidades y aceleraciones, tanto lineales como angulares.

2.14.1. Desplazamiento

En términos generales el desplazamiento es una variable cinemática y puede ser definida como el cambio de posición de un objeto con base a un marco de referencia establecido. El desplazamiento puede ser visto como un vector que cuenta con una magnitud y dirección, esto se puede ejemplificar a través de la Fig. 2.8 en donde se considera un objeto compuesto por los puntos A , B , C y D , el cual está siendo sometido a una traslación que puede ser representada a través del vector \vec{V} , lo cual resulta en una figura con la morfología original pero compuesto por los puntos A' , B' , C' y D' (Hibbeler, 2010).

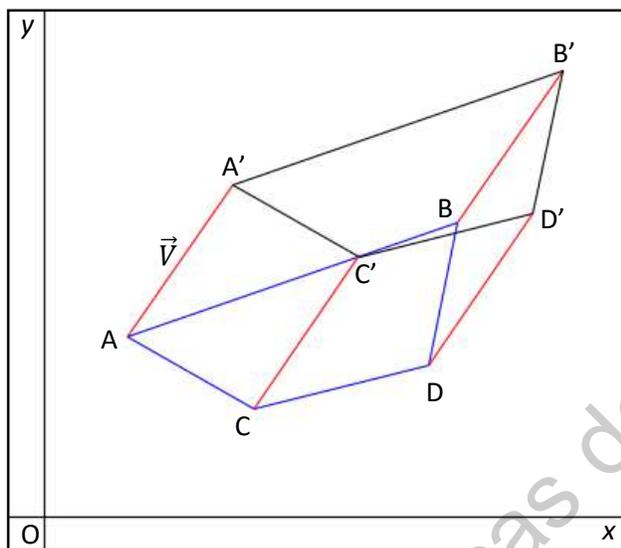


Fig. 2.8 Traslación de un objeto en un plano x - y (basado en Hibbeler, 2010).

Matemáticamente se pueden obtener los nuevos puntos que componen a la figura a través de la ecuación 2-4 o se puede despejar para obtener el desplazamiento a través de 2-5.

$$\overrightarrow{OA'} = \overrightarrow{OA} + \vec{V} \quad (2-4)$$

$$\vec{V} = \overrightarrow{OA'} - \overrightarrow{OA} \quad (2-5)$$

En donde \overrightarrow{OA} es la distancia original de un punto A con respecto al origen O , \vec{V} es el desplazamiento o traslación realizada por el punto y $\overrightarrow{OA'}$ es la distancia final del punto A con respecto al origen. Estas mismas ecuaciones pueden ser aplicadas para cada uno de los puntos. El desplazamiento que se obtenga estará dado en forma de vector, es decir, con componentes en y y en x , por lo cual si se desea únicamente la magnitud será necesario obtener la norma del vector o como se le conoce comúnmente la distancia entre dos puntos, esta puede ser calculada a través de la ecuación 2-6 (Hibbeler, 2010).

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (2-6)$$

Donde d es la norma o magnitud y los valores de (x_1, y_1) y (x_2, y_2) son las coordenadas de dos puntos con respecto a un mismo marco de referencia.

2.14.2. Ángulos de los segmentos de extremidades

Estos análisis requieren que se cuente con al menos dos marcadores, los cuales deben de encontrarse alineados con el eje de la extremidad, definido comúnmente por el hueso más largo. Para mantener una medición homogénea se considera que el ángulo es positivo si este va en contra de las manecillas del reloj y el ángulo 0 se encuentra alineado con la horizontal. Para demostrar el cálculo se tomará como ejemplo la Fig. 2.9 donde se muestra una configuración de marcadores y se realizará el cálculo del ángulo de la pantorrilla (Winter, 2009).

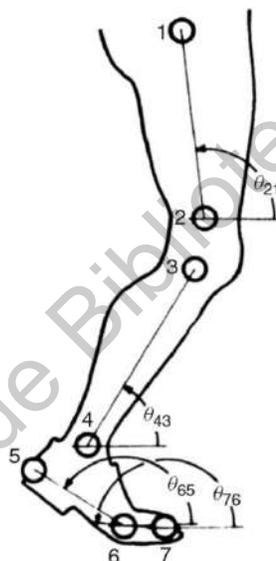


Fig. 2.9 Localización de marcadores en la pierna utilizando un protocolo definido (Winter, 2009).

Si se está analizando la pantorrilla se buscaría obtener el ángulo θ_{43} para esto se obtiene la pendiente entre los puntos 3 y 4, para posteriormente sacar el arcotangente y obtener el ángulo en el que se encuentra la pantorrilla. Esto queda representado a través de 2-7 (Winter, 2009).

$$\theta_{43} = \frac{y_3 - y_4}{x_3 - x_4} \quad (2-7)$$

La cual puede pasarse a una ecuación genérica para cualquier segmento de la extremidad, esto se muestra en 2-8 (Winter, 2009).

$$\theta_{ij} = \frac{y_j - y_i}{x_j - x_i} \quad (2-8)$$

2.14.3. Ángulos de articulaciones

Cada articulación puede ser descrita a través de una magnitud y una polaridad. Dicho esto, es posible describir las acciones que llevan a cabo las articulaciones a base de los ángulos de los segmentos de la extremidad. De esta manera se pueden obtener los ángulos de las rodillas y los tobillos a través de 2-9 y 2-10 respectivamente (Oteyza O. et al., 2005).

$$\theta_k = \tan^{-1} \left(\frac{\theta_{21} - \theta_{43}}{1 + \theta_{21} \theta_{43}} \right) \quad (2-9)$$

$$\theta_a = \tan^{-1} \left(\frac{\theta_{43} - \theta_{65}}{1 + \theta_{43} \theta_{65}} \right) + 90^\circ \quad (2-10)$$

En donde θ_k es el ángulo de la rodilla, θ_{21} es el ángulo del muslo, θ_{43} es el ángulo de la pantorrilla, θ_a es el ángulo del tobillo y θ_{65} es el ángulo del pie.

2.14.4. Velocidad lineal y angular

La velocidad se puede definir como la razón de cambio de la posición en un tiempo determinado, lo cual puede ser expresado a través de la ecuación 2-11.

$$V = \frac{\Delta x}{\Delta t} \quad (2-11)$$

En donde Δx hace referencia al desplazamiento total que se realizó, Δt el cual es el tiempo en que se realizó dicho desplazamiento y V el cual se refiere a la velocidad lineal promedio. Por otro lado, también es posible calcular la velocidad instantánea utilizando el mismo principio, la diferencia recae en el intervalo que se utiliza. Para la velocidad instantánea se tiende a segmentar el tiempo en intervalos cortos, los cuales se representan como dt , y que por consecuencia se toma un segmento del desplazamiento, representado como dx (Beer et al., 2010). Esto se representa matemáticamente en la ecuación 2-12.

$$v = \lim_{\Delta t \rightarrow 0} \frac{\Delta x}{\Delta t} = \frac{dx}{dt} \quad (2-12)$$

Por otra parte, la velocidad angular puede ser calculada bajo el mismo principio, por lo tanto, se puede obtener la velocidad angular a base de la rotación realizada y el tiempo en el que realizó. Lo cual es descrito en 2-13, donde ω corresponde a la velocidad angular, $\Delta\theta$ es la rotación realizada y Δt es el intervalo de tiempo.

$$\omega = \lim_{\Delta t \rightarrow 0} \frac{\Delta\theta}{\Delta t} = \frac{d\theta}{dt} \quad (2-13)$$

2.14.5. Aceleración lineal y angular

La aceleración lineal corresponde a la razón de cambio de la velocidad lineal. Al igual que esta la aceleración lineal se puede obtener de manera instantánea (a) o se puede medir el promedio (A), en donde se utilizará la variación de la velocidad (Δv) y un intervalo de tiempo (Δt), para la aceleración promedio se utilizarán la velocidad y tiempo totales y para la aceleración instantánea se utilizará la velocidad y tiempo durante un intervalo corto de tiempo (Beer et al., 2010). Las ecuaciones de la aceleración promedio e instantánea son 2-14 y 2-15 respectivamente.

$$A = \frac{\Delta v}{\Delta t} \quad (2-14)$$

$$a = \lim_{\Delta t \rightarrow 0} \frac{\Delta v}{\Delta t} = \frac{dv}{dt} \quad (2-15)$$

Para la aceleración angular (α) se utiliza el mismo principio, pero utilizando las velocidades angulares, lo cual resulta en 2-16.

$$\alpha = \lim_{\Delta t \rightarrow 0} \frac{\Delta\omega}{\Delta t} = \frac{d\omega}{dt} \quad (2-16)$$

2.15. Cinética

La cinética cuenta con un mayor peso para la evaluación del movimiento ya que este se enfoca en las causas que generan el movimiento, en donde se consideran las fuerzas externas e internas. En estas se pueden ver involucrados los músculos, los ligamentos e incluso la fricción en las articulaciones como fuerzas internas, por otro lado, las fuerzas externas pueden hacer referencia a las interacciones con el exterior o con objetos. El análisis de la cinética puede llevar a resultados más significativos ya que es posible conocer la forma en la que los

mecanismos del sistema musculoesquelético están trabajando, lo cual al analizar a un paciente con alguna condición puede llevar a conocer las causas que generan dicha condición y comprender que parte del sistema debe ser trabajada para mejorar o corregir la condición. A través de este proceso incluso es posible detectar los movimientos compensatorios que realiza el paciente, ya que estos podían llegar a causar un problema mayor el que están tratando de compensar (Winter, 2009).

2.16. Visión artificial

La visión artificial es un campo que se ha encontrado en desarrollo por más de 50 años, a través del conjunto de diferentes áreas como las matemáticas, la física, la óptica, la computación, entre muchas otras. Formando así un campo de gran complejidad, pero con grandes beneficios, principalmente por que se enfoca a replicar el sentido de la vista de los seres humanos, el cual puede ser clasificado como el sentido que le provee la mayor cantidad de información (Rodríguez-Sosa et al., 2012). Por lo cual el desarrollo de este campo ha llevado a la implementación de sistemas de visión artificial, los cuales a través del procesamiento de imágenes y la implementación de algoritmos matemáticos son capaces de adquirir información que no puede ser fácilmente obtenida por otros sensores, como los colores, formas, tamaños, e incluso con la implementación de algoritmos más complejos la obtención de profundidad, de orientación, cantidades, entre muchas otras variables. Lo cual permite que sean herramientas de uso muy flexible (Pajares & M. de la Cruz, 2002).

El funcionamiento de los sistemas de visión artificial recae completamente en el software, sin embargo, el hardware puede llegar a tener un gran peso en el desempeño del sistema. Esto se debe a que las condiciones de adquisición de imágenes no siempre serán óptimas para la tarea, para esto es posible modificar la iluminación, la óptica de la cámara o incluso el espacio de trabajo.

2.17. Machine learning

Con el desarrollo de la tecnología se ha logrado percibir los límites con los que cuentan muchos sistemas las cuales son una consecuencia de las limitaciones de los algoritmos utilizados, los cuales trabajan a base de un conjunto de comandos definidos los cuales no

puede ser alterados, en otras palabras, los algoritmos no son capaces de aprender para adaptarse a la realización de una tarea. Ante esta problemática han surgido los algoritmos de machine learning los cuales se basan en el funcionamiento de la mente humana, en donde a través de la repetición y la medición de diferentes indicadores, le es posible al algoritmo determinar la situación que se le presenta y actuar de manera correspondiente a esta (Goldberg & Holland, 1988).

De este tipo de algoritmos existen una gran variedad, a causa de que cada uno cuenta con distintas fortalezas. Por ejemplo, algunos pueden desempeñarse mejor en la tarea de clasificación de información, mientras que otros son más eficientes en la optimización de procesos o en la detección de eventos. Por lo cual siempre se deben de tener en consideración los puntos fuertes y débiles del algoritmo que se busque utilizar.

Algunos de los algoritmos de machine learning más utilizados son los siguientes: Support vectos Machine (SVM), Support Vector Regresion (SVR), Naïve Bayes (NB), Logistic Regression (LR), Neuronal networks (NN), k-Nearest Neighbour (KNN), Linear discriminant analysis (LDA), Tree base algoritms, Hidden Markov Models (HMM), Evolutionary algorithms (EA) e incluso se puede llegar a utilizar la combinación de dos o más algoritmos (Belić et al., 2019). Estos algoritmos pueden llegar a ser de tipo supervisado o sin supervisión, en el primero se debe de etiquetar en qué estado se realizó una prueba para que al algoritmo comience a realizar la identificación de patrones, por otra parte un algoritmo sin supervisión comienza da detectar patrones y los clasifica a base de estos, la implementación de este tipo de algoritmos es menos común a causa de que no se pueden controlar los patrones que estará relacionando, lo que ha llevado a ser de uso moderado.

2.18. Support Vector Machine

Support vector machine o SVM es un algoritmo creado por V. Vapnik y su equipo en AT&T el cual se desarrolló con el objetivo de reconocimiento de patrones. La idea principal para el funcionamiento del SVM es el de mapear un conjunto de vectores x de entrada en un espacio de indicadores el cual será de una mayor dimensión, esto se realiza a través de un mapeo no lineal el cual puede ser definido a voluntad, con el fin de generar un conjunto de datos que

sea el óptimo para la tarea a realizar. Posteriormente los datos se separan en este plano a través de reglas de decisión lineales conocidas como hiperplanos (Vapnik, 1995).

2.18.1. Datos de entrenamiento

Para el entrenamiento de un SVM es necesario comprender que se busca obtener un clasificador. Por lo tanto, es necesario dividir la información de entrenamiento, de tal manera que se generen dos grupos. Lo cual se puede ver formalizado a través de 2-17.

$$(x_1, y_1), \dots, (x_m, y_m) \in \mathcal{X} \times \{\pm 1\} \quad (2-17)$$

En donde las x_i son los datos de entrada o patrones los cuales pertenecen al conjunto \mathcal{X} , conocido también como el dominio. Por otra parte, las variables y_i corresponden a las etiquetas o salidas, las cuales son de naturaleza binaria y que por lo tanto solo pueden tener el valor de 1 o -1, lo cual define a que grupo pertenece cada dato de entrada. Todos los datos que se vayan a utilizar para el entrenamiento del SVM deben de haber sido etiquetados previamente (Scholkopf & Smola, 2001).

2.18.2. Semejanza

Ya que lo que se busca es poder identificar si un elemento pertenece a una clase es necesario caracterizar la semejanza que existe entre elementos, lo cual se aplica tanto para las entradas como para las salidas. La semejanza de la salida es simple ya que es una clasificación binaria, por lo que dos etiquetas solo pueden ser iguales o diferentes. Por otra parte, para calcular la semejanza se cuenta con dos patrones x y x' a los cuales se les aplica una operación k , lo cual se representa en 2-18.

$$\begin{aligned} k: \mathcal{X} \times \mathcal{X} &\rightarrow \mathbb{R} \\ (x, x') &\rightarrow k(x, x') \end{aligned} \quad (2-18)$$

La función k utilizada también es conocida como kernel, la cual deberá ser simétrica evitando que sea afectada por el orden en el que se coloquen los patrones. El resultado de esta ecuación será un número real que caracterizará su semejanza.

Una de las técnicas más comunes para el cálculo de la semejanza es a través de la operación de producto punto entre dos vectores. El producto punto canónico entre dos vectores x y x' se muestra en 2-19.

$$(x \cdot x') := \sum_{i=1}^N [x]_i [x']_i \quad (2-19)$$

La interpretación del producto punto se puede ver como el coseno del ángulo que existe entre ambos vectores que se encuentren normalizados a 1. A través de este mismo procedimiento es posible obtener la norma de un vector x , lo cual resulta en la ecuación 2-20.

$$\|x\| = \sqrt{(x \cdot x)} \quad (2-20)$$

Con base a esto debería ser posible obtener la semejanza de los vectores, sin embargo, estos no pertenecen al espacio de producto punto, lo cual sugiere que los vectores podrían corresponder a cualquier tipo de objeto. Para evitar esto es necesario realizar un mapeo que coloque los datos en un espacio de producto punto llamado \mathcal{H} , también conocido como espacio de indicadores, esto se realiza a través de 2-21.

$$\begin{aligned} \Phi: \mathcal{X} &\rightarrow \mathcal{H} \\ x \rightarrow \mathbf{x} &:= \Phi(x) \end{aligned} \quad (2-21)$$

La realización de esta conversión tiene múltiples ventajas. Primeramente, permite definir la medición de la semejanza a través de 2-22.

$$k(x, x') := (\mathbf{x} \cdot \mathbf{x}') = (\Phi(x) \cdot \Phi(x')) \quad (2-22)$$

Esto también permitirá trabajar con la geometría de los patrones, permitiendo su manejo a través de geometría linear y analítica. Además de que da libertad para modificar el mapeo Φ a conveniencia, para adaptar cualquier tipo de patrón que se llegue a utilizar y pasarlo a un espacio donde sea más simple o conveniente su manejo (Scholkopf & Smola, 2001).

2.18.3. Reconocimiento de patrones

En el espacio del producto punto es posible trabajar con distancias referentes a las clases, facilitando la clasificación de nuevos patrones. Esto puede ser realizado a través del cálculo

del promedio de las clases y comparando a cuál punto se encuentra más cercano al nuevo patrón. Para esto primero se deben declarar los promedios de cada clase a través de 2-23 y 2-24 que corresponden a las etiquetas de 1 y -1 respectivamente.

$$c_1 = \frac{1}{m_1} \sum_{\{i: y_i = +1\}} x_i \quad (2-23)$$

$$c_2 = \frac{1}{m_2} \sum_{\{i: y_i = -1\}} x_i \quad (2-24)$$

En donde m_1 y m_2 hacen referencia a la cantidad de datos de cada una de las clases. A través de la Fig. 2.10 se representa de manera gráfica los puntos c_1 y c_2 al igual que el nuevo patrón x .

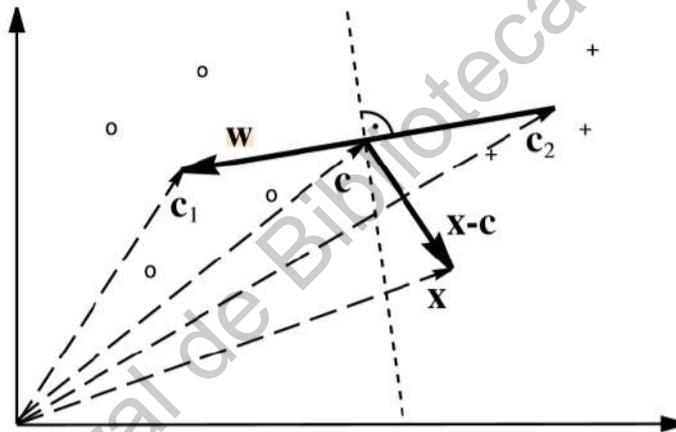


Fig. 2.10 Representación gráfica del reconocimiento de patrones (Scholkopf & Smola, 2001).

En donde el punto c queda definido a través de 2-25.

$$c = (c_1 + c_2)/2 \quad (2-25)$$

Y el vector w se obtiene con 2-26.

$$w = c_1 - c_2 \quad (2-26)$$

Lo cual pasa al desarrollo de la función de decisión y la cual parte de 2-27.

$$y = \text{sgn}\langle (x - c), w \rangle \quad (2-27)$$

La función sgn es utilizada para definir que la magnitud resultante de la operación no es de nuestro interés, pero si lo es el signo de esta, para lo cual se genera una función definida a trozos, la cual se muestra en 2-28.

$$\text{sgn}(x) = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{si } x = 0 \\ -1 & \text{si } x < 0 \end{cases} \quad (2-28)$$

Posteriormente en la ecuación 2-27 se pueden sustituir las ecuaciones 2-25 y 2-26, lo cual al desarrollarse resulta en la ecuación 2-29.

$$y = \text{sgn}(\langle x - (c_1 + c_2), (c_1 - c_2) \rangle) \quad (2-29)$$

$$y = \text{sgn}(\langle x, c_1 \rangle - \langle x, c_2 \rangle + b)$$

Lo cual genera un offset llamado b y que se encuentra definido por 2-30.

$$b = \frac{1}{2} (\|c_2\|^2 - \|c_1\|^2) \quad (2-30)$$

Ahora será necesario colocar las ecuaciones 2-29 y 2-30 en términos de x , para esto se reemplazan las ecuaciones 2-23 y 2-24 obteniendo 2-31, la cual puede colocarse de nuevo en términos de la función k reemplazando la ecuación 2-22 lo cual resulta en 2-32, siendo esta la función de decisión.

$$y = \text{sgn} \left(\frac{1}{m_1} \sum_{\{i: y_i = +1\}} \langle x, x_i \rangle - \frac{1}{m_2} \sum_{\{i: y_i = -1\}} \langle x, x_i \rangle + b \right) \quad (2-31)$$

$$y = \text{sgn} \left(\frac{1}{m_1} \sum_{\{i: y_i = +1\}} k(x, x_i) - \frac{1}{m_2} \sum_{\{i: y_i = -1\}} k(x, x_i) + b \right) \quad (2-32)$$

El mismo procedimiento se aplica al offset b , dando como resultado 2-33.

$$b = \frac{1}{2} \left(\frac{1}{m_2^2} \sum_{\{(i,j): y_i = y_j = -1\}} k(x_i, x_j) - \frac{1}{m_1^2} \sum_{\{(i,j): y_i = y_j = +1\}} k(x_i, x_j) \right) \quad (2-33)$$

A la función de decisión se le aplica una expansión de Kernel la cual corresponde con los hiperplanos que separan el espacio de los indicadores, esto resulta en 2-34.

$$y = \text{sgn}(\sum_{i=1}^m \alpha_i k(x, x_i) + b) \quad (2-34)$$

Esta ecuación será utilizada para la clasificación de nuevos puntos, en donde se llevará a cabo su comparación con cada uno de los datos de entrenamiento los cuales cuentan con un peso α_i diferente de 0, es decir, los vectores de soporte o support vectors. Esta acción se toma para evitar realizar comparaciones con elementos de entrenamiento que no hayan sido importantes para la construcción del hiperplano, reduciendo así la cantidad de cálculos necesarios para la clasificación.

2.18.4. Hiperplano

A partir de los datos de entrenamiento se busca definir una función f , que pueda separar los datos de χ en dos clases a partir de un hiperplano definido por el reconocimiento de patrones lo cual se puede expresar matemáticamente a través de 2-35.

$$f: \chi \rightarrow \{\pm 1\} \quad (2-35)$$

Para la selección de la ecuación f , no siempre se puede tomar aquel le que genere una separación perfecta de los datos, ya que puede llevar a generar una separación muy específica que solo es aplicable para los datos de entrenamiento y la cual podría ser errónea para cualquier dato futuro. Es por ello que se debe asumir que los datos cuentan con una distribución de probabilidad $P(x,y)$ desconocida. Es por ello que, al seleccionar una f , es preferible que se le dé un cierto margen de error a la clasificación de datos, de forma que la división de las clases en el plano sea más clara, aunque el error permisible debe de ser cuidadosamente vigilado ya que de otro modo puede causar la clasificación errónea de datos simples (Scholkopf & Smola, 2001). Ejemplos de estos tres casos se pueden apreciar en la Fig. 2.11.

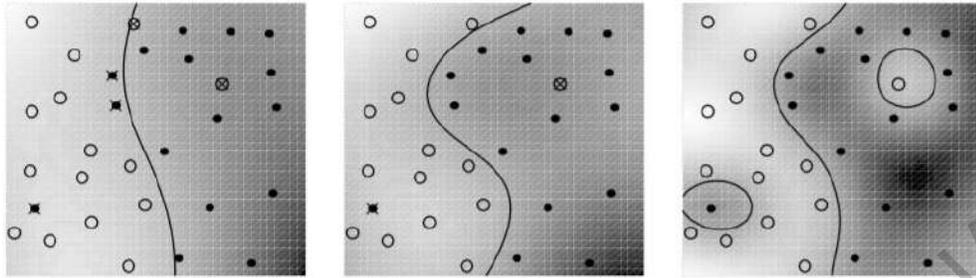


Fig. 2.11.- Ejemplos de implementación de los hiperplanos. A) Hiperplano con un error de clasificación alto. B) Hiperplano con un error de clasificación ideal. C) Hiperplano sin error de clasificación (Scholkopf & Smola, 2001).

De la función f que se seleccione para la división del plano es posible medir su exactitud con 2-36 conocida como función de pérdida o non-zero loss function, la cual toma valores de 0 si el dato fue clasificado correctamente y 1 en cualquier otro caso.

$$\frac{1}{2} |f(x) - y| \quad (2-36)$$

La función de pérdida puede tomar gran importancia en la selección la función f , ya que es posible que exista más de una función que pueda satisfacer la separación de las clases. De tal forma que a través de la función de pérdida es posible determinar cuál función cuenta con el mínimo error promedio de entrenamiento, también conocido como riesgo empírico, que se presenta en 2-37.

$$R_{emp}[f] = \frac{1}{m} \sum_{i=1}^m \frac{1}{2} |f(x) - y| \quad (2-37)$$

También es posible calcular la probabilidad de clasificación errónea, conocida como riesgo, a través de 2-38, la cual se genera a partir de la distribución $P(x,y)$.

$$R[f] = \int \frac{1}{2} |f(x) - y| dP(x,y) \quad (2-38)$$

Para la selección de f se debe considerar que un conjunto de m datos puede ser clasificado de 2^m formas diferentes; sin embargo, no cualquier función es capaz de abarcar todos los casos, a esta cualidad se le conoce como capacidad y es utilizada por la teoría de Vapnik-Chervonenkis (teoría VC) para restringir la cantidad de funciones que pueden ser elegidas y utiliza lo que se conoce como dimensión VC para representar la capacidad de un algoritmo de machine learning a través de un solo número. La dimensión VC es equivalente a la m

mayor que corresponda a m número de puntos o en su dado caso ∞ si no hay un límite. A partir de la teoría VC también se pueden generar límites, los cuales primeramente reducen la cantidad de funciones aceptables ya que se debe cumplir que la dimensión VC de la función (h) debe ser menor a la dimensión VC impuesta por los datos (m), es decir, $h < m$. Considerando que la función cumple la condición, se realiza una comparación entre el riesgo y el riesgo empírico, a este se le suma un término de confianza descrito por 2-39, resultando en el límite 2-40.

$$\phi\left(\frac{h}{m}, \frac{\log(\delta)}{m}\right) = \sqrt{\frac{h\left(\log\frac{2m}{h}+1\right)-\log(\delta/4)}{m}} \quad (2-39)$$

$$R[f] \leq R_{emp}[f] + \phi\left(\frac{h}{m}, \frac{\log(\delta)}{m}\right) \quad (2-40)$$

En este punto es donde se puede identificar si los datos cuentan con alguna relación o si su clasificación es meramente trivial, si este fuera el caso sería necesario contar con un valor de dimensión h grande por parte del algoritmo, lo cual causaría el incremento del termino de confianza que directamente repercutiría en el valor del límite, causando que supere la unidad y se convierta en una clasificación trivial. Por ello es importante que se restrinjan las funciones a partir de su capacidad para obtener clasificaciones no triviales e identificar los casos en donde no es aplicable la separación (Scholkopf & Smola, 2001).

Cuando se busca desea realizar la separación de datos a través del hiperplano, existen una gran variedad de estos: sin embargo, se busca aquel que pueda separar los datos con el mayor margen y teniendo menor error de entrenamiento el cual se conoce como hiperplano optimo, su comportamiento se puede apreciar claramente en la Fig. 2.12.

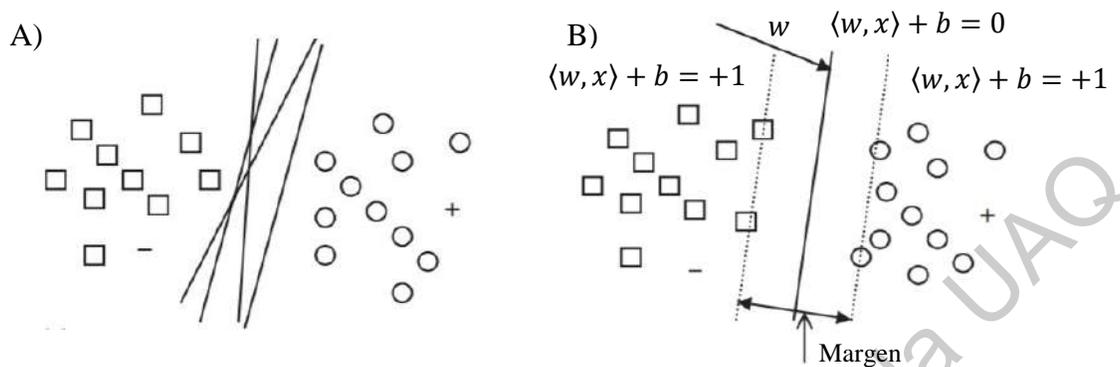


Fig. 2.12 Separación de datos con hiperplanos. A) Posibles hiperplanos. B) Hiperplano óptimo(Begg & Kamruzzaman, 2005).

Para determinar este hiperplano óptimo es necesario definir un conjunto de restricciones, empezando por 2-41 que se debe respetar para cualquier operación que se busque realizar.

$$y_i(\langle w, \phi(x) \rangle + b) \geq 1 \quad (2-41)$$

Sin embargo, en algunos casos se contará con información que no es linealmente separable y que por lo tanto generaran errores en la clasificación. A causa de esto es necesario modificar la restricción 2-41, agregando lo que se conoce como variables de holgura (slack variables), las cuales representan los datos mal clasificados, resultando en la nueva restricción 2-42 y con esto se anexa la restricción 2-43.

$$y_i(\langle w, \phi(x) \rangle + b) \geq 1 - \xi_i \quad (2-42)$$

$$\xi_i \geq 0 \quad (2-43)$$

Es necesario realizar una optimización del hiperplano que separará las clases la cual se ve representada por 2-44, esta se encuentra conformada por dos términos que representan la dimensión VC del clasificador y su error empírico, respectivamente. Además, también se encuentra la constante C que representa la compensación entre el máximo margen y el mínimo error de clasificación (Kim et al., 2003).

$$\frac{1}{2} \langle w, w \rangle + C \sum_{i=1}^L \xi_i \quad (2-44)$$

Este problema busca ser minimizado mientras se cumplen las restricciones 2-42 y 2-43. Para su solución se lleva a cabo la implementación de Lagrangianos lo que resulta en 2-45.

$$W(\alpha) = \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i=1}^L \sum_{j=1}^L \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (2-45)$$

Donde se busca realizar su maximización, mientras se encuentra sometida a la restricción 2-46 y 2-47.

$$\sum_{i=1}^L y_i \alpha_i = 0 \quad (2-46)$$

$$0 \leq \alpha_i \leq C \quad (2-47)$$

Por último, en la ecuación 2-45 se busca evitar el uso del producto punto para cualquier situación, pero tampoco se desea trabajar con $\Phi(x)$, por lo que se puede pasar directamente al uso del kernel como se establece en 2-22. Además, se establece que el valor ideal de w puede ser obtenido con 2-48, en donde SVs, es el número de vectores de soporte, es decir, aquellos datos donde $\alpha_i > 0$.

$$w = \sum_{i \in SVs} \alpha_i y_i \Phi(x_i) \quad (2-48)$$

Al realizar las sustituciones de kernel, se obtiene la ecuación 2-34, la cual ya se había establecido con anterioridad y es la ecuación con la cual estará en funcionamiento cualquier clasificador que se busque implementar con SVM (Begg & Kamruzzaman, 2005).

2.19. Funciones de Kernel

La función de Kernel se encarga de generar el espacio de los indicadores, en donde es posible realizar la separación de los datos, aunque estos no sean linealmente separables. Para realizar esta tarea se utiliza lo que se conoce como truco de Kernel, en donde se proyectan cada uno de los datos en un espacio de mayor dimensión con el fin de poder utilizar algoritmos lineales para la solución del problema. El efecto del truco de Kernel puede ser mejor apreciado si se observa el ejemplo de la Fig. 2.13, en donde se muestra en A) un conjunto de datos que no es linealmente separable; sin embargo, al aplicar el truco de Kernel a los datos se puede observar en B) cómo se aprovecha la forma del espacio de indicadores para separar todos los

datos con un solo plano. El resultado que se muestra en C) es la separación obtenida de los datos en el espacio original (Verplancke et al., 2008).

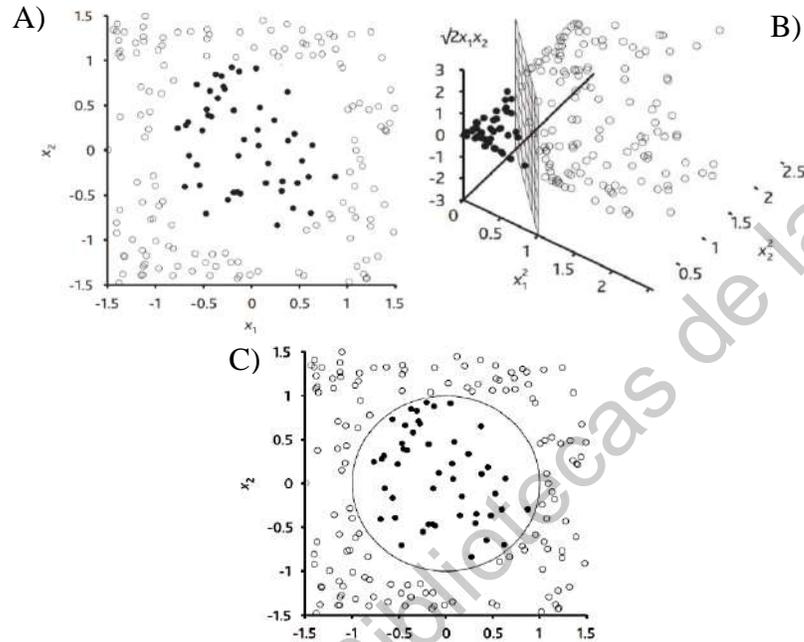


Fig. 2.13.- Representación del truco de Kernel. A) Conjunto de datos no linealmente separables. B) Espacio de indicadores usando Kernel. C) Datos separados en su espacio original (Verplancke et al., 2008).

El truco de Kernel es una de las bases utilizadas para cualquier clasificador a base de Kernels; sin embargo, existen diferentes tipos de Kernels los cuales generan diferentes espacios de indicadores y por lo tanto cuentan con diferentes características. Para su selección se debe tomar en cuenta el tipo de datos con los que se estará trabajando e incluso se recomienda realizar comparaciones entre los resultados obtenidos con diferentes Kernels (Begg & Kamruzzaman, 2005). En la Tabla 2-1, se encuentran un conjunto de los Kernels más comunes y una breve descripción de las situaciones donde son aplicables.

Tabla 2-1.- Funciones de Kernels

Tipo de Kernel	Función	Descripción
Linear	$K(x_i, x_j) = \langle x_i, x_j \rangle \quad (2-49)$	<p>Es el Kernel más simple y se basa en la operación de producto punto, al resultado de la operación se le puede agregar una constante c, con el fin de evitar que los resultados queden en ceros.</p>
Polinómica	$K(x_i, x_j) = (\langle x_i, x_j \rangle + 1)^d \quad (2-50)$	<p>Es del tipo no estacionario, es decir, que su traslación varia. Son útiles cuando se trabaja con datos normalizados. Además, su grado puede ser modificado a través de d.</p>
Gaussiano	$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right) \quad (2-51)$	<p>Con este Kernel es posible modificar que tan lineal se comporta el espacio utilizando el valor de σ. Si se aumenta su valor el espacio se vuelve más lineal y si se reduce se vuelve más sensible.</p>
Exponencial	$K(x_i, x_j) = \exp\left(-\frac{ x_i - x_j }{2\sigma^2}\right) \quad (2-52)$	<p>Esta es una variación del Kernel gaussiano y puede ser útil cuando se cuenta con discontinuidades.</p>

Capítulo 3. Metodología

En el presente trabajo se buscó determinar el estado en el que se encuentra la marcha de una persona. Para llevar a cabo esta tarea se propuso el desarrollo de un sistema que pueda llevar a cabo un diagnóstico. Uno de los primeros pasos fue la recolección de información relacionada a las variaciones que pueden existir en la marcha de diferentes personas. La información que se busca obtener está relacionada con la cinemática, cinética y los parámetros espacio-temporales de la marcha, ya que a través de estos es posible recrear la biomecánica de las extremidades inferiores durante dicho movimiento. Y es a través de estas recreaciones, que es posible determinar si durante el ciclo de caminado se presentan particularidades que difieran con lo que se considera como una marcha sana.

Para la adquisición de información se obtuvo una población inicial, la cual se encontraba compuesta de tres grupos dependiendo del estado en el que se encontraran los individuos, ya sea sanos, con problemas de naturaleza muscular y con problemas de naturaleza ósea. Las pruebas realizadas fueron idénticas sin importar el tipo de problema presente, y a la vez se estará etiquetando la información recabada para posteriormente realizar una clasificación.

A los participantes se les colocaron un conjunto de marcadores y sensores a lo largo de las extremidades inferiores, los cuales se encargan de facilitar la medición de los parámetros de la marcha, cabe mencionar que ninguno de los dispositivos utilizados representa una amenaza para los participantes. Una vez montados los sensores, se le pidió al participante que realizara una caminata de 40 m a una velocidad de confort sobre una caminadora eléctrica, la cual se encontraba bajo techo y con una iluminación controlada. Estas pruebas fueron monitoreadas a través de los sensores montables y se proyectó una luz infrarroja sobre el participante, la cual fue reflejada por los marcadores y percibida por un sistema de visión artificial.

Posteriormente la información fue procesada por un software, el cual aislaría la información provista por los marcadores de cada uno de los cuadros del video obtenido. Con esta información se obtienen mediciones del desplazamiento lineal y angular, así como sus derivados como la velocidad y la aceleración. Esta es combinada con la información del sensor montable y se etiquetará acorde a la condición correspondiente, permitiendo que sea

procesada por un algoritmo de machine learning conocido como Support Vector Machine (SVM), para llevar a cabo su entrenamiento, que consistirá en la identificación de patrones característicos de cada condición. Una vez que el SVM se encuentra entrenada, se realizan nuevas pruebas con una población diferente, con el fin de verificar si el algoritmo puede identificar su condición a partir únicamente de las mediciones. El procedimiento mencionado se encuentra representado en el diagrama de la Fig. 3.1.

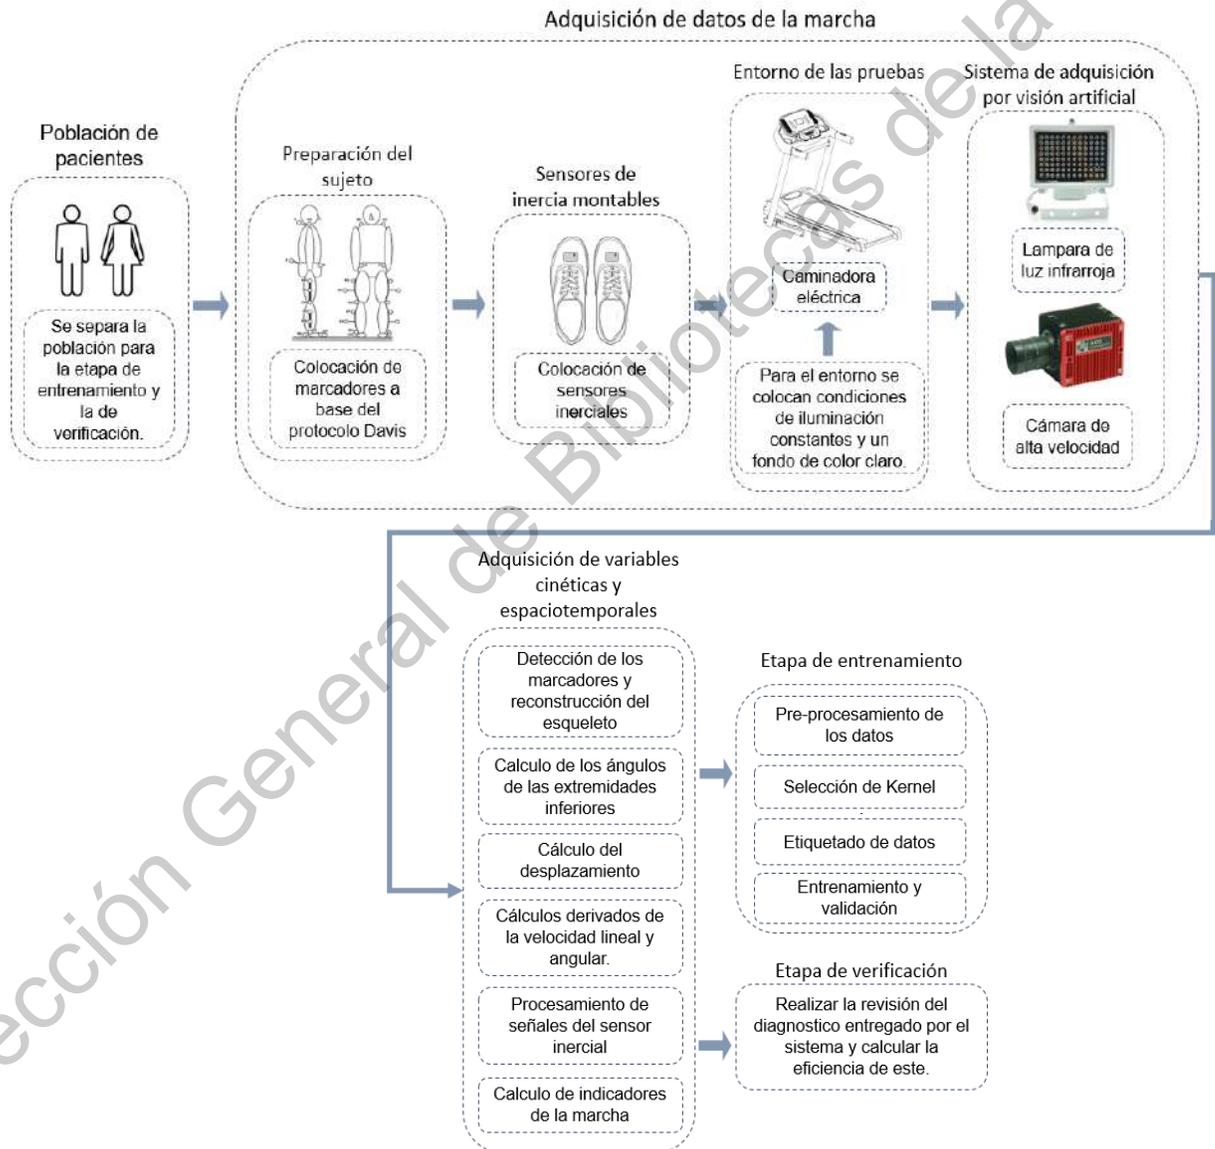


Fig. 3.1.- Diagrama de la metodología

3.1. Población de pacientes

Los sistemas de machine learning, como lo es el SVM, requieren de una amplia base de datos que les permita realizar la identificación de patrones. Para esto fue necesario tomar una población mínima de 10 personas para cada uno de las condiciones que se busca diagnosticar (Byrne et al., 2002), es decir, que se encuentren en estado sano, con problemas óseos o con problemas musculares con base a lo cual se etiquetaron los datos. Por otra parte, es necesario un segundo grupo de personas que permita realizar la verificación del sistema, estas también deberán de estar diagnosticadas, pero sus datos no serán etiquetados por lo que la respuesta del algoritmo dependerá únicamente de los patrones que pueda identificar en los parámetros medidos en la marcha.

3.2. Realización de pruebas físicas por los participantes

Para la realización de las pruebas se le pide al sujeto que realice una caminata con una duración de 90 segundos sobre una caminadora eléctrica, en donde se realizaron múltiples pruebas a diferentes velocidades que se encuentren dentro del rango de una caminata promedio (Trew & Everett, 2006), siendo estos 1.4, 1.9, 2.1 y 2.4 km/h. Esto con el fin de que se cuente con información de las variaciones que pueden darse en la marcha de la misma persona. Todas las pruebas se realizaron bajo techo dentro de las instalaciones de la Facultad de Enfermería, con iluminación controlada y un área delimitada.

3.2.1. Preparación del sujeto

A todos los participantes se les pidió que se presentaran portando prendas de color oscuro, que no delimitaran su movimiento o dificultaran su observación, además de que se les pedirá remover cualquier tipo de accesorio que pueda ser altamente reflejante como cadenas, aretes, pulseras, relojes, etc. Posteriormente, se le coloca al sujeto un conjunto de marcadores reflejantes, los cuales fueron colocados a base del protocolo Davis, ya que facilita la detección del movimiento de los miembros para el sistema de visión artificial. También se colocaron dos sensores de inercia en las puntas de los pies, para obtener las rotaciones que se generan en los 3 planos por parte del pie.

3.2.2. Entorno de las pruebas

Para la realización de las pruebas se contó con una caminadora eléctrica, la cual se encontraba en un entorno con iluminación constante y uniforme provista por reflectores, además de un fondo de color oscuro, con el cual fue más simple resaltar al sujeto de pruebas. De esta manera se contó un entorno que tuviera la mínima cantidad de interferencias.

3.2.3. Sistema de adquisición por visión artificial

Para el sistema de visión artificial se optó por utilizar una cámara monocromática UI-3130CP-M-GL R2, de la compañía IDS. Para la selección del óptico que se utilizaría se consideró la ecuación 3-1.

$$f = \frac{SS*WD}{FOV} \quad (3-1)$$

En donde f es la distancia focal, SS es el tamaño del sensor, WD es la distancia al objeto y FOV es el campo de visión de la cámara, los cuales se pueden ver representados en la Fig. 3.2. Todos los datos utilizados fueron colocados en mm, ya que esta es la escala en la que se trabaja la distancia focal de los ópticos, también solo se consideró la componente vertical del tamaño del sensor de 2.88 mm y el campo de visión de 1000 mm. El resultado obtenido considerando una distancia de trabajo mínima de 1400 mm fue de 4.032 mm, el cual se redondeó a 4mm para que entre en el estándar de las ópticas.

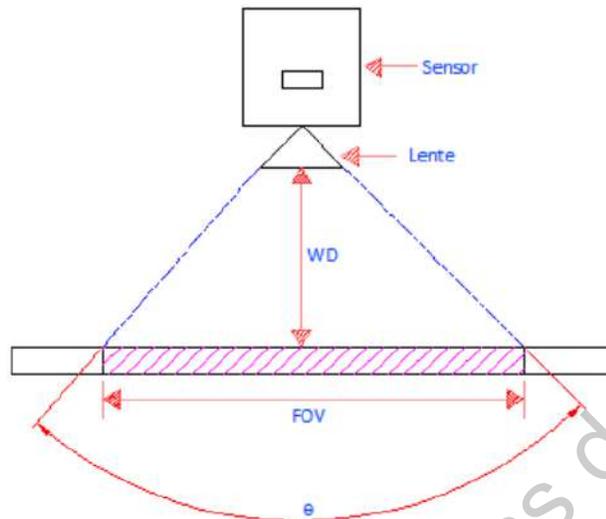


Fig. 3.2.- Representación del campo de visión de una cámara.

Para poder verificar la fidelidad de las mediciones se realizó una revisión previa de sus parámetros intrínsecos. Para esta tarea se utilizó una herramienta de Matlab conocida como “Camera calibration toolbox” (Sandoval Castro et al., 2013). Para su implementación fue necesario la realización de una prueba en específico, en donde se colocará la cámara en una posición fija viendo directamente hacia un patrón de ajedrez, el cual se encuentra a una distancia conocida en este caso a 20 cm. Con la cámara se tomaron una serie de capturas en donde se estuvo rotando el patrón de ajedrez sobre un eje definido, en la Fig. 3.3 se puede apreciar cómo se llevó a cabo la toma de capturas.

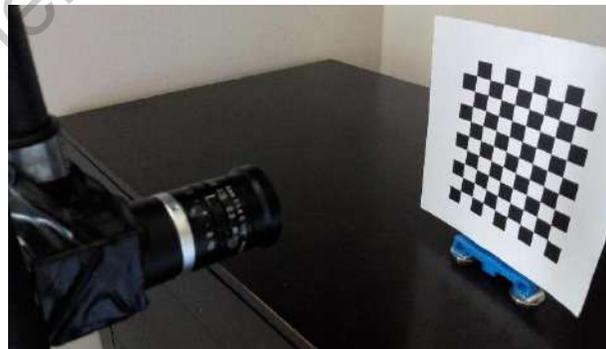


Fig. 3.3.- Espacio de captura para la calibración de la cámara

El conjunto de imágenes es cargado a Matlab, el cual realiza la identificación del patrón y determina la distorsión existente en la cámara. La toolbox genera una grafica de los errores por distorsión, donde se presenta el error que hay entre los puntos detectados del patron y los proyectados por el algoritmo, lo que se presenta en la Fig. 3.4. De estos se puede decir que son aceptables siempre y cuando no superen el error de 1 pixel, lo cual en este caso se cumple.

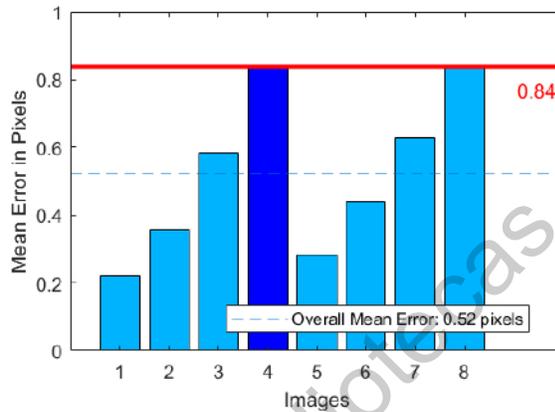


Fig. 3.4.- Errores de proyección

También es posible obtener una recreación del espacio de captura, en donde se presenta la orientación del patrón con respecto a la cámara en cada una de las capturas, lo cual se presenta en la Fig. 3.5 en donde se puede apreciar que el patrón se estuvo girando sobre un mismo eje y a que distancia se encontraba de la cámara.

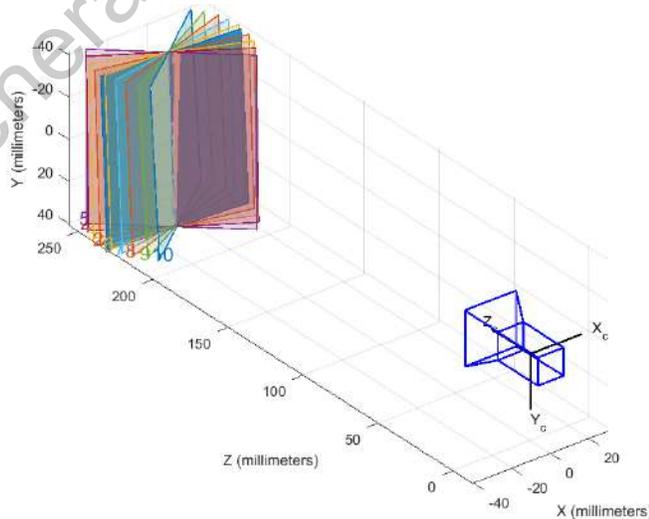


Fig. 3.5.- Recreación del espacio de captura

A partir de estos resultados se obtuvieron los parámetros de la distorsión presente en la cámara, los cuales para este caso se presentan en la Tabla 3-1.

Tabla 3-1 Parámetros intrínsecos de la cámara

Parámetros de la cámara		
<i>Distorsión radial</i>	k_1	-0.2307
	k_2	0.9945
<i>Distorsión tangencial</i>	0	
<i>Skew</i>	0	
<i>Error medio de proyección</i>	0.63	

Una vez conocida la distorsión de la cámara, se decidió desarrollar un sistema de calibración para conocer los errores de medición que surgen al analizar un sistema en movimiento, para esto se optó por la construcción de un mecanismo Hoeken. Este es utilizado en robots para replicar las trayectorias del caminado humano, el cual también fue replicado en forma de simulación para poder comparar las mediciones realizadas con la cámara contra las mediciones en una condición ideal. Se procuró el uso de un mecanismo en lugar de la medición de un caminado real, debido a la dificultad de replicar de manera fiel el caminado humano en una simulación, a causa de su complejidad e irregularidades evitando que se pudieran realizar comparaciones entre las mediciones reales y mediciones simuladas en estado ideal.

Para el diseño del mecanismo Hoeken se consideró el modelo propuesto por Liang et al., 2011, en donde se acompaña con un pantógrafo, el cual no solo amplificara la trayectoria generada por el mecanismo Hoeken sino que también proporciona una estructura que cuenta con una mayor similitud con una pierna, tal como se puede observar en la Fig. 3.6 en donde se muestra el diseño y nombre de cada uno de los eslabones que componen al mecanismo y marca la unión entre ambos.

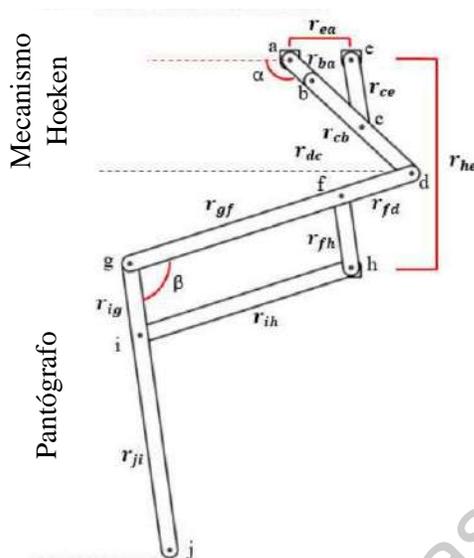


Fig. 3.6.- Esquema del mecanismo Hoeken en conjunto con un pantógrafo.

El mecanismo funciona utilizando el eslabón r_{ba} como la entrada, en donde se colocó un servo motor que modifica el ángulo α , impulsando al resto de los eslabones y obteniéndose la trayectoria deseada, que se presenta en el punto j del eslabón r_{ji} , el cual sería considerado como el eslabón de salida y cuya trayectoria asemeja la de una pierna durante una caminata como se puede observar en la Fig. 3.7.

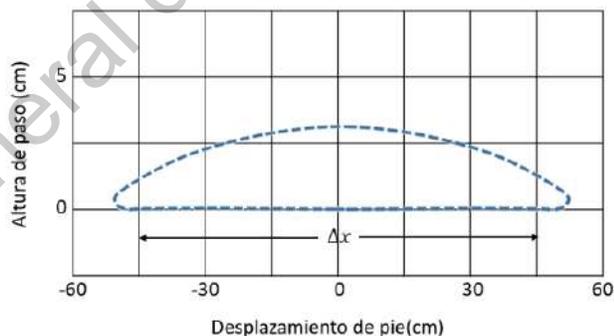


Fig. 3.7.- Trayectoria generada por el mecanismo Hoeken en el punto j

En donde Δx hace referencia a la longitud de zancada, que sería aproximadamente de 49.2 cm, y la cual se tomaría como el parámetro de diseño para establecer las medidas del mecanismo Hoeken. Sin embargo, lo primero que se diseñó fue el pantógrafo, para conocer la amplificación que se le aplicaría a Δx .

Ya que el pantógrafo es la parte del mecanismo que asemeja una pierna, se decidió seleccionar las dimensiones de r_{ji} y r_{gf} que asemejaran a las de una pierna y trabajar a partir del incremento que se generara, la cual se obtiene a través de la ecuación 3-2 en donde R es la amplificación (Patil et al., 2018).

$$R = \frac{r_{jd}}{r_{hd}} = \frac{r_{gd}}{r_{fj}} = \frac{r_{jg}}{r_{fh}} \quad (3-2)$$

Una vez conocida, se divide el desplazamiento Δx por la amplificación R para obtener el desplazamiento real ($\Delta x'$) que tendría que generar el mecanismo Hoeken. Para su diseño se tomaron las recomendaciones propuestas por Norton, 1999, en donde se debía cumplir con ciertas relaciones entre eslabones para obtener un funcionamiento eficiente y más que nada con un movimiento rectilíneo. Las relaciones que se deben cumplir se muestran en 3-3, 3-4 y 3-5.

$$r_{ba} = \frac{\Delta x'}{2.6} \quad (3-3)$$

$$r_{cb} = \frac{r_{ba}}{2.238} \quad (3-4)$$

$$r_{ea} = \frac{r_{ba}}{1.825} \quad (3-5)$$

A partir de estas relaciones entre los eslabones, se obtuvieron las medidas que se presentan en la Tabla 3-2.

Tabla 3-2.- Dimensiones de los eslabones del mecanismo Hoeken y el pantógrafo.

Mecanismo Hoeken	Eslabones	r_{ba}	r_{cb}	r_{ea}	r_{ce}	r_{dc}
	Longitud (cm)	4.73	10.59	8.63	10.59	10.59
Pantógrafo	Eslabones	r_{gd}	r_{fh}	r_{ih}	r_{jg}	r_{he}
	Longitud (cm)	46	11.25	34.5	45	35.33

Una vez construido el modelo real y diseñada la simulación, se realizaron una variedad de pruebas en donde se variaba la velocidad angular del servomotor, lo que permitía determinar el error que existía en cada uno de los casos, tanto en posición como en velocidad, y a partir del cual se calibraba la obtención de los datos. Los resultados finales se pueden apreciar en la Tabla 3-3, en donde el error se encuentra por debajo del 5% para todos los casos lo cual es lo máximo que pueden tener los elementos de medición (Cedeño-Moreno et al., 2020).

Tabla 3-3.- Comparación entre mediciones del Sistema real y el simulado.

Error de posición									
Velocidad de entrada(rpm)	Talón			Rodilla			Cadera		
	RMS		Error (%)	RMS		Error (%)	RMS		Error (%)
	real	simulado		real	simulado		real	simulado	
5.55	78.16	79.33	1.47	55.11	54.68	0.79	21.02	21.93	4.16
4.16	78.04	78.91	1.09	54.21	53.34	1.64	21.4	22.02	2.82
3.33	77.83	78.82	1.26	55.41	54.63	1.42	21.13	21.81	3.12
2.77	77.99	7907	1.37	55.56	54.6	1.75	21.13	21.92	3.63
Error de velocidad									
Velocidad de entrada (rpm)	Talón			Rodilla			Cadera		
	RMS		Error (%)	RMS		Error (%)	RMS		Error (%)
	real	simulado		real	simulado		real	simulado	
5.55	16.31	16.3	0.04	18.26	18.32	0.31	4.31	4.46	3.23
4.16	12.49	12.23	2.13	12.86	13.46	4.39	3.16	3.31	4.43
3.33	10.16	9.96	1.99	10.61	10.79	1.63	2.47	2.56	3.53
2.77	8.49	8.43	0.8	9	9.14	1.53	2.15	2.25	4.73

Por otra parte, para la adquisición de los movimientos se utilizaron marcadores reflejantes sobre los cuales se proyectará una luz infrarroja, esta es reflejada directamente hacia la cámara lo cual facilitará distinguir los marcadores en las capturas. Para poder hacer este proceso más practico se decidió que se le incorporará a la cámara un filtro BP850-27, es cual es un filtro pasabandas que permite el paso de las longitudes de onda entre 800 y 910 nm, esto permite que solo pasen ondas cercanas al infrarrojo. De esta manera se puede eliminar interferencias causadas por cualquier otro tipo de iluminación presente. El resultado de

utilizar este método se puede apreciar en la Fig. 3.8, en donde los marcadores destacan más que el participante.



Fig. 3.8 Captura de los marcadores reflejantes con luz infrarroja (Hafer et al., 2015).

3.2.4. Sensores de inercia montables

En el presente trabajo se decidió complementar la información del sistema de visión artificial utilizando sensores montables, ya que a pesar de que el uso de cámaras permite la medición de múltiples características de la marcha, no es ideal para todas las mediciones, ya que se requerirían múltiples cámaras con diferentes puntos de vista del paciente, lo cual incrementa en gran medida el costo y complejidad del proyecto. Mientras tanto la implementación de sensores de inercia montables representa un menor costo y una mayor facilidad en la adquisición de algunas mediciones, como la inclinación del pie durante el ciclo del caminado.

Para su construcción se tomó como modelo el trabajo realizado por Jaramillo-Arteaga, 2019, donde se toma como base una arduino pro mini, esta fue seleccionada con el fin de reducir el tamaño de todo el sensor ensamblado sin perder mucho del poder de procesamiento. La arduino pro mini trabaja a 8Mhz y requiere de una alimentación de 3.3V, lo cual es suministrado por una batería BAT-T085 que también alimentara el resto de los componentes. Para realizar las mediciones se utiliza un MPU6050, el cual cuenta con un acelerómetro y giroscopio. También se cuenta con un módulo de bluetooth CH-06, que pueda funcionar para recibir la señal de inicio de prueba. Para el almacenamiento de datos se incorporará un

módulo HW-125 junto a una memoria micro SD de 6 GB, en donde se lleva a cabo la escritura de datos en un archivo de texto. En la Fig. 3.9 se puede observar el diagrama de conexión de los elementos.

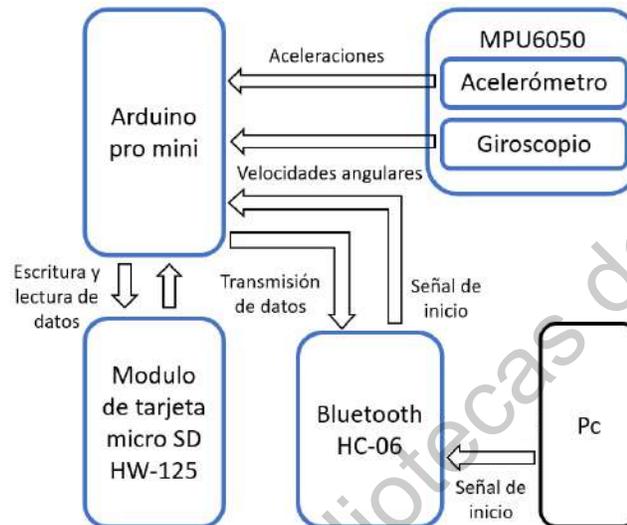


Fig. 3.9.- Diagrama de conexión entre los componentes

Para la obtención de las lecturas del MPU6050 se utilizó la librería MPU6050.h, la cual ya se encuentra desarrollada para arduino, pero también fue necesario utilizar la librería I2Cdev.h, para establecer una comunicación de tipo I²C aun que requiere del uso de la librería Wire.h. El sensor trabaja a una velocidad de 57600 baudios, mientras que la adquisición de datos se llevará a cabo a 20Hz y se utilizan las funciones de getAcceleration y getRotation para obtener las mediciones del acelerómetro y giroscopio respectivamente. Todas las lecturas del MPU6050 tienen un rango mínimo de -32768 hasta 32768, ya que este trabaja a 16 bits, estas deben ser mapeadas para concordar con el tipo de medición del acelerómetro y el giroscopio. El acelerómetro tiene por defecto mediciones desde -2g hasta 2g, mientras que el giroscopio cuenta con mediciones desde -250°/s hasta 250°/s, lo cual se puede mapear con una simple conversión o con la función map.

El MPU6050 cuenta con variables conocidas como offsets, las cuales permiten ajustar sus mediciones para una superficie en específico. Su implementación es relativamente simple, se debe colocar el sensor sobre la superficie decaada en una orientación fija, la cual se debe procurar no mover durante todo el proceso de calibración. Posteriormente se revisan las

lecturas de ambos sensores y se van aumentando o reduciendo los offsets hasta que llegue a las medidas ideales que cada eje debería tener, las cuales se muestran en la Tabla 3-4.

Tabla 3-4.- Medidas ideales del acelerómetro y giroscopio

Acelerómetro			Giroscopio		
x	y	z	x	y	z
0	0	9.81	0	0	0

En donde el eje z idealmente se encuentra midiendo la gravedad.

Para la escritura de datos se utilizan las librerías SPI y SD, las cuales permiten acceder a una memoria micro SD para generar un archivo de texto, en el cual se registra el tiempo en el que se realizó la medición, las mediciones en xyz de ambos sensores y las inclinaciones en los ejes x y y. El motivo por el que se decidió guardar las mediciones en lugar de transmitirlos directamente por bluetooth fue la velocidad, ya que las mediciones se realizan a 50Hz puede surgir el caso donde la información enviada llegue incompleta o no pueda ser recibida por el PC. Causando la posible pérdida de información importante para el estudio. Por ello durante las pruebas el módulo bluetooth solo cuenta con la tarea de recibir la señal de inicio y no es hasta que finalice la prueba, que se debe retirar el sensor del usuario para extraer la información obtenida.

3.3. Adquisición de variables cinéticas y espaciotemporales

Para obtener la información deseada del movimiento analiza cada uno de los fotogramas del video adquirido de una prueba, donde se busca aislar por completo los marcadores de la imagen para poder obtener la trayectoria de cada uno de los puntos de interés. Esto permite la reconstrucción del esqueleto básico de las extremidades inferiores y con ello la posibilidad de determinar su cinética, cinemática y sus parámetros espacio-temporales.

3.3.1. Detección de los marcadores y reconstrucción del esqueleto

Para llevar a cabo la detección de los marcadores, se utilizó un software que analiza cada uno de los fotogramas de una prueba, en estos se aplica un umbralizado que deja una imagen

binaria en donde se encuentren aislados los marcadores. Para esto se utilizaron las librerías de Aforge, en las cuales se encuentra la función de Threshold para el umbralizado y la función de blobcounter para realizar la identificación de los marcadores en la imagen resultante. A través de las funciones de Blobcounter fue posible filtrar los objetos a base de su tamaño, lo cual permite eliminar objetos pequeños o muy grandes que no sean de interés. También es posible obtener su centroide con respecto a un origen, que se ubica en la esquina superior izquierda, lo cual es esencial para la medición del desplazamiento. Un ejemplo de esto se puede observar en la Fig. 3.10.

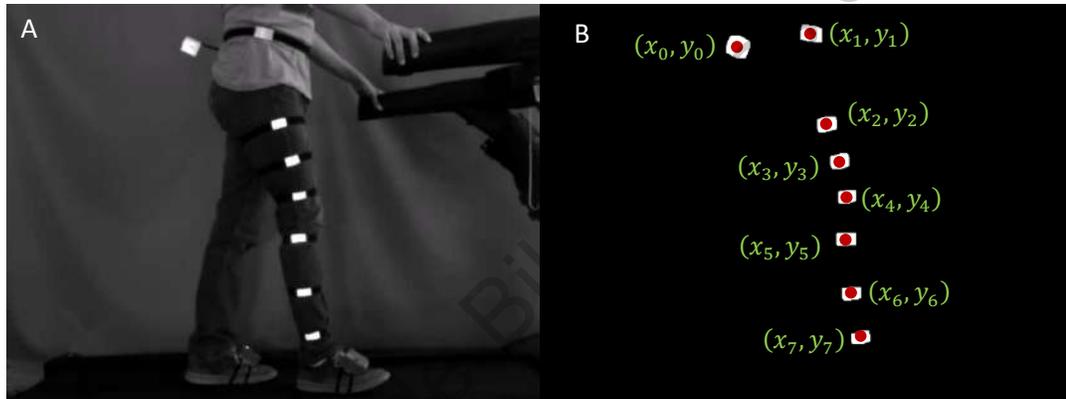


Fig. 3.10.- Umbralización de la imagen y detección de los marcadores. A) Imagen original en blanco y negro durante una prueba. B) Segmentación de los marcadores, detección del centroide y etiquetado.

Posteriormente, se toma uno de los puntos obtenidos como un nuevo sistema de referencia, con el fin de tener una referencia que se mantenga fija al usuario y que no cambie por más que este se mueva. Al realizar esta traslación del origen es necesario pasar las coordenadas de los centroides al nuevo sistema de referencia, para esto se puede utilizar la ecuación 3-6.

$$(x'_A, y'_A) = (x_A, y_A) - (x_{O'}, y_{O'}) \quad (3-6)$$

En donde $(x_{0'}, y_{0'})$ son las coordenadas del nuevo origen con respecto al original, (x_A, y_A) son las coordenadas de el centroide con respecto al origen inicial y (x'_A, y'_A) son las coordenadas correspondientes del centroide al nuevo origen. La traslación del origen se muestra en la Fig. 3.11, donde (x_0, y_0) es el origen inicial.

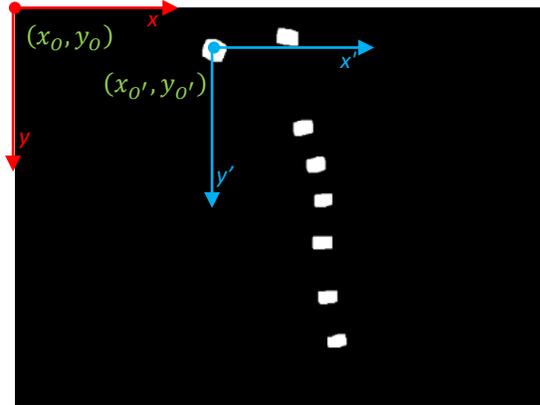


Fig. 3.11.- Traslación del origen

3.3.2. Cálculos de ángulos

Antes de poder realizar el cálculo de los ángulos en el sistema de visión artificial es necesario etiquetar los marcadores, con el fin de que se conozca a que segmento de la extremidad corresponden. Como se muestra en la Fig. 3.12, se le asignaran valores numéricos a cada uno de los puntos de interés, a partir de estos se realizará el cálculo del ángulo θ_k que existe en la rodilla utilizando la ecuación 2-8 y 2-9. Esto se realiza con cada uno de los fotogramas resultando en una gráfica del cambio de ángulo con respecto al tiempo.

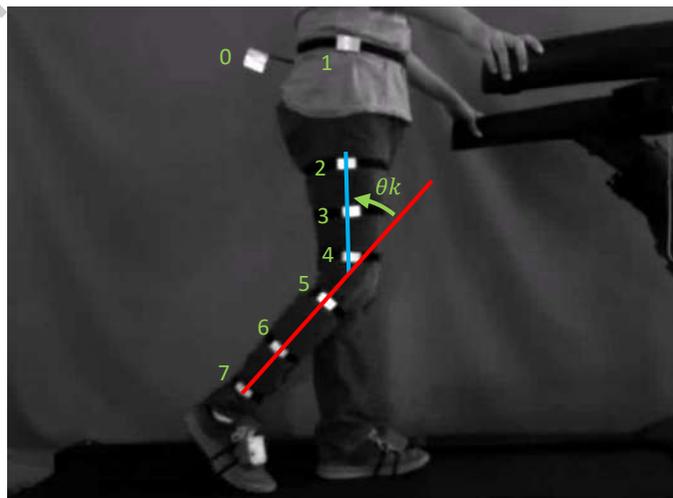


Fig. 3.12.- Numeración de los puntos de interés

En el caso de los sensores montables, utilizando los datos provenientes de MPU6050 se obtiene la inclinación en cada uno de los ejes ya sea utilizando el acelerómetro o el giroscopio; sin embargo, si solo se obtiene la inclinación utilizando solo uno de los sensores los datos tendrían poca confiabilidad, ya que ambos son propensos al error de una u otra forma. El acelerómetro es capaz de realizar las mediciones correctas de las componentes de la gravedad que se presentan en cada uno de los ejes; sin embargo, es susceptible a fuerzas externas causando que sus mediciones sean incorrectas si se encuentra bajo constante movimiento, lo cual es un inconveniente para esta aplicación. Por otra parte, los giroscopios cuentan con algo conocido como drift el cual es un error acumulativo que se va presentando en las lecturas, haciendo que solo sea efectivo para mediciones a corto plazo. Para solucionar ambos problemas se utiliza un método conocido como filtro de complemento, en donde se obtiene la inclinación de los ejes x y y utilizando una combinación entre las lecturas de ambos sensores (Wu et al., 2016), las cuales son utilizadas en la ecuación 3-7.

$$\alpha_t = 0.98(\alpha_{t-1} + \omega_{giroscopio} dt) + 0.02(a_{acelerómetro}) \quad (3-7)$$

La ecuación es utilizada para ambos ejes en donde α es la inclinación sobre un eje, $\omega_{giroscopio}$ es la lectura del giroscopio sobre el mismo eje, dt es el lapso de tiempo entre la medición actual y la anterior y $a_{acelerómetro}$ es la medición del acelerómetro en el mismo eje. En este caso el acelerómetro no aporta mucho ya que solo se está utilizando para suprimir el error producido por el drift.

3.3.3. Cálculo del desplazamiento

Para realizar el cálculo del desplazamiento se utilizan las coordenadas de los centroides de cada uno de los marcadores. Para esto se utiliza la ecuación 3-8, donde (x_A, y_A) son las coordenadas en xy y d es el desplazamiento.

$$d_A = \sqrt{x_A^2 + y_A^2} \quad (3-8)$$

Obteniendo así el desplazamiento, lo cual se debe realizar para cada uno de los fotogramas, lo cual permitirá generar una gráfica del desplazamiento de cada marcador a través del

tiempo. A partir de este conjunto de datos será posible derivar diferentes datos como velocidades, rotaciones, aceleraciones, etc.

3.3.4. Cálculos derivados de velocidad lineal y angular

Ya que se cuenta con los datos tanto del desplazamiento como de la rotación, se derivan para obtener la velocidad lineal y angular, utilizando la formulas 2-12 y 2-13. Sin embargo, al ser mediciones derivadas es posible que las pequeñas variaciones presentes en los datos del desplazamiento se vean reflejadas como ruido, el cual pueda deformar por completo los datos de velocidad, como se muestra en la

Fig. 3.13.

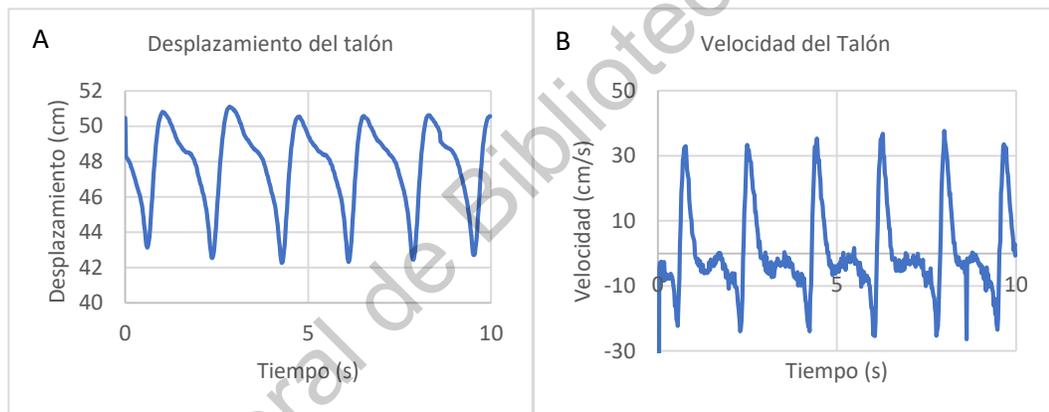


Fig. 3.13.- Resultado de la medición de velocidad derivada de la posición. A) Desplazamiento resultante del talón. B) Velocidad derivada del desplazamiento del talón.

Con el fin de evitar esto se decidió implementar un filtro de media móvil, el cual permite realizar la tarea de suavizar la gráfica al dividir la información en ventanas y obtener su promedio, la función que define esta tarea es la 3-9 (Oppenheim et al., 1999).

$$y(n) = \frac{1}{w}(x(n) + x(n - 1) + \dots + x(n - (w - 1))) \quad (3-9)$$

En donde x hace referencia a un vector que contiene los datos del desplazamiento, m es el número total de datos, w es el tamaño de la ventana y y es el vector de velocidades. El resultado de esta tarea se puede observar en la Fig. 3.14, en donde se puede percibir

claramente la mejora de los datos, lo cual es imprescindible para el entrenamiento eficiente del algoritmo.

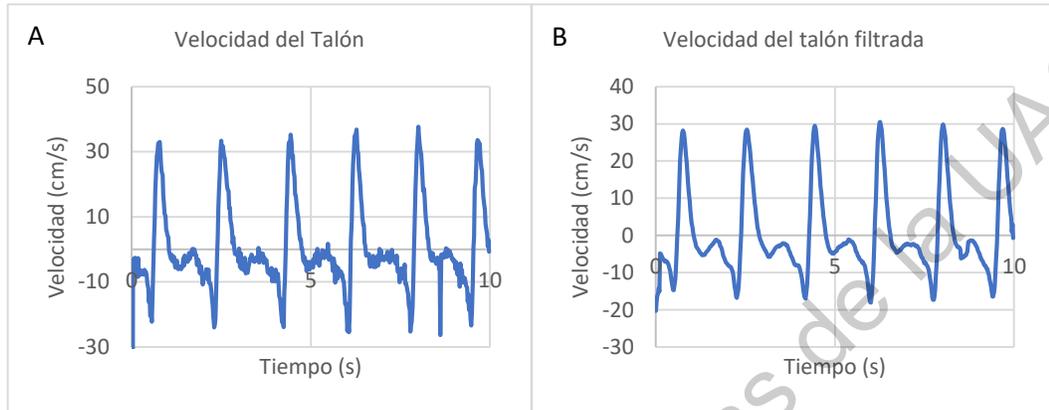


Fig. 3.14.- Grafica de la velocidad con filtro de media móvil. A) Medición de velocidad sin filtro. B) Medición de la velocidad filtrada.

3.3.5. Procesamiento de las señales del sensor inercial

El MPU6050 genera 6 señales pertenecientes al giroscopio y al acelerómetro, las cuales serán utilizadas para el cálculo de tiempos de soporte, balanceo y doble soporte. Sin embargo, las señales no deben ser usadas de manera directa ya que comúnmente cuentan con una gran cantidad de ruido de alta frecuencia, para esto se implementa un filtro de media móvil para cada una de las señales, siguiendo la función 3-3. Posteriormente se busca obtener la magnitud de las mediciones de cada sensor, por lo que es necesario obtener la magnitud resultante de las componentes de los ejes x , y y z , para lo cual se utilizará 3-10 y 3-11. Obteniendo así una sola señal para el acelerómetro y otra para el giroscopio (Hsu et al., 2014).

$$a_r(k) = \sqrt{a_x^2(k) + a_y^2(k) + a_z^2(k)} \quad (3-10)$$

$$\omega_r(k) = \sqrt{\omega_x^2(k) + \omega_y^2(k) + \omega_z^2(k)} \quad (3-11)$$

3.3.6. Cálculo de indicadores de la marcha

A través de las mediciones se obtuvieron datos que representan el desplazamiento y la velocidad de puntos específicos de las extremidades en forma de señales a través del tiempo; sin embargo, al momento de realizar el entrenamiento de la SVM no es posible utilizar las señales obtenidas, sino que es necesario obtener la información que se pueda derivar de ellas.

Con las señales ya obtenidas se buscó realizar el cálculo de los indicadores presentes en la Tabla 3-5 para el entrenamiento, verificación e implementación de la SVM (Begg & Kamruzzaman, 2005).

Tabla 3-5.- Indicadores utilizados para el entrenamiento de la SVM

Indicadores espacio temporales	Indicadores cinemáticos
Tiempo de soporte, balanceo y doble soporte (s)	Ángulo del talón durante el despegue y el golpe de talón
Longitud de paso (m)	Ángulo de la rodilla durante el despegue y el golpe de talón
Velocidad de caminado (m/s)	Amplitud de movimiento articular de la rodilla
Cadencia (pasos/min)	Amplitud de movimiento articular del talón
	Velocidad angular del talón
	Velocidad angular de la rodilla
	Rotación del pie durante despegue y golpe de talón

3.3.6.1. Longitud de zancada

Para el cálculo de la longitud de la zancada se tomaron las componentes del desplazamiento del tobillo en el eje de las x, a partir de esto se elaboró una subrutina en el código que permite identificar los máximos y mínimos de la señal, como se muestra en la Fig. 3.15 en donde se indican los máximos con puntos negros y los mínimos con puntos rojos.

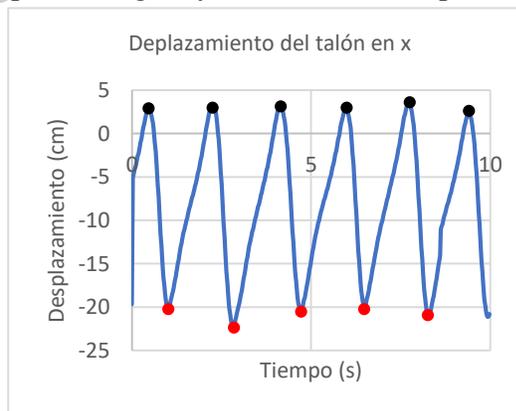


Fig. 3.15.- Detección de picos y valles de la señal de desplazamiento.

En el código se van tomando ventanas de la señal de 20 a 40 datos dependiendo de tan rápido cambie la señal, en la cual se va buscando el punto con mayor magnitud, una vez

encontrado se desplaza la ventana para que este sea el primer elemento que se lee y se revisa que el resto de los datos sean menores o iguales, si esto se cumple se dice que este elemento es un máximo, de otra manera se vuelve a desplazar la ventana y se repite el proceso. Lo mismo se realiza para los valles, pero buscando el elemento de menor amplitud. Este proceso se realiza para toda la señal, permitiendo obtener todos los valles y picos presentes y significativos. Utilizando el conjunto de puntos obtenidos se obtiene el promedio de los máximos y el promedio de los mínimos, de tal forma que la longitud de la zancada se obtiene simplemente con su diferencia.

3.3.6.2. Tiempo de soporte

Para el cálculo del tiempo de soporte se llevó a cabo la detección de los picos y valles de la señal del ángulo del talón en y , obtenida utilizando los datos de los sensores montables, los cuales se despliegan en la gráfica de la Fig. 3.16. Esto se debe que al comparar la señal obtenida y el video se puede observar que los puntos en donde la gráfica alcanza un máximo es el momento exacto en donde el pie realiza el despegue, mientras que durante el golpe de talón se obtiene un mínimo. Utilizando la misma metodología que con la longitud de zancada se obtuvieron todos los máximos y mínimos que se presentaban durante el periodo analizado, pero en este caso primero se obtuvo el periodo que se presentaba en la transición de un mínimo a un máximo y posteriormente se promediaron para obtener el tiempo de soporte promedio.

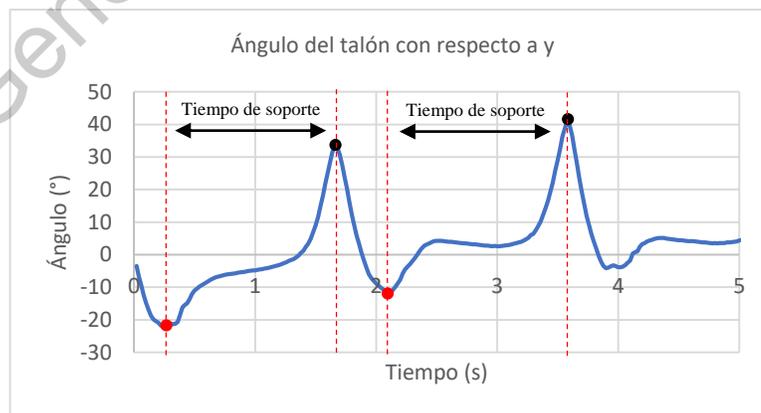


Fig. 3.16.- Obtención del tiempo de soporte a través de máximos y mínimos.

Otro dato que se decidió obtener utilizando esta misma información fue determinar el tiempo de soporte sin incluir las transiciones a la etapa de despegue y de golpe de talón, tal como se muestra en la Fig. 3.17 A. Para esto se decidió utilizar la varianza que existía entre los datos, ya que durante las etapas en donde la planta del pie se encuentra en completo contacto con la superficie, se obtiene una magnitud de varianza baja. Para llevar a cabo el cálculo de la varianza se estuvo dividiendo la señal en ventanas de 3 datos, de los cuales se obtenía la varianza y se registraba como una nueva señal, que puede ser apreciada en la Fig. 3.17 B. A partir de estos nuevos datos, se iba revisando los puntos de la señal en donde los valores de la varianza fueran bajos y se mantuvieran durante al menos 0.2 segundos, marcando el inicio del tiempo de soporte y marcando el final una vez que los valores de la varianza comenzaran a aumentar. De esta manera fue posible ir determinando la duración del tiempo de soporte de cada paso sin considerar sus transiciones y los cuales fueron promediados para contar con una aproximación final (Hsu et al., 2014).

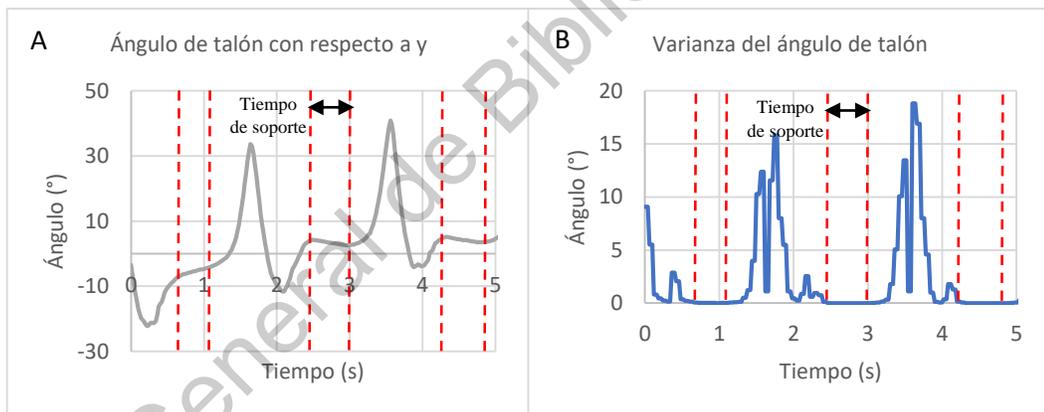


Fig. 3.17.- Obtención del tiempo de soporte sin transiciones. A) Datos originales del ángulo del talón.

B) Varianza de los datos del talón.

3.3.6.3. Tiempo de balanceo

El tiempo de balanceo puede ser fácilmente calculado una vez que ya se ha obtenido el tiempo de soporte, ya que se han obtenido los máximos y mínimos de la señal del ángulo de talón con respecto a y, los cuales representan el despegue y el golpe de talón respectivamente. Considerando esto, lo único que se debe de calcular es la duración de la transición de un máximo a un mínimo, tal como se muestra en la Fig. 3.18. Una vez calculado el tiempo de balanceo de cada uno de los pasos que se realizaron para obtener el tiempo de balanceo promedio realizado durante la prueba.



Fig. 3.18.- Obtención del tiempo de balanceo a través de máximos y mínimos.

3.3.6.4. Tiempo de doble soporte

La manera más simple de obtener el tiempo de doble soporte es si se cuenta con el monitoreo de ambas piernas, lo cual es posible al utilizar los datos de los sensores montables, con estos se puede realizar un procedimiento muy similar al de los tiempos de balanceo y soporte. Para el cálculo del tiempo de soporte es necesario haber detectado los golpes de talón y los despegues, de cada uno de los pies, posteriormente solo se debe calcular la diferencia de tiempo entre el golpe de talón de una pierna y el despegue de la otra, esto se puede observar en la Fig. 3.19.

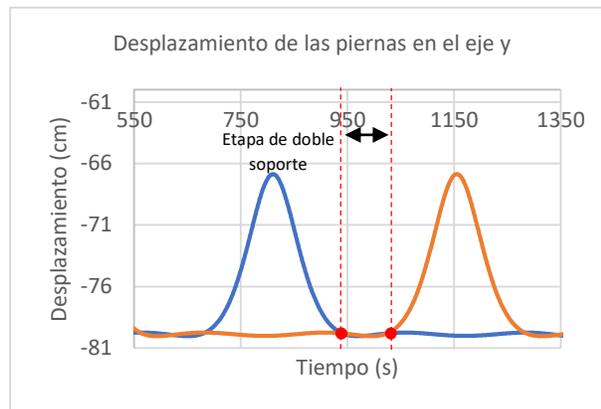


Fig. 3.19.- Representación de la etapa de doble soporte

Este proceso se realiza para cada uno de los pasos para determinar el tiempo de doble soporte promedio utilizando 3-7, donde x serán los tiempos de doble soporte.

3.3.6.5. Ángulos de rodilla y tobillo durante golpe de talón y despegue

En el caso de los ángulos se ha decidido darles mayor importancia a los ángulos que se presentan durante los eventos de golpe de talón y el despegue. Para realizar esta tarea se utilizan los datos de desplazamiento del talón en x generada a partir de las mediciones del sistema de visión artificial, en esta se buscan los máximos y los mínimos, los cuales representaran el despegue y el golpe de talón respectivamente, con esto se conoce los tiempos en los que estos eventos se presentan y por lo tanto basta con revisar el ángulo de la rodilla en el mismo instante de tiempo, tal como se muestra en la Fig. 3.20, en donde se marcan con puntos negros los despegues y en rojo los golpes de talón.

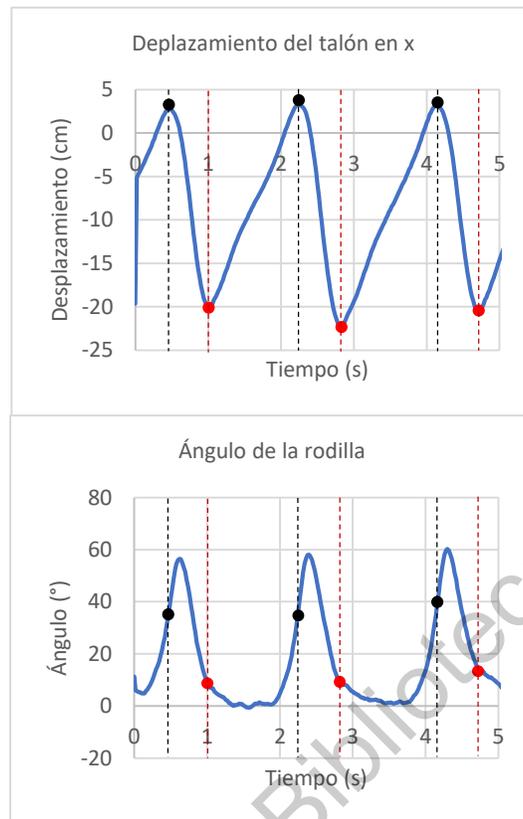


Fig. 3.20.- Obtención de los ángulos de la rodilla durante los golpes de talón y los despegues.

En cuanto a los ángulos del talón, para estos no fue necesario hacer ningún procedimiento en especial, ya que en la señal del talón se puede identificar de manera simple cuando se presentan los eventos de despegue o de golpe de talón, ya que coinciden con los máximos y mínimos de la señal respectivamente. Por lo tanto, solo se promedia la amplitud de cada los máximos y de los mínimos para determinar el ángulo promedio del despegue y del golpe de talón.

3.3.6.6. Velocidad angular de rodilla y tobillo

Para la velocidad angular tanto de la rodilla como del tobillo se tomará le mismo procedimiento que con los ángulos, en donde solo se considerará la velocidad angular durante el golpe de talón y el despegue, como se muestra en la Fig. 3.21, donde se indica con rojo los momentos donde se da un golpe de dato y con negro los despegues.

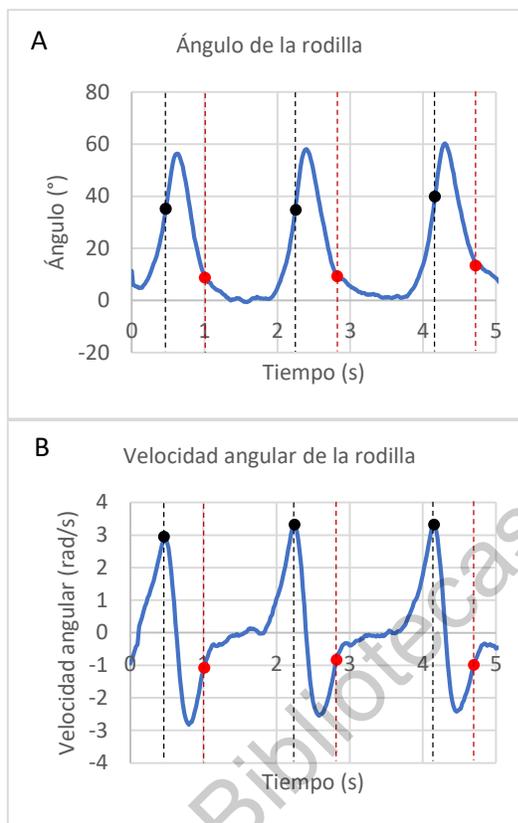


Fig. 3.21.- Velocidad angular durante el golpe de talón y el despegue. A) Grafica del desplazamiento angular de la rodilla. B) Grafica de la velocidad angular obtenida a partir del desplazamiento.

De igual manera se determina el promedio de cada una de las velocidades angulares de la rodilla y del talón, las cuales se agregan a los indicadores.

3.3.6.7. Ángulos de los pies

Utilizando los sensores montables se conocen las diferentes inclinaciones que el pie va tomando a lo largo del ciclo de caminado, incluso siendo uno de estos el ángulo del talón utilizado previamente. Sin embargo, también nos es de interés las inclinaciones que surgen en los otros ejes, ya que estos pueden llegar a aportar información de cuales músculos no se encuentran desarrollados correctamente (Trew & Everett, 2006). Para tomarlos como indicadores se llevó a cabo la detección de su orientación durante el golpe de talón y el despegue, de la misma manera que se realiza con los ángulos de la rodilla y el talón. Los ángulos son posteriormente promediados para obtener el alabeo, cabeceo y guiñada (roll, pitch and yawn) promedios, es decir, las inclinaciones en cada uno de los ejes.

3.3.6.8. Amplitud de movimiento articular

Para realizar este cálculo se tomaron los datos de los ángulos durante el golpe de talón y el despegue. Lo que se busca determinar la amplitud de movimiento articular (ROM), siendo este el grado de movimiento que la articulación genera durante un movimiento, esto se aplica para las etapas de balanceo y soporte. Para esto se decidió determinar el ángulo mínimo y máximo que surgen durante cada una de las etapas, tal como se muestra en la Fig. 3.22, donde se representa el ángulo menor α_{min} con un punto rojo y el ángulo mayor α_{max} con un punto negro.

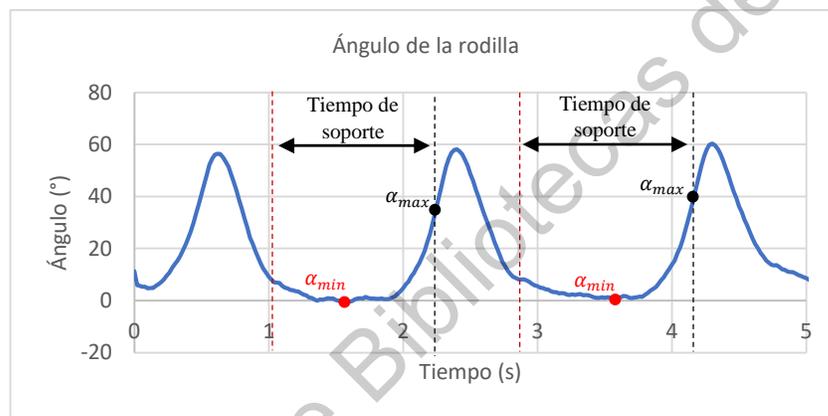


Fig. 3.22.- Representación de la amplitud de movimiento de la rodilla.

Para el cálculo simplemente se utilizaría 3-13 para el cálculo de la amplitud de movimiento ROM_{α} .

$$ROM_{\alpha} = |\alpha_{max} - \alpha_{min}| \quad (3-12)$$

Esto de igual manera se realizaría con cada uno de los pasos para determinar un ROM promedio tanto de la rodilla, el talón y los ángulos del pie, para las etapas de soporte y balanceo.

3.3.6.9. Cadencia

La obtención de la cadencia se puede calcular utilizando los máximos y mínimos del desplazamiento en x del talón obtenido con el sistema de visión artificial. A partir de los puntos obtenidos se puede determinar el periodo de un paso al calcular la diferencia de los tiempos entre dos máximos, lo cual representaría el tiempo que le toma a una persona

completar un ciclo de caminado. Esto se realiza para cada uno de los pasos dados con el fin de obtener un promedio de los periodos. Posteriormente se utiliza 3-14.

$$cadencia = \left(\frac{60}{\bar{T}_{paso}} \right) * 2 \quad (3-13)$$

En donde \bar{T}_{paso} es el periodo promedio en segundos y en donde el resultado de la división se multiplica por dos, debido a que un ciclo completo del caminado está compuesto por dos pasos, uno con cada pierna, lo que da como resultado la cadencia en pasos sobre minuto.

3.3.6.10. Velocidad de caminado

Para el cálculo de la velocidad del caminado ya se cuenta con la longitud de la zancada (Δx) en metros y con el periodo de un paso (\bar{T}_{paso}), por lo que únicamente se realiza su división como se muestra en 3-15.

$$v_{caminado} = \left(\frac{\Delta x}{\bar{T}_{paso}} \right) * 2 \quad (3-14)$$

Obteniendo así la velocidad de caminado ($v_{caminado}$) en metros sobre segundo (m/s).

3.4. Etapa de entrenamiento

Para la etapa de entrenamiento es importante definir diferentes factores, empezando por el lenguaje en donde se llevará a cabo la implementación de la SVM. En este caso se optó por mantener la implementación del clasificador en C#, con el fin de mantener la homogeneidad del software. Para la tarea de implementación de la SVM se optó por el uso de la librería Accord v3.8.2, la cual cuenta con una diversidad de funciones que permiten la configuración de diferentes aspectos de la SVM que se desee implementar.

3.4.1. Pre-procesamiento de los datos

Para generar una base de datos eficiente para el entrenamiento de un algoritmo se debe considerar la normalización de los datos, especialmente en los casos en donde los datos estén trabajando en rangos diferentes, ya que esto podría causar que durante el entrenamiento se le diera un mayor peso a un tipo de dato, impidiendo que se tuvieran comparaciones imparciales. Esto incluso llega a ser una importante consideración si es que se busca

comparar diferentes tipos de caminado, en donde los rangos de las mediciones no variarían solo entre las condiciones (sano, problemas óseos y problemas musculares), sino también entre persona y persona. Por lo que poder comparar los datos en una escala similar tendría como resultado una mayor eficiencia en el entrenamiento y clasificación de la SVM (Priddy & Keller, 2005).

Para la tarea de normalización se utilizó el método de normalización estadística o z-score, en donde se obtiene la media y la desviación estándar de cada indicador para la aplicación de la ecuación 3-15.

$$x' = \frac{(x_i - \mu_i)}{\sigma_i} \quad (3-15)$$

En donde μ_i es la media, σ_i es la desviación estándar, x_i es el dato que se va a normalizar y x' es el dato normalizado, resultando en un nuevo conjunto de datos de entrenamiento con un promedio de 0 y una varianza unitaria para cada indicador. También se debe conservar la información de la media y la desviación estándar, debido a que la SVM sería entrenada con datos normalizados, por lo que cualquier dato nuevo que quiera ser clasificado deberá pasar por la misma normalización, de otro modo se encontraría en una escala incorrecta (Jayalakshmi & Santhakumaran, 2011).

3.4.2. Selección del Kernel

La librería Accord permite el uso de diferentes tipos de Kernels y la configuración de varias de sus características. Para el presente trabajo se optó por trabajar con un Kernel polinómico, el cual es adecuado para los datos que se encuentran normalizados. La librería trabaja a partir del modelo que se presentó en 2-50. En donde el valor de 1 es remplazado por la variable c , la cual puede ser modificada por cualquier valor. Para el trabajo presente se estarán variando los valores de c y d , con el fin de determinar los valores más óptimos para la separación de las clases.

Otra de las características que pueden ser modificadas es la complejidad del Kernel, la cual representa el valor de la variable C en la función 2-44, esta permite modificar el

comportamiento de hiperplano lo cual puede reducir el error de entrenamiento con el riesgo de aumentar la clasificación incorrecta de nuevos datos.

3.4.3. Etiquetado de datos

Una de las desventajas con las que se cuenta con la implementación de SVM es que es un clasificador de naturaleza binaria, por lo que solo se puede contar con salidas de ± 1 , lo cual es contraproducente para la clasificación que se desea realizar ya que se cuenta con tres clases. Para solucionar esto se optó por el uso del método de multiclase de SVM conocido como one-against-all o uno contra todos, en donde para una cantidad m de clases se generan m número de SVM las cuales se dediquen a la identificación de una sola de las condiciones (Vapnik, 1995). En este caso solo se cuenta con 3 clases, por lo que se diseñaran 3 diferentes SVM que se aplicarán a cada uno de los datos que se busquen clasificar, en donde la primera SVM solo diría si es un daño muscular, la segunda SVM revisaría si cuenta con daño óseo y una tercera SVM se encargará del estado saludable. En el caso de que un dato pueda llegar a pertenecer a más de una clase se tomará el método de valores continuos, en donde no solo se revisa el signo obtenido con la función de decisión sino también su magnitud, de tal manera que se dice que el dato pertenece a la clase que dé como resultado el valor más alto (Vapnik, 1998).

3.4.4. Entrenamiento y validación

Para la realización de esta tarea se utilizó el método de validación cruzada (cross-validation), en donde el conjunto de datos será dividido en n partes iguales con el fin de utilizar algunos de los datos para el entrenamiento y otros para la validación. En este caso la información es dividida en 6 partes iguales en donde solamente se utilizan 5 de esas partes para el entrenamiento mientras que la sexta es utilizada para evaluar la precisión, sensibilidad y especificidad, las cuales son calculadas a través de 3-17, 3-18 y 3-19 respectivamente (Pang et al., 2003).

$$\text{Precisión} = \frac{TP+TN}{TP+FP+TN+FN} (100) \quad (3-16)$$

$$\text{Sensitividad} = \frac{TP}{TP+FN} (100) \quad (3-17)$$

$$\text{Especificidad} = \frac{TN}{TN+FP} (100) \quad (3-18)$$

En donde TP y TN son el número de datos clasificados correctamente, positivos y negativos respectivamente, mientras que FP y FN son los son los datos positivos y negativos, respectivamente, clasificados erróneamente. La sensibilidad describe la capacidad del clasificador para detectar anomalías y la especificidad es la capacidad de detectar casos saludables. Este proceso se repite utilizando a cada una de las partes para el entrenamiento del clasificador, de tal forma que se obtengan 6 clasificadores diferentes, de estos se elige el que haya obtenido un mejor desempeño mientras que el resto son descartados (Begg & Kamruzzaman, 2005).

Capítulo 4. Resultados

4.1. Sistema de visión artificial

Para el sistema de visión artificial se estableció el uso de dos lámparas de luz infrarroja de 12W, las cuales se montaron a un metro de distancia de los participantes. Estas son utilizadas en conjunto con una serie de marcadores colocados en la pierna derecha acorde al protocolo Davis utilizando material reflejante, lo cual permite que resalten y den forma a la estructura de la pierna en los videos, tal como se muestra en la Fig. 4.1.



Fig. 4.1.- Visualización de los marcadores con el sistema de visión artificial.

Aquí el marcador que se encuentra en la espalda fue utilizado para establecer un punto de referencia que se mueve con el usuario para la medición de todas variables cinéticas.

4.2. Sensor montable

Para la construcción del sensor se consideró la fabricación de una carcasa utilizando una impresora 3D, la cual se puede apreciar en la Fig. 4.2.



Fig. 4.2.- Modelo físico de los sensores montables.

Se construyeron dos sensores montables los cuales se colocan en cada uno de los pies, como se muestra en la Fig. 4.3, permitiendo que se obtuvieran parámetros cinéticos y espaciotemporales de ambas piernas. Sin embargo, ya que la información obtenida es guardada en una memoria interna es necesario remover los sensores para la lectura de la información, lo cual no afecta de manera directa al proceso de análisis, solo lo ralentiza.



Fig. 4.3.- Colocación de los sensores en el calzado

4.3. Área de trabajo

La realización de pruebas y el montaje del sistema de medición se realizó dentro de las instalaciones de la facultad de Enfermería de la UAQ campus corregidora, en la clínica de rehabilitación de fisioterapia CEFID. En el área de trabajo se contaba con una caminadora eléctrica, la cual se colocó frente a un fondo negro, para facilitar el análisis de las capturas y se colocaron las luces a una distancia de 1 m y la cámara a una distancia de 1.4 m. También se taparon las ventanas y se apagó la iluminación del área para evitar perturbaciones. Esto se puede apreciar en la Fig. 4.4.



Fig. 4.4.- Área de trabajo para la realización de pruebas.

4.4. Pruebas físicas

Para la realización de pruebas y preparación de los participantes, primero se realizaron platicas informativas, días previos a la aplicación de las pruebas, en donde se les comentaba el propósito del trabajo, el funcionamiento del equipo y la participación que ellos tendrían como voluntarios en las pruebas. Todos aquellos que aceptaron la participación se le asignó una fecha y un horario para presentarse en las instalaciones de la facultad de enfermería del campus corregidora de la UAQ, en la clínica de fisioterapia.

Durante la realización de las pruebas se contó en todo momento con la aprobación y asistencia de miembros de la clínica de fisioterapia especializados en el área de la rehabilitación. Al inicio de las pruebas se le daba a cada participante una breve explicación del funcionamiento del equipo, la estructura de las pruebas, algunas recomendaciones y advertencias y finalmente se les presentaba una carta de confidencialidad y de consentimiento informado, en donde se les especifica que su información no se distribuiría y solo sería

utilizada con fines de investigación además de que se asegura su bienestar durante la realización de las pruebas. Posteriormente los miembros de la clínica se encargaron de la colocación de los marcadores en los puntos de interés y en la coordinación de las pruebas.

Debido a la pandemia iniciada en el año 2020 y cuyos efectos han continuado durante más de un año, se han minimizado la realización de experimentos con el fin de atender las medidas de salud establecidas, resultando en la realización de pruebas solo con personas en estado sano, en donde no se cuentan con problemas diagnosticados o lesiones recientes. Culminando en un número total de 12 participantes, con una edad promedio de 21 años y una desviación estándar de 2.84, esto se debe a la dificultad de realizar convocatorias a gran escala en busca de participantes, al incremento en la dificultad de movilidad o de transporte y al seguimiento de las normas de seguridad para la entrada de personas ajenas a la facultad.

Los participantes se presentaron en horarios separados dentro de las instalaciones de la UAQ para la aplicación de las pruebas, en donde se les pidió que realizaran un conjunto de pruebas de la marcha en una caminadora eléctrica, en cada una se estuvo modificando la velocidad de acuerdo a las velocidades previamente establecidas (1.4, 1.9, 2.1, 2.9 km/h). En la Fig. 4.5 se presenta un mosaico de imágenes de algunos de los participantes que apoyaron en el desarrollo del trabajo, con el fin de que se pueda observar las condiciones bajo las cuales se realizaron las pruebas.

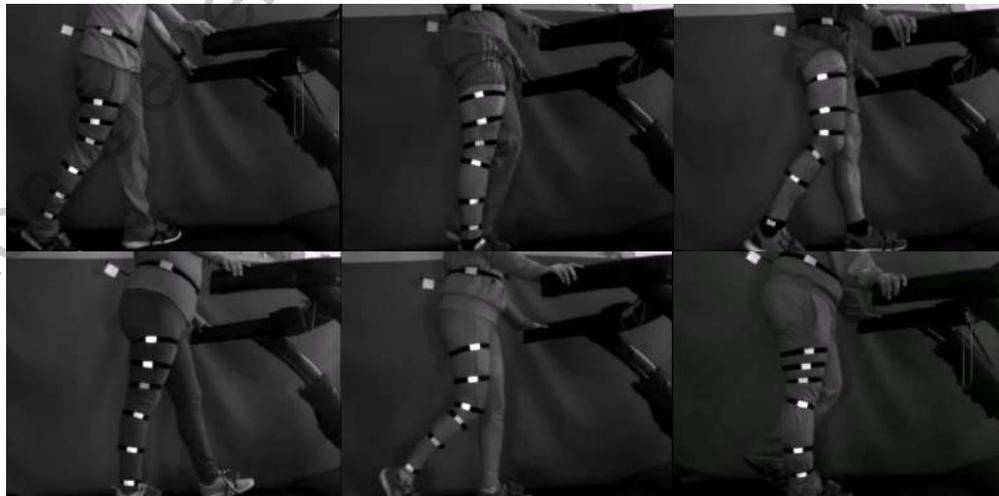


Fig. 4.5.-Muestra de la población de participantes que realizaron la prueba.

4.5. Desarrollo de interfaz de usuario

Al igual que todo el programa, la interfaz se implementó en C#, en esta se buscaba darle al usuario todas las comodidades posibles para la realización de pruebas por lo que cuenta con dos modos diferentes, siendo estos de captura y análisis. En el primero el usuario fue capaz de configurar el tiempo que desea grabar, la cámara que se utilizaría para grabar, la distancia a la cual se encontraba la cámara del paciente, aquí no se le da la opción al usuario de seleccionar el nombre y localización de donde se guardaba el trabajo, para esto se utilizó una dirección predeterminada en el disco de la computadora y se generará un nombre automático utilizando la fecha y un número serial único e irreplicable. Una vez seleccionados los parámetros se puede utilizar el botón “Video” para comenzar a visualizar la imagen de la cámara, esto se hace con el fin de que el usuario revise que todo se encuentra en las condiciones correctas para comenzar la prueba, además, se inicializa la toma de video, la cual se encuentra a 50 fps. También se cuenta con la opción de vincular dos sensores montables vía de bluetooth, estos son opcionales para el funcionamiento del programa, pero se recomienda su uso para la adquisición de una mayor cantidad de información. Una vez que el video se ha iniciado se habilita el botón de “Grabar”, al ser presionado activa una bandera que le indicará al programa que acción se realizará, al mismo tiempo se genera una señal que es enviada a los dos sensores con el fin de iniciar la etapa de calibración. Una vez que se encuentran calibrados los sensores e inicializado el video, se puede utilizar el botón de “Iniciar”, el cual inicializa la grabación de video y un timer interno con el cual establece la duración de la prueba, de la misma manera se les envía a los sensores la señal de inicio, lo cual también comienza con un timer interno de los sensores. Durante el periodo de prueba el usuario podrá estar al tanto de la grabación del video en vivo, por si se llega a presentar alguna eventualidad que obligue a reiniciar la prueba, de la misma manera los sensores montables cuentan con indicadores led para asegurar su funcionamiento. Una vez finalizada la prueba es posible realizar el análisis directo de los datos; sin embargo, será necesario remover las tarjetas de memoria de los sensores para extraer los datos obtenidos.

El programa cuenta con una segunda etapa que es el análisis de los datos, tanto del video como de los datos de los sensores montables. En este el usuario puede definir que prueba

desea analizar ya sea uno recién capturado o de alguna prueba anterior, para esto se utiliza el botón de lectura “Lectura”, el cual le permite al usuario establecer los parámetros como el umbral, la distancia de trabajo y el tiempo que se desea analizar. Una vez establecidos los parámetros se utiliza el botón “Iniciar” para buscar la dirección del archivo y posteriormente se comienza el análisis, primero se toma el video en donde se revisa cada fotograma y se aplica una serie de procesamientos que permite el aislamiento y registro de los marcadores. Con estos se calcula el desplazamiento y la velocidad tanto lineal y angular, al igual que algunos indicadores de la marcha como la cadencia, longitud de zancada, etc. Por otra parte, los datos del sensor de inercia son leídos y procesados para obtener indicadores como el ángulo del talón, el tiempo de doble soporte, etc. Los resultados obtenidos son presentados de manera gráfica en la interfaz de usuario, como se muestra en la Fig. 4.6, en esta también se puede apreciar la estructura principal de la interfaz de usuario.

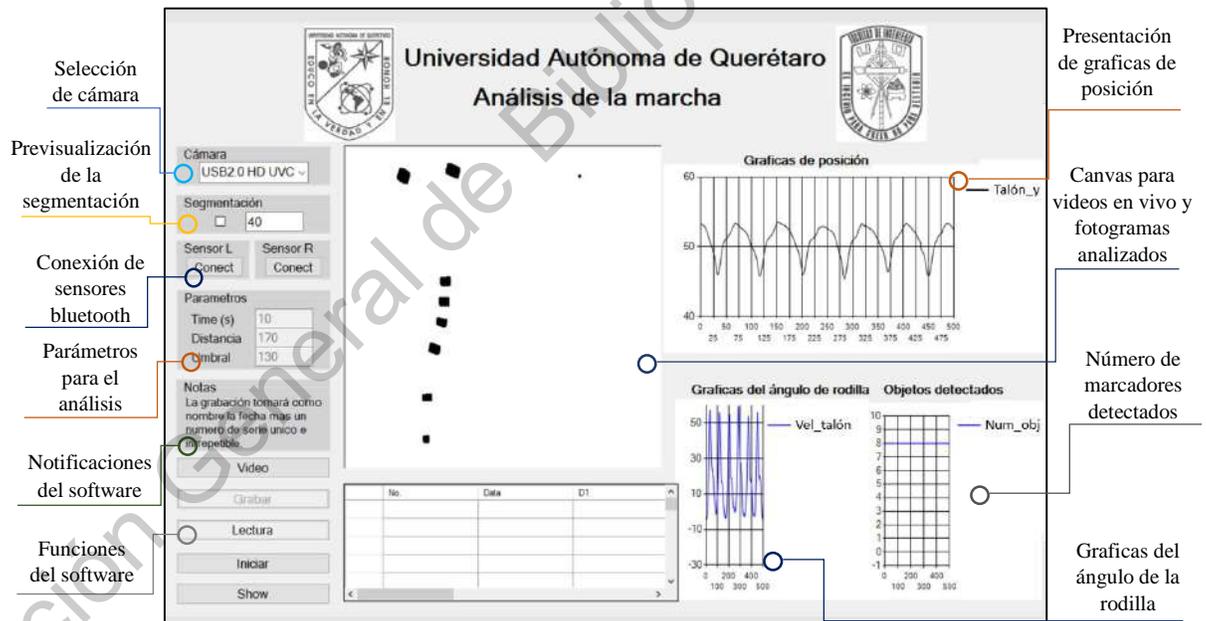


Fig. 4.6.- Interfaz de usuario del sistema de monitoreo.

4.6. Adquisición de video

Para la adquisición de video se utilizaron las librerías de Aforge, las cuales ya cuentan con un conjunto de funciones enfocadas a la adquisición de video, procesamiento de imágenes, etc. A partir de esta se realizó la selección de la cámara utilizada para grabar a través de

“VideoCaptureDevice”, para posteriormente utilizar la función “NewFrameEventHandler” el cual llama a una función cada vez que se cuente con un nuevo fotograma por parte de la cámara. Sin embargo, durante este evento la cámara únicamente presentara el video en vivo al usuario, pero no se graba un video hasta que el usuario así lo desee.

También se cuenta con una función para previsualizar en tiempo real la segmentación que se le aplicaría al video a partir de los parámetros especificados, esto permite verificar que tanto la iluminación como los marcadores se encuentren colocados de manera adecuada, de no ser así se tiene la oportunidad de ver los cambios que surgen en tiempo real al modificar cualquiera de los aspectos mencionados previamente o incluso los parámetros utilizados para segmentar. Lo cual se convierte en una gran ventaja al momento de preparar nuevas pruebas, evitando que se tengan que realizar pruebas de calibración o que surjan errores durante el análisis del video.

Para comenzar la grabación de video el usuario debe utilizar el botón de “Grabar” para establecer los parámetros, seguido del botón “Iniciar”, que inicializa una variable del tipo “VideoFileWriter”, a la cual se le asignará un nombre, un tipo de archivo, en este caso .avi, un alto y un ancho de imagen, los cuales deben coincidir con las capturas de la cámara, y se deben establecer los fotogramas por segundo. También se inicia un timer el cual corresponde con el tiempo de duración de la prueba, por otra parte, ahora cada vez que llegue un fotograma se estará guardando en la nueva variable de video. Una vez terminado el timer se interrumpe el video y se cierra el archivo de video, permitiendo que el usuario pueda acceder libremente al archivo.

4.7. Procesamiento de imágenes

Para el procesamiento de imágenes se utilizaron una vez más las librerías de Aforge, con la cual se puede cargar el video. Primeramente, se revisa a la cantidad de fotogramas que el usuario quiere que se analicen, posteriormente se crea un ciclo en donde se va tomando cada uno de los fotogramas del video y son sometidos a un conjunto de procesamientos. Utilizando el valor de umbral seleccionado por el usuario se realiza la operación de threshold o segmentación, en donde se toma la imagen en blanco y negro proveniente de la cámara y se

revisa pixel a pixel separándolos en dos tipos, aquellos que superan el valor de umbral pasan a un valor de cero, mientras que aquellos con un valor inferior pasan a 1. Generando así una imagen binaria donde solo se muestran los objetos de interés, en este caso los marcadores, tal y como se muestra en la

Fig. 4.7A, en donde son representados en negro; sin embargo, esto es meramente estético para la presentación de resultados donde se invirtieron los tonos de la imagen, ya que el software utiliza puntos blancos como los objetos de interés, esta modificación estética se aplica para todas las imágenes binarias de los resultados.

Fig. 4.7.- Segmentación de un fotograma. A) Imagen monocromática original. B) Imagen resultante del procesamiento.

Posteriormente se aplican las operaciones morfológicas de apertura y clausura para para



eliminar información no deseada que haya dejado la segmentación y para arreglar objetos incompletos, respectivamente, resultando en la Fig. 4.7B. Esto es seguido de un “blobcounter”, el cual es un comando de la librería Aforge que realiza la detección de objetos que cumplan con ciertos parámetros referentes a su dimensión. Una vez que se cuenta con el listado de objetos es posible ordenarlo a partir de su posición con respecto al plano, es decir, que los datos pueden ser acomodados de mayor a menor dependiendo de su coordenada y, lo cual acomoda los datos en el orden adecuado de referencia, cadera, rodilla y talón. Los datos obtenidos son acomodados en un arreglo para su posterior procesamiento.

4.8. Indicadores de la marcha a través de visión artificial

Al contar con todos los datos de los marcadores en cada uno de los fotogramas se comienza a realizar el cálculo del desplazamiento y la velocidad, junto a todos los indicadores que se derivan de estos. Como resultado del proceso de detección de marcadores se cuenta con dos arreglos de datos que contienen la coordenada x y y de cada marcador a lo largo del tiempo, lo primero que se realiza con estas es la traslación de origen y la conversión de unidades, en donde se toma el marcador que se encuentra en la espalda y la conversión a través de 4-1.

$$c = 10464d^{-0.962} \quad (4-1)$$

Donde c será la constante de conversión y d la distancia proporcionada por el usuario. Posteriormente se aplica 3-4 para cada uno de los marcadores en todos los fotogramas, resultando en su desplazamiento el cual será guardado en un arreglo diferente.

Utilizando los nuevos datos de desplazamiento se realiza el cálculo de la velocidad lineal, al obtener la diferencia entre el desplazamiento actual y el anterior dividido por el tiempo de muestreo (0.02 s), lo cual se establece en 2-12. Por otra parte, para el cálculo de los ángulos de la rodilla se utiliza la ecuación 2-9, utilizando el desplazamiento del muslo, la rodilla y el talón. El resultado también es guardado en un arreglo diferente.

Una vez que se calculan los desplazamientos, velocidades y ángulos de cada fotograma, se aplica un filtro de media móvil sobre los datos de velocidad utilizando una ventana de 20. Todos los datos son guardados en archivos de texto diferentes los cuales se enlistan en la Tabla 4-1, en donde se especifica el tipo de dato que se guarda, al mismo tiempo son graficados en la interfaz de usuario para que se pueda verificar su correcto funcionamiento.

Tabla 4-1.- Archivos generados por el software

Nombre del archivo	Información que contiene
<i>Ang_rod.txt</i>	Desplazamiento y velocidad angular de la rodilla.
<i>Cadera_mag.txt</i>	Desplazamiento y velocidad de la cadera.
<i>Rodilla_mag.txt</i>	Desplazamiento y velocidad de la rodilla.
<i>Talon_mag.txt</i>	Desplazamiento y velocidad del talón.

<i>Talon_mag_y.txt</i>	Desplazamiento del talón solo en el eje y.
<i>Features.txt</i>	Listado en forma de tabla de los indicadores obtenidos del análisis
<i>Features_line.txt</i>	Listado en forma de fila de los indicadores obtenidos del análisis

Utilizando las diferentes señales obtenidas tanto del sistema de visión y los sensores montables se obtuvieron las mediciones de los diferentes indicadores propuestos en la metodología, como la longitud de paso, la cadencia, el tiempo de soporte, tiempo de balanceo, etc. Los cuales son guardados en un archivo llamado “features” en un formato similar al que se presenta en la Tabla 4-2, para la visualización del usuario, donde R indica que es un dato de la pierna derecha y L que es un dato de la pierna izquierda. Al mismo tiempo son acomodados en un nuevo archivo llamado “features_line”, en una sola fila para que puedan ser procesador por el algoritmo de clasificación.

Tabla 4-2.- Presentación de indicadores para el usuario.

Indicadores	Magnitud	Unidad
<i>Periodo</i>	1.80	s
<i>Cadencia</i>	66.10	pasos/s
<i>Longitud de paso</i>	24.10	cm
<i>Ángulo de rodilla durante despegue</i>	34.40	grados
<i>Ángulo de rodilla durante golpe de talón</i>	11.70	grados
<i>Rango de movimiento de la rodilla (min, max)</i>	1.16, 59.79	grados
<i>Tiempo de balanceo L</i>	1.37	grados
<i>Tiempo de soporte L</i>	0.41	s
<i>Angulo de despegue promedio L</i>	52.51	grados
<i>Angulo de golpe de talón promedio L</i>	-4.77	grados
<i>Tiempo de soporte solo L</i>	0.50	s
<i>Tiempo de balanceo R</i>	0.36	s
<i>Tiempo de soporte R</i>	1.47	s
<i>Angulo de despegue promedio R</i>	41.08	grados
<i>Angulo de golpe de talón promedio R</i>	-4.49	grados
<i>Tiempo de soporte solo R</i>	0.50	s

La información de los indicadores obtenida de los videos se recopiló en un solo archivo para el entrenamiento de los algoritmos de machine learning, en el cual también se les agregó el

etiquetado que marque la clase a la cual pertenecen, dependiendo del tipo de clasificación que se vaya a realizar. Posteriormente, la base de datos resultante es cargada en el SVM, donde llevo a cabo la tarea de entrenamiento y la implementación del cross-validation.

4.9. Support Vector Machine

Para la implementación del algoritmo de Support Vector Machine (SVM) se utilizaron las librerías de Accord, las cuales permiten realizar el entrenamiento y uso de una SVM. Para esto es necesario que los indicadores se encuentren acomodados en una sola matriz y estén etiquetados de manera adecuada, estos pasan a ser utilizados para el entrenamiento en donde se definio el Kernel que se utilizaría, la complejidad y la tolerancia, una vez finalizado el entrenamiento es posible evaluar cualquier otro dato con respecto a al algoritmo entrenado.

Las desventajas que existen con este es que por una parte no se pueden guardar los pesos obtenidos durante el entrenamiento de la SVM, por lo que es necesario volver a entrenar en cada iteración; sin embargo, esta tarea tiene un tiempo corto de ejecución por lo que no afecta a la velocidad de respuesta, incluso con una base de datos extensa. También no cuenta con una función para la evaluación directa de la precisión, pero esto fue resuelto utilizando las ecuaciones 3-17, 3-18 y 3-19. Uno de los defectos que no surgen a causa de la librería sino por la naturaleza de las SVM, es que es un algoritmo con una respuesta binaria, por lo que solo puede determinar si un elemento pertenece o no a una clase, para solucionarlo se utilizo el método de all agains one, en donde se entrena una SVM para reconocer cada uno de los casos que se desea clasificar.

Considerando esta limitantes, fue posible realizar la clasificación de datos con una precisión del 98%, en donde se estuvieron utilizando bases de datos proporcionadas para pruebas de clasificación (McCaffrey, 2019). Con estas pruebas se logró percibir que la precisión de la clasificación variaría dependiendo de los datos que se destinaran para el entrenamiento y la verificación, por ello se acude al método de cross-validation para determinar la población con la que se obtiene la clasificación más acertada.

4.10. Etapa de entrenamiento y cross-validation

Para esta etapa se decidió considerar únicamente los datos que son obtenidos directamente por el sistema, por lo que algunos parámetros generales como peso, altura y edad no han sido considerados de momento, esto con el fin de determinar si el sistema puede encontrar patrones únicamente a partir de los indicadores de la marcha. Otra consideración que se realizó fue el tipo de clasificación que se realizaría, debido a que como se ha mencionado previamente solo se cuenta con información de personas en un estado sano, por lo que de momento no se puede llevar a cabo la clasificación de problemas; sin embargo, si es posible demostrar que el SVM puede clasificar la información de la marcha.

Para demostrar el funcionamiento del SVM se optó por realizar varias pruebas, una de estas fue la clasificación del caminado de una persona (Costilla-Reyes et al., 2020), en donde el sistema debe de poder identificar a una persona a partir de las características de su marcha, las cuales pueden llegar a tener una gran variación causadas por las características fisiológicas de cada persona, para demostrar esto se tiene la comparación de la marcha de dos personas, donde primeramente se presentan datos generales de los participantes en la Tabla 4-3.

Tabla 4-3.- Datos generales de dos participantes.

Datos	Participante A	Participante B
Edad	22	24
Altura	1.63 m	1.71 m
Peso	62	87 kg
Índice de masa corporal	23.33	29.75
¿Realiza actividad física?	Si	No
¿Lesiones en las piernas previas?	No	No

Mientras que en la Fig. 4.8 se puede apreciar la comparación de los datos obtenidos de su marcha, donde los del participante A se muestran en azul y en naranja los de B.

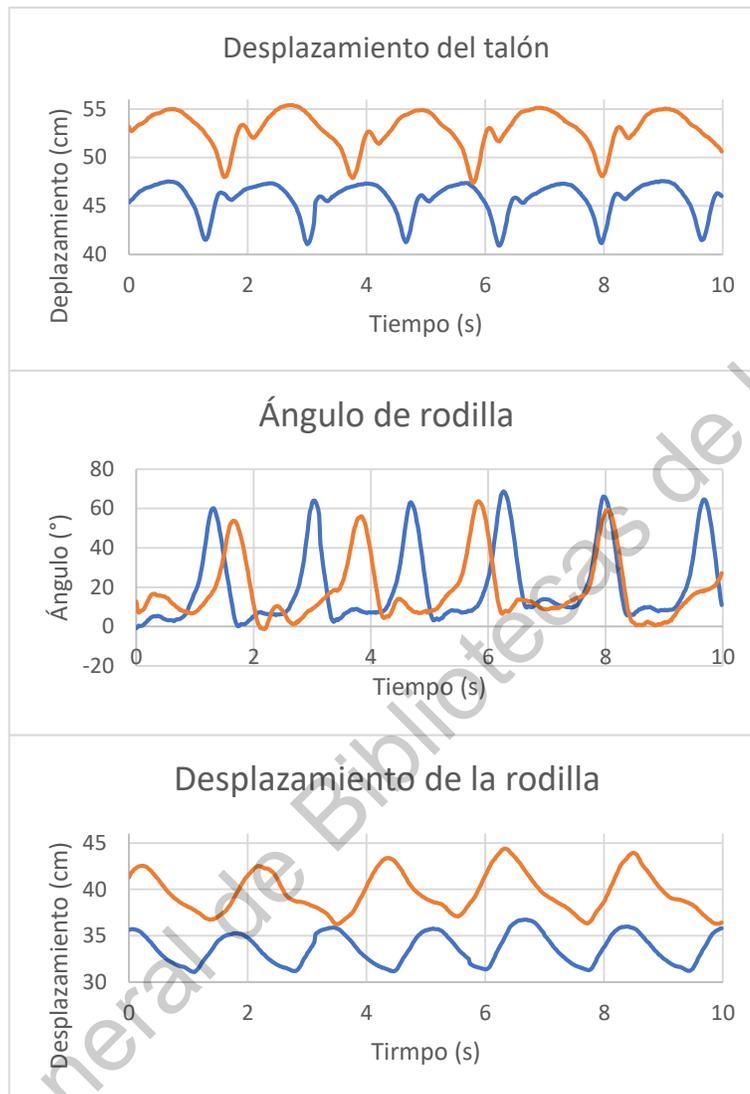


Fig. 4.8.- Comparación entre las mediciones de dos participantes, donde los datos del participante A se presentan en azul y los del participante B en naranja.

Para la clasificación inicialmente se generó una base de datos con la información obtenida de las 4 pruebas a diferentes velocidades (1.4, 1.9, 2.1 y 2.4 km/h) de 3 participantes. Esta información está compuesta por los 17 indicadores establecidos en la metodología, los cuales fueron acomodados en forma de fila y etiquetados de acuerdo a la persona a la que pertenecen los datos, tal como se en el extracto de la Tabla 4-4, en donde solo se representan 8 de los indicadores.

Tabla 4-4.- Base de datos generada a partir de los indicadores para la identificación de la marcha.

	Etiqueta	Cadencia	Periodo	Longitud de paso	Ángulo de rodilla (despegue)	Ángulo de rodilla (golpe de talón)	ROM rodilla mínimo	ROM rodilla máximo
Persona A	1	1.81	66.11	24.09	34.39	11.69	1.16	59.79
	1	1.66	72.07	27.23	36.04	5.47	5.59	34.50
	1	1.53	78.17	26.37	36.86	2.88	1.93	41.45
	1	1.40	85.47	27.21	38.17	5.33	7.14	43.02
Persona B	0	2.21	54.29	28.87	39.52	12.85	10.23	45.53
	0	2.09	57.41	34.83	28.14	5.37	4.33	36.20
	0	1.78	67.41	32.24	32.55	5.80	4.84	45.79
	0	1.77	67.66	34.22	29.23	4.57	4.07	51.90
Persona C	-1	1.66	72.28	23.25	27.88	25.01	2.50	60.42
	-1	1.57	76.19	29.35	32.06	9.91	5.57	50.42
	-1	1.50	80.00	26.24	34.63	34.02	4.11	72.90
	-1	1.57	76.43	33.11	27.38	6.95	1.08	51.94

Posteriormente se llevó a cabo la implementación de la cross-validation en donde se separó la información en dos partes una para entrenar y otra para validar, siendo esta el 25% de los datos. Utilizando los datos de entrenamiento se implementó la normalización por z-score, utilizando la fórmula 3-15, con el fin de obtener una mejor dispersión de los datos y a la vez evitar que los indicadores que trabajen en una mayor magnitud tengan un mayor peso sobre el resultado de la clasificación, el resultado obtenido por el software es presentado en la Tabla 4-5.

Tabla 4-5.- Datos de entrenamiento normalizados obtenidos del software.

	Etiqueta	Cadencia	Periodo	Longitud de paso	Ángulo de rodilla (despegue)	Ángulo de rodilla (golpe de talón)	ROM rodilla mínimo	ROM rodilla máximo
Persona A	1	0.24	-0.37	-1.19	0.39	0.30	-1.18	1.25
	1	-0.33	0.23	-0.44	0.74	-0.64	0.32	-1.48
	1	-1.34	1.61	-0.45	1.20	-0.66	0.85	-0.56
Persona B	0	1.78	-1.59	-0.06	1.49	0.48	1.90	-0.28
	0	1.31	-1.27	1.35	-0.93	-0.66	-0.10	-1.29
	0	0.08	-0.21	1.20	-0.70	-0.78	-0.19	0.40
Persona C	-1	-0.35	0.25	-1.39	-0.99	2.35	-0.72	1.32
	-1	-0.68	0.66	0.05	-0.10	0.03	0.32	0.24
	-1	-0.70	0.68	0.94	-1.10	-0.42	-1.20	0.40

Una vez finalizada la normalización de los datos, se guardaron los promedios y desviaciones estándar de cada una de las columnas de indicadores, ya deberán ser utilizados para la normalización de un nuevo dato, esto se puede apreciar en la Tabla 4-6.

Tabla 4-6.- Datos de validación normalizados a partir de los datos de entrenamiento

Etiqueta	Cadencia	Periodo	Longitud de paso	Ángulo de rodilla (despegue)	Ángulo de rodilla (golpe de talón)	ROM rodilla mínimo	ROM rodilla máximo
1	-0.84	0.86	-0.65	0.92	-1.04	-0.92	-0.73
0	0.11	-0.24	0.74	0.002	-0.59	0.07	-0.26
-1	-0.97	1.05	-0.68	0.44	3.74	-0.17	2.67

Utilizando los datos normalizados de entrenamiento se generan 3 SVM, una para cada uno de los casos, en donde se utilizó un Kernel polinomial de segundo grado, con una complejidad unitaria y una tolerancia de $10e^{-2}$. Una vez finalizado se realizó una evaluación utilizando los mismos datos de entrenamiento, en donde en la mayoría de los casos se obtuvo una precisión del 100%. Posteriormente se pasó a realizar la evaluación con los datos que no fueron utilizados para el entrenamiento, en donde la precisión llegó a variar dependiendo de los datos que se utilizaran para entrenar. Por ello el proceso de entrenamiento se repite en múltiples ocasiones tomando diferentes datos para el entrenamiento y la validación, en cada iteración se revisó la precisión obtenida, finalmente se guarda el caso donde la precisión sea mayor y se dice que esta será la base de datos a utilizar para comparar nuevos datos, en este caso se obtuvo un entrenamiento donde la clasificación obtuvo el 100% de precisión, lo cual se puede apreciar en la Tabla 4-7.

Tabla 4-7.- Resultados de precisión de cada uno de los SVM generados con cross-validation.

	SVM 1	SVM 2	SVM 3	SVM 4
Precisión de SVM	100	100	100	100
Sensitividad de SVM	100	100	100	100
Especificidad	100	100	100	100
Precisión con nuevos datos	33.33	33.33	100	66.66

Otra prueba utilizada para verificar el funcionamiento de la SVM fue la clasificación de datos a partir de la velocidad de la marcha, en donde los datos de las pruebas se etiquetaron acorde a la velocidad colocada en la caminadora (1.4, 1.9 y 2.1 km/h), tal como se presenta en la Tabla 4-8.

Tabla 4-8.- Base de datos normalizada para la clasificación de velocidad

	Etiqueta	Cadencia	Periodo	Longitud de paso	Ángulo de rodilla (despegue)	Ángulo de rodilla (golpe de talón)	ROM rodilla mínimo	ROM rodilla máximo
1.4 km/h	1	0.24	-0.37	-1.19	0.39	0.30	-1.18	1.25
	1	1.78	-1.59	-0.06	1.49	0.48	1.90	-0.28
	1	-0.35	0.25	-1.39	-0.99	2.35	-0.72	1.32
1.9 km/h	2	-0.33	0.23	-0.44	0.74	-0.64	0.32	-1.48
	2	1.31	-1.27	1.35	-0.93	-0.66	-0.10	-1.29
	2	-0.68	0.66	0.05	-0.10	0.03	0.32	0.24
2.1 km/h	3	-0.84	0.86	-0.65	0.92	-1.04	-0.92	-0.73
	3	0.11	-0.24	0.74	0.002	-0.59	0.07	-0.26
	3	-0.97	1.05	-0.68	0.44	3.74	-0.17	2.67

Con los cuales el sistema realizo el mismo proceso que en el caso anterior en donde a través del concepto de cross-validation se obtienen diferentes SVM con diferentes porcentajes de precisión, lo cual se aprecia en la Tabla 4-9 en dónde se obtiene una precisión máxima de 66.67% a causa de la escasez de datos.

Tabla 4-9.- Resultados obtenidos de los SVM para clasificación de velocidad utilizando cross-validation.

	SVM 1	SVM 2	SVM 3
Precisión de SVM	100	100	100
Sensitividad de SVM	100	100	100
Especificidad	100	100	100
Precisión con nuevos datos	66.67	33.33	66.67

Utilizando estas pruebas se determinó que tanto el sistema de adquisición como el sistema de clasificación son capaces de obtener las diferencias entre los tipos de marchas. Para verificar que el sistema pueda clasificar los tres estados propuestos es necesario completar la base de datos con pruebas de los pacientes previamente diagnosticados con alguno de los problemas musculares u óseos que se buscan tratar, lo cuales se han estado programando gradualmente y en grupos pequeños, pero sin suficientes datos para generar un entrenamiento robusto del algoritmo de SVM.

Dirección General de Bibliotecas de la UAG

Capítulo 5. Prospectivas

Hasta el momento el sistema desarrollado es capaz de adquirir datos particulares de la marcha de cada persona, tanto de la información provista por el sistema de visión como de los sensores montables; sin embargo, la información obtenida aún puede continuar expandiéndose, por ejemplo, para el sistema de visión artificial solo se cuenta con los datos de la pierna derecha y solamente en el plano sagital, por lo tanto lo se puede desarrollar es un sistema donde se utilicen múltiples cámaras que puedan grabar y reconstruir por completo la mecánica de las extremidades inferiores, donde se revise el plano sagital y frontal de ambas piernas. Por otra parte, también se puede extender el campo de visión con el fin recabar información de la parte superior del cuerpo, además de que se buscará implementar la aceleración como un indicador que permita revisar la cinemática y detectar movimientos sutiles.

Para el sistema de sensores montables, se puede mejorar la estructura y diseño de los sensores utilizados para que estos sean más ergonómicos y prácticos en su uso, en donde se podría optar por un sistema centralizado, es decir, en donde los diferentes sensores sean controlados por una sola tarjeta.

Como punto más importante a mejorar será la realización de una base de datos más extensa, en donde no solo se cuente con más datos, sino que también se cuente con datos pertenecientes a las condiciones propuestas, además de esto se deberá buscar la realización de una comparación directa entre la información obtenida con el sistema desarrollado y uno de tipo profesional, con el fin de verificar la confiabilidad y precisión del sistema como un elemento de diagnóstico, lo cual se continuará trabajando en proyectos futuros para el desarrollo de un sistema de diagnóstico más robusto.

Capítulo 6. Conclusión

Para el presente trabajo se consideró la posibilidad de diseñar e implementar una metodología a través de la cual fuese posible clasificar el estado en el que se encuentra la marcha de un paciente que no cuente con un diagnóstico previo.

Para esto se delimitaron los tipos de problemas que se estaría abarcando con la ayuda de un especialista, lo que resultó en un énfasis en la clasificación de problemas óseos y musculares, los cuales tienden de contar con características similares por lo que se pueden confundir durante la etapa de evaluación y diagnóstico causando que su tratamiento sea ineficaz y llegue la necesidad de realizar nuevas pruebas y evaluaciones.

Para lograr la clasificación de padecimiento se desarrolló un sistema de adquisición a partir de un sistema de visión artificial basado en el protocolo Davis y con sensores montables, con estos se recopila información de la cinemática del caminado, como el desplazamiento y la velocidad lineal y angular de diferentes puntos de interés. Sin embargo, debido a la importancia de que tienen las mediciones en el trabajo se llevó a cabo la calibración del sistema de medición en donde se obtuvo un error de medición menor del 5%. Con la información obtenida de las mediciones se pasó a obtener parámetros espacio temporales y cinéticos que serían considerados indicadores de la marcha, así como la longitud de zancada, la cadencia, la velocidad del caminado, el rango de movimiento, etc.

Con estos datos se buscó establecer un patrón de caminado ideal; sin embargo, al comenzar a realizar pruebas con pacientes que fueron categorizados en estado sano, se encontró que los indicadores contaban con una gran variación, causada por la diferencia fisiológicas y de hábitos de los participantes, por lo tanto, se decidió no usar un solo patrón de caminado sano sino un conjunto de patrones de diferentes participantes que estuvieran medicamente saludables, de esta manera se comenzó a elaborar una base de datos con la información recabada de personas sanas con diferentes fisiologías. Lamentablemente esta fue la única que se logró desarrollar a causa de la pandemia que tuvo un inicio en el año 2020 y cuyos efectos se mantienen presentes en el año 2021, lo cual ha dificultado la realización de campañas a gran escala para el reclutamiento de participantes con el fin de mantener las medidas

sanitarias. Por lo tanto, se tuvo que optar por un proceso más lento a base de la organización de citas y solo con personas pertenecientes a una institución de la UAQ, de tal manera que se evitaran las aglomeraciones, se asegurara la limpieza del equipo entre cada participante y se tuviera un control sobre las personas que ingresaran a las instalaciones.

También se ha desarrollado de manera efectiva un SVM que, con el principio de all against one, puede clasificar las diferentes condiciones, así como la identificación de personas y la detección de la velocidad, con una precisión de hasta 100% utilizando la cross-validation; sin embargo, este porcentaje aún varía dependiendo de la tarea entre el 66.67 y 100%, a causa de la escasez de información con la que se trabaja. Considerando la información mencionada se puede decir que el sistema es funcional en la tarea de adquisición de los indicadores y clasificación de las condiciones; sin embargo, se debe mantener en cuenta que la base de datos no es lo suficientemente grande para cada uno de los casos que se busca clasificar y que aún se requerirá evaluaciones más minuciosas del sistema.

Capítulo 7. Referencias bibliográficas

1. Beer, F. P., Johnstons, E. R., & Cornwell, P. J. (2010). *Mecánica Vectorial Para Ingenieros*. In *Mc Graw Hill* (9th ed., Vol. 1). McGraw-hill.
2. Begg, R., & Kamruzzaman, J. (2005). A machine learning approach for automated recognition of movement patterns using basic, kinetic and kinematic gait data. *Journal of Biomechanics*, 38(3), 401–408. <https://doi.org/10.1016/j.jbiomech.2004.05.002>
3. Belić, M., Bobić, V., Badža, M., Šolaja, N., Đurić-Jovičić, M., & Kostić, V. S. (2019). Artificial intelligence for assisting diagnostics and assessment of Parkinson's disease—A review. *Clinical Neurology and Neurosurgery*, 184(March). <https://doi.org/10.1016/j.clineuro.2019.105442>
4. Byrne, J. E., Stergiou, N., Blanke, D., Houser, J. J., Kurz, M. J., & Hageman, P. A. (2002). Comparison of gait patterns between young and elderly women: An examination of coordination. *Perceptual and Motor Skills*, 94(1), 265–280. <https://doi.org/10.2466/pms.2002.94.1.265>
5. Cedeño-Moreno, R., Morales-Hernández, L. A., Osornio-Ríos, R. A., & Cruz Albarrán, I. A. (2020). *Design and construction of the Hoeken linkage as a calibration element for an artificial vision system* (pp. 1–7).
6. Cho, C. W., Chao, W. H., Lin, S. H., & Chen, Y. Y. (2009). A vision-based analysis system for gait recognition in patients with Parkinson's disease. *Expert Systems with Applications*, 36(3 PART 2), 7033–7039. <https://doi.org/10.1016/j.eswa.2008.08.076>
7. Clavel, M., Gomar, S. F., & Vaquero Gonzalez, G. F. (1973). *Secot-Spot Ix Congreso Hispano-Luso De Ortopedia Y Traumatología Ponencia Española Displasias Oseas*. 184. https://www.secot.es/uploads/descargas/publicaciones/ponencias_historicas/03DISPLASIASOSEAS.pdf
8. Costilla-Reyes, O., Vera-Rodríguez, R., Alharthi, A. S., Yunas, S. U., & Ozanyan, K. B. (2020). Deep Learning Algorithms And Applications. *Deep Learning: Algorithms and Applications*, 865, 308–334.
9. Davis, R. B., Ounpuu, S., Tyburski, D., & Gage, J. R. (1991). A gait analysis data collection and reduction technique. *Human Movement Science*, 10(5), 575–587.
10. Erazo-Torricelli, R. (2004). Actualización en distrofias musculares. *Revista de Neurología*, 39(9), 860–871. <https://doi.org/10.33588/rn.3909.2004182>
11. Goldberg, D. E., & Holland, J. H. (1988). Genetic Algorithms and Machine Learning. *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, 95–99. <https://doi.org/10.1177/0954408914531118>
12. Hafer, J. F., Brown, A. M., deMille, P., Hillstrom, H. J., & Garber, C. E. (2015). The effect of a cadence retraining protocol on running biomechanics and efficiency: a pilot study. *Journal of Sports Sciences*, 33(7), 724–731. <https://doi.org/10.1080/02640414.2014.962573>
13. Hageman, P. A., & Blanke, D. J. (1986). Comparison of gait of young women and elderly women. *Physical Therapy*, 66(9), 1382–1387. <https://doi.org/10.1093/ptj/66.9.1382>
14. Haro, M. D. (2014). Laboratorio de análisis de marcha y movimiento. *Revista Médica Clínica Las Condes*, 25(2), 237–247. [https://doi.org/10.1016/s0716-8640\(14\)70034-3](https://doi.org/10.1016/s0716-8640(14)70034-3)

15. Hibbeler, R. C. (2010). *Ingeniería mecánica Dinámica*. Pearson Education.
16. Hsu, Y. L., Chung, P. C., Wang, W. H., Pai, M. C., Wang, C. Y., Lin, C. W., Wu, H. L., & Wang, J. S. (2014). Gait and balance analysis for patients with Alzheimer's disease using an inertial-sensor-based wearable instrument. *IEEE Journal of Biomedical and Health Informatics*, 18(6), 1822–1830. <https://doi.org/10.1109/JBHI.2014.2325413>
17. Iucksch, D. D., Israel, V. L., Ribas, D. I. R., & Manffra, E. F. (2013). Gait characteristics of persons with incomplete spinal cord injury in shallow water. *Journal of Rehabilitation Medicine*, 45(9), 860–865. <https://doi.org/10.2340/16501977-1193>
18. Jaramillo-Arteaga, D. (2019). *Sensor inteligente inalámbrico para la medición de la actividad física en personas a través de walkapp*. Universidad Autónoma de Querétaro.
19. Jasuja, O. P., Harbhajan, S., & Anupama, K. (1997). Estimation of stature from stride length while walking fast. *Forensic Science International*, 86(3), 181–186. [https://doi.org/10.1016/S0379-0738\(97\)00038-8](https://doi.org/10.1016/S0379-0738(97)00038-8)
20. Jayalakshmi, T., & Santhakumaran, A. (2011). Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 3(1), 89–93. <https://doi.org/10.7763/ijcte.2011.v3.288>
21. Jeon, H., Lee, W., Park, H., Lee, H. J., Kim, S. K., Kim, H. B., Jeon, B., & Park, K. S. (2017). Automatic classification of tremor severity in Parkinson's disease using a wearable device. *Sensors (Switzerland)*, 17(9), 1–14. <https://doi.org/10.3390/s17092067>
22. Kim, H. C., Pang, S., Je, H. M., Kim, D., & Bang, S. Y. (2003). Constructing support vector machine ensemble. *Pattern Recognition*, 36(12), 2757–2767. [https://doi.org/10.1016/S0031-3203\(03\)00175-4](https://doi.org/10.1016/S0031-3203(03)00175-4)
23. Liang, C., Gu, H., Ceccarelli, M., & Carbone, G. (2011). Design and operation of a tripod walking robot via dynamics simulation. *Robotica*, 29(5), 733–743. <https://doi.org/10.1017/S0263574710000615>
24. Lippert, L., & Hurrell, J. (2006). *Clinical kinesiology and anatomy*. F.A. Davis Company.
25. López Longo, F. J. (2008). Miopatías inflamatorias. Nuevos conceptos. *Reumatología Clínica*, 4, 40–44. [https://doi.org/10.1016/s1699-258x\(08\)76139-4](https://doi.org/10.1016/s1699-258x(08)76139-4)
26. McCaffrey, J. (2019). *Support Vector Machines Using Accord.NET*. Visual Studio Magazine. <https://visualstudiomagazine.com/Articles/2019/02/01/Support-Vector-Machines.aspx?Page=1>
27. Mitchell, T. M. (1997). Machine Learning. In *Intelligent Systems Reference Library* (Vol. 17). https://doi.org/10.1007/978-3-642-21004-4_10
28. Norton, R. L. (1999). *Design of machinery: an introduction to the synthesis and analysis of mechanisms and machines* (2nd ed.). McGraw-Hill.
29. Oppenheim, A. V., Schaffer, R. W., & Buck, J. R. (1999). *Discrete-Time Signal Processing*. Prentice-Hall.
30. Oteyza O., E., Lam Osnaya, E., Hernández Garcíadiego, C., Carrillo Hoyo, A. M., & Ramírez Flores, A. (2005). *Geometría analítica*. Pearson. <https://doi.org/10.1007/978-1-4614-7990-1>
31. Pajares, G., & M. de la Cruz, J. (2002). *Visión por computador, imágenes digitales y aplicaciones*. Alfaomega.
32. Pang, C. C. C., Upton, A. R. M., Shine, G., & Kamath, M. V. (2003). A comparison of algorithms for detection of spikes in the electroencephalogram. *IEEE Transactions on Biomedical Engineering*, 50(4), 521–526. <https://doi.org/10.1109/TBME.2003.809479>

33. Patil, V. S., Anerao, P. R., & Chinchankar, S. S. (2018). Design and Analysis of Compliant Mechanical Amplifier. *Materials Today: Proceedings*, 5(5), 12409–12418. <https://doi.org/10.1016/j.matpr.2018.02.220>
34. Priddy, K. L., & Keller, P. E. (2005). *Artificial neural networks : an introduction*. SPIE Press.
35. Rodríguez-Sosa, L., Calderón-Rosete, G., Anaya, V., & Flores, G. (2012). The caudal photoreceptor in the crayfish: An overview. *Photoreceptors: Physiology, Types and Abnormalities*, 59–77.
36. Sandoval Castro, X. Y., García, M. A., Guerrero, J. D. E., Benitez Escarcega, M. R., & Castillo Castaneda, E. (2013). Estimación de la pose de un robot caminante a través de análisis de imágenes. *XV Congreso Mexicano de Robótica*, 1, 71–77.
37. Scholkopf, B., & Smola, A. J. (2001). Learning with Kernels (SLIDES). In *The MIT Press* (Issue February).
38. Shany, T., Redmond, S. J., Narayanan, M. R., & Lovell, N. H. (2012). Sensors-based wearable systems for monitoring of human movement and falls. *IEEE Sensors Journal*, 12(3), 658–670. <https://doi.org/10.1109/JSEN.2011.2146246>
39. Taratuto, A. L. (2010). Muscle biopsy in congenital myopathies and muscular dystrophies. *Neurologia Argentina*, 2(4), 250–264. [https://doi.org/10.1016/S1853-0028\(10\)70074-4](https://doi.org/10.1016/S1853-0028(10)70074-4)
40. Testut, L., & Latarjet, A. (2014). *Tratado de anatomía humana*. Salvat.
41. Trew, M., & Everett, T. (2006). *Fundamentos del movimiento humano* (Masson (ed.); 5th ed.). Elsevier.
42. Turani, N., Kemiksizoğlu, A., Karataş, M., & Özker, R. (2004). Assessment of hemiplegic gait using the Wisconsin Gait Scale. *Scandinavian Journal of Caring Sciences*, 18(1), 103–108. <https://doi.org/10.1111/j.1471-6712.2004.00262.x>
43. Van Den Noort, J. C., Ferrari, A., Cutti, A. G., Becher, J. G., & Harlaar, J. (2013). Gait analysis in children with cerebral palsy via inertial and magnetic sensors. *Medical and Biological Engineering and Computing*, 51(4), 377–386. <https://doi.org/10.1007/s11517-012-1006-5>
44. Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Springer Science & Business Media. <https://doi.org/10.1017/CBO9781107415324.004>
45. Vapnik, V. (1998). *Statistical Learning Theory*. Wiley-Interscience.
46. Verplancke, T., Van Looy, S., Benoit, D., Vansteelandt, S., Depuydt, P., De Turck, F., & Decruyenaere, J. (2008). Support vector machine versus logistic regression modeling for prediction of hospital mortality in critically ill patients with haematological malignancies. *BMC Medical Informatics and Decision Making*, 8, 1–8. <https://doi.org/10.1186/1472-6947-8-56>
47. Villa-forte, P. A., & Clinic, C. (2017). *Pruebas para el diagnóstico de trastornos musculoesqueléticos*.
48. Villa M., A., Gutiérrez G., E., & Pérez M., J. C. (2008). Consideraciones para el análisis de la marcha humana. Técnicas de videogrametría, electromiografía y dinamometría. *Revista Ingeniería Biomédica*, 2(3), 16–26.
49. Wang, F., Stone, E., Skubic, M., Keller, J. M., Abbott, C., & Rantz, M. (2013). Toward a passive low-cost in-home gait assessment system for older adults. *IEEE Journal of Biomedical and Health Informatics*, 17(2), 346–355.

<https://doi.org/10.1109/JBHI.2012.2233745>

50. Winter, D. A. (2009). Biomechanics and Motor Control of Human Movement: Fourth Edition. In *Biomechanics and Motor Control of Human Movement: Fourth Edition*. <https://doi.org/10.1002/9780470549148>
51. Wray, N. P., & Friedland, J. A. (1983). Detection and Correction of House Staff Error in Physical Diagnosis. *JAMA: The Journal of the American Medical Association*, 250(5), 614. <https://doi.org/10.1001/jama.1983.03340050026017>
52. Wu, J., Zhou, Z., Chen, J., Fourati, H., & Li, R. (2016). Fast Complementary Filter for Attitude Estimation Using Low-Cost MARG Sensors. *IEEE Sensors Journal*, 16(18), 6997–7007. <https://doi.org/10.1109/JSEN.2016.2589660>
53. Zhu, M., Zhang, Z., Hirdes, J. P., & Stolee, P. (2007). Using machine learning algorithms to guide rehabilitation planning for home care clients. *BMC Medical Informatics and Decision Making*, 7, 1–13. <https://doi.org/10.1186/1472-6947-7-41>

Dirección General de Bibliotecas de la UAG