

# Caracterización y Clasificación Automática de Señales Electromiográficas Registradas durante la Marcha en Sujetos con Lesión en Miembro Inferior

C. D. Sandoval-Puentes<sup>1</sup>, S. González-Huerta<sup>1</sup>, L. R. Becerra-Cervantes<sup>1</sup>,  
R. A. Salido-Ruiz<sup>\*2</sup>

<sup>1</sup> Universidad de Guadalajara, Centro Universitario de Ciencias Exactas e Ingeniería (CUCEI), Jalisco, México.

<sup>2</sup> Universidad de Guadalajara, CUCEI, Departamento de Ciencias Computacionales, Jalisco, México.  
*\*ricardo.salido@academicos.udg.mx*

## Resumen

Gracias al uso de redes neuronales artificiales se ha optimizado la clasificación de datos para la predicción de eventos. En este trabajo, se presenta un clasificador automático entrenado para ser capaz de diferenciar señales electromiográficas registradas a pacientes con lesiones en el miembro inferior y sujetos sanos. Los datos fueron obtenidos de una base de datos de acceso libre en Internet que cuenta con un conjunto de 22 registros electromiográficos del músculo recto femoral de pacientes tomados durante el ciclo de la marcha y etiquetados en dos grupos, uno de control y uno patológico con una anomalía en la rodilla. Las señales fueron acondicionadas, procesadas y posteriormente los fueron extraídos conjuntos de características tanto en el dominio del tiempo como en el de la frecuencia. Estas fueron evaluadas estadísticamente para seleccionar las óptimas en el proceso de clasificación. Las características obtenidas se organizaron en 10 diferentes configuraciones, las cuales alimentaron 8 modelos de clasificadores basados en análisis discriminante, k-medias y árboles de decisión. Los errores obtenidos con cada uno de ellos fueron registrados y promediados. Los tres clasificadores con menor error promedio fueron seleccionados para construir un clasificador final. La precisión en fase de entrenamiento fue de alrededor de 95% en los mejores métodos, cambiando a 80% en fase de validación cuando se usa un modelo de árbol simple con ANOVA, o un modelo de 100-árboles con *Filters* y *Wrappers*; y una precisión de 100% con un modelo de discriminante cuadrático y ANOVA para seleccionar características.

**Palabras clave:** ANOVA, Árbol de decisión, Características, Clasificador, Electromiografía.

## 1. Introducción

La rodilla es anatómicamente una articulación bicondílea; y desde un punto de vista mecánico, una tróclea [1]; se encuentra formada por los cóndilos femorales, los patillos tibiales y la rótula. Las lesiones en esta articulación pueden presentarse al realizar diferentes actividades, desde actividades cotidianas hasta actividades atléticas; las más comunes son fracturas, dislocaciones, esguinces, desgarres y luxaciones. Un reporte de la Revista Médica del Instituto Mexicano del Seguro Social menciona que el 14% de 131 deportistas estudiados sufrió lesiones de gravedad variable en las rodillas. Cuando se trata de personas adultas el riesgo de lesión aumenta, esto debido al envejecimiento natural del cuerpo y el sobreuso de estas [2]. El diagnóstico de una lesión en esta estructura se realiza principalmente mediante la toma de radiografías cuando esta se asocia a lesiones óseas, por otro lado, si la lesión se asocia a tejidos blandos y lesiones óseas ocultas, el diagnóstico se realiza mediante resonancia magnética nuclear (RMN) [3]. Técnicas de *machine learning* han sido utilizadas para

determinar la evolución de pacientes con lesión de rodilla [4]. Como ejemplo podemos referir [5], quienes clasificaron sujetos con osteoartritis de rodilla de acuerdo con su género analizando la cinemática durante la marcha mediante un enfoque de *machine learning* utilizando Análisis de Componentes Principales (PCA) y Máquinas de Vectores de Soporte (SVM), con precisiones entre 98-100% a partir de 112 características. De forma similar, en [6] reportaron un estudio en el que extraen características de señales de electromiografía (EMG), las cuales ingresan a modelos de árboles de decisión (precisión de 88%) y *Naive Bayes* (precisión de 54%) para ser clasificadas en 2 grupos: control y Parkinson. En [7] se reportó un sistema basado en redes neuronales artificiales para identificar patrones en la marcha usando señales neuromusculares y análisis de la deformación del tejido suave en músculos de los miembros inferiores, con precisión de 98%.

Este trabajo, como un proyecto de investigación, pretende establecer que la alteración en la biomecánica de la rodilla ante una lesión puede ser identificada en registros de EMG, después de haber sido acondicionados, caracterizados, y clasificados a partir de diversas técnicas. De encontrarse suficientemente fundamentada esta relación, se proyectaría a futuro realizar un estudio con un grupo experimental más amplio y mayor nivel de especificidad en la clasificación de las lesiones. El sistema, pensado como apoyo al diagnóstico, podría funcionar ya sea como un filtro orientado a reservar los estudios de mayor nivel para los sujetos con indicación de lesión o como un estudio indicado para aquellos casos en los que las técnicas de diagnóstico tradicional pudieran no ser adecuadas o accesibles.

## 2. Metodología

Se descargó una base de datos de libre acceso [8] con registros electromiográficos la cual consiste en un conjunto de 5 registros para cada uno de los 22 sujetos en el estudio: 11 sujetos con diferentes anormalidades en la rodilla previamente diagnosticadas por un profesional y 11 sujetos catalogados como normales. Se utilizó el equipo *datalog* MWX8 de *Biometrics*, con una frecuencia de muestreo de 1000 Hz y resolución de 14 bits. Se utilizaron 5 canales para registrar la actividad eléctrica de los músculos vasto medial, semitendinoso, bíceps y recto femoral, y el desplazamiento angular en la rodilla mediante un goniómetro durante la marcha, al flexionar la pierna sentado y en pie; cada serie contiene 5 acciones o repeticiones del movimiento para cada sujeto [8]. Para este estudio se seleccionaron los registros del músculo recto femoral durante el ciclo de la marcha. La amplitud de las señales se encuentra en milivolts y no han sido procesadas con ningún filtro. El procesamiento de las señales que se presentará a continuación se realizó en el entorno de MATLAB R2020a.

### 2.1 Acondicionamiento

Se eliminaron los valores atípicos de la señal (*outliers*) en los percentiles menores a 0.7% y mayores a 99.3%, eliminando componentes de ruido en el dominio temporal, visualizados como picos de amplitud anormalmente mayor que modifican la escala de la señal desviando los valores de las características. Se realizó un proceso de filtrado digital en dos etapas, en la primera se utilizó un filtro paso bandas entre 1-400 Hz de tipo respuesta de impulso infinito (IIR) de orden 16 con una atenuación de 60 dB en la banda de rechazo, y en la segunda etapa un filtro *Notch* a 60 Hz de tipo IIR de orden 16, implementado para eliminar el posible componente de ruido por la interferencia del sistema de red eléctrica en el proceso de adquisición. Finalmente, se realizó una rectificación digital de la señal EMG mediante el cálculo del valor absoluto, como se hizo en [9], para posteriormente obtener la envolvente.

### 2.2 Extracción de Características

La señal acondicionada pasó a la etapa de caracterización, donde se extrajeron 20 características: 13 para el dominio temporal y 7 en el dominio de la frecuencia. Las características en el dominio del tiempo

se obtuvieron a partir de la señal rectificada y de la envolvente resultante de aplicar seguidamente dos filtros de media móvil [10] a 50 puntos, considerando como contracción cuando se supera el umbral de una media más una desviación estándar; y las características frecuenciales a partir de la densidad espectral de potencia (PSD) por el método de Lomb, ya que algunos estudios sugieren mayor precisión en altas frecuencias cuando se utiliza éste método [11].

Las características extraídas fueron: media (1), mediana (2), máximo (3), desviación estándar (STD) (4), varianza (5), valor RMS (6), curtosis (7), medida de la asimetría (8), número de *outliers* (9), integral (10), longitud de contracción (11), longitud de forma de onda (12) [12] y la entropía (13) [13] para el dominio del tiempo; y la mediana de frecuencias (14), media de frecuencias (15), la potencia media (16), potencia total (17), frecuencia máxima (18), STD del espectro (19) y relación señal ruido (20) a partir de PSD para el dominio de la frecuencia. La indexación de las características que aparece entre paréntesis es utilizada para referenciar en las tablas 1, 2, 4 y 5. En las Tablas 1 y 2 se describen las características que repetidamente se identificaron como buenas predictoras en la sección de resultados.

Tabla 1: Características más significativas en el dominio temporal

Característica	Origen	Explicación
9	Señal rectificada	Cantidad de valores de amplitud que se consideran como valores atípicos en señal EMG. Función <i>isoutlier</i> de Matlab con “ <i>median</i> ” como método.
10	Envolvente	Área bajo la curva de la envolvente. Función <i>sum</i> de Matlab.
11	Envolvente	Cantidad de puntos que sobrepasan el umbral de la media más STD. Funciones <i>movmean</i> , con 50 puntos, y <i>sum</i> de Matlab.
12	Envolvente	Longitud de onda acumulada a lo largo del segmento; medida de la amplitud, frecuencia y duración de la señal. [12]

Tabla 2: Características más significativas en el dominio de la frecuencia

Característica	Origen	Explicación
15	Espectro de Lomb	Centro de la distribución de potencia en las frecuencias. Función <i>meanfreq</i> con PSD y vector de frecuencias como entrada.
18	Espectro de Lomb	Pico máximo del espectro de frecuencias. Función <i>max</i> con PSD.

### 2.3 Selección de Características

El funcionamiento final del clasificador depende en gran medida de la calidad de los datos que llegan a él, por lo tanto, el análisis exploratorio de los datos es una parte fundamental en el proceso de investigación. Se utilizaron diferentes técnicas de evaluación de la calidad de las características como predictoras; tanto métodos estadísticos tradicionales como técnicas orientadas al aprendizaje automático (ver Tabla 3).

Para PDF y C no se mostraron indicios de una clara separación de clases para ninguna característica, por lo que al final no se emplearon.

### 2.4 Entrenamiento de Clasificadores

La matriz de características fue estandarizada; se transformó mediante PCA y FLDA. En Figura 1 a) aparece el diagrama de Pareto mostrando que los primeros 7 componentes son suficientes para explicar el 95% de la varianza, logrando una reducción dimensional de 20 a 7. En la Figura 1 b) se visualiza la proyección de clases en una representación 3D a partir de los primeros 3 componentes de PCA, mientras que en la Figura 1 c) se muestra el equivalente para FLDA. Para este caso la transformación PCA parece dividir mejor las 2 clases de estudio (normal y patológico).

El set de características se particionó con un método *Hold Out* en una proporción 75-25%. El 75% de los datos se utilizó para entrenar los modelos de clasificadores y el 25% para validar dichos modelos,

representando los registros de sujetos nuevos y desconocidos para el sistema de clasificación. Se seleccionaron empíricamente 3 topologías diferentes (discriminante, K-Means, y árbol de decisión), ya que son las topologías estudiadas que mejor representan los diferentes métodos para trazar las fronteras de decisión en un plano n-dimensional, fácilmente representables en modelos 2D y 3D. Los modelos de discriminante trazan líneas simples con curvatura de acuerdo con su principio matemático (lineal o cuadrático, por ejemplo), K-Means segmenta núcleos de puntos clasificados en una misma etiqueta y dibuja la frontera de decisión alrededor de dichos núcleos (considerando K como el número de puntos vecinos a considerar); mientras que los árboles de decisión van estableciendo las fronteras en función de un umbral para cada característica. A partir de estas 3 topologías se implementaron 8 modelos diferentes de clasificadores; cada uno de los cuales se entrenó con una de las 10 indexaciones de características (ver Tabla 5). Las configuraciones de características fueron: todas las características, *filters*, *wrappers*, intersección (F/W), ANOVA, unión (F/W + ANOVA), PCA, PCA al 95% (7 componentes), FLDA y FLDA con 7 componentes.

Tabla 3: Criterios para la selección de características

Técnica	Descripción	Objetivo
Función de Densidad de Probabilidad (PDF)	Permite generar una PDF (a 100 puntos) de cada característica para cada clase. Función <i>ksdensity</i> de Matlab.	Identificar si existe separación entre clases.
Correlación (C)	Permite conocer la correlación entre pares de características para cada clase. Función <i>corr</i> de Matlab.	Identificar similitudes y diferencias entre características de una misma clase y de clases diferentes respectivamente.
Análisis de Varianzas (ANOVA)	Análisis de Varianzas. Función <i>anova1</i> de Matlab.	Identificar diferencia estadísticamente significativa de las medias entre las clases de estudio, con $p < 0.05$ .
<i>Wrappers</i> (W) [14] [15]	Métodos <i>forward</i> y <i>backward</i> mediante <i>sequentialfs</i> de Matlab.	Identificar características buenas predictoras mediante etiquetas binarias.
<i>Filters</i> (F) [14]	Métodos <i>Fscore</i> y <i>Relieff</i> de Matlab	Ordenar las características en función de su eficacia para separar las clases.
Combinaciones	Intersección y unión entre W y F.	Combinar métodos de <i>machine learning</i> para robustecer el sistema.
Análisis de Componentes Principales (PCA)	Transformación de los datos redistribuyendo la varianza. Función <i>pca</i> de Matlab.	Formar nuevos vectores de características, reducción dimensional considerando 95% de la varianza.
Análisis Discriminante Lineal de Fisher (FLDA) [16] [17]	Transformación de los datos redistribuyendo la varianza. Función <i>flda</i> externa (referenciada)	Hacer una proyección de la distribución de clases al formar nuevos vectores de características.
Estandarización (E)	Transformar los datos para obtener una media de 0 y STD de 1 para cada característica. Función <i>zscore</i> de Matlab.	Hacer más robusto el sistema al llevar los datos a condiciones similares antes de su clasificación.

Cada una de las 80 combinaciones se probó mediante validación cruzada (K-Fold) con 5 particiones, repitiendo el proceso 50 veces; y *leave one out* repitiendo tantas veces como número de observaciones.

Se registraron los errores para cada experimento y al terminar se promediaron los errores correspondientes a cada uno de los modelos de clasificación. Se seleccionaron las 3 configuraciones de menor error promedio; estos tres clasificadores seleccionados fueron entrenados nuevamente utilizando todas las observaciones que conforman el set de entrenamiento, es decir, excluyendo el set de validación. El proceso general simplificado para el entrenamiento del clasificador se ilustra en la Figura 2. Adicionalmente, se guardaron las matrices de transformación de PCA y FLDA, las condiciones de estandarización del set de entrenamiento y la indexación de las características que se habían seleccionado para cada método y que se usaron en los mejores 3 clasificadores.

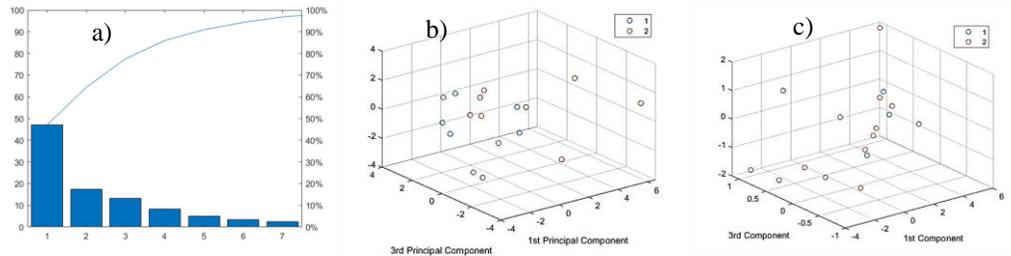


Fig. 1. a) Diagrama de Pareto con los componentes que explican el 95% de la varianza para PCA, b) Proyección de clases PCA y c) Proyección de clases FLDA.

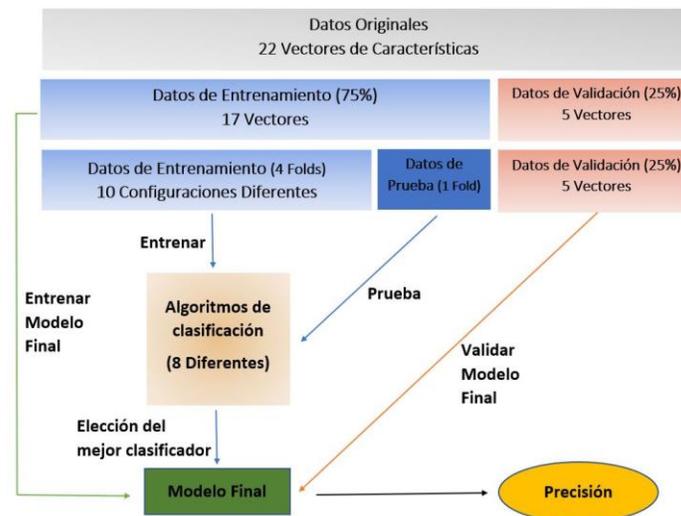


Fig. 2. Diagrama de flujo con el proceso de entrenamiento de las topologías de clasificadores.

### 3. Resultados y Discusión

En la Tabla 4 se sintetizan los resultados de aplicar el análisis de varianzas en cada característica, obteniendo que los predictores con una diferencia estadísticamente significativa entre clases son el número de *outliers*, el área bajo la curva de la señal (integral), la longitud de contracciones, la longitud de forma de onda, la media de frecuencias y el pico máximo de potencia en el espectro de Lomb; los cuales tienen un valor de  $p < 0.05$ , lo que significa un 95% de confiabilidad. La Tabla 5 muestra el resumen de las características que fueron seleccionadas como buenas predictoras por cada uno de los métodos probados, tanto estadísticos como por *machine learning*. La indexación en las tablas 4 y 5 corresponden a la numeración de las características de acuerdo con el orden de la sección 2.2. Para este

análisis, los datos generados al obtener la PDF y las matrices de correlación resultaron no ser determinantes para la separación de clases, por lo que no se reportan en este estudio.

Tabla 4: Resumen de ANOVA para características

Indexación	1	2	3	4	5	6	7	8	9	10
p-value	0.205	0.143	0.238	0.282	0.326	0.249	0.758	0.759	<b>0.004</b>	<b>0.049</b>
Indexación	11	12	13	14	15	16	17	18	19	20
p-value	<b>0.003</b>	<b>0.045</b>	0.691	0.058	<b>0.011</b>	0.605	0.605	<b>0.015</b>	0.758	0.311

Tabla 5: Resumen de indexación de características seleccionadas como predictoras

	Número de característica seleccionada										
Filters	11	9	18	2	10	3	12	1	15	8	5
Wrappers	5	6	7	8	9	11	12	15	18	19	20
Filters-Wrappers	5	8	9	11	12	15	18				
ANOVA	9	10	11	12	15	18					
Unión	5	8	9	10	11	12	15	18			

Los errores promedio para cada configuración en fase de entrenamiento se resumen en la Tabla 6, resaltando el 10% de errores bajos. Los errores más bajos fueron de alrededor de 5%, siendo el de mejor desempeño el clasificador de discriminante cuadrático utilizando como predictores las características seleccionadas con ANOVA, con un error de 4.1%. Notablemente, la topología de árbol de decisión simple fue la de mejor resultado. Los métodos derivados de la transformación de datos por FLDA y PCA obtuvieron errores claramente superiores, mejorando cuando se reduce la dimensionalidad. Los 3 clasificadores seleccionados: discriminante cuadrático con ANOVA (DCA), árbol de decisión simple con ANOVA (ASA), y N-árboles de decisión con N=100 y *Filters/Wrappers* (NAFW), fueron sometidos a fase de validación con 5 nuevos experimentos. NAFW y ASA obtuvieron 4 aciertos y 1 falso positivo para patológico (precisión de 80%); mientras que DCA obtuvo los 5 aciertos (precisión de 100%) (ver Tabla 7). Como alternativa para mejorar el funcionamiento práctico, se implementó una etiqueta simulada de sospechoso para aquellos registros en los que hubiera discrepancias entre los 3 clasificadores seleccionados; de esta forma de los 3 registros normales y 2 patológicos que entran al sistema resultan 2 etiquetas de normal (correctas), 2 de patológico (correctas) y 1 de sospechoso.

**Función de clasificador final:** A partir de los vectores de características como parámetro de entrada, se llevan los datos a las mismas condiciones en las que fueron entrenados los clasificadores, utilizando las matrices de transformación PCA, FLDA, estandarización e indexación de características. Se hace una predicción diferenciando 3 clases: normal, patológico y sospechoso.

Tabla 6: Errores promedio en fase de entrenamiento

	Registros EMG (17 experimentos)							
	Discriminante		K-Means		N-Árbol de decisión			
	Lineal	Cuadrático	K=5	K=sqrt*	N=1	N=Feat**	N=20	N=100
Todas	69.5%	88.5%	79.6%	79.6%	<b>95.9%</b>	81.7%	87.8%	88.4%
Filters	78.4%	87.5%	60%	77.4%	<b>94.1%</b>	89.8%	87.4%	88.6%
Wrappers	68.4%	87.3%	59.1%	71.5%	<b>93.3%</b>	87.7%	89.8%	88.4%
Intersección	81.7%	91.8%	65.6%	84.1%	92.7%	87.6%	93.1%	<b>93.3%</b>
ANOVA	85.4%	<b>95.9%</b>	78.6%	63%	<b>95.9%</b>	83.9%	<b>93.8%</b>	<b>95.4%</b>
Unión	76.4%	87.3%	72.1%	76.8%	86.8%	84.8%	85.8%	86.6%
PCA	36.1%	33.7%	67.3%	68.8%	57.4%	56.3%	46.6%	66.1%
PCA 95%	58.1%	44.5%	54.9%	66%	70.3%	64.6%	66.9%	69.8%
FLDA	16.1%	42.1%	72.2%	72.2%	69.7%	45.9%	34.4%	40.6%
FLDA 95%	61.9%	50.5%	55.6%	66.1%	71.8%	52.4%	56.8%	52.3%

\* Raíz cuadrada de la longitud del set de entrenamiento.

\*\* Número de características consideradas para entrenar el modelo.

Tabla 7: Errores de modelos seleccionados para la función de clasificación

Modelo	Entrenamiento (17 experimentos)	Validación (5 experimentos)
Discriminante cuadrático ANOVA (DCA)	95.88%	100%
Árbol simple ANOVA (ASA)	95.87%	80%
N-Árboles, N=100 Filters/Wrappers (NAFW)	93.24%	80%

Aunque una precisión de 80% puede parecer baja, se debe tomar en cuenta que solo equivale a un evento clasificado erróneamente, y así mismo corresponde siempre al mismo evento, lo que nos podría indicar que en efecto existe una anomalía en dicho registro; aunque no profundizamos en dicho análisis.

## 4. Conclusiones

Los árboles de decisión resultaron tener el mejor comportamiento, sugiriendo que son capaces de generalizar adecuadamente las fronteras de decisión sin sobre ajustar el modelo de clasificador. Los métodos basados en la redistribución de la varianza PCA o FLDA, resultaron tener un desempeño muy inferior a lo esperado (precisiones menores al 50 %) en la mayoría de los casos. La robustez del sistema se logró utilizando ANOVA y *Wrappers*, ya que contribuyeron a mantener un constante error bajo. Se ratificó la utilidad de pruebas estadísticas tradicionales que, en combinación con métodos actuales de *machine learning*, pueden llevarnos a obtener mejores resultados en la separación de clases. En el estudio obtuvimos precisiones alrededor del 90% en la separación de clases, que es una eficiencia correcta en este tipo de aplicaciones de acuerdo con [5], [6] y [7] donde obtuvieron porcentajes de acierto de 98%, 88% y 98% respectivamente.

Finalmente, integramos conceptos desarrollados en estudios previos de lesiones con influencia en el miembro inferior, y mostramos que nuestra metodología sustenta correctamente nuestra hipótesis de que una alteración en la biomecánica de la rodilla puede ser detectable a través de EMG utilizando un clasificador automático, con precisiones similares a los estudios de referencia; aportando bases que soportan la posibilidad de en un futuro integrar *machine learning* en la práctica médica.

Como proyección a futuro nos gustaría considerar la posibilidad de repetir la metodología, esta vez realizando la adquisición de señales como parte del proyecto para controlar plenamente el proceso experimental, y con un mayor número de sujetos de estudio; pues consideramos esa nuestra principal limitante al hacer este trabajo ya que, por convicción, cuantos más datos se tienen disponibles y de mejor calidad, mejores resultados se obtienen en este tipo de investigaciones.

## Declaración de conflictos de interés

Los autores declaran no tener ningún conflicto de interés para este trabajo.

## Agradecimientos

División de Electrónica y Computación, en el Centro Universitario de Ciencias Exactas e Ingenierías de la Universidad de Guadalajara.

## Referencias

- [1] J. Vergara Hernández, M. D. (2004). Protocolo de valoración de la patología de la rodilla. *SEMERGEN - Medicina de Familia*, 226-244.W.-K. Chen, "Linear Networks and Systems: Fourier analysis and state equations," 1990.
- [2] López, U. E., Martínez, S. V., Osorio, A. G., Carmona, A. A., & Borja, V. (2013). Desarrollo de un equipo auxiliar para rehabilitación de pacientes con lesiones en las rodillas de bajo costo. *Memorias del XIX internacional anual de la SOMIM*. Pachuca, Hidalgo.
- [3] Nafarrete, E. B., & Gracia, M. P. (2009). Lesiones multiligamentarias de rodilla. *Ortho-tips*, 49-58.
- [4] Quispe Laura, R. D. (2017). Sistema Inteligente para Determinar la Evolución de Pacientes con Lesiones de Rodilla Basado en Machine Learning y Kinect (Doctoral dissertation)
- [5] Phinyomark, A., Osis, S., Hettinga, B., Kobsar, D., & Ferber, R. (2016). Gender differences in gait kinematics for patients with knee osteoarthritis. *BMC Musculoskeletal Disorders*.
- [6] Subba, R., & Bhoi, A. (2020). Feature Extraction and Classification Between Control and Parkinson's Using EMG Signal. *Cognitive Informatics and Soft Computing*, 45-52.
- [7] Senanayake, S. M., Malik, O. A., & Triioka, J. (2014). Artificial Neural Network Based Gait Patterns Identification Using Neuromuscular Signals and Soft Tissue Deformation Analysis of Lower Limbs Muscles. *International Joint Conference on Neural Networks (IJCNN)*, 3503-3510.
- [8] Dua, D., & Graff, C. (2014). EMG dataset in Lower Limb Data Set. Obtenido de Machine Learning Repository: <http://archive.ics.uci.edu/ml/datasets/EMG+dataset+in+Lower+Limb#>
- [9] García, I. G., Luna, L. L., Reyes, B. A., Dorantes-Méndez, G., Mejía-Rodríguez, A. R., & Mendoza-Gutiérrez, M. O. (2017). Aplicación de Técnicas en el Dominio del Tiempo y la Frecuencia para el Análisis de la Marcha Humana usando Señales de Electromiografía. En S. M. Biomédica, *Memorias del XL Congreso Nacional de Ingeniería Biomédica* (págs. 114-117). Monterrey: SOMIB.
- [10] Oliver-Chiva, E., Vallés-Miquel, M., & Valera-Fernández, Á. (6 de Julio de 2015). Trabajo de Fin de Grado. Desarrollo de un sistema de monitorización de parámetros biomédicos basado en ROS sobre una plataforma empotrada, 8. Valencia, Comunidad Valenciana, España: Universitat Politècnica de València. Obtenido de [https://riunet.upv.es/bitstream/handle/10251/53639/TFG-ErnestoOliver\\_14362083475421314159709674446824.pdf?sequence=3&isAllowed=y](https://riunet.upv.es/bitstream/handle/10251/53639/TFG-ErnestoOliver_14362083475421314159709674446824.pdf?sequence=3&isAllowed=y)
- [11] Delane, A., Bohórquez, J., Gupta, S., & Schiavenato, M. (2016). Lomb Algorithm Versus Fast Fourier Transform in Heart Rate Variability Analyses of Pain in Premature Infants. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 944-947.
- [12] Cifuentes González, I. A. (2012). Extracción de Características y Clasificación de Señales Electromiográficas Utilizando la Transformada Hilbert-Huang y Redes Neuronales. Puebla, México.
- [13] Lee, K. (20 de Marzo de 2012). MathWorks. Obtenido de File Exchange: <https://la.mathworks.com/Matlabcentral/fileexchange/32427-fast-approximate-entropy>
- [14] Hsu, H.-H., Hsieh, C.-W., & Lu, M.-D. (2011). Hybrid feature selection by combining filters and wrappers. *Expert Systems with Applications*. Elsevier, 8144-8150.
- [15] Kohavi, R., & John, G. H. (1997). Wrappers for feature subset selection. Elsevier, 273-324.
- [16] Tortajada, S. (2019). Fisher's Linear Discriminant Analysis. (U. P. València, Ed.) Valencia, Comunidad Valenciana, España.
- [17] D'Errico, J. (31 de Julio de 2013). *MathWorks*. Obtenido de File Exchange: <https://la.mathworks.com/Matlabcentral/fileexchange/42885-nearestspd>