

# Classification of levels of gross motor function measure through machine learning techniques

José Sulla-Torres, Dr<sup>1</sup>, Juan Carlos Copa Pineda, Dr<sup>1</sup> y Raúl Sulla Torres, Dr<sup>1</sup>

<sup>1</sup>Universidad Católica de Santa María, Arequipa, Perú,  
jsullato@ucsm.edu.pe, jcopa@ucsm.edu.pe, rsullato@ucsm.edu.pe

*Abstract– The aim of the article is to classify the levels of gross motor function measurement (GMFCS) in minors using machine learning techniques. The study elements were 16 patients, boys, and girls between 2 and 9 years of age from a rehabilitation and physiotherapy institution suffering from cerebral palsy in gross motor function. The clinical analysis, the application of therapy and its measurement of gross motor function were collected, then the classification of nine machine learning algorithms was applied: k-Nearest Neighbor (k-NN), Gradient Boosted tree, Decision Stump, Random Tree, Rule Induction, Improved Neural Net, Generalized Linear Model, SVM, and Linear Discriminant Analysis, which were compared based on accuracy. The results obtained showed that the Linear Discriminant Model was the one that gave the best result with a 96.88 classification accuracy. Therefore, it is concluded that the use of machine learning techniques allows obtaining good accuracy in the classification of the measured level of gross motor function in boys and girls that can be used by specialists to carry out this task.*

*Keywords– Gross Motor Function Classification System, Disability, Machine Learning, Linear Discriminant Model.*

Digital Object Identifier (DOI):  
<http://dx.doi.org/10.18687/LACCEI2020.1.1.216>  
ISBN: 978-958-52071-4-1 ISSN: 2414-6390

# Clasificación de Niveles de Medida de la Función Motora Gruesa mediante Técnicas de Aprendizaje Automático

José Sulla-Torres, Dr<sup>1</sup>, Juan Carlos Copa Pineda, Dr<sup>1</sup> y Raúl Sulla Torres, Dr<sup>1</sup>

<sup>1</sup>Universidad Católica de Santa María, Arequipa, Perú,  
jsullato@ucsm.edu.pe, jcopa@ucsm.edu.pe, rsullato@ucsm.edu.pe

**Abstract**– *The aim of the article is to classify the levels of gross motor function measurement (GMFCS) in minors using machine learning techniques. The study elements were 16 patients, boys, and girls between 2 and 9 years of age from a rehabilitation and physiotherapy institution suffering from cerebral palsy in gross motor function. The clinical analysis, the application of therapy and its measurement of gross motor function were collected, then the classification of nine machine learning algorithms was applied: k-Nearest Neighbor (k-NN), Gradient Boosted tree, Decision Stump, Random Tree, Rule Induction, Improved Neural Net, Generalized Linear Model, SVM, and Linear Discriminant Analysis, which were compared based on accuracy. The results obtained showed that the Linear Discriminant Model was the one that gave the best result with a 96.88 classification accuracy. Therefore, it is concluded that the use of machine learning techniques allows obtaining good accuracy in the classification of the measured level of gross motor function in boys and girls that can be used by specialists to carry out this task.*

**Keywords**– *Gross Motor Function Classification System, Disability, Machine Learning, Linear Discriminant Model.*

**Resumen**– *El objetivo del artículo es clasificar los niveles de medida de la función motora gruesa (GMFCS) en menores de edad mediante técnicas de aprendizaje automático. Los elementos de estudio fueron 16 pacientes, niños y niñas entre 2 y 9 años de una institución de rehabilitación y fisioterapia que sufren parálisis cerebral en la función motora gruesa. Se recolectó el análisis clínico, la aplicación de terapia y su medida de la función motora gruesa, luego se aplicó la clasificación de nueve algoritmos de aprendizaje automático: k-Nearest Neighbor (k-NN), Gradient Boosted tree, Decision Stump, Random Tree, Rule Induction, Improved Neural Net, Generalized Linear Model, SVM y el Análisis Discriminante Lineal, los cuales se compararon en base a la exactitud. Los resultados obtenidos mostraron que el Modelo Discriminante Lineal fue el que dio el mejor resultado con un 96.88 de exactitud en la clasificación. Por lo que se concluye que el uso de las técnicas de aprendizaje automático permite obtener una buena exactitud en la clasificación del nivel medida de la función motora gruesa en niños y niñas que puede ser utilizado por los especialistas para realizar dicha tarea.*

**Palabras Clave**– *Clasificación de la Función Motora Gruesa, Discapacidad, Aprendizaje Automático, Modelo Discriminante Lineal.*

## I. INTRODUCCIÓN

La parálisis cerebral (PC) es un trastorno neuromotor caracterizado por la debilidad muscular, alteración de la coordinación de los músculos y espasticidad de las extremidades [1], es la discapacidad física más común en la

infancia con una prevalencia de 2.5 a 3.6 casos por 1000 nacidos vivos [2].

El Sistema de clasificación de la función motora gruesa (GMFCS) es una herramienta clínica utilizada para clasificar a los niños con PC en función de su competencia funcional. Palisano (2000) estableció que el GMFCS clasifique la movilidad funcional de niños diagnosticados con PC en cinco clases: I-V [3].

La asignación de nivel de GMFCS supera varias dificultades ya que se basa en un amplio espectro de habilidades funcionales que entran en conflicto con las definiciones de nivel de GMFCS.

En los últimos años, los enfoques analíticos y de aprendizaje automático multivariados se han utilizado cada vez más en la investigación de PC. De hecho, se han realizado estudios donde se aplica las técnicas del aprendizaje automático para superar los desafíos de asignamiento de niveles en GMFCS.

En ese sentido, algunos estudios han utilizado algoritmos de aprendizaje automático para la clasificación de señales de electroencefalografía (EEG) de parálisis cerebral (Cerebral Palsy), análisis de anomalías de conectividad estructural, entre otros [4].

Debido a la amplia gama de resultados motores en la PC, algunos niños pueden no ajustarse a uno de los niveles y la clasificación se puede volver subjetiva, lo que puede convertirse en una dificultad en la clasificación de los niveles de GMFCS. Sin embargo, hasta donde sabemos, ningún estudio previo ha evaluado la utilización de las técnicas de aprendizaje automático para clasificar el GMFCS en niños y niñas con PC.

En ese contexto, el presente trabajo, utiliza la aplicación de técnicas de aprendizaje automático para clasificar los niveles de medida de la función motora gruesa en menores de edad, para ello se comparará diferentes algoritmos de clasificación para determinar cuál de ellos muestra el mejor resultado en cuanto a su exactitud.

Este artículo está organizado de la siguiente manera: en la sección II describe el estado del arte, la sección III presenta los materiales y métodos, donde se explica el método a utilizar, además se detalla el modelo de operación a realizar. En la sección IV se reportan los resultados obtenidos luego de la experimentación, finalmente en la sección V se presenta la conclusión con el grado de cumplimiento del objetivo de este trabajo.

Digital Object Identifier (DOI):

<http://dx.doi.org/10.18687/LACCEI2020.1.1.216>

ISBN: 978-958-52071-4-1 ISSN: 2414-6390

## II. ESTADO DEL ARTE

Los estudios revisados en este documento muestran los métodos analíticos del aprendizaje automático que han sido útiles en la identificación de factores de riesgo, la detección de PC, la evaluación del movimiento para la predicción de la PC y la evaluación de resultados, y los enfoques de ML han permitido identificar automáticamente las alteraciones del movimiento en los pacientes de alto riesgo. Jing Zhang [5] revisa el análisis multivariante y de aprendizaje automático en la investigación de la parálisis cerebral, demostrando que los predictores de resultados para los tratamientos quirúrgicos se han identificado mediante estudios de resultados multivariados. Para que los enfoques multivariante y aprendizaje automático sean útiles en entornos clínicos.

La utilización de enfoques de aprendizaje automático, tienen el potencial de mejorar significativamente la precisión de los niveles de clasificación de GMFCS.

En 2019, Bertoncelli [6] utiliza un modelo de aprendizaje predictivo para identificar los factores asociados con discapacidades intelectuales graves en adolescentes con parálisis cerebral.

En [7] utiliza la predicción basada en el aprendizaje automático de la función motora ambulatoria versus no ambulatoria en niños con parálisis cerebral. Se han utilizado diferentes técnicas de Aprendizaje automático para la Clasificación de GMFCS como los árboles de decisión [8]

Stout [9] utiliza un algoritmo basado en descriptores GMFCS y habilidades funcionales para la asignación del nivel de clasificación de la función motora gruesa (GMFCS).

En el trabajo de Ahmadi [10] hace uso de algoritmos de aprendizaje automático para el reconocimiento de la actividad en niños y adolescentes ambulatorios con parálisis cerebral clasificado en niveles GMFCS I a III. Los clasificadores de *Random Forest* (RF), máquina de vectores de soporte (SVM) y árbol de decisión binario (BDT) fueron utilizados. El rendimiento se evaluó mediante la validación cruzada, concluyendo que los métodos de aprendizaje automático proporcionaron una precisión de clasificación aceptable para la detección de una variedad de actividades comúnmente realizadas por niños ambulatorios con PC.

En 2018, Schwartz [11] utiliza del aprendizaje automático para superar los desafíos en la asignación de nivel GMFCS, para ello aplica el clasificador *Random Forest* para predecir los niveles I-IV del Sistema de clasificación de la función motora gruesa (GMFCS) a partir de las capacidades informadas por el paciente registradas en el Cuestionario de evaluación funcional (FAQ) de Gillette. El clasificador mostró una precisión sobresaliente en los niveles GMFCS I-IV, con 83% -91% de tasa positiva verdadera (TPR).

La aplicación de la electroestimulación nerviosa transcutánea (TENS) y la electroestimulación muscular (EMS) es una alternativa para investigar el efecto del método Intervencionista en la función motora gruesa en niños con parálisis cerebral espástica (PC). Si bien la aplicación muestra mejoras en la función motora gruesa y la movilidad, la

diferencia en la mejora entre los niños tratados con TENS y fisioterapia no alcanza aún significación estadística [12].

En [13], se indica que el PC pueden llevar a otro tipo de problemas como la Obesidad, en su trabajo probó la correlación entre los valores de Índice de masa Corporal (IMC), GMFCS y las puntuaciones z de la Densidad Mineral Ósea (DMO). Los resultados mostraron que existe una correlación significativa entre las puntuaciones z de DMO y los valores de IMC, así como el GMFCS, luego aplicaron el enfoque de simulación Bayesiana para predecir los puntajes z de la DMO utilizando IMC y GMFCS.

## III. MATERIALES Y MÉTODOS

La metodología seguida para el siguiente trabajo está conformada por las etapas mostradas en la Fig. 1.

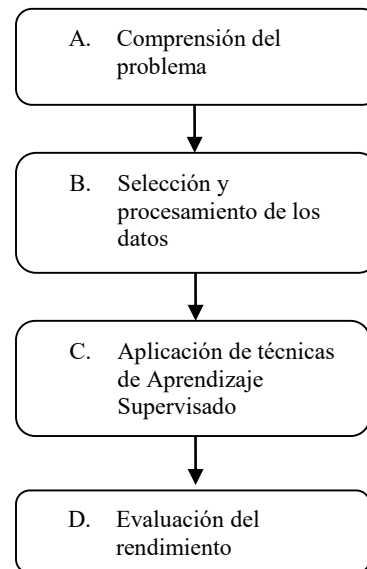


Fig. 1. Metodología propuesta para la clasificación de niveles GMFCS

### A. Comprensión del problema

Los participantes fueron pacientes de una institución de rehabilitación y fisioterapia de la ciudad de Arequipa, Perú, pertenecientes a la Medical Ministry International, establecida en Perú desde 1999.

El objetivo es clasificar los niveles de la función motora gruesa en niños con discapacidad de PC.

El sistema de clasificación de la función motora gruesa está dividida en los siguientes niveles:

I. Puedo caminar, subir escaleras, correr y saltar. Tiene velocidad, equilibrio y coordinación disminuidos.

II Puede subir escaleras con una baranda. Solo tiene una habilidad mínima para correr o saltar.

III. Paseos con dispositivos de movilidad asistida. Puede impulsarse con una silla de ruedas manual y necesitar asistencia.

IV. Capacidad para caminar severamente limitada. Utiliza sillas de ruedas la mayor parte del tiempo. Necesita ayuda.

V. Tiene impedimentos físicos en todas las áreas de la función motora. No puede sentarse o pararse independientemente.

La clasificación de los niveles de la función motora gruesa en niños con discapacidad de PC, es una tarea que requiere una serie de evaluaciones y experiencia que en muchos casos puede volverse subjetiva.

#### B. Selección y procesamiento de los datos

Al momento de la evaluación se tomó en cuenta a 16 pacientes niños entre 2 a 9 años con discapacidad PC que se encontraba disponibles, a los cuales se les ha tomado se recolectó los datos del análisis clínico, la aplicación de terapia y su medida de la función motora gruesa con los siguientes atributos de entrada:

- Edad: entre 2 y 9 años,
  - Sexo: Masculino, Femenino
  - CPK: UI/L
  - Lactato: mmol/L
  - Glucosa: mg/dl
  - Hemoglobina: g/dL
  - Hematocrito: %
  - Hematies:  $10^6/\mu\text{L}$
  - V.C.M.: fL
  - H.C.M.: pg
  - C.H.C.M.: g/dL
  - Plaquetas:  $10^3/\mu\text{L}$
  - Leucositos:  $10^3/\mu\text{L}$
  - Moestimulación: T.E.N.S.
  - Goniómetro: Grados Sexagesimales
- Como atributo de salida, la clase:
- GMFMS: Nivel II, III, IV y V

El protocolo de evaluación adoptado ha sido el siguiente: durante dos meses, los pacientes en tres sesiones semanales han seguido la terapia de rehabilitación durante 45 minutos donde especialistas en el campo de fisioterapia han realizado las evaluaciones a la finalización de cada sesión y almacenado el registro de los atributos mencionados anteriormente, los cuales formaron parte de la base de datos que se utilizó junto con la herramienta de minería de datos.

Una vez recolectado los datos, se procedió a realizar el pre-procesamiento de datos. En esta etapa se prepara los datos con las siguientes actividades:

- Eliminar valores anómalos, inconsistencias, valores ausentes, etc.
- Seleccionar de variables en base a las características en términos de su capacidad de clasificación en los algoritmos con los que se van a trabajar.
- adaptar los valores para su mejorar el tratamiento para el uso en los algoritmos

La Base de datos se almacenó en un fichero CSV (comma-separated values) que son un tipo de documento en formato simple para representar datos en forma de tabla, en las que las columnas se separan por comas y las filas por saltos de línea. Estos archivos pueden ser leídos fácilmente por diferentes herramientas de minería de datos como Rapidminer.

#### C. Aplicación de técnicas de Aprendizaje Supervisado

Para la realización de la experimentación nos hemos basado en el informe del cuadrante mágico para plataformas de ciencia de datos de Gartner [14], donde muestra que uno de los productos software para realizar minería de datos es RapidMiner [15].

Rapidminer es una herramienta para uso y construcción de modelos en los campos de algoritmos de minería de datos como regresión, clasificación, aprendizaje no supervisado, etc. Rapidminer, tiene las siguientes ventajas [17], reducción del trabajo de programación, ya que incluye una librería de algoritmos de aprendizaje evolutivo, y simplificando la integración de tales algoritmos con diferentes técnicas de preprocesamiento.

Los algoritmos evaluados se han elegido en función a su popularidad y uso frecuente en trabajos de investigación relacionados a la propuesta, entre ellos se encuentran k-Nearest Neighbor (k-NN), Gradient Boosted tree, Decision Stump, Random Tree, Rule Induction, Improved Neural Net, Generalized Linear Model, Support Vector Machine (SVM) y Linear Discriminant Model (LDA).

Pasaremos a describir brevemente cada uno de los algoritmos:

##### A. k-Nearest Neighbor (k-NN)

El algoritmo k-Nearest Neighbor (k-NN) es un enfoque de clasificación supervisada basado en similitudes. Es un mecanismo que se utiliza para identificar el punto de dato desconocido basado en el vecino más cercano cuyo valor es conocido.

El algoritmo k-NN ha sido utilizado en trabajos similares para mejorar la planificación de la cirugía multinivel y predecir el resultado postoperatorio en la parálisis cerebral [16].

##### B. Gradient Boosted tree (GBT)

El modelo GBT es una combinación de los modelos de árbol de regresión y clasificación, como los modelos de árbol de decisión. GBT mejora los resultados del poder de predicción a través de la mejora progresiva de las estimaciones. Además, GBT emplea un procedimiento de regresión no lineal que ayuda a mejorar la precisión de los árboles. Se crea una serie de árboles de decisión que producen un conjunto de modelos de predicción débiles. Si bien impulsar árboles aumenta la precisión, también disminuye la velocidad y la capacidad de interpretación humana. El método de aumento de gradiente generaliza el aumento de árboles para minimizar estos problemas [17].

### C. Decision Stump (DS)

El método DS, es un árbol de decisión de un solo nivel, Es decir, es un árbol de decisión con un nodo interno que se conecta inmediatamente a los nodos terminales. Asume la naturaleza booleana de los atributos y una distribución de probabilidad similar para atributos irrelevantes. Se selecciona un único atributo en la predicción de la pertenencia a la clase en base al *score* (S) de eficiencia de separación de clase de cada uno de los atributos [18].

### D. Random Tree

Es un algoritmo de clasificación que funciona formando múltiples árboles de decisión en el entrenamiento y en las pruebas, produce la clase que es el modo de la clasificación. El árbol de decisión funciona aprendiendo reglas de decisión simples extraídas de las características de los datos. Cuanto más profundo es el árbol, más complejas son las reglas de decisión y más se ajusta el modelo. Los bosques de decisión aleatorios superan el problema del sobreajuste de los árboles de decisión [19].

### E. Rule Induction

Las técnicas de minería de datos e inducción de reglas pueden extraer reglas de datos y predecir eventos previamente desconocidos [20]. Las técnicas basadas en el árbol de decisión tienen una alta capacidad para la inducción de reglas y la relación de extracción entre variables, para clasificarlas en clases significativas.

### F. Improved Neural Net

Una red neuronal es un conjunto de elementos de procesamiento altamente interconectado en base a neuronas con capacidad de aprendizaje en base a los datos que toman como entrada. Este operador aprende un modelo por medio de una red neuronal *feed-forward* entrenada por un algoritmo de propagación hacia atrás (perceptrón multicapa). Se ha utilizado este algoritmo para diferentes investigaciones como el reconocimiento de posturas humanas [21]. Para la prueba se utilizó los siguientes parámetros: tamaño de capas ocultas: 2, ciclos de entrenamiento: 200, tasa de aprendizaje: 0.01, y momentum: 0.9.

### G. Generalized Linear Model (GLM)

Los GLM son una extensión de los modelos lineales tradicionales. Este algoritmo ajusta modelos lineales generalizados a los datos maximizando la probabilidad logarítmica. La penalización neta elástica se puede utilizar para regularización de parámetros. El cálculo de ajuste del modelo es paralelo, extremadamente rápido y se escala extremadamente bien para modelos con un número limitado de predictores con coeficientes distintos de cero. El GLM también es utilizado para la evaluación de parámetros seleccionados de la marcha de niños con hemiparesia antes y después de participar en un programa modificado de terapia de movimiento inducido por restricción [22]. Para la prueba se utilizó los siguientes

parámetros: Familia: selección automática, gaussiano para etiquetas numéricas, solver: automatico IRLSM ya que es rápido en problemas con un pequeño número de predictores.

### H. Support Vector Machine (SVM)

Los SVM realizan tareas de clasificación mapeando características en un espacio multidimensional y construyendo límites de decisión, llamados hiperplanos, que maximizan el margen entre las observaciones de diferentes clases de actividad. El margen está determinado por la distancia entre los "vectores de soporte", que son observaciones que se encuentran en un área del espacio que crea un límite entre las clases de actividad. Las nuevas observaciones se asignan al espacio multidimensional y se les asigna una predicción de clase en función de qué lado del hiperplano se encuentra. [10]. Para la prueba se utilizó los siguientes parámetros: tipo de kernel: dot, kernel cache: 200, C:1.0, épsilon convergencia:0.001.

### I. Linear Discriminant Model (LDA)

El método Análisis Discriminante Lineal intenta encontrar la combinación lineal de características que separan mejor dos o más clases de ejemplos. La combinación resultante se usa luego como un clasificador lineal. El análisis discriminante se utiliza para determinar qué variables discriminan entre dos o más grupos naturales, puede tener un objetivo descriptivo o predictivo. Se ha utilizado este método comparándolo con otros patrones de reconocimiento como SVM para diagnóstico del parálisis cerebral en el modo de andar [23].

En base a los conceptos anteriores, se eligieron los algoritmos y se procedió a construir los modelos respectivos de cada uno en la herramienta de minería de datos.

Para poder construir el modelo se tiene que establecer los datos de entrada, fijar los atributos y roles, realizar tareas de preparación de los datos según el algoritmo que se va a utilizar y finalmente aplicar el modelo con el performance de salida. Uno de los modelos construidos del Modelo Discriminante Lineal en la herramienta Rapidminer para los datos utilizados se puede apreciar en la Fig. 2.

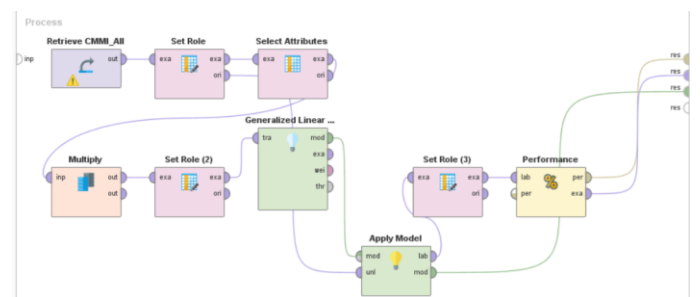


Fig. 2 Análisis Discriminante Lineal para la Clasificación en Rapidminer.

Otro de los Modelos probados fue el del árbol de decisión que permitió construir en función a los atributos lo que se muestra en la Fig 3.

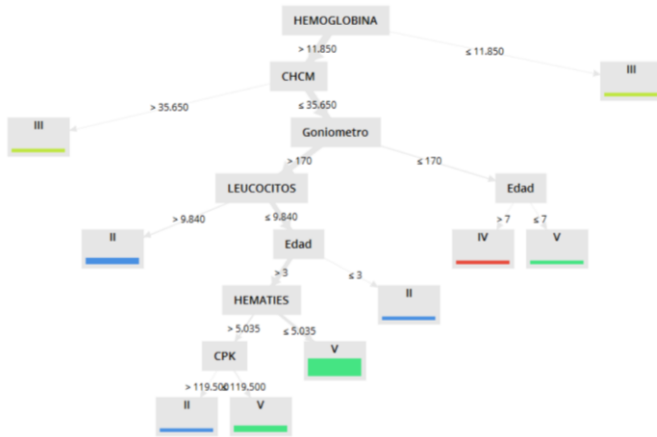


Fig. 3 Árbol de decisión para la Clasificación en Rapidminer.

#### D. Evaluación del Rendimiento

Para la validación se ha utilizado el operador de *performance*, que se utiliza para la evaluación del desempeño. Ofrece una lista de valores de criterios de rendimiento. Estos criterios de rendimiento se determinan automáticamente para adaptarse al tipo de tarea de aprendizaje.

A diferencia de otros operadores de evaluación de rendimiento como el operador de rendimiento (clasificación), el operador de rendimiento (clasificación binominal) o el operador de rendimiento (regresión), este operador se puede utilizar para todo tipo de tareas de aprendizaje. Determina automáticamente el tipo de tarea de aprendizaje y calcula los criterios más comunes para ese tipo.

El criterio para las tareas de clasificación es la Exactitud. La precisión general, exactitud, se utiliza para resumir el rendimiento de clasificación general para todas las clases. Se define según Ec. (1):

$$exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Donde:

- TP: True Positive (Verdaderos Positivos)
- FP: False Positive (Falsos Positivos)
- TN: True Negative (Verdaderos Negativos)
- FN: True Negative (Falsos Negativos)

Así mismo se utilizó el Coeficiente kappa de Cohen, que permite medir la concordancia entre dos examinadores en sus correspondientes clasificaciones de  $N$  elementos en  $C$  categorías.

La ecuación para el coeficiente  $\kappa$  se representa en la Ec. (2):

$$\kappa = \frac{\Pr(a) - \Pr(e)}{1 - \Pr(e)} \quad (2)$$

donde  $\Pr(a)$  es el acuerdo observado relativo entre los observadores, y  $\Pr(e)$  es la probabilidad hipotética de acuerdo por azar, utilizando los datos observados para calcular las probabilidades de que cada observador clasifique aleatoriamente cada categoría. Si los evaluadores están completamente de acuerdo, entonces  $\kappa = 1$ . Si no hay acuerdo entre los calificadores distinto al que cabría esperar por azar  $\kappa = 0$ .

#### IV. RESULTADOS

Según la evaluación realizada a nueve algoritmos populares de clasificación que se muestran en la Tabla I.

TABLA I  
EXACTITUD DE LOS ALGORITMOS DE CLASIFICACIÓN DE LOS NIVELES DE ACTIVIDAD FÍSICA

Algoritmo	Exactitud	Kappa
KNN	78.12	0.606
Gradiente Boosted tree	81.25	0.640
Decision Stump	62.50	0.193
Random Tree	81.25	0.647
Rule Induction	78.12	0.568
Improved Neural Net	90.62	0.836
Generalized Linear Model	93.75	0.891
SVM (Classification by Regression)	81.25	0.640
Análisis Discriminante Lineal	96.88	0.947

Según los resultados de la Tabla I se puede apreciar que, según los valores obtenidos de la exactitud, el algoritmo del Análisis Discriminante Lineal es el que obtiene el mejor resultado con un 96.88 de exactitud y un índice de Kappa de 0.947, lo que lo hace muy adecuado para realizar la clasificación del estudio.

En la Fig. 4 se aprecia la gráfica comparativa de todos los algoritmos de aprendizaje supervisado utilizados en el estudio con sus resultados de exactitud.




Fig. 4 Resultados de exactitud de los algoritmos de estudio.

En la Fig. 5 se aprecia el mejor resultado obtenido con el índice Kappa, donde se aprecia que el modelo discriminante lineal es el que alcanza el valor de 0.947.




Fig. 5 Resultados del índice de Kappa de los algoritmos de estudio.

La Fig 6. Muestra la matriz de confusión con los resultados obtenidos con el Vector de Performance del Análisis Discriminante Lineal (LDA), donde se aprecia que la exactitud alcanzada llega a 96.88 para las salidas de clasificación determinado por los niveles de GMFCS.

Table View Plot View

accuracy: 96.88%

	true II	true V	true III	true IV	class precision
pred. II	8	0	0	0	100.00%
pred. V	0	18	1	0	94.74%
pred. III	0	0	3	0	100.00%
pred. IV	0	0	0	2	100.00%
class recall	100.00%	100.00%	75.00%	100.00%	

Fig. 6 Vector de Performance del Análisis Discriminante Lineal (LDA).

## CONCLUSIONES

De acuerdo al objetivo planteado en el trabajo de investigación y a los resultados obtenidos en la comparación realizada a los nueve algoritmos populares de clasificación de las técnicas del aprendizaje supervisado, se desarrolló modelos con los algoritmos, donde el método de Análisis Discriminante Lineal es el algoritmo que mejor exactitud presenta con un resultado del 96.88, además generó un valor de índice Kappa de 0.947 para la clasificación de los niveles de la función motora gruesa en niños, que determina que las evaluaciones están próximas a estar de acuerdo.

Estos resultados son importantes ya que permiten superar la subjetividad de la clasificación de los niveles del grado de la función motora gruesa y que puede ser utilizado por los especialistas e interesados en la materia.

La presente investigación reforzó los conocimientos acerca de la utilidad de los algoritmos de aprendizaje automático para la exactitud en la clasificación de los niveles GMFCS.

## TRABAJOS FUTUROS

Se recomienda realizar la experimentación, en lo posible, con una cantidad más amplia de pacientes que presenten PC donde se puedan aplicar el uso de otros algoritmos de clasificación de aprendizaje supervisado, como explorar modelos más complejos de redes neuronales y SVM que permitan comparar los resultados obtenidos en la clasificación de niveles de GMFCS.

## AGRADECIMIENTOS

A la Universidad Católica de Santa María, Arequipa-Perú quien ha financiado el proyecto aprobado con 25789-R-2018-UCSM por el financiamiento otorgado para el desarrollo del artículo.

## REFERENCIAS

- [1] S. K. Stackhouse, S. A. Binder-Macleod, and S. C. K. Lee, "Voluntary muscle activation, contractile properties, and fatigability in children with and without cerebral palsy," *Muscle and Nerve*, 2005.
- [2] S. Winter, A. Autry, C. Boyle, and M. Yeargin-Allsopp, "Trends in the prevalence of cerebral palsy in a population-based study," *Pediatrics*, 2002.
- [3] R. Palisano, P. Rosenbaum, S. Walter, D. Russell, E. Wood, and B. Galuppi, "Development and reliability of a system to classify gross motor function in children with cerebral palsy," *Dev. Med. Child Neurol.*, 2008.
- [4] S. Duan, X. Mu, Q. Huang, Y. Ma, and B. Shan, "Occult Spastic Diplegic Cerebral Palsy Recognition Using Efficient Machine Learning for Big Data and Structural Connectivity Abnormalities Analysis," *J. Med. Imaging Heal. Informatics*, 2018.
- [5] J. Zhang, "Multivariate analysis and machine learning in cerebral palsy research," *Frontiers in Neurology*, 2017.
- [6] C. M. Bertoni, P. Altamura, E. R. Vieira, D. Bertoni, S. Thummler, and F. Solla, "Identifying Factors Associated With Severe Intellectual Disabilities in Teenagers With Cerebral Palsy Using a Predictive Learning Model," *J. Child Neurol.*, 2019.
- [7] E. I. et al., "Machine learning based prediction of ambulatory versus non-ambulatory motor function in children with cerebral palsy," *Dev. Med. Child Neurol.*, 2019.
- [8] S. G. Trost, M. Frigala-Pinkham, N. Lennon, and M. E. O'Neil, "Decision trees for detection of activity intensity in youth with cerebral palsy," *Med. Sci. Sports Exerc.*, 2016.
- [9] J. Stout and T. Novacheck, "Assignment of Gross Motor Function Classification (GMFCS) Level Using an Algorithm Based on GMFCS Descriptors and Functional Skills," *Gait Posture*, 2017.
- [10] M. Ahmadi, M. O'Neil, M. Frigala-Pinkham, N. Lennon, and S. Trost, "Machine learning algorithms for activity recognition in ambulant children and adolescents with cerebral palsy," *J. Neuroeng. Rehabil.*, 2018.
- [11] M. H. Schwartz and M. E. Munger, "ESMAC BEST PAPER 2017: Using machine learning to overcome challenges in GMFCS level assignment," *Gait Posture*, 2018.
- [12] I. Bakaniene, G. Urbonaviciene, K. Janaviciute, and A. Prasauskienė, "Effects of the Interventions method on gross motor function in children with spastic cerebral palsy," *Neurol. Neurochir. Pol.*, 2018.

- [13] A. Hegazy, P. Karabelas, and A. Selim, "EFFECTIVE PREDICTION OF OSTEOPOROSIS RISK IN CEREBRAL PALSY CHILDREN," *J. Sci.*, 2016.
- [14] C. J. Idoine, P. Krensky, E. Brethenoux, J. Hare, S. Sicular, and S. Vashisth, "Magic Quadrant for Data Science and Machine-Learning Platforms," *Gartner*, 2018.
- [15] Rapidminer, "RapidMiner | Best Data Science & Machine Learning Platform," 2020. [Online]. Available: <https://rapidminer.com/>. [Accessed: 20-Feb-2020].
- [16] E. Desailly, O. C. Galarraga, and N. Khouri, "Improving multilevel surgery planning and predicting post-operative outcome in cerebral palsy," *Comput. Methods Biomech. Biomed. Engin.*, 2017.
- [17] L. Lombardo, M. Cama, C. Conoscenti, M. Märker, and E. Rotigliano, "Binary logistic regression versus stochastic gradient boosted decision trees in assessing landslide susceptibility for multiple-occurring landslide events: application to the 2009 storm event in Messina (Sicily, southern Italy)," *Nat. Hazards*, 2015.
- [18] R. C. Holte, "Very Simple Classification Rules Perform Well on Most Commonly Used Datasets," *Mach. Learn.*, 1993.
- [19] L. Breiman, "Random forests," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001.
- [20] K. Yoo, S. K. Shukla, J. J. Ahn, K. Oh, and J. Park, "Decision tree-based data mining and rule induction for identifying hydrogeological parameters that influence groundwater pollution sensitivity," *J. Clean. Prod.*, 2016.
- [21] L. Lv, "An improved neural network algorithm for acceleration sensor to recognize human posture," *J. Discret. Math. Sci. Cryptogr.*, 2018.
- [22] P. Coker, T. Karakostas, C. Dodds, and S. Hsiang, "Gait characteristics of children with hemiplegic cerebral palsy before and after modified constraint-induced movement therapy," *Disabil. Rehabil.*, 2010.
- [23] J. Kamruzzaman and R. K. Begg, "Support vector machines and other pattern recognition approaches to the diagnosis of cerebral palsy gait," *IEEE Trans. Biomed. Eng.*, 2006.