

Un enfoque del reconocimiento de patrones de marcha en pacientes con Huntington y Ataxias Hereditarias usando datos de acelerómetros del iPhone

An approach to recognition of gait patterns in Huntington's and Hereditary Ataxias patients using iPhone accelerometer data

Elías Beltrán-Naturi¹, Francisco D. Acosta-Escalante², Marie Catherine Boll³, José Adán Hernández Nolasco²

¹ Universidad Tecnológica de la Selva, Entronque Toniná km 0.5 carretera Ocosingo-Altamirano, Ocosingo, Chiapas, MX
ebnaturi@gmail.com

² Universidad Juárez Autónoma de Tabasco, Carretera Cunduacán-Jalpa Km. 0.5, C.P. 86690, Cunduacán, Tabasco, MX
francisco.acosta@ujat.mx, adan.hernandez@ujat.mx

³ Instituto Nacional de Neurología y Neurocirugía "Manuel Velasco Suarez", Av. Insurgentes Sur 3877 Del. Tlalpan, Ciudad de México, MX
bollneur@gmail.com

Fecha de recepción: 15 de julio de 2019

Fecha de aceptación: 30 de agosto de 2019

Resumen. Las enfermedades de Huntington y Ataxias hereditarias afectan las habilidades motoras de manera progresiva conforme avanza la enfermedad; lo que implica alteraciones en los patrones de marcha y como consecuencia la pérdida del equilibrio y la falta de coordinación en el desplazamiento. Diversas investigaciones se han desarrollado enfocados en el reconocimiento de los patrones de la marcha en estas enfermedades; sin embargo, solo se ha alcanzado un 78.78% de precisión. En este trabajo se propone un método para el reconocimiento de la marcha usando datos de sensores de movimiento capturados con el iPhone colocados en los tobillos de los pacientes. Se implementan diversos algoritmos selectores de atributos para extraer 320 subconjuntos de datos; los algoritmos CfsSubsetEval & LinearForwardSelection permiten obtener las características más representativas de los grupos. La combinación de los algoritmos RandomCommittee & ExtraTree alcanza una precisión de 87.99%, lo que representa una mejora del 9.21%.

Palabras Clave: Sensores de movimiento, Meta-clasificadores, Ataxias Hereditarias, Huntington, patrones de la marcha.

Summary. Huntington's disease and hereditary ataxias affect motor skills progressively as the disease progresses; which implies alterations in the walking patterns and as a consequence the loss of balance and the lack of coordination in the movement. Various investigations have been carried out focused on the recognition of gait patterns in these diseases; however, only 78.78% accuracy has been achieved. In this work, a method for gait recognition is proposed using data from motion sensors captured with the iPhone placed on the ankles of the patients. Various attribute selector algorithms are implemented to extract 320 subsets of data; The CfsSubsetEval & LinearForwardSelection algorithms allow you to obtain the most representative characteristics of the groups. The combination of the RandomCommittee & ExtraTree algorithms achieves an accuracy of 87.99%, representing an improvement of 9.21%.

Keywords: Motion sensors, Meta-classifiers, Hereditary Ataxias, Huntington, gait patterns.

1 Introducción

Las enfermedades de Huntington (HD), las ataxias hereditarias (HA) dañan las habilidades motoras con la progresión de la enfermedad, lo que implica un deterioro del patrón de marcha como consecuencia de la pérdida del equilibrio y la falta de coordinación en la marcha. Las habilidades motrices se ven afectadas de diferentes maneras según el mecanismo patológico de cada enfermedad. El desarrollo de HD y HA muestran afectaciones similares en marcha durante las primeras etapas que pueden confundir al especialista al momento de realizar un examen de la marcha a través de la observación clínica. Ambas enfermedades son hereditarias y progresivas, los síntomas aparecen en la cuarta década de la vida (mediados de los 50 años) [1]; en ambas enfermedades, los trastornos motores suelen ser los signos más frecuentes y visibles [2], [3]; con un empeoramiento progresivo observado durante 15 a 30 años hasta la muerte. La habilidad motora disminuye con la gravedad de la enfermedad, afectando la precisión y la velocidad del movimiento, resultando en la pérdida del equilibrio y de la mecánica normal de la marcha, y provocando caídas [4]–[9]. Los pacientes con enfermedad más avanzada tienen un peor equilibrio y una disminución de la mecánica de la marcha, lo que resulta en un estado de no deambulación [1]. En HD la corea es la alteración más frecuente [10], mientras que en HA, la marcha atáxica [11]. Hasta hoy en día, no se han reportado terapias o intervenciones disponibles que demuestren un inicio retrasado o una progresión lenta de la enfermedad [12], mientras que cantidad de pacientes con estas enfermedades aumenta en país [13].

Trabajos recientes se han enfocado en el reconocimiento de patrones de marcha de estas enfermedades basados en datos obtenidos de sensores movimientos transformados en características utilizando diversas técnicas de procesamiento de la información, para permitir a los algoritmos de clasificación (o aprendizaje automático) generar modelos de aprendizaje para reconocer aquellos elementos que comparten propiedades similares (reconocimiento de patrones). En este trabajo usamos meta-clasificadores con clasificadores de árboles como clasificador base de aprendizaje para mejorar la precisión de la clasificación de pacientes con patrones de marcha similares (HD y HA). Los meta-clasificadores: *Logitboost*, *RandomCommittee* y *MultiBoostAB*, combinados con los árboles clasificadores: *Random Forests*, *Extra Randomized Tree* y *Logistic Model Trees*; demostraron un desempeño superior al clasificar características de la marcha basado en datos obtenidos con los sensores de movimiento de Iphone.

2 Estado del arte

Los diversos enfoques utilizados en los trabajos revisados indican que aún no se ha desarrollado un método capaz de reconocer plenamente los patrones de marcha en las diversas enfermedades neurodegenerativas; la tabla 1 resume los resultados obtenido en los trabajos previos. Se observa que los investigadores centrados en el reconocimiento de pacientes con enfermedades neuro-degenerativas basadas en la marcha han utilizado sensores de presión y movimiento (columna 4), los primeros trabajos utilizaron fuentes de datos públicas, mientras que los más recientes construyeron su propio conjunto de datos para llevar a cabo sus investigaciones (columna 3); se han utilizado una variedad de algoritmos con varios grupos patológicos (columnas 5 y 6). Los resultados en la exactitud de la clasificación (columna 7) muestra que el algoritmo clasificador Bayesiano Normal cuadrático usando sensores de presión (65%) tuvo la precisión más baja y el algoritmo de Máquina Vectorial de Soporte alcanza una precisión más alta (90.9%). Los grupos que incluyen HD han tenido una mejor precisión de clasificación (90.9%) que los que incluyen HA (78%); sin embargo, sólo un trabajo incluye ambas patologías, pero su resultado no es mejor. Los resultados de precisión muestran y una tasa de error en promedio del 20% de los pacientes que no fueron correctamente reconocidos a la clase a la que pertenece; estos resultados pueden ser mejorados con técnicas más robustas de clasificación y procesamiento de datos.

Tabla 5. Precisión en reconocimiento de los patrones de marcha en trabajos previos.

Año	Ref.	Dataset	Sensores	Algoritmos de clasificación	Grupos	Exactitud
2011	[14]	Público	Sensores de presión	Clasificador normal cuadrático de Bayes.	HC, HD, PD, ALS	86.957%
2012	[15]	Público	Sensores de presión	Clasificador normal cuadrático de Bayes.	HC, HD, PD, ALS	65.00%
2014	[16]	Público	Sensores de presión	RadomSubspace and Bagging and PART	HD, PD, ALS	88.67%
2015	[17]	Propietario	Sensores de presión	Red neural artificial y Maquina de soporte vectorial	HC, HA, PPV, BV, PSP ¹	90.90%
2015	[18]	Propietario	Acelerómetros	LogitBost & RandomSubSpace	HC, EP, EH, HA	78.78%
2016	[19]	Propietario	Acelerómetro y giroscopio	Máquina de soporte vectorial y modelos ocultos Markov	EL, HD, PS	90.5%
2016	[20]	Propietario	Acelerómetro y giroscopio	Red neural artificial Multicapa	HC, HA	74.00%
2017	[21]	Propietario	Acelerómetro y giroscopio	Máquina de soporte vectorial y modelos ocultos Markov	HC, HA, DCD	78.40%

Dadas las alteraciones en la marcha y la dificultad de desplazamiento en pacientes con HD y HA, creemos que para lograr nuestro objetivo es obligatorio el uso de un número reducido de dispositivos, portables y fáciles de usar; que deben ser colocados en las partes del cuerpo donde las tareas de caminar son ininterrumpidas mientras se registran los datos. Por estas razones, recopilamos los datos con teléfonos inteligentes iPhone equipados con sensores de movimiento, capacidad de procesamiento y transferencia de datos; y fácilmente accesibles en comparación con los instrumentos especializados implementados en los trabajos relacionados. Usamos un enfoque de combinar múltiples algoritmos para la selección de características, así como también, meta-clasificadores y clasificadores de árboles porque consideramos que las fortalezas de estos algoritmos ayudan a mejorar las precisiones del reconocimiento del patrón de marcha.

3 Metodología

Este trabajo implica la recolección, procesamiento, la extracción de características, clasificación y evaluación del rendimiento de los algoritmos, para reconocer patrones de la marcha de pacientes con HD y HA basado en datos de sensores de un teléfono inteligente.

3.1 Sujetos, materiales y recopilación de datos

Este estudio se realizó en colaboración con *el Instituto Nacional de Neurología y Neurocirugía "Manuel Velasco Suárez" (INNN-MVS) de la Ciudad de México*, que estudia y trata a pacientes con trastornos de la marcha como la enfermedad de Huntington (HD) y Ataxias Hereditarias (HA). El INNN-MVS permitió habilitar un laboratorio de marcha en un espacio de 20 m de largo por 3 m de ancho para recolectar los datos de la marcha utilizando sensores de movimiento de *dos Smartphones 5S de iPhone* (acelerómetro de tres ejes y giroscopio, velocidad 100Hz) [24], sujetos en cada tobillo del paciente. Treinta y nueve sujetos del INNN-MVS participaron en el estudio: catorce pacientes con HA, once pacientes con HD y catorce sujetos sanos (HC). Los pacientes habían sido diagnosticados por los especialistas, y los controles eran personas sanas sin enfermedades neurodegenerativas existentes.

3.2 Preprocesamiento de datos de marcha

Los datos capturados por los sensores del Smartphone (iPhones) fueron preparados para identificar adecuadamente la información de la zancada y la extracción de características; el procedimiento de preprocesamiento se inspiró en los métodos implementados en [25], [26]. El proceso fue el siguiente: (1) *eliminación de los valores atípicos* al inicio y final de la señal relacionados al inicio y fin de la caminata; (2) *calibración de los datos* usando la Interpolación Lineal para obtener un muestreo a intervalos de tiempo; (3) *normalización de media-cero* permite eliminar valores constantes en la señal; como la gravedad y que no son relevantes para el experimento; (4) *normalización L_2* para obtener un solo valor de los 3 ejes de sensor con la finalidad capturar las invariantes de la orientación del acelerómetro; (5) *suavizado de la señal* usando la técnica del promedio móvil equivalente a filtro paso bajo; y (6) *extracción de datos* equivalente a 10 zancadas establecidas como la medida mínima suficiente para representar las características de la marcha [27], con un algoritmo inspirado en [28].

3.3 Extracción de características

Las características primarias de la marcha se extrajeron con una herramienta de evaluación de la marcha asistida por ordenador *IGAIT* [29], usando los datos equivalente a 10 zancadas. La herramienta se configuró usando 10 metros (promedio) de espacio y se estableció un umbral de aceleración máximo de 0.4 para personas sanas y 0.3 para enfermos para determinar las características de la marcha. Se extrajeron 28 características de la marcha (por sensor): *6 espacio-temporales, 15 relacionadas con la frecuencia; y 7 de regularidad y simetría de paso*. Se calcularon características derivadas basadas en las siguientes métricas de distancia: *la distancia de Manhattan, la distancia cuadrada Euclidiana, la distancia normalizada Euclidiana y la distancia de Mahalanobis*; de cada vector resultante se tomaron: la media, la desviación estándar, los valores máximos y mínimos, y las probabilidades acumulativas (0,025, 0,25, 0,5, 0,75 y 0,975 cuantiles). El conjunto de datos final se configuró con 2016 características y 39 sujetos.

3.4 Selección de características y clasificación

Una alta precisión de la clasificación se asocia con la implementación de las características mejor adaptadas a los algoritmos de clasificación. El proceso de selección de características y clasificación se describe en la fig. 1: el *dataset completo* es introducido en el *algoritmo seleccionador de atributos* el cual lo envía al *algoritmo evaluador de atributos*, que asignan una puntuación a cada característica; el *seleccionador de atributos* toma las puntuaciones y selecciona las mejores características generando un nuevo subconjunto. El nuevo subconjunto de datos sirve de entrada para el meta-clasificador, el cual realiza un proceso de muestreo y genera los clasificadores según las iteraciones implementadas. Posteriormente, une los resultados de cada clasificador en un solo para presentar un resultado final de la clasificación.




Figura 2. Proceso de selección y clasificación de las características.

Se usó la herramienta “*Waikato Environment for Knowledge Analysis*” (Weka) en el proceso de selección y clasificación. Para la selección de características se implementaron 16 algoritmos *seleccionadores de atributos* en combinación con 20 algoritmos *evaluadores de atributos*. El proceso de clasificación se realizó usando los meta-clasificadores *Logitboost*, *RandomCommittee* y *MultiBoostAB* con 100 iteraciones cada uno. Los meta-clasificadores se implementaron con clasificadores de árboles como base para el aprendizaje: *Random Forests* [30], [31], *Extra Randomized Tree (ExtraTree)* [32], [33] y *Logistic Model Trees (LMT)* [34], [35]; estos clasificadores han sido implementados en diversos problemas con buen desempeño en el reconocimiento de diversas enfermedades.

3.5 Evaluación del desempeño en el reconocimiento de patrones

La validación del modelo aprendido implica averiguar hasta dónde encaja el modelo usando todos los puntos de datos y qué tan bien se aprende cuando hace nuevas predicciones sobre datos que aún no ha visto; se utilizó una validación cruzada estratificada 10 veces (*k-fold CV*) para seleccionar los mejores subconjuntos de datos [36] y aseguramos el resultado aplicando una validación cruzada dejando uno fuera (LOOCV) [37]. En la evaluación del desempeño de los algoritmos para averiguar que también el modelo es funcional y si fue correctamente entrenado, se consideraron las siguientes medidas: la matriz de confusión, la precisión, el recall, el área ROC, el coeficiente de correlación de Matthews (MCC) y la estadística kappa [38].

4 Resultados experimentales

La selección de características se llevó a cabo ejecutando 16 algoritmos *seleccionadores de atributos* en combinación con 20 algoritmos *evaluadores de atributos*; un total de 320 subconjunto de datos fueron generados. Las combinaciones de los algoritmos: *CfsSubsetEval & BestFirst*, *CfsSubsetEval & Linear-ForwardSelection* y *FilteredSubsetEval & GreedyStepwise* mostraron los mejores resultados. La probabilidad acumulada, la desviación estándar y los valores mínimos de las métricas de distancia cuadrada de Manhattan y Euclidiana fueron las características comúnmente seleccionadas por los algoritmos. Estos estaban relacionados con la cadencia, la densidad espectral de potencia integral (IPSD), la densidad espectral de potencia acumulada (CPSD) y la cadencia en los ejes anteroposterior (AP) y vertical (VER) de los sensores derecho (R) e izquierdo (L).

Las clasificaciones se realizaron en forma binarias combinando las clases participantes *HD vs HC*, *HA vs HC* y *HD vs HA*. Las combinaciones de algoritmos clasificadores con resultados superiores al 80% fueron las combinaciones: *Logitboost & Randomforest (LGBST & RFT)*, *randomcommittee & ExtraTree (RCMT & EXTR)* y *Multiboost-AB & LMT (MLTBST & LMT)*. La tabla 2 muestra la precisión media de la clasificación con diferentes conjuntos de datos después de aplicar LOOCV. El subconjunto de datos *CfsSubsetEval & LinearForwardSelection* alcanzó una precisión global media del 84.6%, mientras que los demás el 82.9%. Los algoritmos *RCMT & EXTR* obtuvieron el mejor resultado (87.99%) y *MLTBST & LMT* el más bajo (80.52%).

Tabla 6. Exactitud de los algoritmos en la clasificación binaria utilizando meta y clasificador.

Dataset	LGBST & RFT	RCMT & EXTR	MLTBST & LMT
CfsSubsetEval & BestFirst	82.90%	84.42%	81.39%
CfsSubsetEval &	85.28%	87.99%	80.52%
FilteredSubsetEval & GreedyStepwise	81.39%	86.80%	80.52%

La Matriz de Confusión indica las instancias clasificadas según la clase a la que pertenecen. La Matriz de Confusión del mejor subconjunto de datos mostro que puntuaciones de las instancias correctamente clasificadas son superiores a las puntuaciones erróneas de todos los algoritmos. La clasificación binaria *HC vs HA* en *LGBST & RFT* y *RCMT & EXTR* fue completa, mientras que en *MLTBST & LMT* fue errónea en 3 casos; *HC vs HD* clasificó incorrectamente 5 instancias con *RCMT & EXTR*, mientras que los demás algoritmos se equivocaron en 6 instancias; *HD vs HA* se equivocó en 4 instancias con *RCMT & EXTR*, mientras que los otros se equivocaron en 5 instancias. La fig. 3 muestra que *LGBST & RFT* y *MLTBST & LMT* tienen una tasa de error similar excepto en el caso *HC vs HA* que fue mejor para *LGBST & RFT*. *RCMT & EXTR* tuvo la tasa de error más baja en comparación con *MLTBST & LMT* que fue menos precisa en la clasificación de todos los casos.




Figura 3. Tasa de error en todas las clasificaciones binarias.

Precisión y Recall se relacionan con la probabilidad de que el algoritmo pueda reconocer correctamente una instancia basándose en la varianza y el sesgo respectivamente. La clasificación binaria *HC vs HA* obtuvo la puntuación más alta (0.964); las puntuaciones más bajas fueron para la clasificación binaria *HC vs HD* (0.772). Los algoritmos *RCMT & EXTR* recibieron la media más alta al clasificar todos los grupos (0.880).

El *área ROC* evalúa el desempeño del algoritmo conforme cambia el umbral de decisión, es una medida equivalente a un gráfico de Sensibilidad vs. Especificidad. El *área ROC* más alta fue alcanzada por *HC vs HA* (0.988) y la más baja puntuación para *HC vs HD* (0.870); el *área ROC* de *RCMT & EXTR* fue la mejor (0.942) y *MLTBST & LMT* fue más inferior (0.880). En el gráfico ROC de la fig. 4 se puede observar que los valores de *RCMT & EXTR* están muy cerca de 1; mientras que para *MLTBST & LMT* sus valores escalan por debajo de los otros dos algoritmos y más cercano a la diagonal.

La estadística kappa indica cuando un clasificador está adivinando al azar incluso si tenemos exactitud, precisión y recall cerca de la unidad. La estadística de Kappa en la tabla 3, muestra que en la clasificación de *HC vs HA* existen puntuaciones más altas sobre todos los algoritmos (0.929) y *HC vs HD* tiene las más bajas (0.536); el promedio de *RCMT & EXTR* es el más alto (0.757) y *MLTBST & LMT* el más bajo (0.629), incluso abajo de *LGBST & RFT* (0.704). Hemos notado que cuanto menor es la puntuación kappa, menor es la precisión de clasificación.

El coeficiente de correlación de Matthews (MCC) es medida de la calidad de las clasificaciones binarias, se considera una medida equilibrada que puede utilizarse incluso si las clases son de tamaños muy diferentes. La puntuación de MCC se calcula con la matriz de confusión. Podemos afirmar que *RCMT & EXTR* tuvo una puntuación promedio cercana a la unidad (0.704) y *MLTBST & LMT* tiene el valor más bajo (0.633). Tanto los resultados de kappa como los de MCC tienen valores similares para todos los algoritmos, ya que ambos miden la precisión de las puntuaciones de clasificación; *HC vs HA* tiene una mejor clasificación (0.929) para todos los algoritmos y *RCMT & EXTR* tuvo un buen rendimiento para todas las clases.




Figura 4. Gráfico ROC de los resultado de la clasificación en las clases HD, HA y HC.

Tabla 7. Kappa estadística y MCC en la clasificación de las características de la marcha.

Meta-clasificador & Clasificador		Kappa estadística	MCC
LGBST & RFT	H vs HA	1.000	1.000
	H vs HD	0.513	0.513
	H vs HD	0.5981	0.600
RCMT & EXTR	H vs HA	1.000	1.000
	H vs HD	0.5902	0.592
	H vs HD	0.6815	0.690
MLTBST & LMT	H vs HA	0.7857	0.788
	H vs HD	0.5033	0.510
	H vs HD	0.5981	0.600

5. Conclusiones y trabajos futuros

Con base a resultados previos, se asumió que los meta-clasificadores estaban bien situados para mejorar la precisión media publicada en la clasificación de los pacientes con enfermedad de HD y HA, a la vez que se reducía el número de dispositivos utilizados para capturar los movimientos de la marcha. Para confirmar esta suposición utilizamos los datos recogidos con los valores del acelerómetro de dos sensores de movimiento colocados en ambos tobillos. Con estos datos construimos el conjunto de datos de la marcha del que se extrajeron un total de 2016 características.

Se realizó una exhaustiva selección de características con múltiples algoritmos los cuales nos permitieron obtener 320 subconjuntos de datos para implementados con los algoritmos de clasificación; la combinación de los algoritmos CfsSubsetEval & Linear- ForwardSelection extrajo el mejor subconjunto de datos; el cual contenía características derivadas con las métricas de distancia y análisis de la frecuencia en los ejes AP y VT de ambos sensores. El subconjunto obtenido sirvió de entrada para los meta-clasificadores que usaron un árbol clasificador como base de aprendizaje. Se desarrollaron múltiples ejecuciones de clasificación en forma binaria para cubrir todos los grupos. La clasificación binaria de *HC vs HA* fue la mejor ya que logro clasificar correctamente 27 sujetos de un total de 28; mientras que la combinación *HC vs HD* fue la más baja clasificando correctamente 18 de 25 sujetos. El porcentaje de clasificación incluyendo las 3 clases se alcanzó con la combinación de algoritmos *RandomCommittee & ExtraTree* con 87.99%; siendo *MultiBoost-AB & LMT* el porcentaje más bajo (80.52%). Estos resultados son similares a los reportado en [39].

En este trabajo se mejoró los resultados del reconocimiento de los patrones de marcha de HD y HA; en [18] se había reportado una precisión de clasificación de 78.78% usando solo meta-clasificadores; mientras que aquí con la combinación de *meta-clasificador & clasificador* se alcanzó un 87.99% de precisión, lo que equivale a una mejora del 9.21% de instancias correctamente clasificadas. Esto confirma la suposición de que la combinación de meta-clasificadores y clasificadores tiene un mejor rendimiento que los clasificadores individuales, incluso cuando estos últimos han sido modificados para adaptarse a una enfermedad específica.

Los hallazgos encontrados en este trabajo están orientado a la investigación futura para la detección y la monitorización continua del deterioro de la marcha en pacientes con HD y HA, ya que la extracción de características y la clasificación binaria puede utilizarse en el diagnóstico diferencial y el seguimiento de la progresión de la enfermedad mediante el análisis del deterioro que se refleja en los cambios en la forma de caminar de los sujetos. Por lo tanto, este trabajo sienta las bases para la generación de herramientas computacionales que apoyen el diagnóstico médico y la monitorización continua de la marcha para supervisar la progresión de estas enfermedades a largo plazo.

Referencias

- [1] A. J. McGarry, K. Biglan, and F. Marshall, "Huntington Disease," in *Rosenberg's Molecular and Genetic Basis of Neurological and Psychiatric Disease*, 2015, pp. 861–868.
- [2] A. Delval and P. Krystkowiak, "Locomotion et maladie de Huntington," *Revue Neurologique*, vol. 166, no. 2, pp. 213–220, 2010.
- [3] M. Singh, M. Singh, and I. Engineering, "Neuro-Degenerative Disease Diagnosis using Human Gait : A Review," 2013.
- [4] R. Du, "Impact of Carylolanemagnolol on Gait and Functional Mobility on Individuals with Huntington's Disease," *Trop. J. Pharm. Res.*, vol. 14, no. 9, pp. 1713–1717, 2015.
- [5] T. Cruickshank, A. Reyes, L. Peñailillo, J. Thompson, and M. Ziman, "Factors that contribute to balance and mobility impairments in individuals with Huntington's disease," *Basal Ganglia*, vol. 4, no. 2, pp. 67–70, 2014.

- [6] A. Barbeau, R. C. Duvoisin, F. Gerstenbrand, J. P. Lakke, C. D. Marsden, and G. Stern, "Classification of extrapyramidal disorders. Proposal for an international classification and glossary of terms.," *J. Neurol. Sci.*, vol. 51, no. 2, p. 311, 1981.
- [7] L. Schöls *et al.*, "Extrapyramidal Motor Signs in Degenerative Ataxias," *Arch. Neurol.*, vol. 57, no. 10, pp. 1495–500, Oct. 2000.
- [8] J. Stephenson *et al.*, "Gait and balance in adults with Friedreich's ataxia," *Gait Posture*, vol. 41, no. 2, pp. 603–607, 2015.
- [9] A. M. Dueñas, R. Goold, and P. Giunti, "Molecular pathogenesis of spinocerebellar ataxias," *Brain*, vol. 129, no. 6, pp. 1357–1370, 2006.
- [10] D. Justo *et al.*, "Is non-recognition of choreic movements in Huntington disease always pathological?," 2013.
- [11] M. Miller, Benjamin Frank and Keane, Claire Brackman and O'Toole, *Encyclopedia & dictionary of medicine, nursing & allied health.*, 7th ed. Saunders, 2003.
- [12] Y. M. Bordelon, "Huntington Disease," *Neurol. Clin.*, vol. 31, no. 4, pp. 1085–1094, Nov. 2013.
- [13] Naldy Rodríguez, "Ataxia. La rara enfermedad que diezma a Tlaltetela," *El universal*, Veracruz. México, p. 1, 02-Nov-2016.
- [14] M. Banaie, M. Pooyan, and M. Mikaili, "Introduction and application of an automatic gait recognition method to diagnose movement disorders that arose of similar causes," *Expert Syst. Appl.*, vol. 38, no. 6, pp. 7359–7363, 2011.
- [15] S. Iram, D. Al-jumeily, P. Fergus, M. Randles, and A. Hussain, "Computational Data Analysis for Movement Signals Based on Statistical Pattern Recognition Techniques for Neurodegenerative Diseases," 2012.
- [16] M. A. W. Eddy Sanchez-Delacruz, Francisco Acosta-Escalante and M.-C. J. J. Hernández-Nolasco José Adán, Pancardo Pablo, "Gait Recognition in the Classification of Neurodegenerative Diseases," in *Ubiquitous Computing and Ambient Intelligence. Personalisation and User Adapted Services*, B. J. Hervás Ramon, Lee Sungyoung, Ed. Springer International Publishing, 2014, pp. 128–135.
- [17] C. Pradhan *et al.*, "Automated classification of neurological disorders of gait using spatio-temporal gait parameters," *J. Electromyogr. Kinesiol.*, vol. 25, no. 2, pp. 413–422, 2015.
- [18] E. Sánchez-delacruz, F. Acosta-escalante, C. Boll-woehrlen, A. Hernández-nolasco, and M. A. Wister, "Categorización de enfermedades neurodegenerativas a partir de biomarcadores de la marcha," *Komputer Sapiens*, vol. II, Metepec estado de México, México, pp. 17–20, Aug-2015.
- [19] A. Mannini, D. Trojaniello, A. Cereatti, and A. M. Sabatini, "A Machine Learning Framework for Gait Classification Using Inertial Sensors: Application to Elderly, Post-Stroke and Huntington's Disease Patients.," *Sensors (Basel)*, vol. 16, no. 1, p. 134, Jan. 2016.
- [20] R. LeMoyné, F. Heerinckx, T. Aranca, R. De Jager, T. Zesiewicz, and H. J. Saal, "Wearable body and wireless inertial sensors for machine learning classification of gait for people with Friedreich's ataxia," in *2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN)*, 2016, pp. 147–151.
- [21] A. Mannini *et al.*, "Automatic classification of gait in children with early-onset ataxia or developmental coordination disorder and controls using inertial sensors," *Gait Posture*, vol. 52, pp. 287–292, Feb. 2017.
- [22] S. H. Subramony *et al.*, "Objective home-based gait assessment in spinocerebellar ataxia.," *J. Neurol. Sci.*, vol. 313, no. 1–2, pp. 95–8, Feb. 2012.
- [23] P. Kutílek, V. Socha, O. Čákr, and Z. Svoboda, "Assessment of postural stability in patients with cerebellar disease using gyroscope data.," *J. Bodyw. Mov. Ther.*, vol. 19, no. 3, pp. 421–8, Jul. 2015.
- [24] Apple, "iPhone 5s - Technical Specifications," 2014. [Online]. Available: https://support.apple.com/kb/SP685?locale=en_GB. [Accessed: 18-Oct-2017].
- [25] V. Chandel, A. D. Choudhury, A. Ghose, and C. Bhaumik, "AcTrak - Unobtrusive activity detection and step counting using smartphones," in *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, 2014, vol. 131, pp. 447–459.
- [26] M. Muaaz and R. Mayrhofer, "Cross pocket gait authentication using mobile phone based accelerometer sensor," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2015, vol. 9520, pp. 731–738.
- [27] J. H. Hollman, K. B. Childs, M. L. McNeil, A. C. Mueller, C. M. Quilter, and J. W. Youdas, "Number of strides required for reliable measurements of pace, rhythm and variability parameters of gait during normal and dual task walking in older individuals," *Gait Posture*, vol. 32, no. 1, pp. 23–28, May 2010.
- [28] U. Ryu *et al.*, "Adaptive Step Detection Algorithm for Wireless Smart Step Counter," in *2013 International Conference on Information Science and Applications (ICISA)*, 2013, pp. 1–4.
- [29] M. Yang, H. Zheng, H. Wang, S. McClean, and D. Newell, "iGAIT: An interactive accelerometer based gait analysis system," *Comput. Methods Programs Biomed.*, vol. 108, no. 2, pp. 715–723, Nov. 2012.
- [30] M. Bahrami and H. Sajedi, "Prediction of diabetic retinopathy based on a committee of random forests," *Int. J. Intell. Mach. Robot.*, vol. 1, no. 2, p. 133, 2018.
- [31] N. Mathew, "A Boosting Approach for Maternal Hypertensive Disorder Detection," in *2018 Second*

- International Conference on Inventive Communication and Computational Technologies (ICICCT)*, 2018, pp. 1474–1477.
- [32] M. Soltaninejad *et al.*, “Automated brain tumour detection and segmentation using superpixel-based extremely randomized trees in FLAIR MRI,” *Int. J. Comput. Assist. Radiol. Surg.*, vol. 12, no. 2, pp. 183–203, Feb. 2017.
- [33] A. Pinto, S. Pereira, D. Rasteiro, and C. A. Silva, “Hierarchical brain tumour segmentation using extremely randomized trees,” *Pattern Recognit.*, vol. 82, pp. 105–117, Oct. 2018.
- [34] I. Kurt, M. Ture, and A. T. Kurum, “Comparing performances of logistic regression, classification and regression tree, and neural networks for predicting coronary artery disease,” *Expert Syst. Appl.*, vol. 34, no. 1, pp. 366–374, Jan. 2008.
- [35] A. Khemphila and V. Boonjing, “Comparing performances of logistic regression, decision trees, and neural networks for classifying heart disease patients,” in *2010 International Conference on Computer Information Systems and Industrial Management Applications (CISIM)*, 2010, pp. 193–198.
- [36] P. Cichosz, “Classification model evaluation,” in *Data Mining Algorithms: Explained Using R*, 1st ed., J. W. Sons, Ed. Chichester, UK: John Wiley & Sons, Ltd, 2015, pp. 189–233.
- [37] C. C. Aggarwal, “An Introduction to Data Classification,” in *Data classification: algorithms and applications*, C. C. Aggarwal, Ed. Boca Raton, FL: Chapman and Hall/CRC Press, 2015, pp. 30–65.
- [38] I. H. Witten, E. Frank, M. A. Hall, and C. J. Pal, *Data Mining: Practical machine learning tools and techniques*, 6th ed. San Francisco, CA: Morgan Kaufmann, 2016.
- [39] F. D. Acosta-Escalante, E. Beltran-Naturi, M. C. Boll, J. A. Hernandez-Nolasco, and P. Pancardo Garcia, “Meta-classifiers in huntington’s disease patients classification, using iPhone’s movement sensors placed at the ankles,” *IEEE Access*, vol. 6, 2018.