

# Reconocimiento automático de marcha antiálgica a partir de la medición de la cantidad de actividad empleando el giroscopio de un teléfono inteligente

Juan-Carlos González-Islas<sup>1,2</sup>, Omar-Arturo Domínguez-Ramírez<sup>1</sup>,  
Omar López-Ortega<sup>1</sup>, René-Daniel Paredes-Bautista<sup>3</sup>, David Díaz Girón-Aguilar<sup>2</sup>

<sup>1</sup> Universidad Autónoma del Estado de Hidalgo,  
México

<sup>2</sup> Universidad Tecnológica de Tulancingo,  
México

<sup>3</sup> Centro de Rehabilitación Integral de Hidalgo,  
México

(juan\_gonzalez7024, omar, lopezo)@uaeh.edu.mx,  
1718110586@utectulancingo.edu.mx,  
drrenedanielparedes@gmail.com

**Resumen.** La estadística de la marcha antiálgica, como consecuencia de diversas enfermedades desarrolladas por el ser humano, sostiene un crecimiento exponencial. Los métodos clásicos de diagnóstico advierten subjetividad en el resultado. El empleo del reconocimiento automático es una alternativa que garantiza certeza y reducción de tiempo en el diagnóstico. En este artículo, se presenta un marco de trabajo para el reconocimiento automático de la marcha para clasificar las marchas antiálgica y no antiálgica, basado en la medición de la cantidad de actividad. Para ello es empleado el giroscopio embebido en un teléfono inteligente. El muestreo, reducción, extracción y selección de características son elementos del marco propuesto que preservan la esencia de los datos brutos. En el estudio comparativo de algoritmos de clasificación para seleccionar el método idóneo para el caso de estudio, se evalúan los algoritmos de: i) Análisis Discriminante Lineal (LDA), ii) k-Vecinos más Cercanos (kNN), iii) Máquinas de Soporte Vectorial (SVM), iv) Naive Bayes (NB), y v) Árboles de Decisión (DT). El desempeño de los algoritmos fue determinado empleando las métricas de tasa de clasificación correcta (CCR), sensibilidad (R), especificidad (SP) y precisión. Siendo SVM el mejor con  $CCR = CR = R = SP = P = 100\%$ . Los resultados obtenidos permiten determinar la viabilidad de emplear el marco de trabajo para diagnóstico objetivo y soporte de toma de decisiones en los tratamientos asociados a la marcha antiálgica en escenarios médicos reales.

**Palabras clave:** Análisis de la marcha, aprendizaje automático, marcha antiálgica, giroscopio.

## Automatic Recognition of Antalgic Gait from the Measurement of the Amount of Activity Using the Gyroscope of a Smartphone

**Abstract.** The statistics of the antalgic gait, as a consequence of various diseases developed by the human being, sustains an exponential growth. Classic diagnostic methods warn of subjectivity in the result. The use of automatic recognition is an alternative that guarantees certainty and reduction of time in the diagnosis. In this article, an automatic gait recognition framework is presented to classify antalgic and non-antalgic gaits, based on the measurement of the amount of activity. For this, the gyroscope embedded in a smartphone is used. Sampling, reduction, extraction, and feature selection are elements of the proposed framework that preserve the essence of the raw data. In the comparative study of classification algorithms to select the ideal method for the case study, the algorithms of: i) Linear Discriminant Analysis (LDA), ii) k-Nearest Neighbors (kNN), iii) Support Vector Machines (SVM), iv) Naive Bayes (NB), and v) Decision Trees (DT). The performance of the algorithms was determined using the correct classification rate (CCR), sensitivity (R), specificity (SP), and precision metrics. Being SVM the best with  $CCR = CR = R = SP = P = 100\%$ . The results obtained allow us to determine the feasibility of using the framework for objective diagnosis and decision-making support in treatments associated with analgesic gait in real medical scenarios.

**Keywords:** Gait analysis, machine learning, antalgic gait, gyroscope.

### 1. Introducción

La marcha humana es la forma más importante de locomoción que el ser humano tiene para desplazarse de manera autónoma usando sus extremidades inferiores [34]. El análisis cuantitativo de este proceso, permite evaluar numéricamente la marcha mediante la medición de los datos clínicos y biomecánicos de ésta. El análisis de la marcha ha sido muy útil en áreas como robótica, biomecánica, deportes, seguridad, rehabilitación y diagnóstico clínico [17, 28, 34].

En términos clínicos, esta herramienta ha sido útil para diagnosticar padecimientos asociados a la marcha antiálgica como: i) osteoartritis de rodilla, ii) artritis reumatoide, iii) derrame cerebral, iv) mal de Parkinson, v) parálisis cerebral, entre otras [16]. La marcha antiálgica es una de las más comunes dentro de las marchas anómalas, la mayoría de alteraciones en huesos, músculos, articulaciones y tejidos blandos derivadas en este tipo de marcha no son tan evidentes, por lo que recientemente ha sido de especial interés el desarrollo de herramientas asistenciales y de diagnóstico para este padecimiento.

Una de sus características es la presencia de cojera en el patrón de marcha, que provoca que se acorte la fase apoyo con respecto a la de oscilación [3]. Por ello, la necesidad de determinar objetivamente la fase del ciclo de marcha con anomalía y su relación con los elementos del sistema músculo esquelético con mayor deterioro.

Derivado de la gran cantidad de datos y naturaleza multivariable, multidimensional e incertidumbre, el problema de análisis de la marcha se puede resolver desde un enfoque basado en aprendizaje automático que se conoce como reconocimiento automático de la marcha, el cual se centra en la evaluación y comparación de patrones de marcha de diferentes sujetos, que permite distinguir la forma de caminar de cada persona [29].

Por lo que es necesario el desarrollo de algoritmos que identifiquen las formas de caminar de las personas como lo es la marcha antiálgica [30]. La aceleración y velocidad angular de las articulaciones del sistema músculo-esquelético de una persona durante el ciclo de marcha son diferentes respecto a otra. Lo que ha posibilitado que este tipo de datos sean utilizados para identificar individuos.

Comúnmente, los sensores se colocan en las partes de interés a evaluar del cuerpo [23], como la rodilla por ejemplo. Hoy en día, los desarrollos en términos de sensores vestibles y electrónica portable, ha permitido el desarrollo de sistemas sofisticados, con alta precisión, bajo nivel de integración y bajo costo, embebidos en los teléfonos inteligentes [33]. En este trabajo se considera el problema de clasificación de personas con un patrón de marcha antiálgica y marcha no antiálgica.

Para lo cual, se describe el desarrollo de un marco de trabajo de reconocimiento automático para clasificar entre ambos tipos de marcha, basado en aprendizaje automático empleando el giroscopio embebido de un teléfono inteligente como dispositivo de adquisición de datos. El cual aduce su aplicación en escenarios médicos para el apoyo en el diagnóstico objetivo y soporte de toma de decisiones en tratamientos en padecimientos relacionados a la marcha antiálgica.


### **1.1. Trabajo relacionado**

Recientemente, el reconocimiento automático de la marcha ha sido usado para determinar anomalías en el patrón de marcha [7]. En términos de la marcha antiálgica, se han reportado trabajos para el diagnóstico de: i) osteoartritis de rodilla [19, 35], ii) artritis reumatoide [22], iii) mal de Parkinson [21], iv) derrame cerebral [8, 14] y v) esclerosis múltiple [1].

Hoy en día, existen múltiples plataformas de adquisición de datos para el análisis automático de la marcha, por ejemplo, la instrumentación de la fuerza de interacción entre la fascia plantar y la superficie de caminata, se ha utilizado para determinar parámetros asociados a condiciones normales o anormales de marcha [5, 36].

De igual manera, la visión artificial se ha empleado para este propósito, en [15] se ha reportado la clasificación de la marcha normal y 5 tipos de marcha anómala entre las que se encuentra la antiálgica, basado en una unidad recurrente cerrada (GRU) con una exactitud del 90.13 %. Por su parte, en [20] se reporta hasta el 88.68 % de tasa de reconocimiento usando redes Bayesianas. También se han usado otros algoritmos de clasificación como redes neuronales artificiales (ANN), redes neuronales convolucionales (CNN) y k-vecinos más cercanos (kNN)[30].

Sin embargo, hay factores asociados tanto al sensor de piso como a los sistemas de visión que limitan el rendimiento de la plataforma de caracterización, además de no permitir detectar de manera explícita el nivel de actividad humana como parte complementaria al tipo de padecimiento [16, 29].



**Fig. 1.** Marco de trabajo de aprendizaje automático supervisado para la clasificación de marchas antiálgica y no antiálgica.

En este trabajo se reporta el uso de sensores de velocidad angular, como una alternativa para la detección de marcha antiálgica basada en el nivel de actividad humana. Aunado a lo anterior, se han desarrollado otros sistemas para el reconocimiento de la marcha con un rendimiento de 94.4 % usando kNN [27]. Por su parte, Hoang [13] usando el acelerómetro embebido en un teléfono y máquinas de soporte vectorial (SVM) ha reportado una exactitud del 91 %. Gafurov et al., [12] usan acelerómetros para el mismo propósito, obteniendo una tasa de reconocimiento de 83.3 % mediante métodos estadísticos.


Los sensores embebidos en un teléfono inteligente resuelven parcialmente el problema de la instrumentación y acondicionamiento de señales inherente a este tipo de sensores, en [2] se ha empleado este enfoque para reconocimiento de actividades humanas como la caminata con una precisión del 95.6 % implementando SVM y en [9] se reporta el reconocimiento de la marcha con una tasa de reconocimiento de 87.6 % y 86.7 % usando LibSVM y modelo logístico de árboles, respectivamente.

El uso de varias unidades inerciales, aunque aumenta la complejidad en el procesamiento, mejora la capacidad del sistema para reconocer la marcha, en [11] se describe el uso de dos acelerómetros. Mientras que Ngo et al., [23] han generado una de las bases de datos más grandes (OUISIR) usando 4 unidades inerciales para identificar si una persona camina sobre una superficie plana o con pendientes positiva o negativa.

Debido a que la marcha es un proceso periódico, muchos de los trabajos que usan la aceleración y la velocidad angular para reconocerla se basan en la detección del periodo para construir patrones de marcha. También es posible emplear características en el dominio de la frecuencia, como la intensidad del espectro o la transformada de Fourier [18].

De acuerdo a la revisión de las aportaciones en la literatura, y como parte complementaria a lo reportado en [4], se establece el siguiente planteamiento:

*Si bien existen muchos trabajos sobre el reconocimiento automático de la marcha, pocos están desarrollados para identificar objetivamente marcha antiálgica y su relación con los elementos del sistema músculo-esquelético, menos aun aprovechando las prestaciones de una unidad inercial embebida en un teléfono inteligente para identificar anomalías con base en la cantidad de actividad humana detectada. Adicionalmente, las*



**Fig. 2.** Disposición del teléfono inteligente y correspondencia entre los ejes anatómicos del sujeto y del giroscopio del teléfono.

*condiciones de eficiencia en la clasificación y validación requeridas por especialistas médicos del área, respecto al diagnóstico de padecimientos no han sido resueltas.*

Este artículo está organizado de la siguiente manera: Sección 1, se presentan la introducción y las aportaciones en la literatura sobre el reconocimiento automático de marcha antiálgica, empleando el giroscopio de un teléfono inteligente. El marco de trabajo de reconocimiento automático y cada una de sus secciones son descritas en la sección de materiales y métodos. Los resultados experimentales y una discusión sobre los mismos se proporcionan en la sección 3. Finalmente, se presentan las conclusiones y el trabajo futuro.

## 2. Marco de trabajo de reconocimiento automático de la marcha

Para el desarrollo de la tarea de clasificación de marchas antiálgica y no antiálgica basado en aprendizaje automático empleando un teléfono inteligente como dispositivo de adquisición de datos planteada en este trabajo de investigación, se requiere una serie de tareas secuenciales e iterativas que procesan el conjunto de datos, la cual se conoce como el marco de trabajo [32, 33].

En la Figura 1 se ilustra la metodología de dicho marco. El marco de trabajo consiste en 2 fases las cuales son entrenamiento y prueba [19]. Para ambas fases el punto de inicio es la adquisición de datos de la marcha, posteriormente se realizan las etapas de acceso y preprocesamiento de datos, extracción y selección de características.

La quinta etapa de la primera fase consiste en el entrenamiento del modelo de clasificación, para lo cual, derivado de la poca cantidad de secuencias se emplea el 80 %

del conjunto de datos, mientras que el otro 20 % se usa en la fase de prueba. Cuando se tiene un conjunto de datos con muchas instancias usualmente se emplea el 70 % para entrenamiento, 20 % para prueba y 10 % de instancias no conocidas (nuevos ejemplos).

La plataforma de trabajo empleada para implementar este trabajo es el toolbox de aprendizaje automático y estadística de MATLAB®. A continuación cada etapa es descrita a detalle. El conjunto de datos asociados a la velocidad angular adquiridos, consiste en las señales de los 3 ejes del giroscopio modelo bmi160 de BOSCH® (embebido en un teléfono inteligente) con una precisión de 0.0001 rad/s y un intervalo máximo de 34.9 rad/s.

El sistema operativo del celular es android 10.0, memoria RAM de 4.00 GB y procesador de 8 núcleos a 2.32 GHz; el cual fue colocado en la parte lateral de la rodilla derecha de los sujetos de estudio como se muestra en la Figura 2, debido a que en este trabajo es la articulación de interés. Sin embargo, puede ser colocado de manera libre en otra parte del cuerpo. El eje anatómico anterior coincide con el eje  $x$ , el eje superior del cuerpo con el eje  $y$ , mientras que el eje derecho con el eje  $z$  del giroscopio, respectivamente.

Los datos brutos sin procesar, capturados con una frecuencia de muestreo de 406 Hz contienen ventanas variables entre 19 y 12 segundos en promedio de marchas antiálgica y no antiálgica, respectivamente. El experimento realizado fue el de la caminata de 10 metros [26], la cual es una medida de rendimiento utilizada para evaluar la velocidad de caminata en metros por segundo en una distancia corta y que se emplea para diagnosticar padecimientos como los citados en la introducción.


La prueba fue realizada con 30 varones entre 18 y 49 años [34], de las cuales se obtuvieron 18 secuencias de una marcha no antiálgica y 12 de una marcha antiálgica sintética, es decir la marcha antiálgica fue emulada para validar los componentes en un ambiente de laboratorio con base en las especificaciones de un especialista clínico (desarrollo tecnológico de acuerdo a la metodología TRL [24]).

Derivado a que no existe un patrón de marcha diferente para hombres o mujeres, solo cambia la magnitud de los parámetros evaluados, en este trabajo como primera etapa se usó solo una muestra masculina. El primer paso en cualquier proyecto de aprendizaje automático es el acceso y exploración de los datos mediante la inspección de algunos ejemplos creando visualizaciones [25].

La Figura 3 muestra las señales de los 3 ejes del giroscopio durante una secuencia de la prueba de caminata de 10 metros de una secuencia de marcha antiálgica y no antiálgica entre la ventana de los 3 y 6 segundos. Las tareas de preprocesamiento de datos, para resolver problemas de ruido, incompletez, inconsistencia y cantidad en las bases de datos son: limpieza, integración, reducción, y transformación [6].

En este trabajo no se consideran datos incompletos, sin embargo, si se aplica un filtro digital pasabajas con una frecuencia de corte de 0.5 Hz. En la etapa de integración, los datos de las señales del giroscopio del eje  $x$  ( $Gx$ ), eje  $y$  ( $Gy$ ) y eje  $z$  ( $Gz$ ) de las secuencias de marchas antiálgica y no antiálgica se incorporan en un solo conjunto de datos.

Posteriormente, se realizó una reducción de dimensionalidad de todas las señales originales mediante la extracción de los datos de la ventana entre (3 - 6) segundos y una frecuencia de muestreo de 100 Hz, resultando secuencias de 305 datos con la



**Fig. 3.** Visualización de las señales del giroscopio ( $G_x$ ,  $G_y$ , y  $G_z$ ) sin preprocesar para una secuencia de: a) Marcha antiálgebra y b) Marcha no antiálgebra.

**Tabla 1.** Valores promedio del conjunto de datos para cada uno de los atributos de las marchas antiálgebra  $\bar{A}$  y no antiálgebra  $\bar{N\bar{A}}$ .

$G_x(m)$	$G_y(m)$	$G_z(m)$	$G_x(s)$	$G_y(s)$	$G_z(s)$	$G_x(r)$	$G_y(r)$	$G_z(r)$	$G_x(p)$	$G_y(p)$	$G_z(p)$	Clase
0.032	-0.002	-0.009	0.280	0.724	0.670	0.283	0.728	0.672	0.517	-0.480	-0.948	$\bar{A}$
0.119	-0.040	0.038	0.700	1.058	1.280	0.715	1.062	1.285	-0.344	0.320	0.632	$\bar{N\bar{A}}$

misma representatividad que los originales. En la etapa de extracción de características los datos brutos se convierten en información útil para los algoritmos de clasificación, eliminando redundancia y facilitando la generalización [32].

Existe una gran variedad de características que se pueden extraer tanto en los dominios del tiempo como de la frecuencia. Por simplicidad, en este caso se calculó la media ( $m$ ), la desviación estándar ( $s$ ), el valor de la raíz cuadrática media (RMS) ( $r$ ) y los valores del análisis de componentes principales (PCA) ( $p$ ) de cada señal  $G_x$ ,  $G_y$  y  $G_z$ , respectivamente [33].

El conjunto de datos consiste de 30 instancias con 12 atributos y la clase (antiálgebra y no antiálgebra) cada una como se ejemplifica en la Tabla 1. Por el tamaño del conjunto de datos, en la tabla solo se presenta el valor promedio de cada uno de los atributos para cada clase, respectivamente.

Los valores obtenidos permiten determinar que ambos tipos de marcha se pueden diferenciar significativamente y a partir de esas métricas clasificarlas. Una vez que se

han extraído las características, se hace una selección de éstas para escoger la menor cantidad, para no tender al sobreajuste y mantener la esencia de los datos [25].

Mediante el método de fuerza bruta empleado sobre las tuplas  $\{Gx(m), Gx(s), Gx(r), Gx(p)\}$ ;  $\{Gy(m), Gy(s), Gy(r), Gy(p)\}$  y  $\{Gz(m), Gz(s), Gz(r), Gz(p)\}$ , se determinó que la media, desviación estandar y el valor RMS representan con mayor precisión el conjunto de datos de cada instancia con su respectiva clase. Para validar dicho proceso se implementó el algoritmo de agrupamiento particional basado en prototipos k-means [10], agrupando el 100 % de los ejemplos en su respectiva clase.

A través de la inclusión de las características de la marcha y las clases, de manera iterativa en la fase de entrenamiento, se generan los modelos de clasificación. Los algoritmos reportados en la literatura más empleados para este propósito y que son implementados en este trabajo son: i) máquinas de soporte vectorial (SVM), ii) análisis discriminante lineal (LDA), iii) árboles de decisión (DT), iv) K-vecinos más cercanos (kNN) y v) Naive-Bayes (NB) [29, 33].

De los 30 sujetos de estudio (instancias), de manera aleatoria y derivado de que son pocas instancias, el 80 % se utilizó para entrenamiento y el 20 % para prueba. Las métricas empleadas para evaluar el desempeño de cada algoritmo de clasificación para  $n$  experimentos son: la tasa de clasificación correcta (CCR), sensibilidad o recall (R), especificidad (SP) y precisión (P) [29]. En este trabajo, para ampliar el análisis de desempeño, además de las métricas anteriores se usan la tasa clasificación errónea (ECR), tasa clasificación (CR) y predominio (Pr) [31]. A continuación, se presentan las ecuaciones para calcular las métricas mencionadas.

– Tasa de clasificación correcta (CCR):

$$\overline{CCR} = \frac{1}{n} \sum_{i=1}^n \frac{VP_i + VN_i}{M_i}, \quad (1)$$

– Tasa clasificación errónea (ECR):

$$\overline{ECR} = \frac{1}{n} \sum_{i=1}^n \frac{FP_i + FN_i}{M_i}, \quad (2)$$

– Tasa clasificación (CR):

$$\overline{CR} = \frac{1}{n} \sum_{i=1}^n (VP_i + VN_i + FP_i + FN_i), \quad (3)$$

– Sensibilidad o Recall (R):

$$\overline{R} = \frac{1}{n} \sum_{i=1}^n \frac{VP_i}{VP_i + FN_i}, \quad (4)$$

– Especificidad (SP):

$$\overline{SP} = \frac{1}{n} \sum_{i=1}^n \frac{VN_i}{VN_i + FP_i}, \quad (5)$$



**Tabla 2.** Desempeño de los algoritmos empleados para la clasificación de marcha antiálgica y no antiálgica.

Métrica / Algoritmo	LDA %	kNN %	SVM %	NB %	DT %
CCR	98.33	99.17	100	94.17	87.50
ECR	1.67	00.83	0	5.83	12.50
CR	100	100	100	100	100
R	100	100	100	90	90.50
SP	97.75	98.75	100	96.50	90
P	95.83	98.33	100	94.17	82.50
Pr	35	40	48.33	39.17	33.33

– Precisión (P):

$$\bar{P} = \frac{1}{n} \sum_{i=1}^n \frac{VP_i}{VP_i + FP_i}, \quad (6)$$

– Predominio (Pr):

$$\overline{CR} = \frac{1}{n} \sum_{i=1}^n VP_i, \quad (7)$$

donde:

- Verdaderos positivos (VP): Instancias de marcha antiálgica clasificadas correctamente.
- Verdaderos negativos (VN): Instancias de marcha no antiálgica clasificados correctamente.
- Falsos positivos (FP): Instancias clasificadas como antiálgica y no lo son.
- Falsos negativos (FN): Instancias clasificados como no antiálgicos y si lo son.
- N: Número total de instancias del conjunto de prueba.
- M: Número total de instancias de prueba clasificadas.

### 3. Análisis y discusión de resultados

El rendimiento del marco de trabajo para clasificar entre marchas antiálgica y no antiálgica propuesto en este trabajo, fue evaluado mediante la ejecución de 20 experimentos por cada algoritmo sobre el conjunto de prueba aleatorio. En la Tabla 2 se resume el resultado que define el desempeño de los algoritmos de clasificación, a partir de la evaluación de las métricas (Ecuaciones: 1, 2, 3, 4, 5, 6 y 7). La tasa de clasificación (CR) en todos los casos fue igual a 100 %, lo que implica que todas las instancias fueron clasificadas por todos los algoritmos.

La tasa de clasificación correcta (CCR), se relaciona a la probabilidad de clasificar acertadamente el tipo de marcha dado un nuevo ejemplo, ya sea antiálgica o no antiálgica, en este caso SVM y DT, tienen las tasas más alta (100 %) y más baja (87.50 %), respectivamente. De igual manera que la CCR, tanto en la Tabla 2 como en la Figura 4a se presenta la tasa de clasificación errónea (ECR), la cual se refiere a la probabilidad de clasificar de manera incorrecta un nuevo ejemplo.

La Figura 4b y la Tabla 2 presentan los resultados de la sensibilidad (R) de los algoritmos implementados, la cual se relaciona a la probabilidad de clasificar correctamente una instancia de marcha antiálgica, siendo LDA, kNN y SVM los métodos con la tasa más alta (100 %) y NB la más baja (90 %). Mientras que la especificidad (SP) (Figura 4c), corresponde a la tasa de clasificación de sujetos con marcha no antiálgica.

En ambos casos, dichas métricas representan gran utilidad para la toma de decisiones en el diagnóstico y tratamiento de los padecimientos relacionados a la marcha antiálgica. En ese sentido, SVM presenta la mayor especificidad (100 %) y NB la menor, con un 90 %. La precisión (P) en este caso, implica la probabilidad de determinar a los sujetos con marcha antiálgica sobre todos los sujetos clasificados correctamente, siendo nuevamente SVM el algoritmo con mejor resultado (100 %) y DT el peor (82.5 %) como se presenta en la Tabla 2 y la Figura 4d.

La utilidad médica de la precisión se centra en la determinación de sujetos con marcha antiálgica. Finalmente, el predominio provee información de la tasa de detección de los sujetos con una marcha antiálgica con respecto a todas las instancias, teniendo un desempeño similar de  $\approx 55\%$  en todos los casos. Como puede observarse en la Tabla 2 y la Figura 4 el algoritmo de clasificación con mejor desempeño para el problema de clasificación de las marchas antiálgica y no antiálgica tratado en este trabajo es SVM.

#### 4. Conclusiones


Ante la posibilidad de emplear a los sensores embebidos de un teléfono inteligente (giroscopio y acelerómetro), es factible la integración de plataformas de instrumentación biomédica de bajo costo, particularmente para la medición de la actividad humana. El ciclo de marcha bípeda, a pesar de que representa una conducta espacial y no temporal (porcentaje en fase de apoyo y oscilación por zancada), puede ser evaluado no sólo a través de la cadencia o cantidad de zancadas por unidad de tiempo, también a partir del nivel de actividad (asociado a la energía total y rendimiento).

Es aquí en el que la señal del giroscopio tiene sentido en la aplicación (diagnóstico de la marcha antiálgica y exclusión de la no antiálgica). Debido a las características y factor de forma de las señales emitidas por el giroscopio, fue indispensable realizar una poda de datos muestreados (preparación o preprocesamiento basado en técnicas de sampling y reducción) que resultan no ser indispensables, sin pérdida de la integridad de los datos brutos significativos.

A partir del volumen de datos resultante; se realizó la extracción de características basado en RMS, media aritmética, desviación estándar y análisis de componentes principales (PCA), siendo excluida ésta última en la etapa de selección desarrollada a partir del algoritmo de agrupamiento (K-Means).

La evaluación de 5 algoritmos de clasificación (LDA, kNN, SVM, NB y DT), enfocados al estudio y clasificación del tipo de marcha (antiálgica o no antiálgica), resultó satisfactoria con la validación de 20 experimentos, para los cuales, derivado del bajo número de instancias, se ocupó el 80 % en la etapa de entrenamiento y definición del modelo, y el 20 % restante para la etapa de prueba.

Para ello, fue propuesta una generalización de las métricas basado en la media aritmética de la evaluación sobre los sujetos de prueba ( $\overline{CCR}$ ,  $\overline{ECR}$ ,  $\overline{CR}$ ,  $\overline{R}$ ,  $\overline{SP}$ ,  $\overline{P}$



**Fig. 4.** Métricas (CCR, ECR, R, SP, P) de los algoritmos de clasificación implementados.

y  $\overline{Pr}$ ), que dependen de manera explícita de los elementos de la matriz de confusión generada por cada algoritmo de clasificación. Como se mencionó anteriormente, la tabla de resultados y las gráficas de desempeño a partir del estadístico de las métricas de evaluación, fue evidente que el algoritmo SVM (Máquinas de Soporte Vectorial) resulta idóneo en la clasificación de marcha antiálgica y no antiálgica.

Derivado del desempeño obtenido en la clasificación es posible extender el marco de trabajo para el diagnóstico de otras enfermedades reflejadas en la marcha o para otro tipo de padecimientos, que derive en el diagnóstico objetivo y soporte de toma de decisiones en tratamiento de la enfermedades de estudio. Además, es posible mejorar el desempeño del marco de trabajo en la etapa de clasificación incrementando el número de instancias tanto en la etapa de entrenamiento como en la etapa de prueba, así como la integración de más datos clínicos y biomédicos que robustezcan el diagnóstico.

## Referencias

1. Alaqdash, M., Sarkodie-Gyan, T., Yu, H., Fuentes, O., Brower, R., Abdelgawad, A.: Automatic classification of pathological gait patterns using ground reaction forces and machine learning algorithms. In: Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pp. 453–457 (2011)

2. Anguita, D., Ghio, A., Oneto, L., Parra, X., Reyes-Ortiz, J. L.: Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine. In: Proceedings of the International workshop on ambient assisted living, Springer, pp. 216–223 (2012)
3. Auerbach, N., Tadi, P.: Antalgic gait in adults. StatPearls, (2020)
4. Brahim, A., Jennane, R., Riad, R., Janvier, T., Khedher, L., Toumi, H., Lespessailles, E.: A decision support tool for early detection of knee osteoarthritis using x-ray imaging and machine learning: Data from the osteoarthritis initiative. *Computerized Medical Imaging and Graphics*, vol. 73, pp. 11–18 (2019), doi: 10.1016/j.compmedimag.2019.01.007
5. Brenton-Rule, A., Mattock, J., Carroll, M., Dalbeth, N., Bassett, S., Menz, H. B., Rome, K.: Reliability of the tekscan matscan® system for the measurement of postural stability in older people with rheumatoid arthritis. *Journal of Foot and Ankle Research*, vol. 5, no. 1, pp. 21 (2012), doi: 10.1186/1757-1146-5-21
6. Ceri, S., Fraternali, P., Bongio, A., Brambilla, M., Comai, S., Matera, M.: Series in data management systems: Designing data-intensive Web applications. Morgan Kaufmann (2003), doi: 10.1016/B978-155860843-6/50000-1
7. Connor, P., Ross, A.: Biometric recognition by gait: A survey of modalities and features. *Computer Vision and Image Understanding*, vol. 167, pp. 1–27 (2018), doi: 10.1016/j.cviu.2018.01.007
8. Cui, C., Bian, G. B., Hou, Z. G., Zhao, J., Su, G., Zhou, H., Peng, L., Wang, W.: Simultaneous recognition and assessment of post-stroke hemiparetic gait by fusing kinematic, kinetic, and electrophysiological data. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 4, pp. 856–864 (2018), doi: 10.1109/tnsre.2018.2811415
9. Derawi, M., Bours, P.: Gait and activity recognition using commercial phones. *Computers and Security*, vol. 39, pp. 137–144 (2013), doi: 10.1016/j.cose.2013.07.004
10. Frigui, H.: Clustering: Algorithms and applications. In: Proceedings of the First Workshops on Image Processing Theory, Tools and Applications, IEEE, pp. 1–11 (2008), doi: 10.1109/ipta.2008.4743793
11. Gafurov, D., Helkala, K., Søndrol, T.: Gait recognition using acceleration from mems. In: Proceeding of the First International Conference on Availability, Reliability and Security, IEEE (2006)
12. Gafurov, D., Snekenes, E., Bours, P.: Gait authentication and identification using wearable accelerometer sensor. In: IEEE workshop on automatic identification advanced technologies, pp. 220–225 (2007), doi: 10.1109/autoid.2007.380623
13. Hoang, T., Nguyen, T., Luong, C., Do, S., Choi, D.: Adaptive cross-device gait recognition using a mobile accelerometer. *Journal of Information Processing Systems*, vol. 9, no. 2, pp. 333–348 (2013), doi: 10.3745/JIPS.2013.9.2.333
14. Ihlen, E. A. F., Støen, R., Boswell, L., de Regnier, R.-A., Fjørtoft, T., Gaebler-Spira, D., Labori, C., Loennecken, M. C., Msall, M. E., Möinichen, U. I., Peyton, C., Schreiber, M. D., Silberg, I. E., Songstad, N. T., Vågen, R. T., Øberg, G. K., Adde, L.: Machine learning of infant spontaneous movements for the early prediction of cerebral palsy: A multi-site cohort study. *Journal of Clinical Medicine*, vol. 9, no. 1, pp. 5 (2019), doi: 10.3390/jcm9010005
15. Jun, K., Lee, Y., Lee, S., Lee, D.-W., Kim, M. S.: Pathological gait classification using kinect v2 and gated recurrent neural networks. vol. 8, pp. 139881–139891 (2020), doi: 10.1109/access.2020.3013029
16. Khera, P., Kumar, N.: Role of machine learning in gait analysis: A review. *Journal of Medical Engineering and Technology*, vol. 44, no. 8, pp. 441–467 (2020), doi: 10.1080/03091902.2020.1822940
17. Kitade, I., Nakajima, H., Takahashi, A., Matsumura, M., Shimada, S., Kokubo, Y., Matsu-mine, A.: Kinematic, kinetic, and musculoskeletal modeling analysis of gait in patients with cervical myelopathy using a severity classification. *The Spine Journal*, vol. 20, no. 7, pp. 1096–1105 (2020), doi: 10.1016/j.spinee.2020.01.014

18. Kobayashi, T., Hasida, K., Otsu, N.: Rotation invariant feature extraction from 3-d acceleration signals. In: Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 3684–3687 (2011), doi: 10.1109/icassp.2011.5947150
19. Kokkotis, C., Moustakidis, S., Papageorgiou, E., Giakas, G., Tsaopoulos, D.: Machine learning in knee osteoarthritis: A review. *Osteoarthritis and Cartilage Open*, vol. 2, no. 3 (2020)
20. Kozlow, P., Abid, N., Yanushkevich, S.: Gait type analysis using dynamic bayesian networks. *Sensors*, vol. 18, no. 10 (2018), doi: 10.3390/s18103329
21. Leightley, D., McPhee, J. S., Yap, M. H.: Automated analysis and quantification of human mobility using a depth sensor. *IEEE Journal of Biomedical and Health Informatics*, vol. 21, no. 4, pp. 939–948 (2016)
22. Nair, S. S., French, R. M., Laroche, D., Thomas, E.: The application of machine learning algorithms to the analysis of electromyographic patterns from arthritic patients. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 18, no. 2, pp. 174–184 (2009), doi: 10.1109/tnsre.2009.2032638
23. Ngo, T. T., Makihara, Y., Nagahara, H., Mukaigawa, Y., Yagi, Y.: The largest inertial sensor-based gait database and performance evaluation of gait-based personal authentication. *Pattern Recognition*, vol. 47, no. 1, pp. 228–237 (2014), doi: 10.1016/j.patcog.2013.06.028
24. Olechowski, A. L., Eppinger, S. D., Joglekar, N., Tomaschek, K.: Technology readiness levels: Shortcomings and improvement opportunities. *Systems Engineering*, vol. 23, no. 4, pp. 395–408 (2020), doi: 10.1002/sys.21533
25. Paluszczek, M., Thomas, S.: MATLAB machine learning. Apress (2016)
26. Physiopedia: 10 metre walk test (2022)
27. Rong, L., Jianzhong, Z., Ming, L., Xiangfeng, H.: A wearable acceleration sensor system for gait recognition. In: Proceedings of the 2nd IEEE Conference on Industrial Electronics and Applications, pp. 2654–2659 (2007), doi: 10.1109/iciea.2007.4318894
28. Sharif Bidabadi, S., Tan, T., Murray, I., Lee, G.: Tracking foot drop recovery following lumbar-spine surgery, applying multiclass gait classification using machine learning techniques. *Sensors*, vol. 19, no. 11, pp. 2542 (2019), doi: 10.3390/s19112542
29. Singh, J. P., Jain, S., Arora, S., Singh, U. P.: Vision-based gait recognition: A survey. *Institute of Electrical and Electronics Engineers Access*, vol. 6, pp. 70497–70527 (2018)
30. Sithi Shameem, F., Wahida, B.: Abnormal walk identification for systems using gait patterns. pp. 112–117 (2016)
31. The MathWorks, Inc: Classperformance properties (2021)
32. The MathWorks, Inc: Heart sound classifier (2021)
33. Wan, C., Wang, L., Phoha, V. V.: A survey on gait recognition. *Association for Computing Machinery Computing Surveys*, vol. 51, no. 5, pp. 1–35 (2019), doi: 10.1145/3230633
34. Whittle, M. W.: Gait analysis: An introduction. Butterworth-Heinemann (2014)
35. Yoo, T. K., Kim, S. K., Choi, S. B., Kim, D. Y., Kim, D. W.: Interpretation of movement during stair ascent for predicting severity and prognosis of knee osteoarthritis in elderly women using support vector machine. In: Proceedings of the 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 192–196 (2013), doi: 10.1109/embc.2013.6609470
36. Zheng, S., Huang, K., Tan, T.: Evaluation framework on translation-invariant representation for cumulative foot pressure image. In: Proceedings of the 18th IEEE International Conference on Image Processing, pp. 201–204 (2011), doi: 10.1109/icip.2011.6115874