

Machine learning for the classification of motor competence with wearable technology in schoolchildren

José Sullá-Torres, Dr¹, Alexander Paul Calla Gamboa¹, Christopher Avendaño Llanque¹, and Manuel Zúñiga Carnero, Dr¹

¹Ingeniería de Sistemas, Universidad Católica de Santa María, Arequipa, Perú
jsullato@ucsm.edu.pe, 71731434@ucsm.edu.pe, christopher.avendano@ucsm.edu.pe, mzunigac@ucsm.edu.pe

Abstract– Personal health can be determined by adequate physical activity; Motor competence is an important aspect to help this and must be carried out from school days. The objective of this study was to assess motor competence with wearable technology, generate the percentiles of the evaluation metrics, and classify motor performance using machine learning techniques in primary and secondary school children. For this, smart bands were used as wearable technologies for data capture during the evaluation of motor skills tests in schoolchildren from educational centers. The CRISP-DM methodology was followed, the data set consisted of 485 schoolchildren between 7 and 18 years of age. As a result of the application of machine learning algorithms, the best precision was achieved with the decision tree with 96.97% in the classification of motor performance in these students. It is concluded that the use of smart bands allows better precision in data capture and processing to better classify motor skills tests in schoolchildren and can be used by interested persons.

Keywords-- Machine Learning, Smart Band, Motor competence, Wearable Technology.

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

Aprendizaje automático para la clasificación de la competencia motora con tecnología vestible en escolares

José Sullato-Torres, Dr¹, Alexander Paul Calla Gamboa¹, Christopher Avendaño Llanque¹, and Manuel Zúñiga Carnero, Dr¹

¹Ingeniería de Sistemas, Universidad Católica de Santa María, Arequipa, Perú
jsullato@ucsm.edu.pe, 71731434@ucsm.edu.pe, christopher.avendano@ucsm.edu.pe, mzunigac@ucsm.edu.pe

Resumen—La salud personal puede estar determinada por una adecuada actividad física; la competencia motora es un aspecto importante para ayudar a ello y debe ser realizado desde la época escolar. El objetivo del presente estudio fue evaluar la competencia motora con tecnología vestible, generar los percentiles de las métricas de evaluación y clasificar el desempeño motriz mediante técnicas de aprendizaje automático en escolares de primaria y secundaria. Para ello se utilizaron las bandas inteligentes como tecnologías vestibles para la captura de datos durante la evaluación de las pruebas de competencia motora en escolares de centros educativos. Se siguió la metodología de CRISP-DM, el conjunto de datos fue de 485 escolares entre 7 y 18 años. Como resultado de la aplicación de algoritmos de aprendizaje automático, la mejor precisión se logró con el árbol de decisión con un 96.97% en la clasificación del desempeño de la motricidad en estos estudiantes. Se concluye que el uso de las bandas inteligentes permite una mejor precisión en la captura de datos y su procesamiento para clasificar de una mejor manera las pruebas de competencia motora en escolares y puedan ser utilizados por las personas interesadas.

Palabras clave—Aprendizaje automático, Bandas inteligentes, Competencia Motora, Tecnología vestible.

I. INTRODUCCIÓN

La salud personal es una medida del estado del ser humano que permite determinar que tan bien se encuentra una persona o es susceptible a padecer de alguna enfermedad. La competencia motora es una base del comportamiento motor humano que permite realizar actividades diarias laborales o recreativas, éstas pueden ser habilidades motrices finas y gruesas que ayudan a estar bien físicamente [1].

El gran avance de la tecnología nos permite ayudar a la mejora de vida en general además de lograrse permitir recoger datos de manera más exacta y amplia [2], el uso de las bandas inteligentes nos permite recoger datos importantes sobre el estado físico de las personas logrando así poder tener un control de datos bueno, además de utilizarlos con técnicas de aprendizaje automático.

El aprendizaje automático es un área de la inteligencia artificial que utiliza métodos estadísticos para la clasificación de datos, segmentación, regresión, entre otros. Pudiendo ser supervisado o no supervisado. Se han aplicado varias técnicas de aprendizaje automático para predecir enfermedades y han demostrado una mayor precisión para el diagnóstico que los métodos clásicos. Estas técnicas permiten clasificar grandes

cantidades de datos de una forma muy útil [3].

Sin embargo, el uso de las bandas inteligentes no es de gran demanda en los centros educativos, teniendo en cuenta que gran parte de herramientas tecnológicas no son usadas debido a su desconocimiento o su falta de uso,

Por otro lado, la evaluación de la competencia motora tradicional suele fallar debido a no poseer estos datos importantes que nos ayudan a verificar si se está bien o no la evaluación. La incorporación de otros atributos como la frecuencia cardíaca, ritmo medio, calorías, cadencia, etc, puede optimizarse con el uso de técnicas del aprendizaje automático para su mejor clasificación [4], a partir de los datos de las bandas inteligentes y así lograr una buena evaluación de la competencia motora en los escolares.

Por tal motivo es que el presente estudio tiene como objetivo evaluar las pruebas de competencia motora con tecnología vestible utilizando las técnicas de aprendizaje automático para su clasificación en escolares de centros educativos primaria y secundaria. Para ello se utilizará las bandas inteligentes como tecnologías vestibles para la captura de datos utilizando sus sensores durante la evaluación de las pruebas de competencia motora para luego clasificar su desempeño utilizando las técnicas de aprendizaje automático y determinar su precisión.

II. TRABAJOS RELACIONADOS

A continuación, se presentan los trabajos más relacionados con el tema de estudio.

Wang, Lizardo y Hachen [5], demuestran que las características sociales, psicológicas, ambientales tiene relación con la actividad física entre los universitarios, utilizando una muestra de 692 alumnos por menos de 2 años, tomando por 4 indicadores demostraron que existe una fuerte relación el crecimiento de actividad física grupal que individual.

En [6], se categorizan las investigaciones realizadas de dispositivos portátiles asequibles, realizaron una revisión de alcance para comprender el consumo, encontrando 7499 artículos, de los cuales se usaron criterios quedando 179 estudios con 189 dispositivos portátiles demostrando han indicado que los grandes datos extraídos de los dispositivos portátiles pueden potencialmente transformar la comprensión de la dinámica de la salud de la población, la capacidad de

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

pronosticar tendencias de salud y falta investigaciones sobre dispositivos portátiles en contextos de bajos recursos.

En el trabajo de Ezakia et al. [7], combinan estrategias conductuales, individuales y grupales para promover la actividad física, utilizando relojes inteligentes creados con esa finalidad, a través de encuestas, programas de entrenamiento y los indicadores del reloj, mostró un resultado, donde existe un mayor desempeño con grupos menores y capacitadores proactivos y competitivos tuvieron una retroalimentación en los rangos de los equipos pasando lo esperado. Demuestra que hay un mejor desempeño en cuanto a la canalización de estrategias basadas en dinámicas grupales como la competencia, la cooperación, la interacción y la comunicación.

Sun y Liu [8], examinaron la confiabilidad y validez en el uso de pulseras inteligentes Fizzo para medir la frecuencia cardíaca en lecciones de educación física. El método fue por dos estudios, uno de correr en cinta y el otro en hacer diferente ejercicio educación física, utilizando dos Fizzos uno en cada muñeca y un Polar para la validez, mostraron los resultados donde es excelente en el primer estudio y moderada en el segundo. El factor principal que afecta la confiabilidad y validez del dispositivo no es por la intensidad de la actividad física sino el tipo de actividad física. Se necesita más investigación para determinar qué tipos de actividad física afectan la confiabilidad y la validez. En última instancia, el Fizzo es preciso, cómodo de usar, fácil de poner y quitar, y tiene un alto valor de aplicación en un entorno de lección de educación física.

El artículo de Creaser et al. [9] muestra que los dispositivos de tecnología vestible (wearables) incorporan numerosas técnicas de cambio, dado que son pocos niños y adolescentes logran las pautas de la actividad física. Revisa la aceptabilidad, viabilidad y la eficacia física en las personas de 5 a 19 años. Los niños y adolescentes informaron dificultades técnicas y un efecto novedoso al usar dispositivos portátiles, lo que puede afectar el uso a largo plazo de los dispositivos portátiles más rigurosos y a largo plazo que investiguen la aceptabilidad, la viabilidad y la eficacia.

En el estudio de Qiu, Wang y Xie [10] se hizo una comparativa amplia sobre diferentes dispositivos portátiles inteligentes, pulseras inteligentes, relojes inteligentes, entre otros, que sirven para poder medir diferentes cantidades de datos además de lograr ayudar a diferentes aspectos de la vida en su uso.

Lee et al. [11], en este estudio se verificó cambios afectivos y de sentimientos mientras se realiza un cambio de acondicionamiento físico, en este caso un programa zumba, se hizo la prueba en 16 participantes mediante el uso de smartwatch sincronizados con celulares inteligentes, y el uso de una aplicación inteligente para medir recursos humanos de afecto y control por parte del reloj inteligente, recopilando datos de este. Se logró comprobar el efecto positivo del ejercicio y se logró medir el afecto en tiempo real durante este. Se concluye que Zumba Fitness activo el afecto positivo y excitación en los participantes, además de que el ejercicio

grupala ayuda a mejorar respuestas afectivas, recomendando así incorporar una varias de ritmos basados en zumba.

En el trabajo de Bat-Erdene y Saver [12] examinan los recientes avances en detección automática de síntomas de accidentes cardiovasculares agudos, se hizo mediante una revisión narrativa, donde se dieron por resultados la activación tardía de EMS (sistemas médicos de emergencia) para los síntomas del accidente cerebrovascular por parte de pacientes y testigos, aquí es donde se realiza la revisión a 11 tecnologías de detección, y 10 factores de forma de dispositivos de consumo como smartwatches, entre otros. Se concluye que las nuevas tecnologías han llegado a una serie de tecnologías de salud que pueden detectar accidentes cardiovasculares y activar la EMS.

En el artículo de Wang et al. [13] se informó de un protocolo de estudio para un ensayo multisitio con componentes de intervención e interfaz de salud, interfaz utilizada para integrar datos de autocontrol del paciente recopilado de un rastreador inteligente y su aplicación a un teléfono inteligente. Se hizo mediante un ensayo clínico multisitio de 3 meses con pacientes elegibles con diabetes mellitus. Como resultados se desarrolló con éxito un rastreador de actividad física con una aplicación de teléfono inteligente complementaria para el autocontrol de nutrición, Concluyen que los resultados del ensayo muestran eficacia preliminar y la facilidad de uso del sistema conectado.

Xie et al. [14] evaluaron la precisión de dispositivos portátiles relacionados al estado físicos en diversas actividades. Esto mediante 44 sujetos sanos donde cada uno usaba 6 dispositivos, y 2 teléfonos inteligentes, para luego estos ser comparados con el estándar oro, calculando sus errores porcentuales absolutos (MAPE). Demostrando que estos dispositivos tuvieron una precisión de medición bastante alta con respecto a la frecuencia cardíaca, estas mediciones variaron de manera insignificante para el mismo indicador en diferentes estados de actividad. Se concluye que los dispositivos pueden medir de manera confiable la frecuencia cardíaca, número de pasos entre otros, aunque el consumo de energía aún es inadecuado.

Dandapani et al. [15] aprovecharon el uso de los sensores móviles para la investigación clínica para obtener medidas de salud y actividad para el control, la prevención y el tratamiento de enfermedades; presenta un marco rentable de código abierto que captura actividades y rutinas diarias que utiliza algoritmos ponibles. Esto se probó mediante el uso del reloj inteligente Bangle.js a 12 personas, quienes usaron los relojes a la hora de su elección todos los días.

En [16] se realizó un estudio de campo de un año de duración, se recogió la frecuencia cardíaca instantánea nocturna de 9 participantes utilizando pulseras inteligentes comerciales y se extrajeron las características de la variabilidad de la frecuencia cardíaca (VFC). Además, se midió la temperatura corporal central utilizando un sensor de temperatura flexible diseñado a medida y la SpO2 con un oxímetro de pulso de dedo. La temperatura corporal central, junto con los síntomas notificados por el usuario, se han

utilizado para el seguimiento espacio temporal automatizado de la gravedad de los síntomas de la gripe en tiempo real. Los valores de las características de la VFC extraídas están dentro del intervalo de confianza del 95% de los valores normativos y muestran una tendencia anticipada para el género y la edad.

En el trabajo de Beltrame et al. [17] estudia si la actividad física está relacionada con la demanda energética, para esto se realiza una pruebas con 13 hombres sanos donde realizaron protocolos de ejercicio moderado controlador durante 6 horas por día, en 4 días, los datos recopilados fueron procesados mediante un modelo de regresión aplicando el modelo de “bosque aleatorio”, concluyendo que los datos tenían una alta correlación entre estos, todo controlado por laboratorio, donde concluyeron que el sistema aeróbico se puede investigar mediante actividades no supervisadas con dispositivos portátiles, además de afirmar que los algoritmos de aprendizaje automático tienen un gran potencial para la detección de cambios de salud en sus usuarios.

En cuanto a la metodología utilizada, en [18] en esta investigación se utilizó la metodología Crisp.DM para predecir la duración de la estadía hospitalaria médica, en este caso se utilizó para la gran cantidad de datos que se pueden recopilar en estos hospitales, donde mediante esta metodología logran el uso de los datos para cumplir sus objetivos.

III. MATERIALES Y MÉTODOS

Para el desarrollo del proyecto se efectuó un estudio transversal con la metodología Crisp-DM [19], que es una metodología enfocada a la minería de datos, aplicable a la realización de aprendizaje automático, lo cual servirá para poder realizar las actividades del estudio propuesto.

Esta metodología comprende una serie de fases que se muestran en la Fig 1.

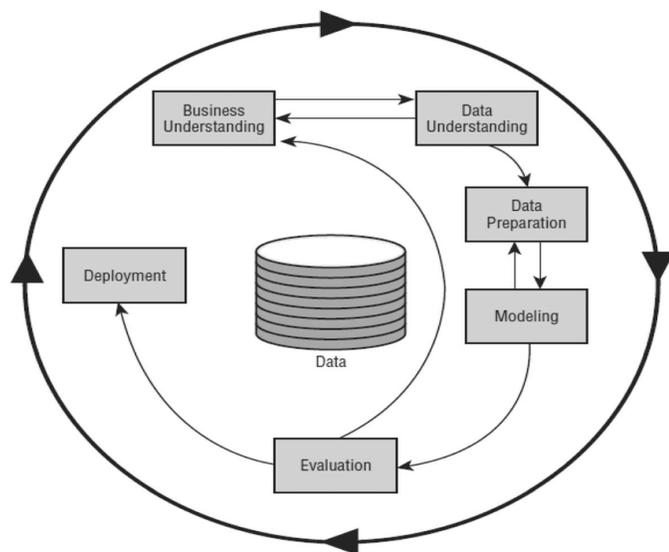


Fig. 1 Fases de CRISP-DM [19]

A. Comprensión del negocio.

En esta fase se alinean los objetivos del proyecto, tratando de enfocarnos en lo que realmente se desea realizar y no llegar hacia otros fines.

El objetivo principal de este trabajo es la de aplicar técnicas de aprendizaje automático para evaluar la competencia motora de los escolares utilizando bandas inteligentes como tecnología vestible.

Se utilizaron 30 bandas inteligentes capaz de obtener datos de manera eficaz de cualquier persona, estos se utilizarán en los escolares para obtener datos durante las pruebas de competencia motora. Las mismas que se utilizaron en los centros educativos para lograr obtener datos de estos escolares se siguieron los protocolos con permiso de colegios y la medición para la obtención de datos.

Con los datos recolectados y procesados con las técnicas de aprendizaje automático, se podrán lograr realizar clasificaciones y/o predicciones del estado de la competencia motora de los escolares.

B. Compresión de los datos.

En esta fase debemos conocer los datos, su distribución y su estructura.

1) **Población:** Alumnos de entre 7 y 18 años de los centros educativos de la provincia de Arequipa-Perú.

Método de muestreo: No probabilístico con un total de 485 escolares.

2) **Métodos, Técnicas e Instrumentos de Recolección de Datos**

Se utilizaron 2 técnicas en específico: Documental, donde tomaremos como referencia la cantidad de documentos que podemos encontrar el fin de recopilar información útil para el proyecto. Esto se hará en las bases de datos documentales como: SCOPUS, IEEE, Scienedirect, etc.

Las bandas inteligentes, como tecnologías vestibles, permite capturar los datos precisos al momento de que los alumnos los utilicen. Se obtendrán datos con el uso de Smart bands en colegios de Arequipa en diferentes grados de primaria y secundaria. La banda inteligente utilizada fue la Huawei band 6 y 7 con pantalla AMOLED de 1.47 pulgadas y 194 x 368 pixeles, con sensor de aceleración, sensor giroscópico y sensor óptico de frecuencia cardiaca (Fig 2), que brinda la tecnología True series para la salud y bienestar.

Se inició la recopilación de datos en los centros educativos seleccionados para el estudio utilizando las bandas inteligentes, con una muestra de 485 escolares.



Fig. 2 Smart Bands Huawei 7 [20]

Cada registro de datos tiene los siguientes atributos dentro de la base de datos:

- 1) *Datos antropométricos*: Edad (años), Peso (kg), Estatura (m), Estatura sentado (cm), y Circunferencia Cintura (cm).
- 2) *Ritmo medio*: son el tiempo en el que la persona pueda caminar un kilómetro, vienen a ser número en formato de minutos y segundos.
- 3) *Cadencia media*: son los pasos por minutos que pueda hacer, vienen a ser números sin formato.
- 4) *Pasos*: son todos los pasos que haya realizado la persona durante la actividad, vienen a ser números sin formato.
- 5) *Calorías*: son aquellas calorías que la persona haya quemado durante la actividad, vienen a ser números sin formatos.
- 6) *Velocidad media*: es el promedio de velocidad en el que se haya desplazado la persona durante la actividad en kilómetros/hora, está en formato de número con decimales sin formatos
- 7) *Zancada media*: es el promedio de distancia que haya dado cada paso, vienen a ser números sin formatos
- 8) *Frecuencia cardíaca*: estas son las pulsaciones por minuto que haya dado el corazón durante la actividad, vienen a ser números sin formatos.
- 9) *Frecuencia cardíaca máxima*, esta es la máxima cantidad de pulsaciones por minuto que haya dado el individuo en la actividad, vienen a ser números sin formatos.

La estadística descriptiva antropométricas del conjunto de datos se muestran en la Tabla I.

TABLA I
ESTADÍSTICA DESCRIPTIVA ANTROPOMÉTRICAS DE LOS ESCOLARES

| index | Edad (años) | Peso (kg) | Estatura (m) | Estatura sentada (cm) | Circunf. Cintura (cm) |
|-------|-------------|-----------|--------------|-----------------------|-----------------------|
|-------|-------------|-----------|--------------|-----------------------|-----------------------|

| index | Edad (años) | Peso (kg) | Estatura (m) | Estatura sentada (cm) | Circunf. Cintura (cm) |
|-------|-------------|-----------|--------------|-----------------------|-----------------------|
| count | 485 | 485 | 485 | 485 | 485 |
| mean | 13.0 | 50.33 | 1.51 | 79.31 | 72.92 |
| std | 2.9 | 15.50 | 0.14 | 7.88 | 10.74 |
| min | 7.0 | 18.0 | 1.11 | 58.0 | 51.0 |
| 25% | 11.0 | 40.0 | 1.43 | 74.0 | 66.0 |
| 50% | 14.0 | 51.3 | 1.55 | 81.0 | 71.1 |
| 75% | 15.0 | 59.9 | 1.62 | 85.0 | 79.0 |
| max | 18.0 | 111.7 | 1.82 | 95.5 | 119.8 |

C. Preparación de los datos.

El objetivo principal de esta fase es lograr obtener los datos finales sobre los cuales aplicaremos las técnicas de aprendizaje automático.

Una vez capturado los datos, se procedió a limpiar y normalizar según la información de las bandas inteligencias, a través de su App Health compatible con Android 6.0 y iOS 9.1 o posterior.

Los ejercicios elegidos para las pruebas de competencia motora fueron:

- 1) *Caminata Libre*: ejecutada durante el momento de los recreos que en la mayoría de los casos tiene una duración de 15 minutos (Tabla II).
- 2) *Caminata de 6 min ida y vuelta*: A una distancia de 30 metros y con una separación por cada escolar de un metro se recorre ida y vuelta durante 6 minutos (Tabla III).

TABLA II
DATOS DE LA PRUEBA DE CAMINATA LIBRE POR 15 MIN. DE LOS ESCOLARES

| index | Cadencia media | Calorías | Velocidad Media (km/h) | Zancada media (cm) | Frecuencia Cardíaca media |
|-------|----------------|----------|------------------------|--------------------|---------------------------|
| count | 485 | 485 | 485 | 485 | 485 |
| mean | 55.84 | 89.73 | 3.08 | 78.17 | 121.45 |
| std | 31.52 | 43.472 | 7.13 | 9.06 | 49.41 |
| min | 5.0 | 17.0 | 0.1 | 53.0 | 66.0 |
| 25% | 29.0 | 54.0 | 1.23 | 72.0 | 101.0 |
| 50% | 52.0 | 82.0 | 2.53 | 78.0 | 115.0 |
| 75% | 79.0 | 119.0 | 3.99 | 84.0 | 139.0 |
| max | 145.0 | 252.0 | 155.0 | 118.0 | 1075.0 |

TABLA III
DATOS DE LA PRUEBA DE CAMINATA 6 MIN. IDA Y VUELTA DE LOS ESCOLARES

| index | Cadencia media | Pasos | Calorías | Veloc. Media (km/h) | Zancada media (cm) | Frecue. Cardíaca media |
|-------|----------------|--------|----------|---------------------|--------------------|------------------------|
| count | 485 | 485 | 485 | 485 | 485 | 485 |
| mean | 114.86 | 752.38 | 50.62 | 5.31 | 76.90 | 124.41 |
| std | 48.68 | 352.41 | 27.13 | 1.27 | 7.76 | 19.85 |

| index | Cadencia media | Pasos | Calorías | Veloc. Media (km/h) | Zancada media (cm) | Frecue. Cardíaca media |
|-------|----------------|--------|----------|---------------------|--------------------|------------------------|
| min | 12.0 | 102.0 | 18.0 | 1.53 | 52.0 | 83.0 |
| 25% | 101.0 | 623.0 | 32.0 | 4.35 | 71.0 | 110.0 |
| 50% | 110.0 | 687.0 | 47.0 | 5.14 | 77.0 | 120.0 |
| 75% | 125.0 | 803.0 | 59.0 | 6.16 | 81.0 | 136.0 |
| max | 1106.0 | 6683.0 | 221.0 | 8.98 | 104.0 | 188.0 |

D. Modelado.

En esta fase se tiene que construir un modelo de datos que nos permita alcanzar los objetivos del proyecto que estamos realizando. En la Fig 3 se muestra el modelo propuesto.

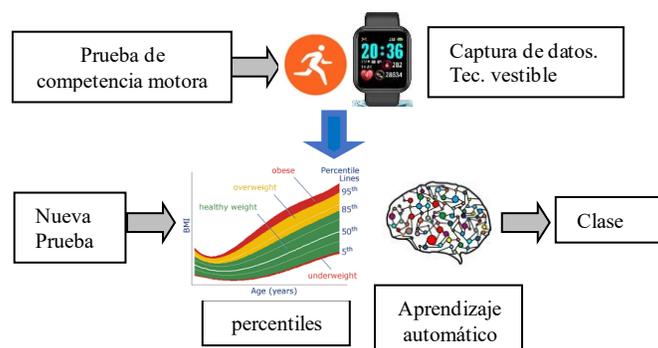


Fig. 3 Modelo de clasificación de competencia motora con tecnología vestible y aprendizaje automático.

Para ello se elaboró los percentiles P15, P50 y P85 (Tabla IV) con relación a las métricas de competencia motora: Cadencia media (Fig 4), Pasos (Fig 5), Velocidad Media (Fig 6) y Zancada media (Fig 7)

TABLA IV
PERCENTILES DE MÉTRICAS DE COMPETENCIA MOTORA DE LOS ESCOLARES

| Métrica | Edad Escolar | | | | | | | | | | | |
|------------------------|--------------|------|-------|-------|-------|--------|--------|-------|--------|--------|-------|-------|
| | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 |
| Cadencia media | | | | | | | | | | | | |
| p15 | 123.6 | 112 | 126.1 | 122.6 | 120.6 | 88 | 100 | 101.1 | 95 | 93.95 | 93.4 | 85.2 |
| p50 | 131.5 | 134 | 140 | 135 | 134 | 101 | 112.5 | 108 | 104.5 | 101 | 99 | 98 |
| p85 | 143.1 | 143 | 149.2 | 148 | 140.7 | 114.75 | 126.3 | 119.9 | 115.85 | 110 | 106 | 108.8 |
| Pasos | | | | | | | | | | | | |
| p15 | 759 | 715 | 805.1 | 760 | 770.8 | 689.5 | 623.35 | 604.2 | 582.9 | 575.9 | 556.2 | 529.4 |
| p50 | 814.5 | 807 | 886 | 857 | 828 | 1306 | 706 | 667 | 641.5 | 615.5 | 601 | 595 |
| p85 | 888.65 | 908 | 945.3 | 917 | 875.5 | 1773 | 807.55 | 728.9 | 713.65 | 665.1 | 639.8 | 658.6 |
| Velocidad Media | | | | | | | | | | | | |
| p15 | 5.716 | 5.21 | 5.857 | 5.974 | 5.766 | 3.925 | 4.509 | 4.26 | 3.9715 | 3.7295 | 3.646 | 3.01 |
| p50 | 6.425 | 6.74 | 7.39 | 6.56 | 6.6 | 4.99 | 5.45 | 5.02 | 4.64 | 4.31 | 4.1 | 4.09 |
| p85 | 7.98 | 7.47 | 8.163 | 8.204 | 7.282 | 5.7075 | 6.663 | 5.643 | 5.5095 | 5 | 4.778 | 4.834 |
| Zancada media | | | | | | | | | | | | |
| p15 | 79 | 78 | 78 | 78 | 78 | 75.25 | 73 | 69 | 68 | 65.95 | 64.2 | 60 |
| p50 | 81.5 | 82 | 86 | 81 | 82 | 82 | 79 | 75 | 73.5 | 71 | 69 | 66 |
| p85 | 93.8 | 87 | 93.5 | 86.8 | 87 | 89 | 86.65 | 80.9 | 78 | 75 | 74.8 | 75.2 |

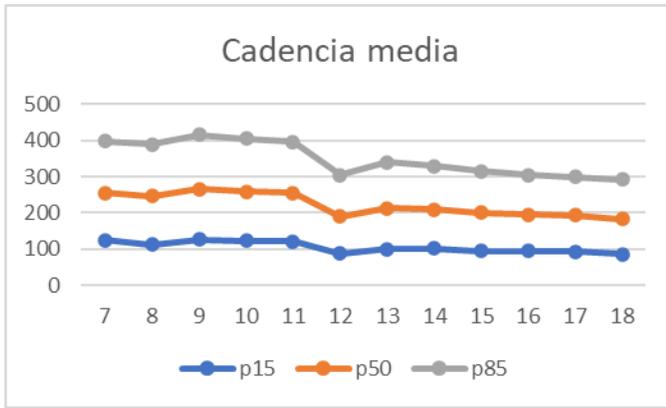


Fig. 4 Percentil de Cadencia media en prueba de caminata de los escolares

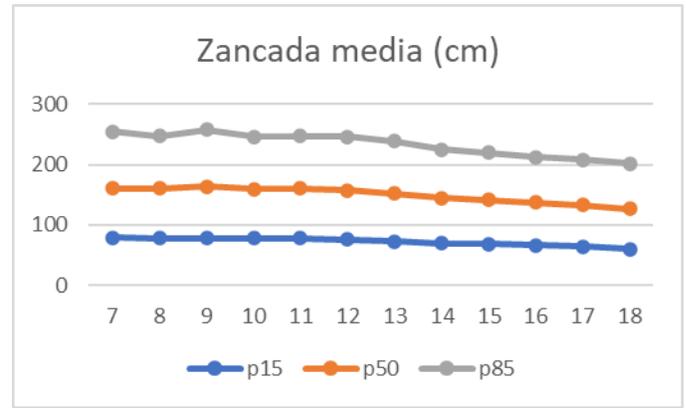


Fig. 7 Percentil de Zancada media en prueba de caminata de los escolares

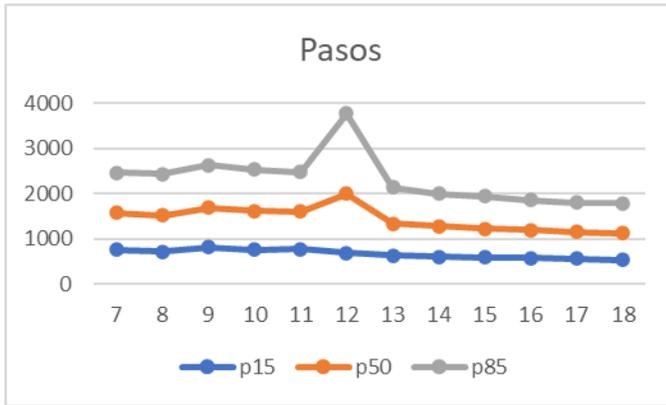


Fig. 5 Percentil de Pasos en prueba de caminata de los escolares

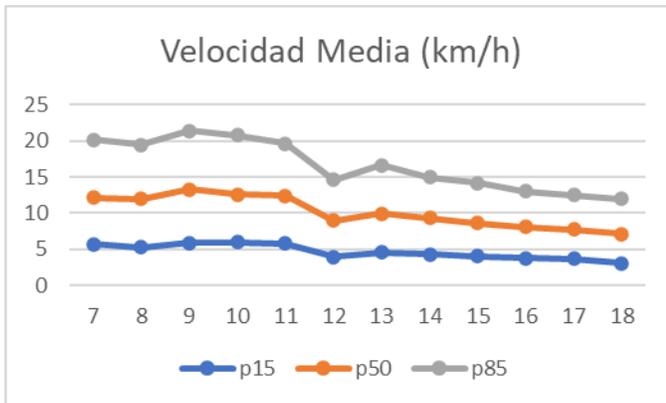


Fig. 6 Percentil de Velocidad media en prueba de caminata de los escolares

Los percentiles generados permiten realizar la clasificación de la competencia motora de los escolares, considerando las clases: Bajo (<p15), Normal (>p15 y <p85) y Alto (>p85).

E. Evaluación.

En esta fase tenemos que evaluar el uso de los algoritmos de aprendizaje automático y sus resultados en cuanto a la precisión. Se seleccionaron algoritmos de clasificación de aprendizaje automático populares en la clasificación como Vecinos más cercanos (KNN), árboles de decisión, DecisionTable, y JRip, que permitan obtener la precisión de la operación con los datos procesados y preparados según los percentiles generados. El grupo de entrenamiento fue del 66% y el grupo de prueba fue del 34%. Se utilizó la herramienta de Google Colab [21] y Weka para realizar las operaciones de clasificación, lo que se muestran en la Tabla V.

TABLA V
RESULTADO DE LA PRECISIÓN DE LA CLASIFICACIÓN DE LOS ALGORITMOS DE APRENDIZAJE AUTOMÁTICO

| Algoritmo | Precisión |
|--------------------------|-----------|
| Arbol de decisión | 96.97% |
| Vecino mas cercano (KNN) | 90.90% |
| NaiveBayes | 91.52% |
| DecisionTable | 95.15% |
| JRip | 92.72% |

De la evaluación realizada se puede apreciar que el algoritmo de árbol de decisión es la que muestra la mejor precisión con un 96.97%, lo cual confirma los resultados en estudios similares.

IV. CONCLUSIONES

Con el uso de las bandas inteligentes Huawei Band 6/7 se pudo recopilar datos de 485 escolares de diferentes edades entre primaria y secundaria, donde se recopiló datos de manera precisa y eficiente como frecuencia cardiaca, conteo de pasos, calorías, entre otros.

En base a los datos recopilados, antropométricos y de competencia motora, se pudo desarrollar modelos de

clasificación y entrenar con una herramienta de aprendizaje automático que nos permite evaluar el rendimiento de la competencia motora en escolares de primaria y secundaria

Se construyeron los percentiles con las métricas relacionadas a la competencia motora como son la Cadencia, cantidad de pasos recorridas, velocidad y zancada medias, tomando en cuenta el percentil 15, 50 y 85 lo que permitió clasificar a los escolares en sus pruebas realizadas.

Se logró entrenar los algoritmos de árbol de decisión, vecino más cercano, Naive Bayes, Decision Table y JRip donde el mejor resultado de clasificación fue obtenido por el árbol de decisión con un 96.97% de precisión.

Se evidenció la correlación de datos que existen en lo que respecta a competencia motora en diferentes casos de registros de datos, además de lograr un estudio específico para usarse a futuro.

Con respecto a los resultados vistos, se concluye que los datos recopilados fueron eficaces para poder crear un conjunto de datos en condiciones, realizado tempranamente en centros educativos de primaria y secundaria que puede servir como referencia para futuros estudios.

Como trabajos futuros se recomienda ampliar el conjunto de datos, así como el uso de otras variables que los sensores de las bandas inteligentes capturan del comportamiento humano físico y puedan ser implementadas para su despliegue en una herramienta automatizada.

AGRADECIMIENTO

Se agradece al Vicerrectorado de Investigación de la Universidad Católica de Santa María, por el apoyo al proyecto “Desarrollo de una herramienta cuantitativa para la evaluación de la competencia motora utilizando tecnología vestible en escolares de la provincia de Arequipa”.

REFERENCES

[1] M. Cossio-Bolaños *et al.*, “Reproductibilidad de pruebas de competencia motriz y percentiles para niños y adolescentes que viven a altitud moderada del Perú,” *Arch. Argent. Pediatr.*, vol. 119, no. 2, Apr. 2021, doi: 10.5546/aap.2021.91.

[2] C. M. Durán Chinchilla, C. L. García Quintero, and A. A. Rosado Gómez, “El rol docente y estudiante en la era digital,” *Rev. Boletín Redipe*, vol. 10, no. 2, 2021, doi: 10.36260/rbr.v10i2.1213.

[3] P. Larrañaga *et al.*, “Machine learning in bioinformatics,” *Brief. Bioinform.*, vol. 7, no. 1, pp. 86–112, Mar. 2006, doi: 10.1093/bib/bbk007.

[4] J. Sulla-Torres, A. Bedoya-Carrillo, R. Gomez-Campos, and M. Cossio-Bolaños, “Clasificación de la densidad mineral ósea utilizando técnicas de aprendizaje automático en niños y adolescentes según edad y sexo,” in *Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology*, 2019, vol. 2019-July, doi: 10.18687/laccei2019.1.1.120.

[5] C. Wang, O. Lizardo, and D. S. Hachen, “Using Fitbit data to examine factors that affect daily activity levels of college students,” *PLoS One*,

vol. 16, no. 1 January, 2021, doi: 10.1371/journal.pone.0244747.

[6] S. Huhn *et al.*, “The Impact of Wearable Technologies in Health Research: Scoping Review,” *JMIR mHealth and uHealth*, vol. 10, no. 1. 2022, doi: 10.2196/34384.

[7] A. Esakia, S. McCrickard, S. Harden, M. Horning, and N. P. Ramalingam, “Using smartwatches to facilitate a group dynamics-based statewide physical activity intervention,” *Int. J. Hum. Comput. Stud.*, vol. 142, 2020, doi: 10.1016/j.ijhcs.2020.102501.

[8] J. Sun and Y. Liu, “Using smart bracelets to assess heart rate among students during physical education lessons: Feasibility, reliability, and validity study,” *JMIR mHealth uHealth*, vol. 8, no. 8, 2020, doi: 10.2196/17699.

[9] A. V. Creaser *et al.*, “The acceptability, feasibility and effectiveness of wearable activity trackers for increasing physical activity in children and adolescents: A systematic review,” *International Journal of Environmental Research and Public Health*, vol. 18, no. 12. 2021, doi: 10.3390/ijerph18126211.

[10] H. Qiu, X. Wang, and F. Xie, “A Survey on Smart Wearables in the Application of Fitness,” in *2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress (DASC/PiCom/DataCom/CyberSciTech)*, Nov. 2017, pp. 303–307, doi: 10.1109/DASC-PiCom-DataCom-CyberSciTec.2017.64.

[11] J. Lee, J. Park, Y. Kim, and M. Woo, “Affective Change With Variations in Zumba Fitness Intensity as Measured by a Smartwatch,” *Percept. Mot. Skills*, vol. 128, no. 5, 2021, doi: 10.1177/00315125211022700.

[12] B. O. Bat-Erdene and J. L. Saver, “Automatic Acute Stroke Symptom Detection and Emergency Medical Systems Alerting by Mobile Health Technologies: A Review,” *Journal of Stroke and Cerebrovascular Diseases*, vol. 30, no. 7. 2021, doi: 10.1016/j.jstrokecerebrovasdis.2021.105826.

[13] J. Wang, D. C. Coleman, J. Kanter, B. Ummer, and L. Siminerio, “Connecting smartphone and wearable fitness tracker data with a nationally used electronic health record system for diabetes education to facilitate behavioral goal monitoring in diabetes care: Protocol for a pragmatic multi-site randomized trial,” *JMIR Res. Protoc.*, vol. 7, no. 4, 2018, doi: 10.2196/10009.

[14] J. Xie, D. Wen, L. Liang, Y. Jia, L. Gao, and J. Lei, “Evaluating the validity of current mainstream wearable devices in fitness tracking under various physical activities: Comparative study,” *JMIR mHealth uHealth*, vol. 6, no. 4, 2018, doi: 10.2196/mhealth.9754.

[15] H. G. Dandapani *et al.*, “Leveraging Mobile-Based Sensors for Clinical Research to Obtain Activity and Health Measures for Disease Monitoring, Prevention, and Treatment,” *Front. Digit. Heal.*, vol. 4, Jun. 2022, doi: 10.3389/fdgh.2022.893070.

[16] M. J. Rahman, B. I. Morshed, and B. Harmon, “A Field Study to Capture Events of Interest (EoI) from Living Labs Using Wearables for Spatiotemporal Monitoring Towards a Framework of Smart Health (sHealth),” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2020, vol. 2020-July, doi: 10.1109/EMBC44109.2020.9175771.

[17] T. Beltrame, R. Amelard, A. Wong, and R. L. Hughson, “Extracting aerobic system dynamics during unsupervised activities of daily living using wearable sensor machine learning models,” *J. Appl. Physiol.*,

vol. 124, no. 2, 2018, doi: 10.1152/japplphysiol.00299.2017.

- [18] N. Caetano, P. Cortez, and R. M. S. Laureano, "Using data mining for prediction of hospital length of stay: An application of the CRISP-DM methodology," in *Lecture Notes in Business Information Processing*, 2015, vol. 227, doi: 10.1007/978-3-319-22348-3_9.
- [19] P. Chapman *et al.*, "CRISP-DM 1.0: Step-by-step data mining guide," 2000.
- [20] Huawei, "Huawei Band 7," 2022. <https://consumer.huawei.com/pe/wearables/band7/> (accessed Aug. 01, 2022).
- [21] E. Bisong and E. Bisong, "Google Colaboratory," in *Building Machine Learning and Deep Learning Models on Google Cloud Platform*, 2019.