


Universidad Católica de Santa María
Facultad de Ciencias e Ingenierías Físicas y Formales
Escuela Profesional de Ingeniería de Sistemas



**Construcción de un modelo de inteligencia artificial para medir la
competencia motora de escolares de centros educativos de Arequipa
mediante un aplicativo móvil y tecnología vestible**

Tesis presentada por los Bachilleres:

Avendaño Llanque, Christopher Bryan

ORCID: 0009-0000-1618-2046

Calla Gamboa, Alexander Paul

ORCID: 0009-0004-5248-1544

para optar el Título Profesional de Ingeniero de Sistemas

Asesor (a):

Dr. Zúñiga Carnero, Manuel Mariano

ORCID: 0000-0002-1091-9438

Arequipa - Perú

2024

UCSM-ERP

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA DE SISTEMAS

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 07 de Diciembre del 2023

Dictamen: 009299-C-EPIS-2023

Visto el borrador del expediente 009299, presentado por:

2017800461 - CALLA GAMBOA ALEXANDER PAUL

2017600251 - AVENDAÑO LLANQUE CHRISTOPHER BRYAN

Titulado:

**CONSTRUCCIÓN DE UN MODELO DE INTELIGENCIA ARTIFICIAL PARA MEDIR LA
COMPETENCIA MOTORA DE ESCOLARES DE CENTROS EDUCATIVOS DE AREQUIPA MEDIANTE
UN APLICATIVO MÓVIL Y TECNOLOGÍA VESTIBLE**

Nuestro dictamen es:

APROBADO

**29302116 - DELGADO DELGADO FREDY RAMIRO
DICTAMINADOR**



**29612305 - SULLA TORRES JOSE ALFREDO
DICTAMINADOR**



**29695284 - CASTRO GUTIERREZ EVELING GLORIA
DICTAMINADOR**



Construcción de un modelo de inteligencia artificial para medir la competencia motora de escolares de centros educativos de Arequipa mediante un aplicativo móvil y tecnología vestible

INFORME DE ORIGINALIDAD

3%

INDICE DE SIMILITUD

3%

FUENTES DE INTERNET

1%

PUBLICACIONES

2%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1

Submitted to Universidad San Ignacio de Loyola

Trabajo del estudiante

1%

2

repositorio.umsa.bo

Fuente de Internet

1%

3

docplayer.es

Fuente de Internet

1%

4

cronfa.swan.ac.uk

Fuente de Internet

1%

5

vsip.info

Fuente de Internet

1%

Excluir citas

Apagado

Excluir coincidencias < 1%

Excluir bibliografía

Apagado

DEDICATORIA

Se dedica este trabajo en primer lugar a nuestros padres, pilar fundamental de nuestra vida. A
nuestros amigos que siempre nos apoyaron y a esos docentes que siempre estuvieron
dispuestos a ayudarnos y brindarnos ánimos



AGRADECIMIENTOS

Debemos agradecer principalmente a nuestros padres tanto Gabino y Roxana como Adrián y Agripina por darnos la vida y formarnos como buenas personas además de ayudarnos a formar una excelente carrera profesional.

Agradecer también a los docentes de quienes se aprendió bastante durante la carrera profesional y que fueron un pilar fundamental para lograr y avanzar en nuestras metas. Finalmente agradecer a nuestros compañeros, en especial a Fabrizzio y Bruno, quienes ayudaron de manera significativa durante el transcurso de este proyecto.



RESUMEN

Diferentes tecnologías avanzadas son poco usadas, como tecnologías vestibles, aplicativos móviles, algoritmos de inteligencia artificial, las tecnologías están en constante evolución, sin embargo, tanto en centros educativos como profesionales de la enseñanza en actividad física usan poco o nada estas tecnologías, por lo cual no se puede obtener un resultado preciso en las evaluaciones de competencia motora, que puedan ayudar a los interesados en el campo de la actividad física.

Por lo que este trabajo busca proponer un modelo de Inteligencia artificial recolectando datos de dispositivos de tecnología vestible como las bandas inteligentes, luego integrarlo en un aplicativo móvil para poder evaluar la competencia motora de los escolares, tomando como caso de estudio cinco centros educativos para la recolección de datos y dos centros educativos para la validación del producto. Para lo cual se ha utilizado las metodologías Crisp-DM y SCRUM para el desarrollo de la propuesta, siguiendo las recomendaciones que estas sugieren. Los resultados obtenidos han sido el desarrollo del modelo de Inteligencia Artificial utilizando el algoritmo de redes neuronales como alimentación directa, obteniéndose también los percentiles de los escolares en base a la evaluación de las pruebas de competencia motora, luego la construcción de un aplicativo móvil para la automatización de las pruebas realizadas y finalmente la validación realizada en dos centros educativos. Con lo que se concluye que la propuesta desarrollada beneficia a los interesados en el campo de la competencia motora para mejorar sus controles en las evaluaciones a realizar.

Palabras clave: Inteligencia Artificial, tecnología vestible, smartband, competencia motora, escolares

ABSTRACT

Different advanced technologies such as wearable technologies, mobile applications, artificial intelligence algorithms are rarely used, technologies are constantly evolving, however, both educational centers and physical activity teaching professionals use these technologies little or not at all. so an exact result cannot be obtained. in motor competence assessments, which can help those interested in the field of physical activity.

Therefore, this work seeks to propose an Artificial Intelligence model by collecting data from wearable technology devices such as smart bracelets, and then integrating them into a mobile application to evaluate the motor competence of schoolchildren, taking five educational centers as a case study. for data collection. and two educational centers for product validation. For which the Crisp-DM and SCRUM methodologies have been used to develop the proposal, following the recommendations they suggest. The results obtained have been the development of the Artificial Intelligence model using the Neural Networks algorithm as Direct Feeding, also obtaining the percentiles of the schoolchildren based on the evaluation of motor competence tests, then the construction of a mobile application for automation Of the tests. carried out and finally the validation carried out in two educational centers. With which it is concluded that the developed proposal benefits those interested in the field of motor competence to improve their controls in the evaluations to be carried out.

Keywords: Artificial intelligence, wearable technology, smartband, motor competence, schoolchildren

ÍNDICE

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

ABSTRACT


INTRODUCCIÓN	1
CAPITULO I.....	4
1. PLANTEAMIENTO DE LA INVESTIGACIÓN	4
1.1. Planteamiento del Problema	4
1.2. Objetivos de la Investigación.....	5
1.2.1 Objetivo General.....	5
1.2.2 Objetivos Específicos	5
1.3 Preguntas de Investigación.....	5
1.4 Formulación de la Hipótesis, Variables, Indicadores	6
1.5 Línea y Sub-línea de Investigación a la que corresponde el Problema	6
1.6 Palabras Clave.....	7
1.7 Solución Propuesta.....	7
1.7.1 Justificación e Importancia.	7
1.7.2 Descripción de la Solución.....	8
1.7.3 Aporte	8
CAPITULO II	10
2. FUNDAMENTOS TEÓRICOS.....	10
2.1 Antecedentes de la Investigación.....	10
2.2 Estado del arte.....	11
2.3 Bases Teóricas de la Investigación	17
2.3.1 Inteligencia Artificial:	17

2.3.2 Machine Learning:	17
2.3.3 Redes Neuronales de alimentación directa:	18
2.3.4 Banda Inteligente (Smart Band):.....	18
2.3.5 Competencia motora:	18
2.3.6 CRISP-DM:.....	19
2.3.7 SCRUM	21
2.3.8 MOSCA	23
2.3.9 Aplicativo responsivo	24
CAPITULO III.....	25
3. MARCO METODOLÓGICO.....	25
3.1 Alcances y Limitaciones.....	25
3.1.1 Alcances	25
3.1.2 Limitaciones	25
3.2 Tipo y Nivel de la Investigación	26
3.3 Universo, Población y Muestra	26
3.4 Métodos, Técnicas e Instrumentos de Recolección de Datos.....	26
3.5. Plan de análisis estadístico de los datos	27
3.6. Plan del proyecto.....	28
CAPITULO IV	29
4. DESARROLLO DE LA PROPUESTA	29
4.1 CRISP-DM	30
4.1.1 Comprensión empresarial	30
4.1.2 Comprensión de los datos	32
4.1.3 Análisis y Preparación de los datos.....	35
4.1.4 Modelado	36
4.1.5 Evaluación	36
4.1.6 Despliegue.....	38
4.2 SCRUM.....	40

4.2.1 Equipo SCRUM	41
4.2.2 Proceso de SCRUM.....	42
4.2.3 Planificación de Sprints	43
4.2.4 La revisión de Sprint.....	45
CAPITULO V.....	59
5. ANALISIS Y VALIDACION DE RESULTADOS.....	59
5.1 Análisis de los datos	59
5.2 Análisis del modelo de Inteligencia Artificial	61
5.3 Analizar Encuestas.....	62
5.4 Análisis Metodológico: Evaluación del Proceso a través de la Metodología MOSCA	74
5.5 Estimación de Calidad de software.....	75
5.5.1 Funcionalidad.....	75
5.5.2 Fiabilidad.....	76
5.5.3 Usabilidad.....	77
5.6 Resultados del Grado de satisfacción	78
DISCUSIÓN	80
CONCLUSIONES.....	81
RECOMENDACIONES.....	82
TRABAJOS FUTUROS	83
REFERENCIAS.....	84
ANEXOS.....	90

ÍNDICE DE TABLAS

Tabla 1 Detalles de búsqueda y código	10
Tabla 2 Número de artículos encontrados	11
Tabla 3 Técnicas definición e instrumento	26
Tabla 4 Recolección de datos por centro educativo	33
Tabla 5 Equipo SCRUM	41
Tabla 6 Funcionalidades Encontradas	42
Tabla 7 Funcionalidades realizadas en el primer SPRINT.....	43
Tabla 8 Funcionalidades realizadas en el segundo SPRINT	44
Tabla 9 Categorías y características de acuerdo a la metodología MOSCA	75
Tabla 10 Resultado del grado de satisfacción total (MOSCA)	79




ÍNDICE DE FIGURAS

<i>Figura 1.</i> Dimensiones, Categorías Características, Subcaracterísticas, Métricas	23
<i>Figura 2.</i> Diagrama de Gantt del proyecto	28
<i>Figura 3.</i> Proceso de Negocio	30
<i>Figura 4.</i> Instrumento de registro de datos para bandas inteligentes	32
<i>Figura 5.</i> Percentiles por años y pasos	35
<i>Figura 6.</i> Estadística descriptiva de los datos de los escolares.	36
<i>Figura 7.</i> Importaciones del modelo y subida de datos	37
<i>Figura 8.</i> División y normalización de datos	37
<i>Figura 9.</i> Especificaciones del modelo	37
<i>Figura 10.</i> Entrenamiento del modelo	37
<i>Figura 11.</i> Precisión del modelo actual	38
<i>Figura 12.</i> Exportación del modelo a .tflite	39
<i>Figura 13.</i> Arquitectura del proyecto con respecto a Inteligencia Artificial	40
<i>Figura 14.</i> Arquitectura de la aplicación	45
<i>Figura 15.</i> Interfaz de Presentación	46
<i>Figura 16.</i> Interfaz de Inicio sesión	47
<i>Figura 17.</i> Interfaz de crear nuevo Usuario	48
<i>Figura 18.</i> Interfaz de crear nuevo Usuario	49
<i>Figura 19.</i> Interfaz de Lista de Alumno	50
<i>Figura 20.</i> Interfaz de Búsqueda del Alumno	51
<i>Figura 21.</i> Interfaz información del Alumno I	52
<i>Figura 22.</i> Interfaz información del Alumno II	53
<i>Figura 23.</i> Interfaz información del Alumno III.	54

<i>Figura 24.</i> Interfaz Calculadora de IMC.	55
<i>Figura 25.</i> Interfaz de Información	56
<i>Figura 26.</i> Estructura de código del aplicativo	57
<i>Figura 27.</i> Firebase Authentication	58
<i>Figura 28.</i> Firebase Realtime Database	58
<i>Figura 29.</i> Media de pasos con respecto a la Edad	59
<i>Figura 30.</i> Media de pasos con respecto a la cadencia	60
<i>Figura 31.</i> Cantidad de pasos con respecto a la clase.	61
<i>Figura 32.</i> Cantidad de pasos con respecto a la clase.	62
<i>Figura 33.</i> Encuesta - Gráfica de la pregunta 1	62
<i>Figura 34.</i> Encuesta - Gráfica de la pregunta 2	63
<i>Figura 35.</i> Encuesta - Gráfica de la pregunta 3	63
<i>Figura 36.</i> Encuesta - Gráfica de la pregunta 4	64
<i>Figura 37.</i> Encuesta - Gráfica de la pregunta 5	64
<i>Figura 38.</i> Encuesta - Gráfica de la pregunta 6	65
<i>Figura 39.</i> Encuesta - Gráfica de la pregunta 7	65
<i>Figura 40.</i> Encuesta - Gráfica de la pregunta 8	66
<i>Figura 41.</i> Encuesta - Gráfica de la pregunta 9	66
<i>Figura 42.</i> Encuesta - Gráfica de la pregunta 10	67
<i>Figura 43.</i> Encuesta - Gráfica de la pregunta 11	67
<i>Figura 44.</i> Encuesta - Gráfica de la pregunta 12	68
<i>Figura 45.</i> Encuesta - Gráfica de la pregunta 13	68
<i>Figura 46.</i> Encuesta - Gráfica de la pregunta 14	69
<i>Figura 47.</i> Encuesta - Gráfica de la pregunta 15	69

<i>Figura 48.</i> Encuesta - Gráfica de la pregunta 16	70
<i>Figura 49.</i> Encuesta - Gráfica de la pregunta 17	70
<i>Figura 50.</i> Encuesta - Gráfica de la pregunta 18	71
<i>Figura 51.</i> Encuesta - Gráfica de la pregunta 19	71
<i>Figura 52.</i> Encuesta - Gráfica de la pregunta 20	72
<i>Figura 53.</i> Encuesta - Gráfica de la pregunta 21	72
<i>Figura 54.</i> Encuesta - Gráfica de la pregunta 22	73
<i>Figura 55.</i> Encuesta - Gráfica de la pregunta 23	73
<i>Figura 56.</i> Estimación de Funcionalidad	76
<i>Figura 57.</i> Estimación de Fiabilidad	77
<i>Figura 58.</i> Estimación de Usabilidad	78



INTRODUCCIÓN

El progreso tecnológico ha conducido a mejoras en la calidad de vida al posibilitar la recopilación precisa y extensa de datos relacionados con la salud. Esto incluye métricas como el ritmo cardíaco, el número de pasos, las calorías quemadas, la velocidad media, entre otros aspectos relevantes. Esta abundancia de datos se ha vuelto particularmente valiosa en el ámbito de la investigación, donde se observa una mayor precisión proporcionada por dispositivos vestibles como las bandas inteligentes (conocidas como *SmartBand*), especialmente aquellos utilizados sobre ejercicios de actividad física.

La inteligencia artificial (IA) ha desempeñado como uno de los papeles fundamentales en verificar y prever el estado de salud de las personas, mediante el análisis de sus registros médicos. Gracias a la capacidad de la IA para procesar grandes cantidades de información de manera eficiente, se ha logrado un avance significativo en la interpretación de datos de salud, brindando una comprensión más profunda y precisa de la condición física y médica de los individuos. Este enfoque integrado de tecnología vestible, recopilación de datos avanzada y análisis impulsado por inteligencia artificial abre nuevas posibilidades para la gestión proactiva de la salud y el bienestar que puede ser utilizado en entornos escolares.

La integración de dispositivos de tecnología vestible amplía la cantidad de datos disponibles, facilitando que las técnicas de inteligencia artificial, incluido el aprendizaje automático (Machine Learning), logren una precisión aún mayor en sus análisis. Este énfasis no solo mejora la capacidad de monitorear la salud, sino que también proporciona una comprensión más profunda y predictiva de los resultados médicos. Frecuentemente, se recurre a tecnologías vestibles para la recopilación de datos, siendo las bandas inteligentes un instrumento comúnmente empleado para evaluar la actividad física de las personas. Sin embargo, surge un inconveniente cuando los centros educativos, a pesar de tener conocimiento acerca de estas

tecnologías, no las utilizan de manera apropiada o simplemente optan por no adquirirlas, ya que están arraigadas a métodos más convencionales.

Este desafío se evidencia en la ciudad de Arequipa, Perú, donde la gran mayoría de centros educativos no utilizan de manera eficaz la tecnología necesaria para evaluar de forma precisa las competencias motoras de sus escolares. Como resultado, las mediciones antropométricas y evaluaciones de competencia motora realizadas no proporcionan la precisión necesaria para comprender adecuadamente su estado de salud. Además, los registros generados no se almacenan internamente en el centro educativo o no se utilizan, lo que impide realizar un seguimiento continuo de la salud de los escolares y determinar si están experimentando mejoras o empeoramientos en su condición física.

El proyecto se centra en la construcción de un modelo de Inteligencia Artificial con el uso de datos de bandas inteligentes. Para ellos se realizará una revisión bibliográfica para encontrar diferentes usos con respecto a la Inteligencia Artificial y así tomarlos de referencia. Luego mediante el uso de la metodología CRISP-DM se realizará la construcción del modelo de IA mediante todas sus fases, para luego mediante la metodología SCRUM desarrollar un producto software que incruste el modelo de IA en un aplicativo móvil. Donde finalmente mediante la metodología de validación denominado MOSCA permita realizar la validación del producto de software.

El objetivo principal es construir un modelo de IA para medir la competencia motora de escolares de centros educativos de Arequipa mediante un aplicativo móvil y tecnología vestible. En este documento y sus capítulos se presenta el proyecto a desarrollar. Presentado como el primer capítulo se expone el plan de investigación, con sus partes: objetivo general, objetivos específicos, preguntas de investigación, hipótesis, variables. En nuestro segundo capítulo se exponen fundamentos teóricos en los cuales presentamos nuestro estado del arte y marco

teórico. En nuestro tercer capítulo se expone el marco metodológico. En nuestro cuarto capítulo se expone el desarrollo de la propuesta. En el quinto capítulo se validan los resultados sobre el aplicativo con el modelo de IA. Finalmente se realiza la discusión llegando a las conclusiones y recomendaciones.



CAPITULO I

1. PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1. Planteamiento del Problema

La salud de las personas es un tema de relevancia a nivel mundial y debe abordarse desde las etapas tempranas de la vida, especialmente durante el crecimiento y desarrollo. Este enfoque es crucial debido a los numerosos beneficios que aporta tanto a la salud física como a la salud psicológica, y es particularmente significativo cuando se considera desde el ámbito escolar.

(Yáñez-Silva et al., 2014).

El gran avance de la tecnología nos permite ayudar a la mejora de vida en general además de lograrse permite recoger datos de manera más exacta y amplia como ritmo cardíaco, pasos recorridos, calorías quemadas, velocidad media, entre otros (Durán Chinchilla et al., 2021). Existen diferentes tipos de ejercicios con diferentes dispositivos de medición, pero donde se realizan más investigaciones y encuentran más exactitud, con menos ruido son en los ejercicios de “correr” o “caminar”.

En muchas investigaciones la inteligencia artificial ayudó a comprobar o predecir el estado de salud de personas con sus registros de salud con mayor facilidad, además, la utilización de dispositivo de medición para recopilar más datos facilita que las técnicas de inteligencia artificial tengan mayor precisión, así como Machine Learning (Huhn S. et al., 2022). El dispositivo de medición más utilizado y económico es la banda inteligente que permite recoger datos importantes sobre la competencia motora de las personas con mayor exactitud (Jia Y, 2018). Al recolectar estos datos de manera más factible se puede realizar investigaciones sobre la salud de las personas, ya sea de enfermedades, o medir la competencia motora de las personas. Sin embargo, la mayoría de las personas en la provincia de Arequipa utilizan las bandas inteligentes solo para uso personal, igual al uso de los celulares inteligentes, teniendo en cuenta

que gran parte de herramientas tecnológicas no aprovechan todo su potencial debido a su desconocimiento o por falta de uso, además no se utiliza adecuadamente en actividades grupales (*Estudiantes Crean Plataforma Para Capacitar a Docentes Peruanos En El Uso de Las TIC | Noticias | Agencia Peruana de Noticias Andina*, 2021). Por otro lado, la evaluación en el Perú de la competencia motora suele no considerar los atributos necesarios al usar el método tradicional y no poseer los datos exactos, por lo tanto, no ayudan a verificar sobre la precisión de la evaluación (frecuencia cardiaca, ritmo medio, calorías, zancada, cadencia, entre otros.) (Masci, I., et al, 2012), Esta evaluación puede optimizarse con el uso de inteligencia artificial y Machine Learning, a partir de los datos de la banda inteligente y así lograr una buena evaluación de competencia motora.

1.2. Objetivos de la Investigación

1.2.1 Objetivo General

Construir un modelo de IA para medir la competencia motora de escolares de centros educativos de Arequipa mediante un aplicativo móvil y tecnología vestible.

1.2.2 Objetivos Específicos

- Recopilar datos en escolares de diferentes centros educativos (calorías, tiempo, frecuencia cardiaca, edad) mediante bandas inteligentes en su actividad motora.
- Identificar la técnica de Machine Learning a utilizar para la clasificación de la competencia motora.
- Desarrollar un aplicativo móvil responsivo con un modelo de IA
- Validar el aplicativo en la evaluación de la competencia motora.

1.3 Preguntas de Investigación

- ¿Cómo podemos obtener gran cantidad de datos sobre competencia motora de manera eficaz?

- ¿Utilizar la técnica de Machine Learning para representar los datos recopilados?
- ¿Cómo presentar la información de resultados de manera interactiva y fácil de acceder?
- ¿Cumple el aplicativo en evaluar el rendimiento de los escolares con los datos planteados?

1.4 Formulación de la Hipótesis, Variables, Indicadores

a) Hipótesis

Dado que la evaluación de la competencia motora en los escolares es importante, es probable que utilizando un modelo de IA basado en datos de tecnología vestible puede optimizar estas evaluaciones mediante un aplicativo móvil.

b) Variable dependiente

Competencia motora de escolares de centros educativos de Arequipa.

c) Variable independiente

Modelo de IA basado en datos de tecnología vestible.

d) Indicadores

Para “Competencia motora de escolares de centros educativos de Arequipa”:

- Percentiles con respecto a los datos obtenidos
- Cantidad de datos obtenidos

Para “Modelo de IA basado en datos de tecnología vestible”:

- Algoritmo utilizado de modelo de IA
- Precisión del modelo de IA

1.5 Línea y Sub-línea de Investigación a la que corresponde el Problema

línea de Investigación:

Inteligencia artificial.

Sub-línea de investigación:

Aprendizaje Automático.

1.6 Palabras Clave

Inteligencia Artificial, tecnología vestible, smartband, competencia motora, escolares.

1.7 Solución Propuesta.

1.7.1 Justificación e Importancia.

En el contexto actual, se destaca la ausencia de trabajos que utilicen tecnologías vestibles en la ciudad de Arequipa, Perú. Las cuales aún son poco utilizadas en esta región, según revela una revisión sistemática.

La propuesta presentada es innovadora, ya que introduce el uso de un modelo de Inteligencia Artificial en un aplicativo móvil, marcando un avance significativo en su aplicación en el ámbito local.

La relevancia de esta propuesta se intensifica al abordar aspectos cruciales de la salud pública, contribuyendo así al mejoramiento general de las condiciones de salud en la comunidad.

Cabe destacar que la construcción del aplicativo propuesto con el modelo se caracteriza por su costo mínimo, al aprovechar herramientas de libre distribución. Esto asegura que la implementación no tenga un impacto económico significativo en los interesados, promoviendo así la accesibilidad y la participación.

Tiene un aspecto distintivo de este aplicativo sobre su enfoque no inmersivo, lo que significa que no afecta físicamente a los usuarios. Este atributo garantiza una experiencia cómoda y sin inconvenientes para aquellos que utilicen la aplicación.

Además, el aplicativo propuesto no genera impactos negativos en el medio ambiente. Este enfoque sostenible es esencial para garantizar que la adopción de la tecnología no conlleve consecuencias adversas para el entorno.

1.7.2 Descripción de la Solución

La salud física es importante para la vida diaria, en especial en jóvenes y niños que están en proceso de crecimiento. Para tener una buena condición física es recomendable realizar diferentes actividades, pero la mayoría de los niños, que practican la actividad física obligatoria, están en los centros educativos (Sujatha et al., 2022). Al realizar un ejercicio para evaluarlo, se guardan estos datos en un registro. En repositorios se encuentra una gran variedad de registros con esta información para realizar investigaciones. Estas investigaciones se crean comúnmente en países desarrollados, y raramente en países subdesarrollados. En este proyecto al realizar una revisión sistemática sobre los registros para la competencia motora entre 6 a 17 años, no se encontró documentado o presentado en el Perú, menos en el departamento de Arequipa. Teniendo la cantidad de datos necesaria recolectada en Perú, ayudaría mucho al crecimiento de la investigación en la zona, esto fomentará crear un repositorio de diversos centros educativos del estado donde podrán compartir sus registros para mejorar las técnicas de Machine Learning sobre la competencia motora en el Perú.

1.7.3 Aporte

Se aporta al campo de Ingeniería de Sistemas al proporcionar una perspectiva de cómo usar los datos que se obtienen con tecnologías vestibles como es un modelo de Inteligencia Artificial, esto a través de la metodología CRISP-DM, además de incrustar el modelo en un aplicativo móvil con el uso de Dart y Flutter. La aplicación móvil con el modelo de IA desarrollado aportará en el proceso de evaluación de competencia motora de un escolar para saber si su condición física es buena

según sus datos y registros de pruebas en la línea de actividad física. También se elaborarán los percentiles según la competencia motora evaluada. Además de que se construirá un base de datos que tenga diferentes mediciones obtenidas por las bandas inteligentes, que se podrá usar para futuros trabajos futuros o para alimentar diferentes modelos de IA.



CAPITULO II

2. FUNDAMENTOS TEÓRICOS

2.1 Antecedentes de la Investigación

En la Tabla 1 se muestra la forma de una búsqueda avanzada en repositorios en buscar artículos sobre el tema.

Tabla 1 Detalles de búsqueda y código

Código	Nro. de búsqueda	Palabras clave	Detalle
B1	Búsqueda 1	(smart AND band AND fitness) AND (Smart LIMIT TO (SUBJAREA , "COMP") OR LIMIT-TO (SUBJAREA , "ENGI"))	Band Fitness
B2	Búsqueda 2	(machine AND Learning AND motor AND skill AND data) AND (LIMIT-TO (SUBJAREA , "COMP") OR LIMIT-TO (SUBJAREA , "ENGI")) AND (LIMIT-TO (EXACT KEYWORD , "Machine Learning"))	Machine Learning motor skill
B3	Búsqueda 3	(motor AND skills AND machine AND Learning AND wearables)	motor skills machine Learning wearables

Nota: En base desde 2017 a 2022

En la tabla 2 se muestra la búsqueda realizada con las palabras claves en las diferentes bases de datos principales y seleccionar los artículos relacionados al tema

Tabla 2 Número de artículos encontrados

Base de datos	Palabras clave			Nro. de Artículos	Artículos seleccionados
	B1	B2	B3		
Science Direct	12	9	0	21	4
SCOPUS	67	41	23	131	19
IEEE	4	3	2	9	4
SPRINGER	52	43	7	102	14
TOTAL	135	96	32	263	41

2.2 Estado del arte

Wang C. (Wang C. et al., 2021) demostró que características sociales, psicológicas y ambientales tienen relación con la actividad física que se tiene entre los universitarios, esto lo probó con 692 escolares por al menos 2 años con el uso de la banda inteligente Fitbit, demostrando que existe una fuerte relación entre el crecimiento de la actividad física grupal que la individual. Al igual que en el trabajo de Esakia (Esakia et al., 2020) se centra en el diseño y evaluación de tecnología destinada a facilitar estrategias basadas en dinámicas grupales para promover la actividad física dentro de equipos pequeños socialmente conectados. Presentando

un sistema centralizado en un reloj inteligente llamado FitAware, que utiliza sensores para rastrear automáticamente la actividad física y aprovecha las ventajas del formato de reloj para facilitar estrategias de comportamiento tanto a nivel grupal como individual mediante actualizaciones no intrusivas, rápidas y frecuentes. En otro estudio desarrollado por Sun (Sun & Liu, 2020), se basa en examinar la confiabilidad y validez al usar pulseras inteligentes Fizzo, para medir la frecuencia cardíaca en sesiones de educación física, en este caso se realizaron 2 estudios uno de correr en cinta y el otro en hacer diferentes ejercicios de educación física, utilizando los dispositivos Fizzos en ambas muñecas, mostraron resultados excelentes en el primer estudio y una moderada en el segundo. Donde el factor principal que afecta la confiabilidad y validez del dispositivo no es la intensidad física sino el tipo de actividad física que se ejecuta, para asegurar que los valores tomados por los relojes son eficaces. En el trabajo de Huhn (Huhn et al., 2022), se recapitula de una visión general de investigaciones realizadas con dispositivos portátiles asequibles, realizando una revisión de alcance para comprender el consumo de estos, utilizando el marco PRISMA-ScR, identificando 7499 artículos, posteriormente, mediante criterios específicos, se seleccionaron 179 estudios que involucraron 189 dispositivos portátiles. Estos resultados indican que las considerables cantidades de datos recopilados mediante dispositivos portátiles tienen el potencial de transformar nuestra comprensión de la dinámica de salud de la población y mejorar la capacidad de anticipar tendencias de salud. Además, señalan la falta de investigaciones en el uso de dispositivos portátiles en contextos de bajos recursos. Otros estudios como el de Qui (Qiu et al., 2018) y el de Creaser (Creaser et al., 2021) nos hacen una comparativa de los diferentes aparatos electrónicos que se usan para poder medir diferentes cantidades de datos, que permiten ayudar a diferentes aspectos de la vida en su uso, y además muestran que estos dispositivos muestran numerosas técnicas de cambio, puesto que, son pocos niños y adolescentes los que logran las pautas de educación física. Creaser revisa la aceptabilidad, viabilidad y eficacia física en

personas de 5 a 19 años, donde se identifican 33 estudios diversos en los cuales los niños y adolescentes reportaron desafíos técnicos y una experiencia novedosa al utilizar dispositivos portátiles. Estos aspectos podrían influir en la utilización sostenida de dispositivos portátiles más avanzados, ampliando así la necesidad de investigaciones futuras sobre aspectos como aceptabilidad, viabilidad y eficacia.

Con respecto a la salud se pudo verificar con Lee (Lee et al., 2021), qué existen cambios afectivos y de sentimientos mientras se realiza un cambio de acondicionamiento físico, esto lo vieron mediante el programa zumba donde hizo una prueba a 16 participantes mediante el uso de smartwatch sincronizados con celulares inteligentes, esto con el fin de medir recursos humanos de afecto y control por parte del reloj inteligente, obteniendo datos de este. Este estudio logró comprobar el efecto positivo del ejercicio y logró medir el afecto en tiempo real durante el programa. Concluyendo que el programa Zumba activa el efecto positivo y de excitación en los participantes, además de que el ejercicio grupal ayuda a mejorar respuestas afectivas y recomendando así incorporarlo en varios ritmos basados en zumba. Con respecto a la salud física en el trabajo realizado por (Bat Erdene & Saver, 2021), se estudió los recientes avances en detección automática de síntomas de accidentes cardiovasculares agudos, esto se hizo mediante una revisión narrativa, donde se dieron por resultados la activación tardía de EMS(sistemas médicos de emergencia) para síntomas de accidentes cardiovasculares para pacientes y testigos, aquí se revisó 11 tecnologías de detección y 10 factores de forma de dispositivos de consumo como smartwatches, entre otros, donde se concluye que las nuevas tecnologías han llegado a una serie de tecnologías de salud que pueden detectar accidentes cerebrovasculares y activar el EMS, Con esto podemos comprobar que el uso de relojes y bandas inteligentes pueden ayudar de diferentes maneras a la salud de su usuario. Con respecto al desarrollo tanto en el estudio de (J. Wang et al., 2018) y el de (Alade & Sowunmi, 2018) nos muestran que el desarrollo de aplicaciones en relojes o bandas inteligentes tienen grandes

beneficios donde el primero nos muestra un estudio sobre 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 de teléfono inteligente, Esto mediante un ensayo clínico de 3 meses con paciente elegibles con diabetes mellitus. Dando como resultados el desarrollo con éxito de un rastreador de actividad física con una aplicación de teléfono inteligente complementaria para el autocontrol de la nutrición. Y en segundo nos muestra cómo se aprovecha la plataforma de teléfonos inteligentes mediante el desarrollo de una aplicación fitness, esto mediante una aplicación realizada mediante diagramas de lenguaje unificado, como diagramas de casos de uso o diagramas de secuencia. Muestra que aplicaciones de este estilo pueden ganar mucho terreno en cuanto a su adopción dado que es más barato descargar aplicación que comprar otro reloj inteligente. Mostrando así estos 2 artículos, beneficios del desarrollo de aplicaciones para bandas y relojes inteligentes.

Hablando sobre los datos, en el estudio de (Xie et al., 2018) en el que el objetivo fue evaluar la precisión de dispositivos portátiles relacionados al estado físico en diversas actividades. Lo probaron en 44 sujetos sanos donde cada uno usaba 6 dispositivos y 2 teléfonos inteligentes, para luego estos ser comparados con el estándar oro, calculando errores porcentuales.

Demostrando que estos dispositivos tuvieron una precisión de medición bastante alta con respecto a la frecuencia cardíaca. Concluyen que los dispositivos pueden medir de manera confiable la frecuencia cardíaca, número de pasos entre otros. Como también en el estudio de (Dandapani et al., 2022). donde también se utilizaron sensores de dispositivos móviles para obtener medidas de actividad y salud de los participantes de esa investigación, creando una app para poder recopilar datos del giroscopio de dispositivo y el acelerómetro para pruebas cognitivas y de aptitud física. Todos estos datos los transmiten mediante una API. Donde concluyen emplear lecciones aprendidas de GAP care podría ayudar a crear aplicaciones de

investigación adaptadas al estudio y acceder a información sobre su investigación. Sobre datos, en el trabajo de (Rahman et al., 2020), donde el estudio con un año de duración se recogió la frecuencia cardíaca instantánea nocturna de 9 participantes utilizando pulseras inteligentes comerciales y se extrajeron características sobre variabilidad de frecuencia cardíaca, además de medir temperatura corporal central, utilizando los sensores de temperatura y la SpO2 con un oxímetro de pulso de dedo. Todo esto para el seguimiento espacio temporal automatizado de la gravedad de los síntomas de la gripe en tiempo real. Los valores de las características de VFC extraídas dentro del intervalo de confianza del 95% de los valores normativos muestran una tendencia anticipada para el género y la edad, mostrando que estos datos también son relevantes para diferentes estudios. Estos trabajos muestran que se puede sacar grandes cantidades de datos y de calidad de dispositivos.

Un estudio adicional (Striggles, 2021), mostró una comparación entre la exactitud y la precisión de la medición de la Frecuencia Cardíaca (FC) por 2 monitores de muñeca: Fitbit 4 y Xiaomi Band 5. Se pidió a 31 voluntarios sanos que realizarán una prueba de esfuerzo en una cinta de correr. Las frecuencias cardíacas fueron registradas simultáneamente por pulseras y un electrocardiograma (ECG) a intervalos de 1 minuto. Se calculó el porcentaje de error absoluto medio (MAPE) y el coeficiente de correlación de concordancia de Lin (LCCC) y análisis de Bland-Altman para comparar la precisión y la exactitud de las mediciones de la frecuencia cardíaca. Los criterios de validación estimados fueron $MAPE < 10\%$ y $LCCC < 0,8$. El MAPE y el LCCC generales del Fitbit fueron del 10,19% (11,79%) y 0,753 (IC del 95%: 0,717-0,785), respectivamente. El MAPE y el LCCC del Xiaomi fueron del 6,89% (9,75) y 0,903 (0,8860,917), respectivamente, donde se concluye que la precisión y exactitud de ambos dispositivos disminuyeron con el aumento de la intensidad del ejercicio.

El estudio de Hoelzemann (Hoelzemann et al., 2022) nos mostró que se puede utilizar un marco rentable de código abierto para captura de actividades y rutinas diarias, esto con relojes inteligentes Bangle.js a 12 personas.

El trabajo de Site, Nurmi y Lohan (Site, Nurmi & Lohan, 2021) se revisan algoritmos de aprendizaje automático para el análisis de datos de salud basándose en dispositivos portátiles donde muestran un potencial significativo en mejorar la satisfacción del cliente y calidad de atención médica con algoritmos de aprendizaje automático o machine Learning (ML), donde se concluye que algoritmos de redes neuronales (neural network) y máquinas de vectores de soporte (support vector machine) son las que mejor rendimiento tienen a la hora de analizar datos sanitarios entre otros algoritmos. Algo similar se utiliza en el trabajo de Ceron (Ceron, López y Hofmann, 2017) donde proponen un método de clasificación de conductas sedentarias utilizando teléfonos inteligentes y balizas bluetooth, para lo cual siguiendo la metodología CRISP-DM recopilan datos del acelerómetro, giroscopio y barómetro del teléfono inteligente y así utilizar el algoritmo de Random Forest como modelo de Inteligencia Artificial.

Por último, el objetivo de un estudio (Abrishami et al., 2019), se aborda la identificación de retrasos en el desarrollo de infantes mediante el empleo de sensores portátiles, enfocándose específicamente en el análisis estadístico de las características de movimiento de las piernas durante un día completo. En particular, se examina la eficacia de estas características en un conjunto limitado de datos, donde se conocía el movimiento del infante, específicamente en intervalos de 5 minutos que son más representativos de observaciones clínicas.

2.3 Bases Teóricas de la Investigación

2.3.1 Inteligencia Artificial:

Es la habilidad que llegan a tener las máquinas de poder realizar actividades basadas en humanos como tomar decisiones o realizar actividades de manera inteligente, en ingeniería de sistemas la inteligencia artificial es una rama que permite a los desarrolladores realizar estos sistemas de máquinas inteligentes.

Sistemas basados con las recomendaciones en YouTube, o los videos que salen periódicamente en Tiktok, son otros ejemplos de Inteligencia Artificial, recientemente una inteligencia artificial que salió a la luz fue DALL-E que es un IA que dibuja cualquier cosa en base a lo que le indiquemos siendo una poderosa herramienta de dibujo, y a diferencia de lo que algunos puedan pensar que también hace el buscador de Google, DALL-E genera imágenes nuevas, es decir que nunca fueron dibujadas antes siendo arte creado artificialmente y nuevo (González, 2022).

2.3.2 Machine Learning:

Es la rama de inteligencia artificial que se basa en el aprendizaje automático de las máquinas lo cual permite a la máquina poder lograr actividades más complejas y seguir aprendiendo por sí misma, como en seguir un camino donde la máquina podría llegar a sortear un camino con obstáculos el mismo. Machine Learning tiene 2 tipos principales que son los que se utilizan con más frecuencia los cuales son:

Supervisado, Este algoritmo se basa en entrenar antes el modelo del algoritmo en base a datos, lo cual se utiliza para predecir y tomar acciones en base a eso

No Supervisado, A diferencia del anterior, el aprendizaje no supervisado no cuenta con un entrenamiento previo, sino que genera sus patrones en base al caso que ya tengan los datos con

el fin de lograr un patrón que pueda organizarlos de alguna manera efectiva (Goodfellow, 2016).

2.3.3 Redes Neuronales de alimentación directa:

Conocidas como Feedforward neural networks, son redes neuronales donde toda la información va dirigida u orientada a una dirección en específico, desde la entrada a través de capas ocultas (en caso hubiera) llegando hasta la capa de salida.

Estas se pueden utilizar tanto para reconocimiento de patrones, procesamiento de lenguaje natural, aprendizaje automático, análisis de datos, etc.

Estas redes neuronales son la base para muchos otros tipos de redes neuronales de mayor complejidad, como redes convolucionales llamadas CNN o redes recurrentes llamadas RNN (Pan et al., 2019).

2.3.4 Banda Inteligente (Smart Band):

Es una banda inteligente que permite al usuario recopilar todo tipo de información de manera sencilla, como frecuencia cardiaca, cantidad de pasos caminados, tiempo, ritmo, etc. (Qiu et al., 2018). Existen varios tipos de bandas inteligentes como Fitbit, Huawei band 6 o 7, Xiaomi band, amazfit band 6, entre otras, cada una con diferentes atributos mejores frente a la otra, pero ninguna destacando exageradamente entre otras.

2.3.5 Competencia motora:

Es el manejo que llega a tener una persona sobre sus facultades físicas, como sus acciones reacciones y este va evolucionando en medida del control que tenga la persona sobre sí mismo, como también el termino de realizar variedad de tareas motrices con un buen control corporal

y una conveniente coordinación de los movimientos se le conoce como competencia motora, y es mayor considerarlos en edad temprana como en primaria y secundaria donde afecta varios aspectos positivos para la salud como estado físico o pérdida de peso (Godoy, 2022).

2.3.6 CRISP-DM:

Crisp-DM es una metodología orientada al desarrollo de minería de datos, el cual consta de 6 fases: comprensión del negocio, comprensión de datos, preparación de datos, modelado, evaluación de modelo, despliegue. Nos proporciona una estructura para la planificación, desarrollo y ejecución de proyectos. Aunque esta metodología se centra en minería de datos, también es aplicable a Machine Learning (Schröer, 2021) sus fases se dividen en:

- Comprensión empresarial: Esta se enfoca en comprender los objetivos y requisitos del proyecto desde una perspectiva comercial y luego convertir este conocimiento en una definición del problema de minería de datos. Se basa en:
 - ❖ Objetivos del negocio: Se expande la información a la que se quiere llegar con respecto a los objetivos y al resultado que se quiere llegar.
 - ❖ Situación actual: Donde se establece cual es el momento en el que se encuentra con respecto a los objetivos que se desean llegar.
 - ❖ Criterios de éxito: El cumplimiento del objetivo de manera que se pueda probar si es que funciona o no, esto varía dependiendo del objetivo del negocio
- Comprensión de datos: Recopilación de datos inicial y se familiariza con los datos, identificando problemas de calidad de los datos. La formulación del problema de la minería de datos y el plan del proyecto requieren al menos cierta comprensión de los datos disponibles.

- Preparación de datos: Abarca todas las actividades para construir el conjunto de datos final a partir de los datos sin procesar iniciales. Las tareas incluyen la selección de tablas, registros y atributos, la limpieza de datos, la construcción de nuevos atributos y la transformación de datos para técnicas de modelado.
- Modelado: Selección y aplicación de varias técnicas de modelado, y sus parámetros se calibran a valores óptimos. Algunas técnicas requieren formatos de datos específicos.
- Evaluación: Se ha creado uno o más modelos que parecen tener alta calidad, desde una perspectiva de análisis de datos. Antes de continuar a la parte final, es importante evaluar más a fondo el modelo y revisar los pasos ejecutados para construir el modelo, para asegurarse de que logre correctamente los objetivos comerciales. Al final de esta fase, se debe llegar a una decisión sobre el uso de los resultados de la minería de datos.
- Despliegue: La creación del modelo generalmente no es el final del proyecto. Por lo general, el conocimiento adquirido deberá organizarse y presentarse de manera que el cliente pueda utilizarlo. Según los requisitos, la fase de implementación puede ser tan simple como generar un informe o tan compleja como implementar un proceso de extracción de datos repetible. En muchos casos será el usuario, no el analista de datos, quien llevará a cabo los pasos de despliegue. Es importante comprender de antemano qué acciones deberán llevarse a cabo para poder utilizar realmente los modelos creados. (Wirth, 2000)

2.3.7 SCRUM

La metodología SCRUM es un marco de trabajo ágil para la gestión de proyectos de software. Según el libro "Scrum: A Pocket Guide (Best Practice (Van Haren Publishing))" de Gunther Verheyen, Scrum se basa en tres pilares esenciales: transparencia, inspección y adaptación, donde se busca una colaboración continua entre el equipo y el cliente para alcanzar el éxito en el proyecto

Scrum se divide en varias partes, tales como:


- El equipo Scrum: El equipo Scrum está compuesto por un Product Owner, un Scrum Máster y los miembros del equipo. Donde:
 - ❖ Product Owner: responsable de maximizar y mejorar el producto y la productividad del trabajo del equipo. Este está en constante colaboración con los Stakeholders para reconocer los requisitos del producto y priorizar de manera adecuada los pendientes y el producto
 - ❖ Scrum Master: es el líder, asegura que se sigan ética, valores, reglas y prácticas de la metodología Scrum, es el responsable de facilitar reuniones, minimizar obstáculos y garantizar un entorno de desarrollo ágil.
 - ❖ Equipo de desarrollo: formado por los profesionales en el área, que se dedican a realizar el trabajo del incremento del producto entregable al final de cada iteración.
- El Product Backlog: El Product Backlog es una lista de todas las características del producto, funcionalidades que tendrá, requisitos que necesita, mejoras y correcciones que constituyen los cambios que se desean realizar al producto. Permite al equipo de desarrollo entender y comprender qué es lo que se debe de realizar para lograr los objetivos. Comprende los siguientes aspectos

- ❖ Elementos del Backlog: elementos que varían desde características específicas hasta problemas que deben abordarse, como mejoras a realizar.
- ❖ Priorización: los elementos del backlog deben de priorizarse según su importancia y valor
- ❖ Transparencia: El backlog debe de ser transparente y comprensible para todas las partes interesadas para así poder facilitar un desarrollo efectivo y enfocado.
- La planificación de Sprint: Durante la planificación de Sprint, el equipo Scrum selecciona las tareas del Product Backlog que desea completar durante el siguiente ciclo de trabajo. Este se lleva mediante algunos elementos que llegan a ser clave de la planificación del Sprint:
 - ❖ Selección de elementos del Product Backlog:
 - ❖ Definición del objetivo del Sprint
 - ❖ Descomposición de tareas
 - ❖ Creación del plan del Sprint:
- El Sprint: El Sprint es un ciclo de trabajo de una duración fija, generalmente de 2 a 4 semanas, durante el cual el equipo trabaja para completar las tareas seleccionadas en la planificación de Sprint.
- La revisión del Sprint: Al final de cada Sprint, el equipo se reúne para revisar el trabajo completado y planificar el próximo Sprint.
- La retrospectiva del Sprint: Al final de cada Sprint, el equipo también se reúne para reflexionar sobre lo que funcionó bien y lo que se puede mejorar (Verheyen G, 2016).

2.3.8 MOSCA

Llamado, así como Prototipo de Modelo Sistémico de Calidad de Software (MOSCA), este modelo se planea sobre la base de 6 características de calidad internacional estandarizadas, a través de un conjunto de categorías características y métricas, que miden y evalúan la calidad de software de un producto y logran hacer de este modelo un instrumento de medición de gran valor cubriendo aspectos imprescindibles para la calidad de software.

Figura 1. Dimensiones, Categorías Características, Subcaracterísticas, Métricas



Fuente: (Mendoza L., et al,2005)

Este consta de 4 niveles en los que envuelve: métricas, características, categorías y dimensiones, y estas se dividen de manera ascendente. Aunque MOSCA propone 6 categorías en total, MOSCA sugiere escoger solo 3 categorías y subdivisiones como se puede ver en la figura 1, estas se definen así:

- Dimensiones: que es el Producto a desarrollar
- Categorías: las cuales serán:
 - ❖ Funcionalidad: Capacidad del producto software de cumplir con las necesidades específicas
 - ❖ Usabilidad: Capacidad para que el software sea fácil de usar, atractivo
 - ❖ Fiabilidad: Capacidad del software para mantenerse en un nivel de rendimiento estable cuando es utilizado
- Características: que es el conjunto que está asociado a cada categoría
- Subcaracterísticas: se entiende que algunas características tengan subcaracterísticas ●

Métricas: la cual es una serie de métricas que se proponen para cada característica (Mendoza L., et al,2005).

2.3.9 Aplicativo responsivo

La responsividad está directamente conectada con la interfaz, una interfaz de usuario responsiva significa que el diseño se adapta automáticamente a diferentes tamaños de pantalla y dispositivos, lo que permite una mejor experiencia de usuario en todos los dispositivos. Se considera característica esencial en el diseño de aplicaciones modernas, ya que permite que el contenido se vea claro y legible ya sea desde computadoras de escritorio hasta teléfonos móviles y tabletas (Google Developers, 2022).

CAPITULO III

3. MARCO METODOLÓGICO

3.1 Alcances y Limitaciones

3.1.1 Alcances

Se planea desarrollar un producto software basado en inteligencia artificial el cual nos permite evaluar de manera eficiente la aptitud física de los escolares.

Viabilidad: Con respecto a información se encontró una gran cantidad de trabajos similares los cuales ayudaran al manejo del proyecto y al alcance de este. Con respecto a la recolección de datos se usarán una cantidad aproximada de 705 escolares entre otros centros educativos

Lugar: centros educativos de Arequipa entre primaria y secundaria

Tiempo: Se plantea que el proyecto dure un tiempo de 1 año aproximadamente

Financiación: El proyecto está financiado por la universidad en cuanto al asesoramiento y los dispositivos bandas inteligentes que se usarán para la recolección de datos.

3.1.2 Limitaciones

- Solo recolectamos datos de niños escolares de primaria y secundaria entre 6 a 17 años.
- Sólo se recolectarán datos de escolares de Arequipa-Perú.

- Solo aceptaremos datos que tengan poco ruido, es decir, que no haya demasiada diferencia con las bases de las pruebas en base al tiempo de pruebas, o a la actividad física que realicen
- Sólo mediremos niños sanos que no tengan problemas o enfermedades graves.
- Solo se utilizarán bandas inteligentes para la recolección de datos inicial.

3.2 Tipo y Nivel de la Investigación

Nuestro tipo de investigación es aplicativo pues queremos “calibrar” el sistema en base a los datos que recopilamos y así lograr que el sistema funcione de manera correcta. El nivel será experimental puesto que se tiene que verificar que los datos sean correctos y estos puedan verificarse en relación con los obtenidos del sistema.

3.3 Universo, Población y Muestra

Universo: Escolares de centros educativos estatales de la ciudad de Arequipa.

Muestra: Muestra no probabilística por conveniencia entre 6 a 17 años donde $N=705$.

3.4 Métodos, Técnicas e Instrumentos de Recolección de Datos

En la tabla 3 se menciona sobre los instrumentos que se utilizan para la recolección de investigaciones y los datos de niños y jóvenes.

Tabla 3 Técnicas definición e instrumento

Técnica	Definición	Instrumento
Documental	Cantidad de documentos que se pueda encontrar con el fin de recopilar información útil para el proyecto.	Bases de datos documentales (Scopus)

Muestra	A través de la implementación de bandas inteligentes, se logrará obtener datos precisos de los escolares en tiempo real. Este innovador enfoque se llevará a cabo mediante el uso de bandas inteligentes en diversos grados de primaria y secundaria en centros educativos de Arequipa.	Smart band 6/7
Evaluación	Utilizados en la penúltima fase de la metodología Crisp-DM para la veracidad del modelo de inteligencia artificial	Algoritmos de evaluación de modelos de IA
Encuesta	Se realizará una encuesta sobre el aplicativo final sobre su prototipo de modelo sistémico de calidad de software (MOSCA), a los profesores de educación física de manera anónima y respuestas simples.	MOSCA

Nota: tabla que muestra técnicas a usar, su definición e instrumento.

3.5. Plan de análisis estadístico de los datos

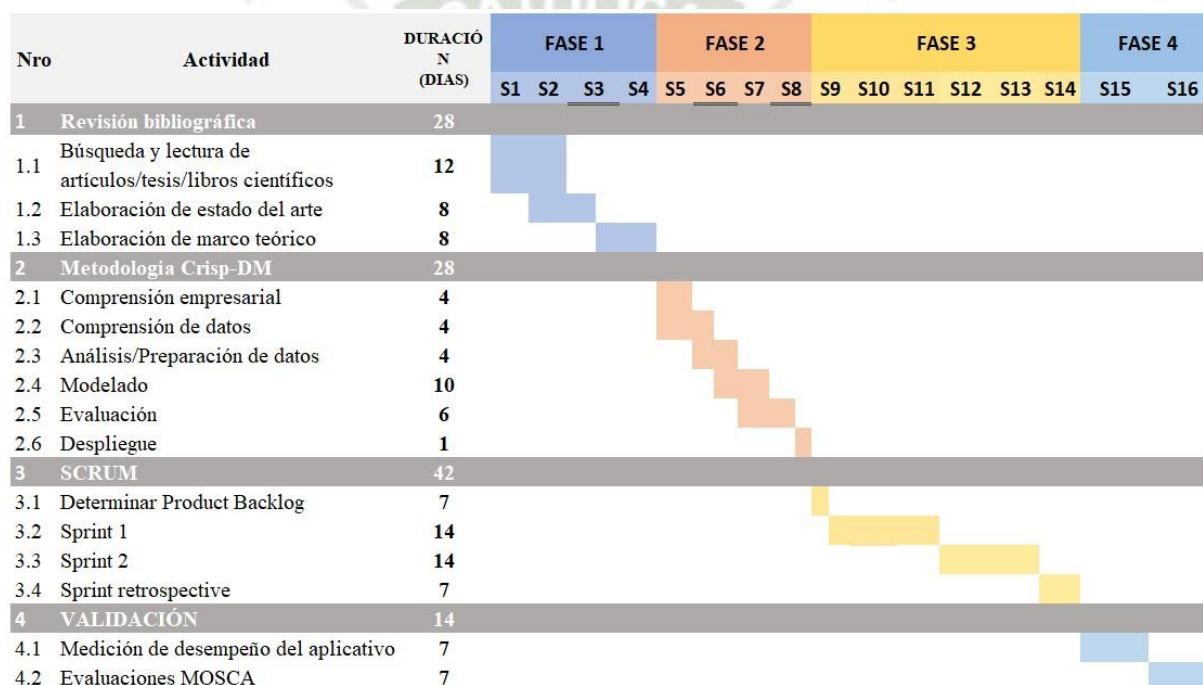
Se implementará un enfoque sistemático de calidad de software mediante el Prototipo de Modelo Sistémico de Calidad de Software (MOSCA) para la evaluación del software. En este proceso, las encuestas resueltas y distribuidas a los docentes de educación física constituirán una parte integral de las métricas obtenidas según el modelo. Estas métricas se presentarán de manera tabular, con el objetivo de determinar si el software cumple con los estándares de calidad establecidos. De esta manera, se obtendrá una evaluación precisa que revelará si el sistema alcanza un nivel adecuado de satisfacción para los usuarios.

3.6. Plan del proyecto

Diagrama de Gantt

En la figura 2 muestra el diagrama de Gantt sobre el proyecto al realizar, como primera parte es la Revisión Bibliográfica, el uso de metodologías tanto Crisp-DM para recolección de datos y creación del modelo de inteligencia Artificial y SCRUM para el desarrollo del aplicativo donde se incrustará el modelo de IA, y finalmente la Validación de la propuesta.

Figura 2. Diagrama de Gantt del proyecto



Fuente: Elaboración propia

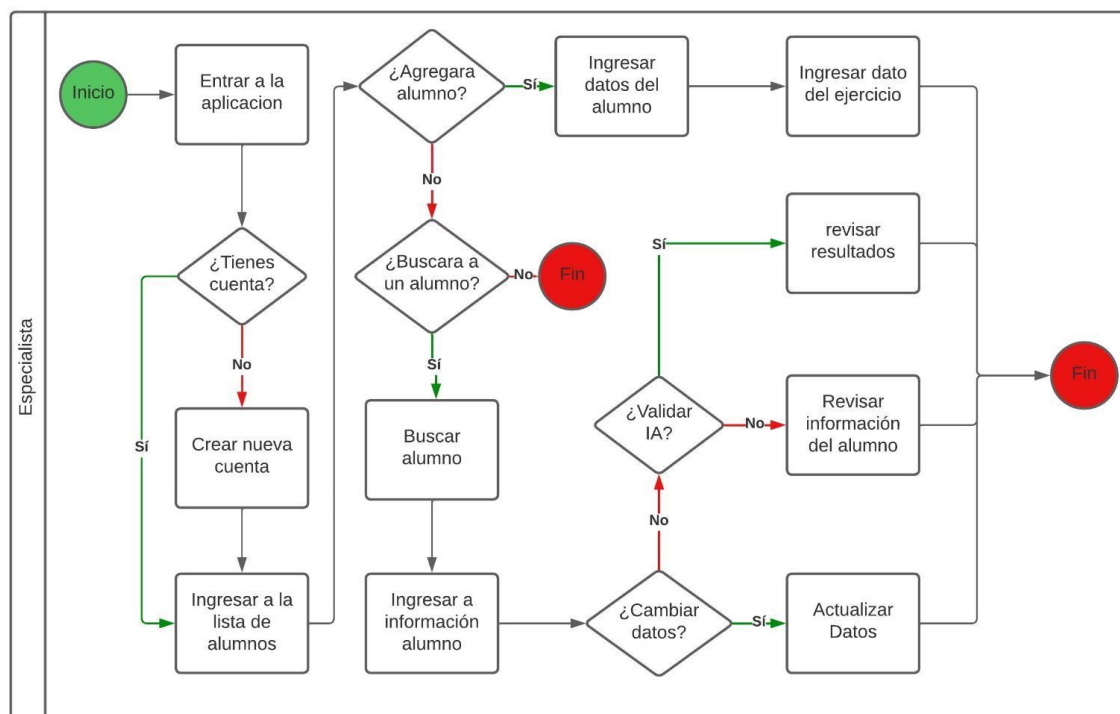
CAPITULO IV

4. DESARROLLO DE LA PROPUESTA

En este capítulo se abordan aspectos vinculados al desarrollo de la propuesta, delineando las etapas que surgieron a raíz de la revisión exhaustiva de los fundamentos teóricos. Para la creación del modelo de inteligencia artificial, se emplearon dos metodologías: Crisp-DM, que se utilizó en el desarrollo del modelo de inteligencia artificial, y SCRUM, que se aplicó en la elaboración del aplicativo móvil que albergará dicho modelo. Las mediciones antropométricas y la utilización de la banda inteligente se llevaron a cabo conforme a las pautas establecidas por el comité de ética local (UCSM-096-2022) y la Declaración de Helsinki de la (Asociación Médica Mundial), específicamente para estudios en seres humanos. Se seguirán todas las fases delineadas por estas metodologías, precedidas por un análisis exhaustivo del proceso de negocio.

Como análisis del contexto, un docente de educación física, al evaluar a un estudiante, comienza por registrar sus medidas antropométricas de forma tradicional y guarda esta información en registros manuales. Sin embargo, al inicio del siguiente año escolar, se ve obligado a repetir este proceso de medición y anotación. Además, carece de un sistema de seguimiento efectivo para determinar con precisión la competencia motora de cada escolar. La mayoría de los centros educativos no cuentan con tecnología que respalda este procedimiento. En la figura 3 se presenta el procedimiento que favorecerá una administración organizada y eficaz con el modelo IA en la aplicación.

Figura 3. Proceso de Negocio



Fuente: Elaboración propia

4.1 CRISP-DM

4.1.1 Comprensión empresarial

Esta metodología se utilizó para obtener una técnica de Machine Learning para evaluar la competencia motora de los escolares,

a) Objetivos del negocio

El objetivo del negocio principalmente es el de poder clasificar cómo se encuentra la competencia motora de los escolares con los datos obtenidos de las bandas inteligentes. Se podrá realizar más clasificaciones y procesos de datos según sea necesario, definiéndose los siguientes objetivos con respecto a los datos.

- Obtener y limpiar todos los datos recogidos de las bandas inteligentes.
- Clasificar la competencia motora de los escolares.

b) Situación actual

Se evaluaron pruebas de competencia motriz mediante la cuantificación del número de pasos durante el recreo escolar de 15 minutos y ejercicio de caminata de 6 minutos controlado. Este análisis se llevó a cabo utilizando pulseras inteligentes de la marca Huawei, modelo band 7, originarias de China. Estas pulseras están equipadas con una pantalla AMOLED de 194 x 368 y tienen un tamaño de 1.47 pulgadas. Es relevante destacar que esta marca de banda ya ha sido utilizada en estudios previos (Bayoumy et al., 2021).

Cada niño y adolescente participante en el estudio llevaba consigo la pulsera inteligente colocada en la muñeca derecha. Se dispone de un total de 30 bandas inteligentes, capaces de recopilar datos de manera eficaz de cualquier persona. Estas pulseras se emplearán en el monitoreo de datos en el entorno escolar, contando con la debida autorización de los centros educativos para la obtención de información. Además, se dispone de equipos personales para el desarrollo de la herramienta y la limpieza de datos, asegurando así la eficacia y precisión del proceso de recopilación de información.

Primero se realizó una prueba piloto con 10 personas para verificar el buen funcionamiento de los dispositivos además de ver la fiabilidad y calidad de datos, es decir que estos concuerden con el estado físico de los participantes, donde con ayuda de un especialista en aptitud física, se validó que los datos eran fiables. Además, se hizo una revisión sistemática en la que se verificó mediante varios artículos que estos dispositivos wearables son fiables y sus datos son fiables.

c) Criterios de éxito

Desde la perspectiva del negocio vinculado a este proyecto, se fundamenta en la capacidad exitosa para clasificar la competencia motora con un alto nivel de confiabilidad. Esto permitirá ofrecer consejos prácticos, asistencia y asesoramiento basado en la información obtenida.

4.1.2 Comprensión de los datos

a) Recopilación inicial de datos

Se realizó una recopilación total en 5 centros educativos con las bandas inteligentes, donde se tuvo un total de 705 escolares.

Para realizar el registro de los datos se utilizó un instrumento basado en una hoja de cálculo proporcionado por los especialistas en educación física como se ve en la figura 4. Instrumento el cual fue validado por una prueba piloto realizada por voluntarios del trabajo de investigación.

Figura 4. Instrumento de registro de datos para bandas inteligentes

Ejercicio en Smart Band: Caminar al aire libre										
		Fecha nacimiento			Edad (años)	Peso (kg)	Estatura (m)	Estatura sentada (cm)	Circunf. Cintura C. C. (cm)	
N°	Nombres	Día	Mes	Año						
1	Ejemplo	15	9	1998	24	82	1,72			
RECREO 1 (15min)										
Ritmo medio (min,seg)	Cadencia media	Pasos	Calorias	Veloc. Media (km/h)	Zancada media (cm)	Frecue. Cardíaca FC media	Frecue. Cardíaca FC máxima			
17,27	95	1431	57	3,44	60	83	90			
RECREO 2 (15min)										
Ritmo medio (min,seg)	Cadencia media	Pasos	Calorias	Veloc. Media (km/h)	Zancada media (cm)	Frecue. Cardíaca FC media	Frecue. Cardíaca FC máxima			
17,27	93	1397	52	3,44	62	77	86			

Como se puede ver en la Tabla 4 donde se muestra la cantidad de datos que fueron recolectados en los diferentes niveles de estudio, desde primero de primaria hasta quinto de secundaria haciendo un total de 705 escolares.

Tabla 4 Recolección de datos por centro educativo

	Colegio 1	Colegio 2	Colegio 3	Colegio 4	Colegio 5	TOTAL	Porcentaje
1ro Primaria	25		16	15		56	7,94 %
2do Primaria	38		8	16		62	8,79 %
3ro Primaria	27		9	10		46	6,52 %
4to Primaria	23		5	17		45	6,38 %
5to Primaria	29		8	6	9	52	7,38 %
6to Primaria	26		9	15	6	56	7,94 %
1ro secundaria		47			8	55	7,80 %
2do Secundaria		80		10	10	100	14,18 %
3ro Secundaria		67			10	77	10,92 %
4to Secundaria		74			11	85	12,06 %
5to Secundaria		62			9	71	10,07 %
						705	100,00 %

b) Descripción de datos

Cada registro de datos cuenta con los siguientes atributos:

- Ritmo medio: son el tiempo en el que la persona pueda caminar un kilómetro, vienen a ser número en formato de minutos y segundos.
- Cadencia media: son los pasos por minutos que pueda hacer, vienen a ser números sin formato (pasos/minuto)

- Pasos: son todos los pasos que haya realizado la persona durante la actividad, vienen a ser números sin formato (pasos).
- Calorías: son aquellas calorías que la persona haya quemado durante la actividad, vienen a ser números sin formatos (calorías).
- Velocidad media: es el promedio de velocidad en el que se haya desplazado la persona durante la actividad en kilómetros/hora, este en formato de número con decimales sin formatos (kilómetros/hora).
- Zancada media: es el promedio de distancia que haya dado cada paso, vienen a ser números sin formatos (centímetro/paso)
- Frecuencia cardiaca: estas son las pulsaciones por minuto que haya dado el corazón durante la actividad, vienen a ser números sin formatos(pulsaciones/minuto).
- Frecuencia cardiaca máxima, esta es la máxima cantidad de pulsaciones por minuto que haya dado el individuo en la actividad, vienen a ser números sin formatos (pulsaciones máximas/minuto).
- Altura, el tamaño de la persona en metros (metros).
- Peso, la fuerza con la que es atraído un cuerpo a la tierra (kilogramos).
- Circunferencia de cintura, la distancia que hay alrededor de la cintura del individuo(centímetro).
- Edad, el tiempo en años en el que vive una persona(años).

c) Exploración de datos

Con respecto a la exploración de datos se decidió utilizar los datos en específico que nos sugieren especialistas en la educación física como son: Edad, Peso, Talla, IMC (índice masa corporal), Cantidad de Pasos, Zancada, Velocidad, Cadencia.

4.1.3 Análisis y Preparación de los datos

En la construcción de la base de datos final, se priorizaron los registros completos, descartando aquellos con faltas o irregularidades por parte de los estudiantes. Es importante destacar que la cantidad de datos utilizados como base inicial podría aumentar a medida que se recopilan más registros de otros centros educativos. La información recopilada por las bandas inteligentes, obtenida directamente por los autores del proyecto, requerirá una limpieza menos profunda y exhaustiva. No obstante, se procederá a descartar registros con datos incompletos derivados de las irregularidades identificadas previamente por los estudiantes, garantizando así la integridad y calidad de la base de datos utilizada en el proyecto.

Con los datos obtenidos se obtuvieron medidas de percentiles, los cuales se utilizarán para dar una mejor explicación a la hora de ver los datos como se puede ver en la figura 5.

Figura 5. Percentiles por años y pasos

Edad (Años, Years)	P3	P5	P10	P15	P25	P50	P75	P85	P90	P95	P97
Males (Hombres)											
6-7 años	656.6	762.9	917.4	1016.8	1157.8	1406.4	1640.9	1762.0	1842.5	1959.6	2034.4
8-9 años	407.0	522.5	696.5	812.0	980.2	1288.0	1590.0	1750.2	1858.0	2016.9	2119.6
10-11 años	305.4	396.5	543.5	646.5	803.4	1108.8	1428.3	1604.8	1726.0	1908.3	2028.1
12-13 años	263.7	333.0	451.8	539.8	681.0	977.5	1314.9	1512.0	1651.7	1867.5	2013.2
14-15 años	178.6	218.1	298.2	344.9	439.1	656.2	933.3	1109.0	1239.4	1450.4	1599.1
16-17 años	143.7	170.9	221.4	262.3	334.5	515.5	775.0	955.8	1097.8	1341.7	1523.9
Females (Mujeres)											
6-7 años	683.3	788.2	929.0	1014.0	1129.1	1319.5	1488.1	1571.8	1626.4	1704.3	1753.3
8-9 años	462.4	579.9	744.6	848.0	992.2	1241.4	1472.3	1590.4	1668.5	1781.6	1853.6
10-11 años	337.0	420.2	550.8	640.4	774.4	1029.0	1288.7	1429.8	1526.0	1669.4	1763.1
12-13 años	258.4	310.7	400.1	466.6	573.8	802.0	1066.8	1223.9	1336.2	1511.3	1630.7
14-15 años	191.5	225.9	287.7	336.2	418.9	613.3	869.7	1037.2	1163.8	1372.7	1522.8
16-17 años	146.8	172.6	220.5	259.4	328.4	504.0	762.3	946.5	1093.5	1350.4	1545.7

Leyenda. P: percentiles.

Una vez obtenida la base de datos que se muestra en la figura 5 es la estadística descriptiva de los datos de los escolares.

Figura 6. Estadística descriptiva de los datos de los escolares.

Estadísticos descriptivos									
	Rango	Mínimo	Máximo	Media	Desv. estándar	Varianza	Asimetría	Curtosis	
							Error estándar	Error estándar	
Edad	11	6	17	12.49	2.759	7.615	-.245	.115	-.973
Peso	89.7	18.0	107.7	47.578	16.1883	262.061	.233	.115	-.342
Estatura	.67	1.14	1.81	1.4904	.16289	.027	-.336	.115	-1.022
CircunCintura	64.6	50.0	114.6	71.937	11.3786	129.472	.563	.115	.272
Cadencia	153	10	163	59.58	34.462	1187.595	.620	.115	-.476
BMI	28.24	11.71	39.95	20.7498	4.27930	18.312	.637	.115	.713
Pasos	2063	126	2189	910.64	504.132	254148.813	.581	.115	-.457
Zancada	58	53	111	79.74	10.356	107.251	.566	.115	.268
Velocidad	9.45	.31	9.76	2.9923	1.93877	3.759	.833	.115	.231
Clase	2	0	2	1.06	.710	.505	-.093	.115	-1.012

Fuente: Elaboración propia

4.1.4 Modelado

Para este paso se realizará el modelado del algoritmo de Machine Learning, en este caso se utilizará el algoritmo de redes neuronales de alimentación directa, por ser uno de los algoritmos que más se utiliza en trabajos similares (Pan et al., 2019), lo que nos permitirá realizar la evaluación correspondiente en la base de datos creada y así verificar si los escolares tienen o no una buena competencia motora. Se dividirá en 3 posibles resultados, 0 si es que tiene una competencia motora por debajo de la media, 1 si es que está en una competencia motora normal y 2 si es que tiene una competencia motora por encima de la media.

Para realizar este producto de software, se utiliza el lenguaje de programación Python versión 3 en el entorno de Google Colaboratory, donde se ha implementado el algoritmo de Red neuronal.

4.1.5 Evaluación

Después de varias revisiones y ajustes al modelo, se llegó a unas especificaciones iniciales del modelo, donde en la figura 7 cargamos los datos a través de un archivo csv, dividimos en “X” y “Y” los datos, en la figura 8 dividimos los datos en datos de entrenamiento

y datos de prueba, en la figura 9 creamos las especificaciones del modelo, y en la figura 10 donde finalmente entrenamos el modelo.

Figura 7. Importaciones del modelo y subida de datos

```
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler, LabelEncoder
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.utils import to_categorical

# Carga datos en .csv
data = pd.read_csv('AllH_Recreo700.csv')

# División de conjunto x y y
X = data.iloc[:, :-1].values
y_str = data.iloc[:, -1].values
```

Figura 8. División y normalización de datos

```
# Divide los datos en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y_categorical, test_size=0.2, random_state=42)

# Normalización de datos
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)
```

Figura 9. Especificaciones del modelo

```
# Modelo de red neuronal
model = Sequential()
model.add(Dense(64, input_dim=9, activation='relu'))
model.add(Dense(32, activation='relu'))
model.add(Dense(y_categorical.shape[1], activation='softmax'))
```

Figura 10. Entrenamiento del modelo

```
# Entrenamiento del modelo y evaluación de este
model.fit(X_train_scaled, y_train, epochs=100, batch_size=32, verbose=1)

loss, accuracy = model.evaluate(X_test_scaled, y_test)
print(f'Loss: {loss}, Accuracy: {accuracy}')
```


Donde finalmente después de entrenar al modelo se llegó a un “accuracy de 0.87912 o 87% como se ve en la figura 11

Figura 11. Precisión del modelo actual

```
12/12 [=====] - 0s 2ms/step -  
3/3 [=====] - 0s 3ms/step - 1c  
Loss: 0.3830728530883789, Accuracy: 0.8791208863258362  
3/3 [=====] - 0s 4ms/step
```

4.1.6 Despliegue

Última fase de CRISP-DM y en la cual como objetivo principal tendremos el de explicar cómo funciona el proyecto construido basado en datos de Tecnologías Vestibles, así como el de exponer todos los resultados obtenidos de forma entendible. Se generará un informe en que se incluyan mejoras a futuro y listado de dificultades a la hora de realizarse.

Además, tener en cuenta, que esta fase no es el final, si es que se llegara a obtener una mayor cantidad de datos se podría volver a repetir algunas fases, según sea necesario.

El uso de la metodología Crisp-DM nos permitió encontrar y lograr un comportamiento predictivo a la hora de estimar la competencia motora y la media de estos datos. Se logró encontrar un plan de normalización, codificación de datos para la realización de los procesos puestos.

Con respecto a los obtenido se puede entender que se logró una precisión del modelo del 87.9% que, aunque es alto, se planea mejorar y valorar más este resultado, además que según Adite (Site, Nurmi & Lohan, 2021), este porcentaje de precisión se encuentra dentro del rango aceptable que es entre 70% y 99%, ahora bien, el proceso de datos no ha acabado pues se planea agregar más data, para así aumentar la precisión de los datos y la precisión del modelo, también lograr una base de datos óptima que sirva para trabajos futuros tanto relacionados como no al

presente proyecto de investigación. Ahora bien, gracias a esto, el modelo se exportará a tecnologías móviles, para así poder usarlo desde un celular o dispositivo móvil similar.

Figura 12. Exportación del modelo a .tflite


```
from tensorflow import lite

converter = lite.TFLiteConverter.from_keras_model(model)
tflite_model = converter.convert()

# Guarda el modelo TFLite en un archivo
with open('modeloentrenado.tflite', 'wb') as f:
    f.write(tflite_model)
```

El modelo fue trabajado con tecnología Python, a partir de librerías de Tensor Flow, se ingresó el conjunto de datos de las bandas inteligentes para así poder realizar un Modelo de Inteligencia Artificial en este caso Redes Neuronales de alimentación directa, para luego poder exportarlo como “modelo_entrenado.tflite” el cual es archivo con formato “.tflite” como se ve en la figura 12, el cual se puede implementar en código de Dart en Flutter para así poder usarlo en el aplicativo, presentando en la arquitectura del proyecto en figura 13.

Figura 13. Arquitectura del proyecto con respecto a Inteligencia Artificial



Fuente: Elaboración propia

Ahora seguiremos con la fase SCRUM, donde se incrustará el modelo de IA desarrollado en el aplicativo para el uso más fácil,

4.2 SCRUM

Implementamos la metodología ágil conocida como SCRUM para el desarrollo de nuestro proyecto. Esta elección se basó en la naturaleza dinámica de SCRUM (Babič et al., 2018), que permitió una gestión ágil y eficiente del proyecto, ya que, se caracteriza por su enfoque en la realización de iteraciones rápidas y la entrega continua de productos con valor agregado al cliente. Este enfoque garantiza la satisfacción del cliente al proporcionar resultados tangibles y valiosos en etapas tempranas del proyecto, evitando inconvenientes al final del proceso.

4.2.1 Equipo SCRUM

Tabla 5 Equipo SCRUM

Puesto	Persona a Cargo	Descripción
SCRUM Master	Christopher Avendaño	Se encargó y guio las decisiones para el proyecto
Equipo de desarrollo	Alex Calla Gamboa	Diseño y desarrollo de la aplicación
Product Owner	Profesores de Educación Física	Determinó las funciones o cambios constantes sobre el producto final

En la Tabla 5 se designó los roles teniendo en cuenta las capacidades individuales, al mismo tiempo se fomentó el apoyo mutuo en todo el equipo. Christopher Avendaño fue asignado como Scrum Master debido a su conocimiento y experiencia en la metodología Scrum, lo que le permitió liderar la aplicación. El rol de Product Owner, que implica la toma de decisiones finales con respecto al producto, se confió a los profesores de educación física. Esta elección se basó en su capacidad para colaborar estrechamente y participar activamente como usuarios designados, lo que garantizó una retroalimentación constante y valiosa. Además, Alexander Calla fue designado como miembro del Equipo de desarrollo, encargándose del diseño y desarrollo de la aplicación gracias a sus habilidades técnicas y creativas. Esta distribución de roles permitió un equilibrio eficiente de competencias y responsabilidades dentro del equipo, contribuyendo al éxito del proyecto.

4.2.2 Proceso de SCRUM

Determinar el Product Backlog

En esta sección de la metodología Scrum, se abordaron los requisitos funcionales que se recopilaron gracias a la colaboración con nuestros usuarios finales conocida como historia de usuarios de los profesores de educación física quienes utilizarían todas estas funcionalidades, y se consideran nuestras fuentes de confianza. De manera orgánica, se creó una lista que detalla sus necesidades y requisitos para el producto.

Tabla 6 Funcionalidades Encontradas

ID	Funcionalidad	¿Por qué?
F01	Iniciar Sesión	Poder ingresar como usuario
F02	Ingresar nuevo usuario	Permitir identificarte como usuario
F03	Cerrar Sesión	Lograr salir de tu interfaz
F04	Agregar información del escolar	Conseguir añadir o actualizar un dato
F05	Actualizar información del escolar	Conseguir añadir o actualizar un dato
F06	Ver la lista de escolar	Tener control de la lista de los escolares
F07	Eliminar escolar	Descartar escolares retirados
F08	Buscar escolar	Tener control de la lista de los escolares
F09	Calcular índice Masa Corporal	Facilitar el cálculo de IMC
F10	Agregar datos de ejercicio del escolar	Conseguir añadir o actualizar un dato
F11	Actualizar datos del ejercicio del escolar	Conseguir añadir o actualizar un dato

F12	Ver la media de datos del ejercicio en todos los escolares	Facilitar el cálculo de los escolares
F13	Visualizar gráfico (edad-Pasos)	Visualizar de una gráfica de relación
F14	Calcular Condición Física con IA	Aplicar el modelo IA en la aplicación
F15	La condición física representada en el gráfico	Mostrar condición sobre el escolar

Es importante destacar que se llevó a cabo un proceso de filtrado, en el que todo el equipo colaboró activamente, para identificar y priorizar las funcionalidades esenciales.

4.2.3 Planificación de Sprints

El equipo de desarrollo y el Product Owner llevaron a cabo reuniones para determinar el objetivo de las tareas que serían abordadas y el plazo en el que se completarán. Durante este proceso, se tuvo en cuenta el rendimiento del equipo de desarrollo y la carga de trabajo asociada a cada elemento del Product Backlog. Respetando el cronograma del equipo, se propusieron y definieron los siguientes Sprints

PRIMER SPRINT

Durante el primer Sprint, se dio prioridad a la base de la aplicación, comenzando con la implementación de un sistema de inicio de sesión (Login) y la creación de la primera pantalla que muestra la lista de los escolares, durante 15 días hábiles para el desarrollo de estas funcionalidades.

Tabla 7 Funcionalidades realizadas en el primer SPRINT

ID	Funcionalidad	¿Por qué?
----	---------------	-----------

F01	Iniciar Sesión	Poder ingresar como usuario
F02	Ingresar nuevo usuario	Permitir identificarte como usuario
F03	Cerrar Sesión	Lograr salir de tu interfaz
F04	Agregar información del escolar	Conseguir añadir o actualizar un dato
F05	Actualizar información del escolar	Conseguir añadir o actualizar un dato
F06	Ver la lista de escolar	Tener control de la lista de los escolares
F07	Eliminar escolar	Descartar escolares retirados
F08	Buscar escolar	Tener control de la lista de los escolares

SEGUNDO SPRINT

En el segundo Sprint, nos enfocamos en establecer la conexión con la base de datos y en desarrollar interfaces conectadas a la aplicación que incorporan inteligencia artificial, lo que permitió una representación gráfica y el cálculo de promedios del ejercicio realizado en los escolares. Durante 20 días hábiles para el desarrollo de estas funcionalidades.

Tabla 8 Funcionalidades realizadas en el segundo SPRINT

ID	Funcionalidad	¿Por qué?
F09	Calcular índice Masa Corporal	Facilitar el cálculo de IMC
F10	Agregar datos de ejercicio del escolar	Conseguir añadir o actualizar un dato
F11	Actualizar datos del ejercicio del escolar	Conseguir añadir o actualizar un dato
F12	Ver la media de datos del ejercicio en todos los escolares	Facilitar el cálculo de los escolares

F13	Visualizar gráfico (edad-Pasos)	Guiarse de una gráfica de relación
F14	Calcular Condición Física con IA	Generar IA en la aplicación
F15	La condición física representada en el gráfico	Mostrar condición sobre el escolar

Tras la finalización de los dos Sprints, se dedicó una semana adicional para perfeccionar el aspecto visual incluida la gráfica, los esquemas de colores de la aplicación y las últimas reuniones o cambios generales.

4.2.4 La revisión de Sprint

En la revisión del Sprint, se presenta una descripción detallada de las interfaces y acciones implementadas en la aplicación. Se explica cómo funcionan de forma independiente, con la base de datos y en la figura 14 se proporciona una visión general de la arquitectura de la aplicación.

Figura 14. Arquitectura de la aplicación



Fuente: Elaboración propia

Interfaz de Presentación

En la figura 15 se muestra en la pantalla inicial de la aplicación, una presentación inicial del aplicativo, antes de proceder el inicio de sesión.

Figura 15. Interfaz de Presentación




Fuente: Elaboración propia

Interfaz de iniciar Sesión

En la figura 16 se muestra en la pantalla antes de acceder a la aplicación, los docentes deberán iniciar sesión utilizando su dirección de correo electrónico y la contraseña correspondiente.

Figura 16. Interfaz de Inicio sesión



Fuente: Elaboración propia

Interfaz crear nuevo Usuario.

En la figura 17 se muestra en la pantalla cuando se quiere crear un nuevo usuario con, nuevos docentes deberán iniciar sesión utilizando una dirección de correo electrónico y una contraseña adecuada.

Figura 17. Interfaz de crear nuevo Usuario



Fuente: Elaboración propia

Interfaz Menú Principal.

En la figura 18 se muestra en la pantalla para interactuar para ir la siguiente interfaz sobre la lista de sus escolares, la IMC, información sobre la aplicación o cerrar sesión de tu cuenta

Figura 18. Interfaz de crear nuevo Usuario




Fuente: Elaboración propia

Interfaz Lista de Alumno.

En la figura 19 se muestra en la pantalla para interactuar con la lista de escolares, dispondrás de varias opciones, como observar el promedio de sus pasos entre otras opciones de datos, buscar escolares por nombre o apellido, añadir nuevos escolares o, si así lo prefieres, eliminarlos mediante un sencillo proceso de arrastrar y soltar.

Figura 19. Interfaz de Lista de Alumno




Fuente: Elaboración propia

Interfaz Búsqueda del Alumno

En la figura 20 se muestra en la pantalla para localizar a un alumno por su nombre o apellido en la lista de manera más eficiente.

Figura 20. Interfaz de Búsqueda del Alumno




Fuente: Elaboración propia

Interfaz Información del Alumno I

En la figura 21 se muestra en la pantalla cuando se registra a un estudiante por primera vez y se ingresan sus datos correspondientes, existe la opción de calcular el Índice de Masa Corporal

(IMC) de manera automática. Además, se proporciona una tabla que permite identificar la clasificación del IMC del alumno.

Figura 21. Interfaz información del Alumno I



The screenshot shows a mobile application interface for entering student information. The title bar is green with a back arrow and the word 'Alumno'. Below the title bar, there are input fields for 'Nombre' (containing 'C'), 'Apellido' (containing 'bu'), 'Altura (metros)', 'Peso (kilogramos)', 'Circunferencia d...', 'Edad (años)', and 'IMC' (containing '0.00'). There is a green button labeled 'Indice Masa Corporal' and a green button labeled 'Guardar'. Below the input fields, there is a table with two columns: 'IMC' and 'Estado'.

IMC	Estado
Por debajo de 18.5	Bajo peso
18.5–24.9	Peso normal
25.0–29.9	Pre-obesidad o Sobrepeso
30.0–34.9	Obesidad clase I
35.0–39.9	Obesidad clase II

Fuente: Elaboración propia

Interfaz Información del Alumno II.

En la figura 22 se muestra en la pantalla, una vez que se hayan almacenado los datos iniciales, se procederá a ingresar la información del ejercicio.

Figura 22. Interfaz información del Alumno II



The screenshot shows a mobile application interface for student information. At the top, the status bar displays the time 12:32 and various icons. The app title 'Alumno' is centered at the top. Below the title, there are two columns of input fields for student data:

- Nombre:** Dairlin
- Apellido:** Paco Linares
- Altura (metros):** 1.49
- Peso (kilogramos):** 42.5
- Circunferencia de cintu...:** 69.0
- Edad (años):** 10
- IMC:** 19.14
- Indice Masa Corporal:** A green button with a calculator icon and the text 'Indice Masa Corporal'.
- Velocidad (Kilo...):** A field with a red error message 'Solo numeros' below it.
- Zancada (centim...):** A field with a red error message 'Solo numeros' below it.
- Cadencia (pasos...):** A field with a red error message 'Solo numeros' below it.
- Pasos (pasos e...):** A field with a red error message 'Solo numeros' below it.

At the bottom, there are two green buttons: 'Guardar' (Save) and 'IA' (Analyze). Below these buttons is a line graph with the y-axis labeled 'asos' (steps) ranging from 1500 to 2500. The graph shows three data series: a blue line starting at 2000, a red line starting at 1800, and a pink line starting at 1500. All three lines show a downward trend over time.

Fuente: Elaboración propia

Interfaz Información del Alumno III.

En la figura 23 se muestra en la pantalla, de manera similar a la interfaz anterior, en esta ocasión, un texto aparecerá para evaluar el ejercicio con base en los datos proporcionados. Posteriormente, el gráfico se actualizará e indicará el rendimiento del estudiante. se encuentra por encima o por debajo del promedio.

Figura 23. Interfaz información del Alumno III.




Fuente: Elaboración propia

Interfaz Calculadora de IMC

En la figura 24 se muestra en la pantalla, para calcular el IMC sin necesidad de ingresar datos de forma manual, simplemente puedes utilizar una barra de desplazamiento que te permitirá obtener rápidamente el valor del IMC, evitando así la necesidad de guardar información de antemano.

Figura 24. Interfaz Calculadora de IMC.



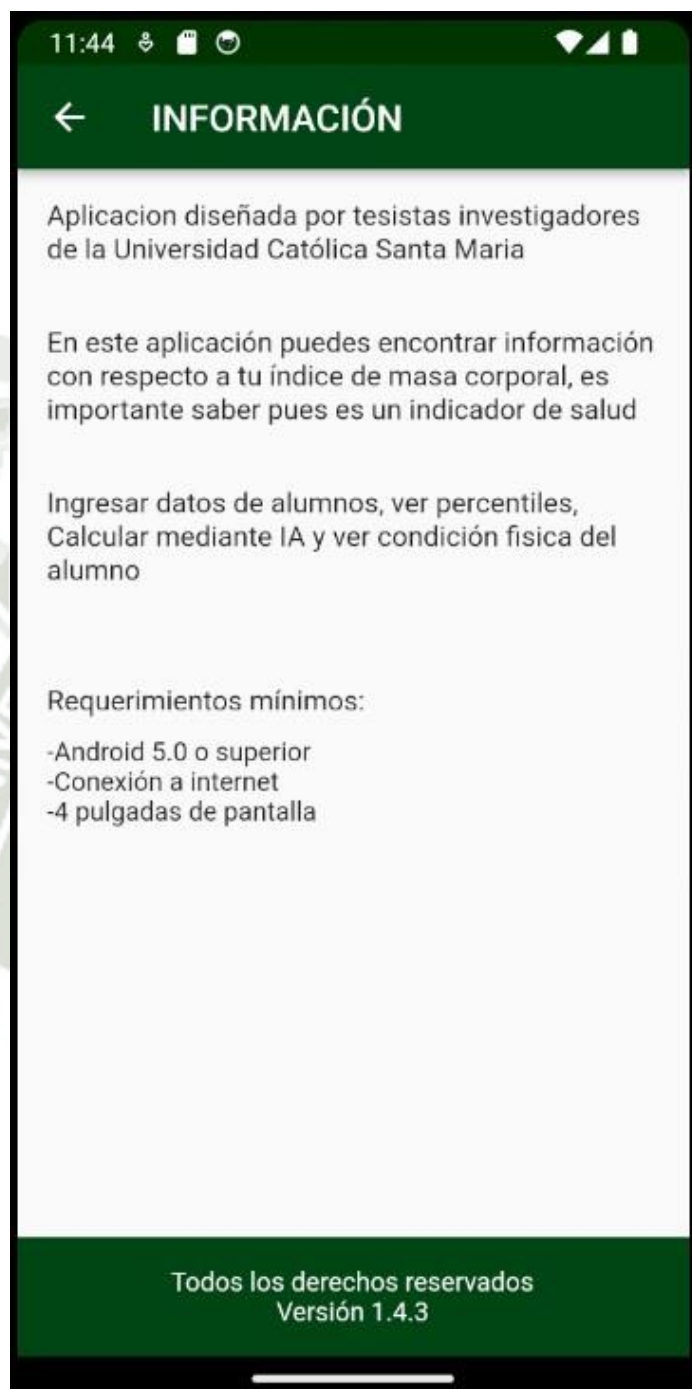
IMC	Estado
Por debajo de 18.5	Bajo peso
18.5–24.9	Peso normal
25.0–29.9	Pre-obesidad o Sobrepeso
30.0–34.9	Obesidad clase I
35.0–39.9	Obesidad clase II
Por encima de 40	Obesidad clase III

Fuente: Elaboración propia

Interfaz de Información

En la figura 25 se muestra en la pantalla información sobre el aplicativo.

Figura 25. Interfaz de Información




Fuente: Elaboración propia

Estructura de código del aplicativo

En la figura 26 se muestra la estructura del código del aplicativo, es importante destacar que se desarrolló en Android Studio utilizando el framework Flutter. La estructura del código se organizó de acuerdo con las mejores prácticas de desarrollo de aplicaciones móviles y siguiendo el patrón de diseño recomendado por Flutter.

También se implementaron buenas prácticas de documentación para facilitar su comprensión y mantenimiento a lo largo del ciclo de vida del proyecto. En pocas palabras, el código se organizó conforme a las directrices de desarrollo recomendadas por Flutter y Android Studio, lo que aseguró su eficiencia en funcionamiento y su sencillez en el mantenimiento.

Figura 26. Estructura de código del aplicativo



Fuente: Elaboración propia


Firestore

En la figura 27 y en la figura 28 se presenta la base de datos empleada en Firestore, la cual se utiliza para la autenticación y para almacenar los datos en formato JSON, lo que contribuye a una respuesta más ágil y eficiente.

Figura 27. Firestore Authentication



Figura 28. Firestore Realtime Database



Concluido el análisis de la metodología SCRUM, avanzaremos hacia la siguiente fase, que se centra en la validación.


CAPITULO V

5. ANALISIS Y VALIDACION DE RESULTADOS

5.1 Análisis de los datos


Con respecto los datos de los escolares que fueron recolectados, se puede observar que estos cumplen con la normalidad como se puede ver en los siguientes gráficos

Figura 29. Media de pasos con respecto a la Edad



En la figura 29 Se sacó una media con respecto a la edad y se puede ver que hay una distribución normal con respecto los pasos en relación con la edad. dando así un resultado positivo.


Figura 30. Media de pasos con respecto a la cadencia



En la figura 30 se puede verificar como con respecto a la cadencia se puede ver que la cantidad de pasos aumenta, dando a demostrar así que la cadencia aumenta proporcionalmente a los pasos.

Luego de reuniones con especialistas se obtuvo resultados con respecto a los datos donde se dividió en 3 clases, donde 0 es igual a buena condición física, 1 es igual a condición física ideal, y 2 es igual a condición física baja o por debajo de la media.

Figura 31. Cantidad de pasos con respecto a la clase.



Como se puede ver en la figura 31, a más pasos mejor condición física, hay que tener en cuenta que el valor de clase tiene en cuenta más factores de datos como puede ver velocidad, peso, altura, zancada entre otros.

5.2 Análisis del modelo de Inteligencia Artificial

Como se pudo ver en la fase de evaluación de CRISP-DM, metodología la cual nos permitió recolectar datos y poder construir el modelo de IA. Utilizando los datos de bandas inteligentes donde se recolectó un total de 705 datos de escolares entre 5 centros educativos, se logró llegar una precisión del 87% con respecto al modelo de Inteligencia Artificial como se ve en la figura 32, esto con el uso de redes neuronales de alimentación directa lo cual demuestra que sí es un modelo que cumple con lo que se requiere, es decir “medir la competencia motora de escolares”.

Figura 32. Cantidad de pasos con respecto a la clase.

```
12/12 [=====] - 0s 2ms/step -
3/3 [=====] - 0s 3ms/step - 100%
Loss: 0.3830728530883789, Accuracy: 0.8791208863258362
3/3 [=====] - 0s 4ms/step
```


Donde podemos ver que es un resultado aceptable en comparación con trabajos como el de Adite Site (Site, Nurmi & Lohan, 2021), donde también concluyen que el uso de redes neuronales es ideal para este tipo de datos.

5.3 Analizar Encuestas

Utilizando la metodología SCRUM, logramos desarrollar la aplicación con el modelo de inteligencia artificial. Para evaluar la usabilidad y funcionalidad del sistema, se realizó encuestas a 2 centros educativos, y se obtuvieron los resultados siguientes donde (1) es Muy en desacuerdo, (2) Algo en desacuerdo, (3) Ni en desacuerdo, ni de acuerdo, (4) Algo de acuerdo y (5) Muy de acuerdo.

Pregunta 1: ¿Existe corrección al momento de ingresar algún dato incorrecto?


Figura 33. Encuesta - Gráfica de la pregunta 1



Interpretación: El resultado reflejado en la figura 33, nos indica que el sistema de corrección al momento de ingresar datos incorrectos tiene una identidad del 50% de Ni en desacuerdo, ni de acuerdo y 50 % de Algo de acuerdo. Falta colocar algunas restricciones cuando ingresen datos.

Pregunta 2: ¿La búsqueda de escolares es rápida?


Figura 34. Encuesta - Gráfica de la pregunta 2



Interpretación: El resultado reflejado en la figura 34, nos indica que la búsqueda de escolares es rápida tiene una identidad del 100% en Muy de acuerdo. La función de búsqueda de escolares de la lista es eficiente.

Pregunta 3: ¿La adaptación del programa a tus necesidades fue adecuada?


Figura 35. Encuesta - Gráfica de la pregunta 3



Interpretación: El resultado reflejado en la figura 35, nos indica que la adaptación del programa a las necesidades fue adecuada tienen una identidad de 50% Algo de acuerdo y 50 % de Muy de acuerdo. Cumpliendo con todas las funciones del usuario.

Pregunta 4: ¿El aplicativo se adapta a diferentes tipos de alumnado?


Figura 36. Gráfica de la pregunta 4



Interpretación: El resultado reflejado en la figura 36, nos indica que aplicativo se adapta a diferentes tipos de alumnado al ingresar la información de sus datos tiene una identidad del 100% en Muy de acuerdo. Puedes ingresar datos de cualquier tipo de escolar.

Pregunta 5: ¿Se identifican los objetivos de cada opción?


Figura 37. Encuesta - Gráfica de la pregunta 5



Interpretación: El resultado reflejado en la figura 37, nos indica que se identificó los objetivos de cada opción, tienen una identidad del 50% de Ni en desacuerdo, ni de acuerdo y 50 % de Algo de acuerdo. Los objetivos de cada interfaz son claros.

Pregunta 6: ¿El aplicativo identifica errores de manejo y explica que se debe hacer?


Figura 38. Gráfica de la pregunta 6



Interpretación: El resultado reflejado en la figura 38, nos indican que el aplicativo identificó cada error de manejo y explicó lo que se debe hacer, tienen una identidad del 50% de Algo de acuerdo y 50 % de Muy de acuerdo. Aunque muestran los errores, no contribuyen significativamente al problema.

Pregunta 7: ¿El contenido preciso y claro?


Figura 39. Encuesta - Gráfica de la pregunta 7



Interpretación: El resultado reflejado en la figura 39, nos indica que el contenido es preciso y claro, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 8: ¿La información de la app está actualizada?


Figura 40. Gráfica de la pregunta 8



Interpretación: El resultado reflejado en la figura 40, nos indica que la información de la app está actualizada, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 9: ¿Se indica qué acción realizar?


Figura 41. Encuesta - Gráfica de la pregunta 9



Interpretación: El resultado reflejado en la figura 41, nos indica que acción realizar, tienen una identidad del 50% de Algo de acuerdo y 50 % de Muy de acuerdo. Los enunciados necesitan aumentar de tamaño.

Pregunta 10: ¿Existe intercambio de información entre usuario y software?


Figura 42. Gráfica de la pregunta 10



Interpretación: El resultado reflejado en la figura 42, nos indica sobre intercambio de información entre usuario y software, tiene una identidad del 100% en Algo de acuerdo, La información se guarda en la base datos en Firebase mediante internet.

Pregunta 11: ¿Es intuitivo el software?


Figura 43. Encuesta - Gráfica de la pregunta 11



Interpretación: El resultado reflejado en la figura 43, nos indica que es intuitivo el software, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 12: ¿Registra accesos de usuario?


Figura 44. Gráfica de la pregunta 12



Interpretación: El resultado reflejado en la figura 44, nos indica que sí registró los accesos de usuario, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 13: ¿La información en pantalla le resulta suficiente?


Figura 45. Encuesta - Gráfica de la pregunta 13



Interpretación: El resultado reflejado en la figura 45, nos indica que la información en pantalla le resultó suficiente, tienen una identidad del 50% de Algo de acuerdo y 50 % de Muy de acuerdo. Se pueden agregar más acciones en las interfaces.

Pregunta 14: ¿Resultó un manejo fácil del software?


Figura 46. Gráfica de la pregunta 14



Interpretación: El resultado reflejado en la figura 46, nos indica que resultó un manejo fácil del software, tiene una identidad del 100% en Muy de acuerdo

Pregunta 15: ¿Se permite al usuario corregir una respuesta aceptada por el sistema?


Figura 47. Encuesta - Gráfica de la pregunta 15



Interpretación: El resultado reflejado en la figura 47, nos indica que sí se permitió un usuario corregir una respuesta aceptada por el sistema, tienen una identidad del 50% de Algo de acuerdo y 50 % de Muy de acuerdo, se puede actualizar los datos.

Pregunta 16: ¿La presentación general le resulta adecuada?


Figura 48. Gráfica de la pregunta 16



Interpretación: El resultado reflejado en la figura 48, nos indica que la presentación general le resulta adecuada, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 17: ¿La gama de colores le parece agradable?


Figura 49. Encuesta - Gráfica de la pregunta 17



Interpretación: El resultado reflejado en la figura 49, nos indica sobre la gama de colores es agradable, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 18: ¿El color de fondo es adecuado y cómodo, para una correcta lectura?


Figura 50. Gráfica de la pregunta 18



Interpretación: El resultado reflejado en la figura 50, nos indica sobre el color de fondo es adecuado y cómodo, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 19: ¿Gráficos o imágenes facilitan el manejo de la aplicación?


Figura 51. Encuesta - Gráfica de la pregunta 19



Interpretación: El resultado reflejado en la figura 51, nos indica sobre los gráficos o imágenes facilitaron el manejo, tiene una identidad del 100% en Muy de acuerdo.

Pregunta 20: ¿Tienes libertad de elecciones en diferentes pantallas?


Figura 52. Gráfica de la pregunta 20



Interpretación: El resultado reflejado en la figura 52, nos indica que tuvo libertad de elecciones en diferentes pantallas, tiene una identidad del 100% en Muy de acuerdo. El menú principal solo redirecciona a la lista de escolares.

Pregunta 21: ¿No surgió error alguno que obligue a detener el uso?


Figura 53. Encuesta - Gráfica de la pregunta 21



Interpretación: El resultado reflejado en la figura 53, nos indica que no surgió error alguno que obligue a detener el uso, tienen una identidad del 50% de Algo de acuerdo y 50 % de Muy de acuerdo.

Pregunta 22: ¿La velocidad de paso de información de una pantalla a otra es apropiada?

Figura 54. Gráfica de la pregunta 22



Interpretación: El resultado reflejado en la figura 54, nos indica que la velocidad de información es apropiada, tienen una identidad del 50% de Algo de acuerdo y 50 % de Muy de acuerdo. No demoro en cargar los datos o las interfaces.

Pregunta 23: ¿Estaría dispuesto/a a utilizar este software en su práctica educativa?

Figura 55. Encuesta - Gráfica de la pregunta 23



Interpretación: El resultado reflejado en la figura 55, tiene una identidad del 100% en Si para utilizar en su centro educativo el software.

Análisis final: La realización de encuestas en los centros educativos desempeñó un papel crucial para evaluar el rendimiento del modelo de inteligencia artificial en la aplicación. Las respuestas

recopiladas se integraron con el propósito de someter al Prototipo de Modelo Sistémico de Calidad de Software (MOSCA) para evaluar tanto la usabilidad como la funcionalidad.

5.4 Análisis Metodológico: Evaluación del Proceso a través de la Metodología MOSCA

La obtención de datos se llevó a cabo a través de encuestas con los profesores de educación física de los centros educativos, con el propósito principal de evaluar las funcionalidades de la aplicación. La información recopilada es fundamental para mejorar la aplicación y asegurar que cumpla con las expectativas, ya que proporciona una comprensión de las necesidades de la población.

Una vez integrado los diversos entrevistados, se procedió con el método de evaluación basado en el Prototipo de Modelo Sistémico de Calidad de Software, que comprende un total de 11 categorías. De estas, hemos seleccionado 3 categorías específicas relacionadas con el software: funcionalidad, fiabilidad y usabilidad, porque estas aplican para el caso de estudio. A continuación, proporcionaremos una descripción detallada de cada una de estas categorías con las entrevistas realizadas

Tabla 9 Categorías y características de acuerdo a la metodología MOSCA


Categoría	Característica
Funcionalidad (FUN)	FUN. 1 Ajuste a los propósitos
	FUN. 2 Precisión
	FUN. 3 Interoperabilidad
	FUN. 4 Seguridad
	Total de métricas:33
Usabilidad (USA)	USA. 1 Facilidad de Compresión
	USA. 2 Capacidad de Aprendizaje
	USA. 3 Interfaz Gráfica
	USA. 4 Operabilidad
	Total de métricas:20
Fiabilidad (FIA)	FIA. 1 Madurez
	FIA. 2 Tolerancia a fallas
	FIA. 3 Recuperación
	Total de métricas:11

5.5 Estimación de Calidad de software

5.5.1 Funcionalidad

En cuanto a la Funcionalidad de la aplicación con un total de 33 métricas, se evaluaron indicadores relacionados con la seguridad, interoperabilidad, precisión y ajustes de los objetivos. En la Figura 56 se demostró un nivel de cumplimiento satisfactorio en tres de los cuatro indicadores, con un grado de satisfacción promedio del 81.88%.

Figura 56. Estimación de Funcionalidad




Fuente: Elaboración propia

5.5.2 Fiabilidad

En cuanto a la Fiabilidad de la aplicación con un total de 11 métricas, se evaluaron indicadores relacionados con la recuperación, tolerancia a fallos, y madurez. En la Figura 57 se demostró un nivel de cumplimiento satisfactorio en uno de los indicadores, con un grado de satisfacción promedio del 69.09%.

Figura 57. Estimación de Fiabilidad




Fuente: Elaboración propia

5.5.3 Usabilidad

En cuanto a la Usabilidad de la aplicación con un total de 20 métricas, se evaluaron indicadores relacionados con la operabilidad, interfaz de gráficos, capacidad de aprendizaje y facilidad de comprensión. En la Figura 58 se demostró un nivel de cumplimiento satisfactorio en tres de los cuatro indicadores, con un grado de satisfacción promedio del 82.73%.

Figura 58. Estimación de Usabilidad



Fuente: Elaboración propia

Se evaluaron un total de 64 métricas, y los indicadores de Funcionalidad y Usabilidad cumplen con los estándares del modelo sistémico de calidad de software (MOSCA), a diferencia del indicador de Fiabilidad.

5.6 Resultados del Grado de satisfacción

Los resultados finales se presentarán en la Tabla 10 sobre el nivel de calidad de software supera el umbral del 75%.

Tabla 10 Resultado del grado de satisfacción total (MOSCA)

Categorías	Características	Métricas	Porcentaje de Cumplimiento	Nivel de calidad
Funcionalidad (FUN)	FUN. 1 Ajuste a los propósitos	20	84%	Satisface
	FUN. 2 Precisión	6	86.67%	Satisface
	FUN. 3 Interoperabilidad	4	86.67%	Satisface
	FUN. 4 Seguridad	3	53.33%	No satisface
	Subtotal	33	81.88%	Satisface
Usabilidad (USA)	FIA. 1 Facilidad de Compresión	5	90%	Satisface
	FIA. 2 Capacidad de Aprendizaje	8	92%	Satisface
	FIA. 3 Interfaz Gráfica	4	95%	Satisface
	FIA. 4 Operabilidad	3	52%	No satisface
	Subtotal	20	82.73%	Satisface
Fiabilidad (FIA)	USA. 1 Madurez	5	60%	No satisface
	USA. 2 Tolerancia a fallas	4	90%	Satisface
	USA. 3 Recuperación	2	50%	No satisface
	Subtotal	11	69.09%	No satisface
TOTAL		64	77.09%	Satisface

Considerando los niveles de satisfacción alcanzados en las categorías de Funcionalidad, Fiabilidad y Usabilidad, mediante el cálculo de la media aritmética, se llega a la conclusión de que el grado de satisfacción de la aplicación para los profesores de educación física es del 77.09%. Al contrastar este resultado con el nivel de calidad INTERMEDIA, se evidencia que la aplicación cumple con estándares significativos.

DISCUSIÓN

Con el trabajo actualmente realizado, la investigación de (Abrishami et al., 2019) proporciona un marco de referencia valioso para nuestra propuesta. Gracias al trabajo desarrollado en nuestro proyecto, se logró validar la aplicabilidad de la Inteligencia Artificial en el ámbito de la competencia motora, utilizando escolares como enfoque.

Los especialistas contribuyeron a la validación de los instrumentos, proporcionando datos de referencia sobre la competencia motora de escolares a través de bandas inteligentes. Estos resultados serán fundamentales para establecer una sólida base de datos de referencia. Por otro lado, resaltar a la metodología CRISP-DM (Schröer, 2021) sobre desempeño en el desarrollo del modelo de inteligencia artificial. La estructura proporcionada por CRISP-DM orientó la correcta recolección, limpieza y exploración de datos para así llegar a un análisis y preparación de estos donde finalmente se logró al modelado y evaluación de inteligencia artificial de redes neuronales de alimentación directa. Continuando con la siguiente metodología SCRUM (Verheyen G, 2016) que desempeñó un papel esencial en la fase de desarrollo del aplicativo en nuestra investigación. SCRUM, conocida por su enfoque ágil, proporcionó una estructura dinámica y flexible que facilitó la gestión y ejecución efectiva del desarrollo del aplicativo, a través de iteraciones regulares y la colaboración continua entre el equipo.

La combinación de los estándares propuestos por (Mendoza L. et al., 2005) y la aplicación del MOSCA refuerza la confianza en la calidad general de nuestro proyecto. Es fundamental destacar la viabilidad del uso de Redes neuronales de Alimentación directa donde según Adite (Site, Nurmi & Lohan, 2021), demostraron ser el mejor algoritmo aplicable a datos obtenidos de tecnología vestible y nos permitieron lograr un modelo dentro los rangos que plantean.

CONCLUSIONES

PRIMERO, se logró crear un Modelo de inteligencia artificial basado en redes neuronales de alimentación directa que es capaz de evaluar la competencia motora de escolares basados en sus datos.

SEGUNDO, se logró completar un dataset utilizando bandas inteligentes como tecnología para recopilar una gran cantidad de datos en escolares de entre primaria y secundaria de 5 centros educativos alrededor de Arequipa.

TERCERO, se logró incrustar el modelo de inteligencia artificial a un aplicativo móvil con tecnología Dart y Flutter.

CUARTO, El uso de Flutter como framework principal para el desarrollo de aplicativos móviles resultó ideal para el involucramiento de tecnología de Inteligencia Artificial.

QUINTO, se concluyó que según la metodología MOSCA el software móvil utilizado resultó con una calidad de software de 77.09% que es mayor al 75% por lo cual el sistema logró el nivel de calidad intermedia.


SEXTO, tomando en cuenta la validación de software MOSCA, se concluye que el modelo de Inteligencia Artificial basado en redes neuronales de alimentación directa nos permite evaluar la competencia motora de los escolares. Esto a través del propio aplicativo que incrusta la Inteligencia Artificial.

RECOMENDACIONES

Primero: Utilizar 2 metodologías tanto para el desarrollo de un Modelo de Inteligencia Artificial (CRISP-DM) y el desarrollo de un aplicativo móvil (SCRUM) nos permite una creación limpia y continua del producto.

Segundo: El dataset resultante se puede utilizar para diferentes propósitos como el de crear otros modelos de inteligencia artificial, así como crear otros patrones y así generar posibles trabajos futuros.

Tercero: Usar aplicativos móviles resulta apropiado para el uso en entornos abiertos como puede ser el ejercicio al aire libre durante una clase de Educación física.



TRABAJOS FUTUROS

Sobre este trabajo es valioso extender el desarrollo de Inteligencia Artificial a los datos que se pueden obtener y utilizar para evaluar a una persona como pueden ser datos cognitivos, psicomotrices y afectivos, para lograr una evaluación mas amplia de la persona.

Una posible mejora con respecto a la calidad del modelo de inteligencia artificial llegaría a ser el aumentar el número de datos que se puedan recopilar de diferentes escolares de centros educativos.

Con la evolución de la tecnología es posible llegar a utilizar en conjunto el uso de las tecnologías para que estén directamente conectadas tanto tecnología vestible como inteligencia artificial y llegar a utilizar un aplicativo más automatizado.

Para futuras investigaciones se sugiere examinar posibles formas de uso de las tecnología vestible como en diferentes ejercicios, o diferentes partes del cuerpo donde se usan, con el objetivo de comprender diferentes formas de evaluar la competencia motora.

REFERENCIAS

- Abrishami, M. S., Nocera, L., Mert, M., Trujillo-Priego, I. A., Purushotham, S., Shahabi, C., & Smith, B. A. (2019). Identification of developmental delay in infants using wearable sensors: Full-Day Leg Movement Statistical Feature analysis. *IEEE Journal of Translational Engineering in Health and Medicine*, 7, 1-7.
<https://doi.org/10.1109/jtehm.2019.2893223>
- Aditi Site, Jari Nurmi, & Elena Simona Loan. (2021). *Systematic Review on Machine Learning Algorithms Used in Wearable-Based eHealth Data Analysis*. IEEE access: practical innovations, open solutions, 9, 112221–112235.
<https://doi.org/10.1109/ACCESS.2021.3103268>
- Alade, O. M., & Sowunmi, O. Y. (2018). *Developing a Calorie Counter Fitness App for Smartphones*. 724, 14–22. <https://doi.org/10.1007/978-3-319-74980-8>
- Babič, F., Gašpar, V., & Satala, P. (2018). *New Trends in Mobile Technologies Education in Slovakia: An Empirical Study*. 2018 16th International Conference on Emerging eLearning Technologies and Applications (ICETA).
<https://doi.org/10.1109/iceta.2018.8572277>
- Bat-Erdene, B. O., & Saver, J. L. (2021). Automatic Acute Stroke Symptom Detection and Emergency Medical Systems Alerting by Mobile Health Technologies: A Review. *Journal of Stroke and Cerebrovascular Diseases*, 30(7), 105826.
<https://doi.org/10.1016/j.jstrokecerebrovasdis.2021.105826>
- Bayoumy, K., Gaber, M. A., Elshafeey, A., Mhaimeed, O., Dineen, E. H., Marvel, F. A., Martin, S. S., Muse, E. D., Turakhia, M. P., Tarakji, K. G., & El-Shazly, M. (2021). Smart

wearable devices in cardiovascular care: where we are and how to move forward. *Nature Reviews Cardiology*, 18(8), 581–599. <https://doi.org/10.1038/s41569-021-00522-7>

Ceron, J.D., López, D.M., & Hofmann, C. (2017). A Two-Layer Method for Sedentary Behaviors Classification Using Smartphone and Bluetooth Beacons. En B. Blobel y W. Gooseen (Eds.), *pHealth 2017: Proceedings of the 14th International Conference on Wearable Micro and Nano Technologies for Personalized Health* (pp. 115). IOS Press. <https://doi.org/10.3233/978-1-61499-791-0-115>

Creaser, A. V., Clemes, S. A., Costa, S., Hall, J., Ridgers, N. D., Barber, S. E., & Bingham, D. D. (2021). 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*, 18(12). <https://doi.org/10.3390/ijerph18126211>

Dandapani, H. G., Davoodi, N. M., Joerg, L. C., Li, M. M., Strauss, D. H., Fan, K., Massachi, T., & Goldberg, E. M. (2022). Leveraging Mobile-Based Sensors for Clinical Research to Obtain Activity and Health Measures for Disease Monitoring, Prevention, and Treatment. *Frontiers in Digital Health*, 4(June), 1–12. <https://doi.org/10.3389/fdgth.2022.893070>

Durán Chinchilla, C. M., García Quintero, C. L., & Rosado Gómez, A. A. (2021). El rol docente y estudiante en la era digital. *Revista Boletín Redipe*, 10(2), 287–294. <https://doi.org/10.36260/rbr.v10i2.1213>

Esakia, A., McCrickard, S., Harden, S., Horning, M., & Ramalingam, N. P. (2020). Using smartwatches to facilitate a group dynamics-based statewide physical activity intervention. *International Journal of Human Computer Studies*, 142(December 2019), 102501. <https://doi.org/10.1016/j.ijhcs.2020.102501>

Estudiantes crean plataforma para capacitar a docentes peruanos en el uso de las TIC |

Noticias | Agencia Peruana de Noticias Andina. (n.d.). Retrieved August 24, 2022, from <https://andina.pe/agencia/noticia-estudiantes-crean-plataforma-para-capacitar-adocentes-peruanos-el-uso-las-tic-856177.aspx>

Godoy Cumillaf, A. E. R. (2022). Efectividad de las intervenciones de actividad física en la condición física, la competencia motora y la adiposidad en niños y adolescentes de América latina.

González, O. (2022). Los cimientos de la Inteligencia Artificial en el sistema productivo de contenidos periodísticos automatizados The role of artificial intelligence in the production of automated journalistic content. *MARKA Revista de Marketing Aplicado*, 26(1), 15–35. <https://doi.org/10.17979/redma.2022.26.1.9056>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. Google

Developers. (2022). Diseño Responsivo. Recuperado de

<https://developers.google.com/web/fundamentals/design-and-ux/responsive/>

Hoelzemann, A., Pithan, J. S., & Van Laerhoven, K. (2022). Open-Source Data Collection for Activity Studies at Scale. *Smart Innovation, Systems and Technologies*, 291(January), 27–38. https://doi.org/10.1007/978-981-19-0361-8_2

Huhn, S., Axt, M., Gunga, H. C., Maggioni, M. A., Munga, S., Obor, D., Sié, A., Boudo, V.,

- Bunker, A., Sauerborn, R., Bärnighausen, T., & Barteit, S. (2022). The Impact of Wearable Technologies in Health Research: Scoping Review. *JMIR MHealth and UHealth*, 10(1). <https://doi.org/10.2196/34384>
- Jia Y, Wang W, Wen D, Liang L, Gao L, Lei J. 2018. Perceived user preferences and usability evaluation of mainstream wearable devices for health monitoring. *PeerJ* 6:e5350 <https://doi.org/10.7717/peerj.5350>
- Lee, J., Park, J., Kim, Y., & Woo, M. (2021). Affective Change With Variations in Zumba Fitness Intensity as Measured by a Smartwatch. *Perceptual and Motor Skills*, 128(5), 2255–2278. <https://doi.org/10.1177/00315125211022700>
- Mendoza, L. E., Pérez, M. A., & Grimán, A. C. (2005). Prototipo de Modelo Sistémico de Calidad (MOSCA) del Software. *Computación y Sistemas*, 8(3), 196-221. <https://www.redalyc.org/pdf/615/61580304.pdf>
- Pan, L., He, C., Tian, Y., Wang, H., Zhang, X., & Jin, Y. (2019). A classification-based surrogate-assisted evolutionary algorithm for expensive many-objective optimization. *IEEE transactions on evolutionary computation : a publication of the IEEE Neural Networks Council*, 23(1), 74–88. <https://doi.org/10.1109/tevc.2018.2802784>
- Qiu, H., Wang, X., & Xie, F. (2018). A Survey on Smart Wearables in the Application of Fitness. *Proceedings - 2017 IEEE 15th International Conference on Dependable, Autonomic and Secure Computing, 2017 IEEE 15th International Conference on Pervasive Intelligence and Computing, 2017 IEEE 3rd International Conference on Big Data Intelligence and Compu*, 2018-Janua, 303–307. <https://doi.org/10.1109/DASC-PICom-DataCom-CyberSciTec.2017.64>

Rahman, M. J., Morshed, B. I., & Harmon, B. (2020). A Field Study to Capture Events of Interest (EoI) from Living Labs Using Wearables for Spatiotemporal Monitoring Towards a Framework of Smart Health (sHealth). *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2020-July*, 5943–5947. <https://doi.org/10.1109/EMBC44109.2020.9175771>

Masci, I., Vannozzi, G., Bergamini, E., Pesce, C., Getchell, N., & Cappozzo, A. (2013). Assessing locomotor skills development in childhood using wearable inertial sensor devices: the running paradigm. *Sensors* (Basel), 20(7), 2047. <https://doi.org/10.1016/j.gaitpost.2012.09.017>

Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, 181(2019), 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>

Striggles, P. (2021). Wristbands in Home-Based Rehabilitation—Validation of Heart Rate Measurement. *Nursing*, 20(4), 22–24. <https://doi.org/10.1038/scientificamerican07181896-40>

Sujatha, Somasundaram, S., Alagesan, J., & Adhitya P.S., V. (2022). Developmental coordination disorder in school children- A systematic review. *Biomedicine (Trivandrum)*, 42(6), 1156–1161. <https://doi.org/10.51248/.v42i6.1102>

Sun, J., & Liu, Y. (2020). Using smart bracelets to assess heart rate among students during physical education lessons: Feasibility, reliability, and validity study. *JMIR MHealth and UHealth*, 8(8), 1–12. <https://doi.org/10.2196/17699>

Verheyen, G. (2016). *Scrum: A pocket guide (Best practice (Van Haren Publishing))*.

Zaltbommel, Países Bajos: Van Haren Publishing.

Wang, C., Lizardo, O., & Hachen, D. S. (2021). Using Fitbit data to examine factors that affect daily activity levels of college students. *PLoS ONE*, 16(1 January), 1–20.

<https://doi.org/10.1371/journal.pone.0244747>

Wang, J., Coleman, D. C., Kanter, J., Ummer, B., & Siminerio, L. (2018). 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 Research Protocols*, 7(4). <https://doi.org/10.2196/10009>

Wirth, R., & Hipp, J. (2000, April). CRISP-DM: Towards a standard process model for data mining. In Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining (Vol. 1, pp. 29-39).

Xie, J., Wen, D., Liang, L., Jia, Y., Gao, L., & Lei, J. (2018). Evaluating the validity of current mainstream wearable devices in fitness tracking under various physical activities:

Comparative study. *JMIR MHealth and UHealth*, 6(4).

<https://doi.org/10.2196/mhealth.9754>

Yáñez-Silva, A., Hespanhol, J. E., Campos, R. G., & Cossio-Bolaños, M. (2014). Valoración de la actividad física en adolescentes escolares por medio de cuestionario. *Revista chilena de nutrición*, 41(4), 360-366. <https://doi.org/10.4067/s071775182014000400003>

A. Artículos Publicados



Article

Quantification of the Number of Steps in a School Recess by Means of Smart Bands: Proposal of Referential Values for Children and Adolescents

Jose Sulla-Torres ¹, Rubén Vidal-Espinoza ², Christopher Avendaño Llanque ¹, Alexander Calla Gamboa ¹, Manuel Zúñiga Carnero ¹, Marco Cossio-Bolaños ^{3,*} and Rossana Gomez-Campos ^{3,*}

¹ Escuela de Ingeniería de Sistemas, Universidad Católica de Santa María, Urb. San José, San José s/n, Yanahuara, Arequipa 04001, Peru

² Escuela de Educación Inicial, Departamento de Educación Diferencial, Facultad de Educación, Universidad Católica Silva Henríquez, Santiago 8330225, Chile

³ Carrera de Ciencias de la Actividad Física y del Deporte, Facultad de Ciencias de la Salud, Universidad San Ignacio de Loyola, Av. La Fontana 550, La Molina, Lima 15024, Peru

* Correspondence: mcossio1972@hotmail.com (M.C.-B.); rossauicamp@gmail.com (R.G.-C.); Tel.: +56-956008825 (M.C.-B.); +56-973718375 (R.G.-C.)

Abstract: (1) Background: Regular physical activity has multiple benefits. Therefore, school recess is a key tool to provide opportunities for schoolchildren to engage in extracurricular physical activity, have fun, play and interact with their peers. The aim is to provide reference data to quantify the number of steps that children and adolescents perform in a school recess using smart bands according to age range and sex. (2) Method: A descriptive cross-sectional study was carried out in 494 schoolchildren aged 6 to 17 years (292 males and 202 females). Weight, standing height and waist circumference (WC) were evaluated. The body mass index (BMI) was calculated. The quantification of the number of steps during school recess was performed using a smart band. (3) Results: Percentiles were constructed for the number of steps (number of steps/recess). The cut-off points considered were <p25 (below average), p25 to p75 (average) and >p75 (above average). The median values in both sexes decreased as the age range increased. Youth who walked fewer steps during recess (<p25: below average) had elevated BMI and WC values relative to those who walked within average and above average. (4) Conclusion: The number of steps taken by schoolchildren during school recess decreases drastically with advancing age. The proposed reference values can be used to categorize schoolchildren according to the number of steps taken and to compare them among their peers. The results suggest their use and application in schools as a way of achieving the minimum physical activity recommendations.

Keywords: steps; school recess; reference values; smart band



Citation: Sulla-Torres, J.; Vidal-Espinoza, R.; Avendaño Llanque, C.; Calla Gamboa, A.; Zúñiga Carnero, M.; Cossio-Bolaños, M.; Gomez-Campos, R. Quantification of the Number of Steps in a School Recess by Means of Smart Bands: Proposal of Referential Values for Children and Adolescents. *Children* **2023**, *10*, 915. <https://doi.org/10.3390/children10060915>

Academic Editor: Antonis Kambas

Received: 24 February 2023

Revised: 12 May 2023

Accepted: 17 May 2023

Published: 23 May 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Regular physical activity (RPA) promotes growth and development in children and adolescents and has multiple physical, mental and psychosocial health benefits [1,2]. It also positively affects body composition, i.e., higher levels of physical activity are associated with a healthy weight status in children and adolescents [3].

RPA is one of the most effective ways to prevent cardiovascular and mental diseases, as well as to improve physical fitness in children and adolescents [4]. Its assessment in the school stage is relevant, since it helps in the regulation and quantification of daily physical activity levels [5].

In fact, among the most commonly used methods are subjective measures (self-report, such as questionnaires, and proximity reports from parents and teachers), as well as objective measures (such as heart rate, accelerometry, pedometers, direct observation and doubly labeled water) [6].

Recently, smart bands have become part of people's daily lives, since they can be used as an objective method that allows to evaluate factors directly on the body [7], where they continuously monitor and record data in real time, such as physical activity, energy consumption and sleep quality [8], among other parameters.

In recent years, several studies have prioritized the measurement and monitoring of physical activity patterns by counting steps per day in free-living conditions in children and adolescents in various regions of the world using pedometers [9–12] and accelerometers [13–17]. However, studies that have quantified the number of steps during school recess are scarce [18–20]. It is widely known that recess is a part of the school day that allows children and teachers to rest from classes [1].

Recess is also characterized as a potentially important time, and during which children can engage in daily physical activity. For many children, it represents the main opportunity to engage in physical activity during the school day [19], as well as to interact outdoors among peers [21].

In general, regardless of the performance of physical activity during recess, scientific evidence suggests that the practice of RPA is associated with high levels of physical fitness (e.g., cardiovascular endurance, muscular strength and endurance, flexibility and body composition), which lead to the preservation of better physical, mental and social health status among children and adolescents [22–24].

In this context, the Center for Disease Control and Prevention (CDC) and the American Society of Health and Physical Educators SHAPE [25] recommend at least 20 min as a rest period within the school day, although the scheduling and duration of school breaks may vary between countries and geographic regions [26]. Therefore, an analysis of children and adolescents' leisure time activity should be carried out, taking into account the cultural, socioeconomic and climatic environment [18], respectively.

Therefore, based on the fact that there is freedom in establishing a prudent time for a school recess, the Ministry of Education of Peru in its guidelines for the development of schedules in educational institutions suggests about 20 min [27], although some schools generally set their recesses at 15 min. This indicator could help to identify the number of steps that children and adolescents take.

This information could serve as an effective motivational tool and a way to monitor and promote the accumulation of RPA in schools and consequently allow the achievement of the minimum physical activity recommendations [28].

In fact, the pedometer is an inexpensive, unobtrusive and ideal measurement tool for large populations. It can be used primarily to monitor and quantify the short and frequent periods that occur during the school day. It can even be used to plan and evaluate school-based physical activity intervention programs.

Therefore, the main objective of this study was to provide baseline data to quantify the number of steps taken by children and adolescents in a school recess using smart bands according to age range and sex.

2. Materials and Methods

2.1. Type of Study and Sample

A descriptive cross-sectional study was carried out in 494 schoolchildren (292 males and 202 females) with an age range of 6 to 17 years (13.7 ± 2.9 years). The sample selection was non-probabilistic (convenience). Two state schools in the city of Arequipa (Peru) were evaluated. This city is located south of Lima (capital of Peru) at 2320 m above sea level. The schoolchildren attended physical education classes twice a week, each lasting 45 min.

In order to carry out the study in both schools, permission was requested from the administration of each school. Then, parents and/or guardians were informed about the objective of the project. Parents who agreed to participate in the study signed the informed consent form to authorize their children's participation. On the day of the evaluation, the children and adolescents signed the informed assent.

Schoolchildren from 6 to 17 years of age were included. Schoolchildren who were on medical rest and those who could not perform any type of physical activity during school hours due to medical prescription were excluded from the study.

Anthropometric measurements and the use of the smart band were applied according to the suggestions described by the local ethics committee (UCSM-096-2022) and the Declaration of Helsinki (World Medical Association) for human beings.

2.2. Techniques and Procedures

Anthropometric measurements were evaluated at each school's facilities. The evaluation team consisted of 4 experienced physical education teachers. Weight and standing height were evaluated using the standardized protocol of Ross and Marfell-Jones [29]. Body weight (kg) was evaluated using an electronic scale BC-730 (Tanita Corporation, Tokyo, Japan), United Kingdom with a scale from 0 to 150 kg and an accuracy of 100 g. Standing height was measured according to the Frankfurt plane using a portable stadiometer (Seca 216, GmbH and Co. KG, Hamburg, Germany) accurate within 0.1 mm. Waist circumference (WC) was measured using a tape measure (Seca) to the nearest 1 mm. The body mass index (BMI) was calculated using the following formula: $BMI = \text{weight (kg)} / \text{height}^2 \text{ (m)}$. According to the BMI Z-score, patients were classified as follows: underweight/normal weight with Z-scores between -2 and $+0.99$, overweight from 1 to 1.99 , obese from 2 to 2.99 and very obese ≥ 3 [30].

To categorize abdominal adiposity (WC) by age and sex, the suggestions described by Fernández et al. [31] were used. It was categorized into two groups (without risk $< p75$ and with risk $> p75$).

The quantification of the number of steps during school recess was performed using a smart band (Huawei band 7, China) with an AMOLED screen of 194×368 , and with 1.47 inches. This band marking had been previously used in other studies [32]. Each child and adolescent were fitted with the smart band on the wrist of the right hand before recess. They were instructed to go about their daily activities as normal during the 15 min of recess. After recess was over, the evaluators approached each child to remove the smart band. A daily one-week school break was evaluated.

2.3. Statistical Analysis

All data were normal and verified using the Kolmogorov–Smirnov (K-S) test. Descriptive statistics (mean and standard deviation) were calculated. Differences between both sexes were calculated by means of the *t*-test for independent samples. The LMS method [33] was used to construct the percentiles. The curves L, M and S represent skewness (lambda), median (mu) and coefficient of variation (sigma). The LMS method uses the Box–Cox transformation to fit the data distribution to a normal distribution by minimizing the effects of skewness. The L, M and S parameters were calculated according to the maximum penalized method [34]. Data processing was performed using LMS Chartmaker Pro software (The Institute of Child Health, London, UK) [35]. Differences between BMI and WC values according to step/recreation categories were determined via one-way ANOVA and Tukey's test of specificity. In all cases, $p < 0.05$ was considered to be significant. Calculations were performed in Excel spreadsheets and SPSS 18.0.

3. Results

The variables characterizing the children and adolescents studied are shown in Table 1. In terms of body weight, there were no differences between both sexes from 6–7 years old to 12–13 years old ($p > 0.05$); then, at 14–15 years old and 16–17 years old, males presented a higher body weight ($p < 0.05$). In terms of height, there were no differences from 6–7 years to 10–11 years ($p > 0.05$). However, from 12–13 years to 16–17 years, males presented a taller height than females ($p < 0.05$). In terms of BMI, there were no significant differences in all age ranges between both sexes ($p > 0.05$).

Table 1. Anthropometric, physical and physiological characteristics of the schoolchildren studied.

Age (Years)	n	Weight (kg)		Standing Height (cm)		BMI (kg/m ²)		WC (cm)		Steps (Number)		Average HR (bpm)		Maximum HR (bpm)	
		X	SD	X	SD	X	SD	X	SD	X	SD	X	SD	X	SD
Males (n = 292)															
6–7 years	19	25.0	3.1	121.6	6.1	16.7	1.5	60.7	4.4	1423.9 *	310.1	152.8	16.6	173.1	15.2
8–9 years	37	33.2	9.4	131.4	6.7	19.0	3.5	68.4 *	11.9	1244.2 *	538.5	149.1	17.1	172.9	15.3
10–11 years	22	41.0	13.0	143.1	8.9	19.8	4.7	73.2	11.9	1054.1 *	423.5	148.8	17.6	171.6	17.0
12–13 years	64	51.7	9.8	155.4 *	8.2	21.4	3.5	74.0 *	9.0	1087.7 *	419.1	124.1	17.8	151.0	19.8
14–15 years	106	60.0 *	11.7	163.3 *	6.4	22.4	4.0	77.5 *	10.5	707.5	400.9	105.1	15.2	128.6	18.2
16–17 years	44	63.1 *	10.2	165.6 *	7.4	23.0	3.5	78.5 *	8.6	605.6	344.5	100.9	14.5	125.1	17.0
Females (n = 202)															
6–7 years	20	24.2	7.1	119.4	5.4	17.2	4.5	63.1	12.8	1210.0	363.0	147.2	9.7	171.8	10.1
8–9 years	27	30.3	7.9	130.5	7.2	18.5	3.4	61.8	9.2	1372.0	287.3	142.3	8.8	164.2	15.3
10–11 years	24	42.8	10.1	145.3	6.5	20.1	3.8	72.6	9.8	940.3	369.1	137.1	17.9	162.5	19.1
12–13 years	42	51.4	9.6	152.5	5.7	22.0	3.4	70.4	8.4	853.2	389.7	118.0	16.4	142.1	17.8
14–15 years	57	56.0	11.6	154.5	4.4	23.4	4.6	73.4	10.1	667.7	402.1	104.5	15.7	127.3	14.7
16–17 years	32	58.2	8.5	156.2	5.3	23.8	3.4	75.4	7.8	583.8	266.5	100.2	10.2	123.8	12.5

Legend: X: mean, SD: standard deviation, PI: weight index, WC: waist circumference, HR: heart rate, *: significant difference in relation to women ($p < 0.05$).

In terms of WC, males presented a higher WC than females at 8–9 years and at advanced ages (12–13 years, 14–15 years and 16–17 years), while there were no differences at 6–7 years and 10–11 years ($p > 0.05$).

Regarding the number of steps taken in the 15 min recess, males took more steps than females from 6–7 years old to 12–13 years old ($p < 0.05$). Then, at older ages (14–15 years and 16–17 years), no differences were observed between both sexes ($p > 0.05$). There were no significant differences in mean and maximum HR between both sexes ($p > 0.05$).

The distributions of the percentiles (P3, P5, P10, P25, P50, P75, P90, P95 and P97) for the number of steps/recreation are shown in Table 2 and Figure 1. The median values in both sexes decrease as the age range increases. For example, the number of steps at 8–9 years decreases by 8.4% in males and 5.9% in females; at 10–11 years, it drops for 21.2% in males and 22.0% in females; at 12–13 years, it decreases by 30.5% in males and 39.2% in females; at 14–15 years, it decreases by 53.3% in males and 53.5% in females and at 16–17 years, it decreases by 63.4% in males and 61.8% in females.

Table 2. Percentile distribution of the number of steps taken in 15 min school breaks by age range and sex.

Age (Years)	L	M	S	P3	P5	P10	P15	P25	P50	P75	P85	P90	P95	P97
Males														
6–7 years	1.34	1406.4	0.25	656.6	762.9	917.4	1016.8	1157.8	1406.4	1640.9	1762.0	1842.5	1959.6	2034.4
8–9 years	1.08	1288	0.35	407.0	522.5	696.5	812.0	980.2	1288.0	1590.0	1750.2	1858.0	2016.9	2119.6
10–11 years	0.84	1108.8	0.42	305.4	396.5	543.5	646.5	803.4	1108.8	1428.3	1604.8	1726.0	1908.3	2028.1
12–13 years	0.6	977.5	0.48	263.7	333.0	451.8	539.8	681.0	977.5	1314.9	1512	1651.7	1867.5	2013.2
14–15 years	0.35	656.2	0.56	178.6	218.1	289.2	344.9	439.1	656.2	933.3	1109	1239.4	1450.4	1599.1
16–17 years	0.14	515.5	0.62	143.7	170.9	221.4	262.3	334.5	515.5	775.0	955.8	1097.8	1341.7	1523.9
Females														
6–7 years	1.89	1319.5	0.20	683.3	788.2	929.0	1014	1129.1	1319.5	1488.1	1571.8	1626.4	1704.3	1753.3
8–9 years	1.39	1241.4	0.29	462.4	579.9	744.6	848.0	992.2	1241.4	1472.3	1590.4	1668.5	1781.6	1853.6
10–11 years	0.92	1029.0	0.37	337.0	420.2	550.8	640.4	774.4	1029.0	1288.7	1429.8	1526.0	1669.4	1763.1
12–13 years	0.52	802.0	0.46	258.4	310.7	400.1	466.6	573.8	802.0	1066.8	1223.9	1336.2	1511.3	1630.7
14–15 years	0.24	613.3	0.54	191.5	225.9	287.7	336.2	418.9	613.3	869.7	1037.2	1163.8	1372.7	1522.8
16–17 years	0.08	504.0	0.62	146.8	172.6	220.5	259.4	328.4	504.0	762.3	946.5	1093.5	1350.4	1545.7

Legend: P: percentile, L: (skewness, lambda), M: (median, mu), S: (coefficient of variation, sigma).

The BMI and WC values according to the categories of the number of steps during school recess are shown in Table 3. In the comparison of BMI in both sexes, there were no differences between youth categorized as below-average steps versus above-average steps ($p > 0.05$) and between the category average steps versus above-average steps ($p > 0.05$).

However, there were differences in BMI between the categories of below-average steps versus above-average steps ($p < 0.05$).




Figure 1. Distribution of percentiles for the number of steps in a school recess in both sexes.

In relation to WC, men categorized as below-average steps presented higher WC values in relation to their peers categorized as average and above-average steps ($p < 0.05$). In females, differences were observed among the three categories ($p < 0.05$), where WC increased as the number of steps decreased.

Table 3. BMI and WC values according to step categories in a school recess.

Indicators	Categories of Number Steps						Comparisons				
	Under Average		Average		Above Average		<i>p</i>	UA-A	UA-AA	A-AA	
	X	SD	X	SD	X	SD					
Males											
<i>n</i>	82		124		86						
BMI (kg/m ²)	21.9	5.0	20.6	4.2	20.1	4.4	0.01	>0.05	<0.05	>0.05	
WC (cm)	78	12.2	74.3	10.5	74.1	9.6	0.027	<0.05	<0.05	>0.05	
Females											
<i>n</i>	55		89		58						
BMI (kg/m ²)	22.0	3.3	20.9	4.6	19.6	5.3	0.05	>0.05	<0.05	>0.05	
WC (cm)	74.5	7.1	71.1	7.8	69.5	9.5	0.004	<0.05	<0.01	<0.05	

Legend: BMI: body mass index, X: mean, SD: standard deviation, BP: below average (<p25), p: average (p25 to p75), AP: above average (>p75).

Figure 2a shows the comparison of the number of steps in three age groups. There were no significant differences between both sexes in each of the age categories ($p > 0.05$). However, we observed significant differences between the three categories and in both sexes ($p < 0.05$). This is evidence that the number of steps gradually decreases in each age category. At older ages (14 to 17 years), the number of steps decreases drastically to 677 ± 388.9 steps in males and 638.2 ± 360.9 steps in females.

Figure 2b shows the comparisons of the number of steps according to WC categories in both sexes. When we compared the number of steps between WC categories with and without risk, we found significant differences in both sexes ($p < 0.05$). For example, males (923.6 ± 510.4 steps) and females (963.0 ± 470.8 steps) categorized as non-risk performed a higher number of steps than their non-risk counterparts (males 884.8 ± 478.3 steps and females 782.9 ± 426.5 steps). Furthermore, when we compared between males and females in the same category (with risk and without risk), there were no significant differences ($p > 0.05$). The prevalence of abdominal adiposity with risk (according to the WC category) was 23.9% in both sexes (in males 15.4%, $n = 76$, and in females 8.5%, $n = 42$).




Figure 2. Comparison of the number of steps by age ranges, WC categories and BMI categories in both sexes. Legend: a: significant difference in relation to the group of 6 to 9 year olds; b: significant difference in relation to the group of 10 to 13 year olds; *: significant difference in relation to the category of without risk; +: significant difference in relation to the category of normal weight.

Figure 2c shows the comparisons of the number of steps in both sexes according to BMI categories (Z-Score). There were no significant differences between males and females in the normal weight category (males: 975.2 ± 444.5 steps, and females: 950.3 ± 411.2 steps) and in the overweight category (males: 865.1 ± 440.0 steps, and females: 823.4 ± 442.2 steps). However, we observed significant differences ($p < 0.05$) in the number of steps between males categorized as normal weight (975.2 ± 444.5 steps) versus overweight (865.1 ± 440.0 steps) and in females categorized as normal weight (950.3 ± 411.2 steps) versus overweight (823.4 ± 442.2 steps). The prevalence of nutritional status was 57.7% normal weight (males (33.4%, $n = 165$), females (24.3%, $n = 120$)) and 42.3% overweight (males (25.7%, $n = 127$), females (16.6%, $n = 82$)).

4. Discussion

The objective of the study was to provide reference data to quantify the number of steps that children and adolescents performed in a school recess using smart bands according to age range and sex.

The results of the study have evidenced that the number of steps children perform in a 15 min school recess range on average from 1406.4 to 504 steps in both sexes. Furthermore, we verified that the number of steps in both sexes decreases rapidly with increasing age, being more pronounced in females than in males. For example, during adolescence (at 14–15 years of age), they decreased by ~53.3% in males and ~53.5% in females, which evidently is a clear sign that physical activity patterns start to decrease during adolescence, drastically decreasing the physical activity volumes [36].

This information could help in the promotion of physical activity during school recess periods to develop strategies to encourage adequate physical activity levels [37,38].

In fact, the percentiles proposed in this study are a valuable tool that will allow for a cross-sectional assessment of the number of steps that children and adolescents perform during a 15 min school recess. This information can be useful for physical education

teachers, parents and health professionals in general. It is widely known that the reference values proposed here can help to follow the trajectories of physical activity during school breaks at primary and secondary school level.

In this context, this study adopted the cut-off points of some recent research [39,40], where authors have proposed percentiles of the number of steps in a day. These can be interpreted as <p25 as below average, p25 to p75 as average and >p75 as above average.

In essence, percentiles based on step counts, regardless of the method used, can be applied to set targets for improvement, especially with those children and adolescents below the 25th percentile [39]. For example, children and adolescents in this study categorized below p25 (number of steps/recreation) evidenced higher values of BMI and WC relative to their counterparts who performed a higher volume of steps during a 15 min recess. Additionally, we verified that children and adolescents categorized according to WC with risk showed lower values in the number of steps compared to their counterparts without risk who reflected a higher number of steps.

In essence, the relationships made between BMI and WC with the number of steps have shown negative associations, confirming the importance of maintaining adequate values of BMI and WC.

This is clear evidence that the practice of free RPA in a 15 min school recess can have important repercussions on the weight status of the schoolchildren studied. In fact, some recent studies support the notion that the practice of physical exercise, both of a short duration as well as on a regular basis, allows children and adolescents to reduce their amount of fat, reduce their body weight and improve their cardiovascular function [41,42].

In addition, recently, the World Health Organization (WHO) [43] has recommended that all countries establish national guidelines and implement appropriate national and subnational physical activity policies and programs to enable people of all ages and abilities to be physically active and improve their health.

In general, the reference values proposed here can serve to motivate people to be physically active [40]. Childhood and adolescence are the best stages of human development to form adequate eating habits and maintain a healthy lifestyle, including the practice of physical activity [42].

In this sense, schools in recent years have become the focus of physical activity interventions among researchers, especially when aiming to quantify the time that children spend in this environment [44,45].

Therefore, it is important to individually monitor and diagnose physical activity patterns in children and adolescents [46]. Thus, school recess periods not only of a day but also of a week could provide accurate information on physical activity volumes expressed by one's number of steps.

Thus, children and adolescents can accumulate up to 40% of their daily time doing physical activity during recess [47]. Therefore, it is counterproductive to suspend recess or replace it with classroom activities as punishment [2]. This limits the opportunity to participate in daily physical activity, preserve healthy bodies and enjoy movement, regardless of the times and seasons of the year, infrastructure and climate.

This study presents some potentialities and weaknesses that deserve to be analyzed. For example, the use of smart wristbands plays an important role in the field of health care and can be better integrated into people's daily lives [7]. Their corresponding inclusion in the school setting can be considered, as they provide convenience and safety in monitoring physiological data generated by body movement in relation to other equipment and technologies. Additionally, as far as is known, this is the first study that has been carried out in Peru and in South America, whose information can serve as a baseline for future comparisons based on longitudinal studies, as well as for comparison with other realities and sociocultural contexts.

We also emphasize that this study has some weaknesses, which have to do with the type of sample selection. Therefore, future studies should calculate the sample size in a probabilistic way to achieve possible generalizations of the results. In addition, the cross-

sectional design used in this study does not allow for causal relationships to be formulated; so, future studies should plan to carry out longitudinal studies. It is also suggested that it is necessary to monitor not only one school recess, but also all of the school recesses within a week.

5. Conclusions

This study concludes that the number of steps taken by children and adolescents during a 15 min school break decreases drastically with advancing age. Schoolchildren decreased their volume of steps by more than 50% around the age of 14–15 years. The reference values proposed in this study can be used to categorize schoolchildren according to the number of steps taken and to compare them among their peers. The results suggest their use and application in schools as a way of achieving the minimum recommendations for physical activity during school recess.

Author Contributions: Conceived and designed by J.S.-T., R.G.-C. and M.C.-B. Data collection: J.S.-T., C.A.L., A.C.G. and M.Z.C. Analysis of data: M.C.-B., R.G.-C., R.V.-E. and J.S.-T. Writing, review and editing of the paper: M.C.-B., R.V.-E. and R.G.-C. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the Vicerrectorado de Investigación of the Universidad Católica Santa María, Arequipa, Peru. Project: Desarrollo de una herramienta cuantitativa para la evaluación de la competencia motora utilizando tecnología vestible en escolares de la provincia de Arequipa.

Institutional Review Board Statement: The study was performed in accordance with the Declaration of Helsinki and was approved by the ethical committee of the Catholic University of Santa Maria (UCSM-096-2022) for human studies.

Informed Consent Statement: Signed consent from all study participants was obtained.

Data Availability Statement: The data is available upon request from the authors.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Janssen, I.; LeBlanc, A.G. Systematic review of the health benefits of physical activity and fitness in school-aged children and youth. *Int. J. Behav. Nutr. Phys. Act.* **2010**, *7*, 40. [CrossRef] [PubMed]
2. Committee on Physical Activity and Physical Education in the School Environment (CPAPESE); Food and Nutrition Board; Institute of Medicine; Kohl, H.W., III; Cook, H.D. (Eds.) Physical Activity and Physical Education: Relationship to Growth, Development, and Health. In *Educating the Student Body: Taking Physical Activity and Physical Education to School*; National Academies Press (US): Washington, DC, USA, 2013. Available online: <https://www.ncbi.nlm.nih.gov/books/NBK201497/> (accessed on 15 November 2022).
3. Poitras, V.J.; Gray, C.E.; Borghese, M.M.; Carson, V.; Chaput, J.P.; Janssen, I.; Katzmarzyk, P.T.; Pate, R.R.; Connor Gorber, S.; Kho, M.E.; et al. Systematic review of the relationships between objectively measured physical activity and health indicators in school-aged children and youth. *Appl. Physiol. Nutr. Metab.* **2016**, *41* (Suppl. S3), S197–S239. [CrossRef] [PubMed]
4. Neil-Sztramko, S.E.; Caldwell, H.; Dobbins, M. School-based physical activity programs for promoting physical activity and fitness in children and adolescents aged 6 to 18. *Cochrane Database Syst. Rev.* **2021**, *9*, CD007651. [CrossRef]
5. Bremer, E.; Graham, J.D.; Veldhuizen, S.; Cairney, J. A program evaluation of an in-school daily physical activity initiative for children and youth. *BMC Public Health* **2018**, *18*, 1023. [CrossRef] [PubMed]
6. Loprinzi, P.D.; Cardinal, B.J. Measuring Children's Physical Activity and Sedentary Behaviors. *J. Exerc. Sci. Fit.* **2011**, *9*, 15–23. [CrossRef]
7. Lu, L.; Zhang, J.; Xie, Y.; Gao, F.; Xu, S.; Wu, X.; Ye, Z. Wearable Health Devices in Health Care: Narrative Systematic Review. *JMIR mHealth uHealth* **2020**, *8*, e18907. [CrossRef] [PubMed]
8. Xu, L.; Zhou, C.; Ling, Y.; Ding, H.; Wang, Q.; Wu, Y.; Qian, Y.; He, B.; Ni, T. Effects of Short-Term Unsupervised Exercise, Based on Smart Bracelet Monitoring, on Body Composition in Patients Recovering from Breast Cancer. *Integr. Cancer Ther.* **2021**, *20*, 15347354211040780. [CrossRef]
9. Duncan, J.S.; Schofield, G.; Duncan, E.K. Step count recommendations for children based on body fat. *Prev. Med.* **2007**, *44*, 42–44. [CrossRef]

10. Tudor-Locke, C.; Craig, C.L.; Cameron, C.; Griffiths, J.M. Canadian children's and youth's pedometer-determined steps/day, parent-reported TV watching time, and overweight/obesity: The CANPLAY Surveillance Study. *Int. J. Behav. Nutr. Phys. Act.* **2011**, *8*, 66. [CrossRef]
11. Beets, M.W.; Beighle, A.; Bottai, M.; Rooney, L.; Tilley, F. Pedometer-determined step-count guidelines for afterschool programs. *J. Phys. Act. Health* **2012**, *9*, 71–77. [CrossRef]
12. Groffik, D.; Fromel, K.; Badura, P. Composition of weekly physical activity in adolescents by level of physical activity. *BMC Public Health* **2020**, *20*, 562. [CrossRef] [PubMed]
13. Treuth, M.S.; Hou, N.; Young, D.R.; Maynard, L.M. Accelerometry-measured activity or sedentary time and overweight in rural boys and girls. *Obes. Res.* **2005**, *13*, 1606–1614. [CrossRef] [PubMed]
14. Wolff-Hughes, D.L.; Bassett, D.R.; Fitzhugh, E.C. Population-referenced percentiles for waist-worn accelerometer-derived total activity counts in U.S. youth: 2003–2006 NHANES. *PLoS ONE* **2014**, *9*, e115915. [CrossRef] [PubMed]
15. Oliveira, L.C.; Ferrari, G.L.M.; Araújo, T.L.; Matsudo, V. Overweight, obesity, steps, and moderate to vigorous physical activity in children. *Rev. Saude Publica* **2017**, *51*, 38. [CrossRef] [PubMed]
16. Burns, R.D.; Brusseau, T.A.; Fu, Y.; Zhang, P. Development of Step-Count Cut Points for School-Day Vigorous Physical Activity. *BioMed Res. Int.* **2018**, *2018*, 9717848. [CrossRef] [PubMed]
17. Jussila, A.M.; Husu, P.; Vähä-Ypyä, H.; Tokola, K.; Kokko, S.; Sievänen, H.; Vasankari, T. Accelerometer-Measured Physical Activity Levels and Patterns Vary in an Age- and Sex-Dependent Fashion among Finnish Children and Adolescents. *Int. J. Environ. Res. Public Health* **2022**, *19*, 6950. [CrossRef]
18. Guinhouya, C.B.; Hubert, H.; Dupont, G.; Durocher, A. The Recess Period: A Key Moment of Prepubescent Children's Daily Physical Activity? *Int. Electron. J. Health Educ.* **2005**, *8*, 126–134.
19. Lopes, V.; Margarida Silva Vasques, C.; Ferreira Leite de Oliveira Pereira, M.B.; Maia, J.M.; Malina, R.M. Physical Activity Patterns during School Recess: A Study in Children 6 to 10 Years Old. *Int. Electron. J. Health Educ.* **2006**, *9*, 192–201.
20. Weaver, R.G.; Beets, M.W.; Perry, M.; Hunt, E.; Brazendale, K.; Decker, L.; Turner-McGrievy, G.; Pate, R.; Youngstedt, S.D.; Saelens, B.E.; et al. Changes in children's sleep and physical activity during a 1-week versus a 3-week break from school: A natural experiment. *Sleep* **2019**, *42*, zsy205. [CrossRef]
21. Bermejo-Cantarero, A.; Álvarez-Bueno, C.; Martínez-Vizcaino, V.; García-Hermoso, A.; Torres-Costoso, A.I.; Sánchez-López, M. Association between physical activity, sedentary behavior, and fitness with health related quality of life in healthy children and adolescents: A protocol for a systematic review and meta-analysis. *Medicine* **2017**, *96*, e6407. [CrossRef]
22. Chen, W.; Hammond-Bennett, A.; Hypnar, A.; Mason, S. Health-related physical fitness and physical activity in elementary school students. *BMC Public Health* **2018**, *18*, 195. [CrossRef] [PubMed]
23. McNamara, L.; Lakman, Y.; Spadafora, N.; Lodewyk, K.; Walker, M. Recess and children with disabilities: A mixed-methods pilot study. *Disabil. Health J.* **2018**, *11*, 637–643. [CrossRef] [PubMed]
24. Pellegrini, A.D. *Recess: Its Role in Education and Development*, 1st ed.; Lawrence Erlbaum Associates, Inc.: Mahwah, NJ, USA, 2005.
25. Centers for Disease Control and Prevention and SHAPE America—Society of Health and Physical Educators. *Strategies for Recess in Schools*; Centers for Disease Control and Prevention, US Dept. of Health and Human Services: Atlanta, GA, USA, 2017.
26. NASPE. Two New Position Papers from NASPE: Recess for Elementary School Students Opposing Substitution and Waiver/Exemptions for Required Physical Education. *Strategies* **2006**, *19*, 11–13. [CrossRef]
27. Perú: Ministerio de Educación: Orientaciones para la Elaboración de Horarios en las Instituciones Educativas del Modelo de Servicio Educativo de Jornada Escolar Completa. 2023, pp. 1–12. Available online: [https://www2.congreso.gob.pe/sicr/cendocbib/con5_uibd.nsf/1D17FC6E72C04380052583220071A904/\\$FILE/Orientaciones_elaboracion_de_horarios.pdf](https://www2.congreso.gob.pe/sicr/cendocbib/con5_uibd.nsf/1D17FC6E72C04380052583220071A904/$FILE/Orientaciones_elaboracion_de_horarios.pdf) (accessed on 14 March 2022).
28. Marzi, I.; Tcymbal, A.; Gelius, P.; Abu-Omar, K.; Reimers, A.K.; Whiting, S.; Wickramasinghe, K. Monitoring of physical activity promotion in children and adolescents in the EU: Current status and future perspectives. *Eur. J. Public Health* **2022**, *32*, 95–104. [CrossRef]
29. Ross, W.D.; Marfell-Jones, M.J. *Kinanthropometry*; MacDougall, J.D., Wenger, H.A., Geeny, H.J., Eds.; Physiological Testing of Elite Athlete; Human Kinetics: London, UK, 1991; Volume 223, pp. 308–314.
30. Freedman, D.S.; Berenson, G.S. Tracking of BMI z Scores for Severe Obesity. *Pediatrics* **2017**, *140*, e20171072. [CrossRef] [PubMed]
31. Fernández, J.R.; Redden, D.T.; Pietrobello, A.; Allison, D.B. Waist circumference percentiles in nationally representative samples of African-American, European-American, and Mexican-American children and adolescents. *J. Pediatr.* **2004**, *145*, 439–444. [CrossRef]
32. Bayoumy, K.; Gaber, M.; Elshafeey, A.; Mhaimeed, O.; Dineen, E.H.; Marvel, F.A.; Martin, S.S.; Muse, E.D.; Turakhia, M.P.; Tarakji, K.G.; et al. Smart wearable devices in cardiovascular care: Where we are and how to move forward. *Nat. Rev. Cardiol.* **2021**, *18*, 581–599. [CrossRef]
33. Cole, T.J.; Bellizzi, M.C.; Flegal, K.M.; Dietz, W.H. Establishing a standard definition for child overweight and obesity worldwide: International survey. *BMJ* **2000**, *320*, 1240–1243. [CrossRef]
34. Cole, T.J.; Green, P.J. Smoothing reference centile curves: The LMS method and penalized likelihood. *Stat. Med.* **1992**, *11*, 1305–1319. [CrossRef]
35. Pan, H.; Cole, T.J. LMS Chartmaker 2006. Available online: <http://www.healthforallchildren.co.uk> (accessed on 28 March 2022).

36. Sember, V.; Jurak, G.; Kovač, M.; Đurić, S.; Starc, G. Decline of physical activity in early adolescence: A 3-year cohort study. *PLoS ONE* **2020**, *15*, e0229305. [\[CrossRef\]](#)
37. Ridgers, N.D.; Salmon, J.; Parrish, A.M.; Stanley, R.M.; Okely, A.D. Physical activity during school recess: A systematic review. *Am. J. Prev. Med.* **2012**, *43*, 320–328. [\[CrossRef\]](#) [\[PubMed\]](#)
38. Chin, J.J.; Ludwig, D. Increasing children's physical activity during school recess periods. *Am. J. Public Health* **2013**, *103*, 1229–1234. [\[CrossRef\]](#) [\[PubMed\]](#)
39. Barreira, T.V.; Schuna, J.M.; Mire, E.F., Jr.; Broyles, S.T.; Katzmarzyk, P.T.; Johnson, W.D.; Tudor-Locke, C. Normative steps/day and peak cadence values for united states children and adolescents: National Health and Nutrition Examination Survey 2005–2006. *J. Pediatr.* **2015**, *166*, 139–143. [\[CrossRef\]](#) [\[PubMed\]](#)
40. Lammers, A.E.; Romanowski, A.L.; Baumgartner, H.; Diller, G.P.; Uebing, A. Reference Values for Wristband Accelerometry Data in Children Aged 6–11 Years of Age. *Front. Pediatr.* **2022**, *10*, 808372. [\[CrossRef\]](#)
41. Whooten, R.; Kerem, L.; Stanley, T. Physical activity in adolescents and children and relationship to metabolic health. *Curr. Opin. Endocrinol. Diabetes Obes.* **2019**, *26*, 25–31. [\[CrossRef\]](#)
42. Weres, A.; Baran, J.; Czenczek-Lewandowska, E.; Leszczak, J.; Mazur, A. The association between steps per day and blood pressure in children. *Sci. Rep.* **2022**, *12*, 1422. [\[CrossRef\]](#)
43. Bull, F.C.; Al-Ansari, S.S.; Biddle, S.; Borodulin, K.; Buman, M.P.; Cardon, G.; Carty, C.; Chaput, J.P.; Chastin, S.; Chou, R.; et al. World Health Organization 2020 guidelines on physical activity and sedentary behaviour. *Br. J. Sport. Med.* **2020**, *54*, 1451–1462. [\[CrossRef\]](#)
44. Dobbins, M.; Husson, H.; DeCorby, K.; LaRocca, R.L. School-based physical activity programs for promoting physical activity and fitness in children and adolescents aged 6 to 18. *Cochrane Database Syst. Rev.* **2013**, *2*, CD007651. [\[CrossRef\]](#)
45. Morton, K.L.; Atkin, A.J.; Corder, K.; Suhrcke, M.; van Sluijs, E.M. The school environment and adolescent physical activity and sedentary behaviour: A mixed-studies systematic review. *Obes. Rev. Off. J. Int. Assoc. Study Obes.* **2016**, *17*, 142–158. [\[CrossRef\]](#)
46. Kang, H.S.; Exworthy, M. Wearing the Future-Wearables to Empower Users to Take Greater Responsibility for Their Health and Care: Scoping Review. *JMIR mHealth uHealth* **2022**, *10*, e35684. [\[CrossRef\]](#)
47. Ridgers, N.D.; Stratton, G.; Fairclough, S.J. Physical activity levels of children during school playtime. *Sport. Med.* **2006**, *36*, 359–371. [\[CrossRef\]](#) [\[PubMed\]](#)

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

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

José Sulla-Torres, Dr¹, Alexander Paul Calla Gamboa¹, Christopher Avendaño Llanque¹, and Manuel Zúñiga Camero, 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 Sulla-Torres, Dr¹, Alexander Paul Calla Gamboa¹, Christopher Avendaño Llanque¹, and Manuel Zúñiga Camero, 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

21st LACCEI International Multi-Conference for Engineering, Education, and Technology: "Leadership in Education and Innovation in Engineering in the Framework of Global Transformations: Integration and Alliances for Integral Development". Hybrid Event, Buenos Aires - ARGENTINA, July 17 - 21, 2023.

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

grupal 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 un 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 cerebrovasculares 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 estadia 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. Comprensión 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, Sciencedirect, 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 números 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)
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

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 inteligentes, 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	Calorias	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

	Edad Escolar											
Cadencia media	7	8	9	10	11	12	13	14	15	16	17	18
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), arboles 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 cardíaca, 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 recorridos, 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. I. 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.

Article

Classification of Motor Competence in Schoolchildren Using Wearable Technology and Machine Learning with Hyperparameter Optimization

José Sulla-Torres ^{*}, Alexander Calla Gamboa, Christopher Avendaño Llanque, Javier Angulo Osorio  and Manuel Zúñiga Carnero

Escuela Profesional de Ingeniería de Sistemas, Universidad Católica de Santa María, Arequipa 04000, Peru; christopher.avendano@ucsm.edu.pe (C.A.L.); jangulo@ucsm.edu.pe (J.A.O.)

* Correspondence: jsullato@ucsm.edu.pe; Tel.: +51-9599-50467



Citation: Sulla-Torres, J.; Calla Gamboa, A.; Avendaño Llanque, C.; Angulo Osorio, J.; Zúñiga Carnero, M. Classification of Motor Competence in Schoolchildren Using Wearable Technology and Machine Learning with Hyperparameter Optimization. *Appl. Sci.* **2024**, *14*, 707. <https://doi.org/10.3390/app14020707>

Academic Editor: Grzegorz Dudek

Received: 19 November 2023

Revised: 14 December 2023

Accepted: 15 December 2023

Published: 14 January 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: Determining the classification of motor competence is an essential aspect of physical activity that must be carried out during school years. The objective is to evaluate motor competence in schoolchildren using smart bands, generate percentiles of the evaluation metrics, and classify motor performance through machine learning with hyperparameter optimization. A cross-sectional descriptive study was carried out on 764 schoolchildren (451 males and 313 females) aged 6 to 17 years. Five state schools in the city of Arequipa, Peru were evaluated. Weight, height, and waist circumference were assessed, and body mass index (BMI) was calculated. The tests evaluated in the schoolchildren measured walking and running for 6 minutes. These tests were carried out using smart bands, capturing cadence, number of steps, calories consumed, speed, stride, and heart rate. As a result, the percentiles were created through the LMS method [L (asymmetry: lambda), M (median: mu), and S (coefficient of variation: sigma)]. The cut-off points considered were <P25 (below average), p25 to p75 (average), and >p75 (above average). For classification, the machine-learning algorithms random forest, decision tree, support vector machine, naive Bayes, logistic regression, k-nearest neighbor, neural network, gradient boosting, XGBoost, LightGBM, and CatBoost were used, and the hyperparameters of the models were optimized using the RandomizedSearchCV technique. In conclusion, it was possible to classify motor competence with the tests carried out on schoolchildren, significantly improving the accuracy of the machine-learning algorithms through the selected hyperparameters, with the gradient boosting classifier being the best result at 0.95 accuracy and in the ROC-AUC curves with a 0.98. The reference values proposed in this study can be used to classify the walking motor competence of schoolchildren. Finally, the mobile software product built based on the proposed model was validated using the prototype of the Software Quality Systemic Model (SQSM) based on three specific categories: functionality, reliability, and usability, obtaining 77.09%. The results obtained can be used in educational centers to achieve the suggested recommendations for physical activity in schoolchildren.

Keywords: machine learning; classification; motor competence; schoolchildren; wearable; hyperparameters

1. Introduction

1.1. Background

Machine-learning classification is training a computer model to recognize and categorize data based on specific characteristics. It is typically classified as supervised, unsupervised, semi-supervised, or reinforced [1]. In supervised classification, the model is trained using labeled data to identify patterns and predict new data [2]. This technique has many applications, including healthcare, education, and technology. One such application is using smart bands in schoolchildren to monitor their physical activity and health status [3].

Physical activity, such as motor competence, is crucial for developing children and adolescents, as it promotes overall health and well-being. Unfortunately, sedentary lifestyles

and lack of physical activity have become increasingly common among school students. Smart bands have emerged as a tool to combat this problem and measure physical activity levels in students [4].

Smart bands are wearable devices that can monitor a person's vital health statistics, including heart rate, using a combination of sensors and machine-learning algorithms [3]. In the context of schoolchildren, smart bands can be used to track their physical activity levels, sleep patterns, and overall health status. Machine-learning classification can be used to analyze the data collected with smart bands and identify patterns that can help improve the health and well-being of schoolchildren [1].

The importance of machine-learning classification for schoolchildren lies in its ability to provide personalized and adaptive learning experiences. By analyzing data collected from smart bands, machine-learning algorithms can create profiles for individual students and design learning paths tailored to their specific needs and abilities [5,6]. Additionally, machine-learning classification can identify students at risk for health issues and provide early interventions to prevent or mitigate these issues [7]. Overall, the use of machine-learning classification with smart bands in school children has the potential to improve their physical and mental health and academic performance significantly. Machine-learning algorithms can be optimized by tuning with hyperparameters, obtaining better results [8].

This research aims to explore the use of smart bands and the application of machine learning to promote physical activity and motor competence in educational centers and analyze the potential benefits of this approach. We will examine how smart bands measure levels of motor competence, how machine learning with hyperparameter optimization is used, and the benefits of using them in educational centers. In doing so, we hope to shed light on the potential of these technologies to improve levels of motor competence among students and ultimately contribute to improved health and academic outcomes.

1.2. Related Work

Smart bands are wearable devices that have become increasingly popular for tracking and monitoring various physical and health activities, including motor competence. The main works in this regard are presented.

The work of Kounoudes, Kapitsaki, and Katakis [1] indicates that smart bands and wearable fitness devices can measure physical activity levels through various sensors and tracking mechanisms. One of the most common ways smart bands can measure physical activity levels is by monitoring the number of steps the user takes throughout the day. Pedometer readings are commonly used to describe physical activity levels in adults, and fitness trackers like Fitbit record the number of steps the user takes each day. Additionally, VO2max measurements are often used to determine whether the user has increased or decreased fitness level, and variations in VO2max are used as an indicator of overall health. Garmin activity data include VO2max measurements, which can help determine fitness levels. Daily step counts can show people's habits and lifestyle as well as their risk of mortality that may occur to them.

Amor and James [2] suggest that activity monitoring (AM) is a well-established method for assessing an individual's physical activity. The swift emergence of smartwatch technology provides the capability to monitor activity and seamlessly engage with other healthcare systems. Al-Janabi and Hamza [3] propose an intelligent data analysis model to find optimal patterns in human activities based on biometric characteristics obtained from smartwatches and smartphones. The forward and backward rule-based pattern finder generates the optimal patterns that help humans organize their activities. The results show that good patterns are generated for human activities. In addition, Weiss, Yoneda, and Hayajneh [5] suggest that wearable devices include sensors that provide a platform to implement and deploy motion-based mobile behavioral biometrics using the smartwatch accelerometer by basically investigating the physical activity of walking. Therefore, they used different sensors to evaluate physical activity better. The results show that motion-based biometrics using smartwatches yield good results for the activities assessed.

Ali et al. [7] concentrated on introducing innovative techniques for identifying and recording physical activities using machine-learning methods and wearable sensors. Everyday physical activities tend to be unstructured or unplanned, with specific activities or actions (such as sitting or standing) occurring more frequently than others (such as walking or going up and down stairs). Existing activity classification systems have not explored the impact of such class imbalances on the effectiveness of machine-learning classifiers. Therefore, the study's primary aim was to examine the influence of class imbalance on the performance of machine-learning classifiers and to identify which classifiers are more sensitive to class imbalance than others. The research utilized motion sensor data from 30 participants recorded during the performance of various activities of daily living.

Wang, Lizardo, and Hachen [9] demonstrate that social, psychological, and environmental characteristics are related to physical activity among students by using Fitbit devices to collect data on daily movement activities, number of calories, and heart rate, among other measurements from a sample of 692 students, taking four indicators; they showed that there is a strong relationship between the growth of group and individual physical activity.

According to Sabry et al. [10], the application of machine learning to promote physical activity includes fall detection, seizure detection, vital sign monitoring and prediction, and activity recognition. Machine-learning techniques are also being explored for health monitoring, elder care, and fitness tracking. Additionally, machine-learning techniques have been used to link physical activity to obesity by examining the relationship between physical activity and weight status in a large-scale dataset. The study found that the weighted SVM algorithm with a penalized approach offered the best classification performance, followed by ADA(RF).

Zhou et al. [11] indicate that machine learning can also automate and personalize physical activity promotion programs by tracking people's activity patterns and developing therapy and exercise plans to reduce obesity. Additionally, machine-learning methods predict exercise relapse and improve physical activity interventions by identifying unlikely individuals to adhere to a physical exercise regimen.

Creaser et al. [12] note that smart bands and machine learning can promote the health, well-being, or understanding of children or adolescents in schools. However, more research is needed to explore their full impact. Wearables can also be used beyond encouraging physical activity, such as studying and teaching health concepts. However, research indicates when and how wearable devices with the most frequently used functions can be used in schools. It suggests that they are acceptable instruments in the school environment to monitor students' physical activity levels or educate them about the importance of physical activity.

Site, Nurmi, and Lohan [13] reviewed machine-learning algorithms to analyze eHealth data collected from wearable devices, emphasizing the significant potential for enhancing healthcare quality and customer satisfaction through machine learning (ML). The ML algorithms were applied to both time and frequency domain healthcare data derived from wearable devices and sensors. The authors explored how ML techniques can effectively process and analyze health sensor data, noting that accelerometers, gyroscopes, ECG (electrocardiogram), EEG (electroencephalogram) monitors, and blood glucose sensors are the primary sources of eHealth data. The study delved into various aspects, including types of features and methods for feature extraction and ML algorithms commonly used in eHealth data analysis. Notably, the authors concluded that, among the ML algorithms studied in the literature, neural network (NN) algorithms and support vector machines (SVMs) had demonstrated the most promising performance for analyzing healthcare data.

Himi et al. [14] introduce a predictive system named "MedAi", which is based on a smartwatch and employs machine-learning algorithms to predict multiple diseases. The system consists of three main components: a "Sense O'Clock" smartwatch prototype equipped with eleven sensors to gather body statistics, a machine-learning model for analyzing the collected data and making predictions, and a mobile application to display the prediction results. The researchers obtained a dataset of body statistics from patients at

a local hospital. Several machine-learning algorithms were utilized in the study, including support vector machine (SVM), support vector regression (SVR), k-nearest neighbor (KNN), extreme gradient boost (XGBoost), long short-term memory (LSTM), and random forest (RF). The goal was to identify the most effective algorithm. The experimental results on the dataset revealed that the random forest (RF) algorithm outperformed the other machine-learning algorithms tested.

Machine-learning algorithms commonly rely on a set of hyperparameters, the values of which need to be chosen thoughtfully, and these choices often have a substantial impact on the algorithm's performance [15]. Hyperparameters are settings that are not directly learned from the dataset but especially impact model performance. The most used search strategies are grid search, manual search, and random search [14]. Several works are related to optimization with hyperparameters, such as the one developed by Yagin et al. [16], who used neural networks with hyperparameter optimization to predict obesity based on physical activity. Rivera, Avilés, and Castillo-Castaneda [17] classified the physical activity indicator using machine learning, and after feature, importance selection, and hyperparameter were tuned. There are also works regarding health in general with the optimization of hyperparameters [18].

2. Materials and Methods

2.1. Methodology

Machine-learning classification with smart bands in schoolchildren involves several steps, including data collection and analysis. Smart bands are equipped with sensors that collect data on physiological parameters, such as heart rate and physical activity levels. The data are then analyzed to identify patterns and trends that can be used to develop machine-learning models for classification.

Feature selection and preprocessing are crucial steps in the machine-learning classification process. Feature selection involves identifying the most relevant features from the data that will be used to train the model. Preprocessing involves cleaning and transforming the data to ensure they are suitable for analysis. These steps aim to provide the machine-learning model access to high-quality data that will enable accurate classification.

The machine-learning model is trained and tested once the data have been collected, analyzed, and preprocessed. Supervised machine-learning techniques are commonly used for classification tasks, where the model is trained on labeled data. The model's performance is evaluated using accuracy, precision, f1-score, and recall metrics. The goal is to develop a model that can accurately classify schoolchildren based on their physiological parameters, which can be used to monitor their health and well-being.

The methodology used was CRISP-DM [19]. It comprises six phases: business understanding, data understanding, data preparation, modeling, evaluation, and deployment.

2.1.1. Business Understanding

This initial phase will identify the problem caused by traditional methods of evaluating motor competence in educational centers, and a solution will be projected to resolve the present issue. In this phase, there are different activities for understanding the business, each of which will be described below.

1. **Determination of objectives:** The main goal focuses on exploring the use of smart bands and the application of machine learning optimized to promote physical activity and motor competence in schoolchildren and analyzing the potential benefits of this approach.
2. **Evaluation of the situation:** A descriptive cross-sectional study was conducted on 764 schoolchildren (451 males and 313 females) aged 6 to 17. The sample selection was non-probabilistic by convenience. Five state schools in the city of Arequipa, Peru, were evaluated. The schoolchildren attended physical education classes twice a week. Permission was requested from each school's administration to conduct the study in both schools. Then, parents were informed about the objective of the project. Parents

who agreed to participate in the study signed the informed consent form to authorize their children's participation.

3. Determination of the goal of machine learning: At this stage, the determination will be made to apply a correct supervised machine-learning technique to determine the best algorithm that finds the best accuracy, precision, f1-score, and recall in students' motor competence classification. A classifier is a function f that takes as input a set of features $x \in X$, where X is the feature space, and outputs a class label $y \in \{1, \dots, C\}$, where C is the class space.

2.1.2. Data Understanding

Anthropometric measurements and the utilization of the smart band followed the recommendations outlined by the local ethics committee (UCSM-096-2022) and adhered to the principles of the Declaration of Helsinki (World Medical Association) concerning ethical standards for human research.

1. Collection of initial data: Anthropometric measurements were conducted on-site at each school. The evaluation team comprised professional physical education teachers and research assistants. Weight and height were measured using Ross and Marfell Jones's standardized method. To determine body weight (kg), a BC 730 (Tanita Corporation) electronic scale was used, with a scale from 0 to 150 kg. Standing height was measured using a portable stadiometer (Seca 216, Seca GmbH and Co., Hamburg, Germany), accurate within 0.1 mm. Waist circumference (WC) was measured using a tape measure (Seca) to the nearest 1 mm. The body mass index (BMI) was calculated by dividing the kilograms of weight by the square of the height in meters: $BMI = \text{weight (kg)} / \text{height}^2 \text{ (m)}$.

According to the BMI Z-score, patients were classified as underweight/normal weight with Z-scores between -2 and $+0.99$, overweight from 1 to 1.99 , obese from 2 to 2.99 , and very obese ≥ 3 [20]. To categorize abdominal adiposity (WC) by age and sex, the suggestions described by Fernández et al. [21] were used. It was categorized into two groups (without risk $< p75$ and with risk $> p75$).

The motor competence tests that were evaluated were the quantification of the number of steps during school recess, and the 6-minute walk test was performed using a smart band (Huawei band 7) with an AMOLED screen of 194×368 and with 1.47 inches. This smart band has been used in other similar research [22]. The smart band was placed on the wrist of each student's hand, and its use was explained.

2. Describe and explore the data: The Kolmogorov–Smirnov test verified the dataset's normality. Descriptive statistics (mean, standard deviation, min, and max) were calculated. Table 1 shows the description of the data of the schoolchildren.

Table 1. Description of schoolchildren's data.

	Age	Weight	Height	Waist	BMI	Cadence	Steps	Speed	Stride
mean	12.48	47.57	1.49	71.93	20.74	59.58	910.64	2.99	79.73
std	2.75	16.18	0.16	11.37	4.27	34.46	504.13	1.93	10.35
min	6	18.00	1.140	50.00	11.71	10.00	126.00	0.310	53.00
25%	10	34.00	1.370	63.00	17.66	30.00	499.00	1.315	72.50
50%	13	48.00	1.520	70.50	20.30	53.00	833.00	2.570	78.00
75%	15	58.10	1.630	78.50	23.35	82.50	1241.50	4.365	86.00
max	17	107.70	1.810	114.60	39.95	163.00	2189.00	9.760	111.00

t-test was used to calculate differences between both sexes in independent samples. Differences between BMI and waist values were determined via one-way ANOVA and Tukey's specificity test. In all cases, $p < 0.05$ was significant.

2.1.3. Data Preparation

In this phase, the data are selected according to the most critical attributes to train and test the algorithms that will be chosen for the study.

1. Data selection: Through data selection, it became feasible to identify and emphasize those fields that would provide valuable contributions to the analysis of physical activity for motor skill tests. Each data record has the following attributes within the database:
 - a. Anthropometric data: age (years), weight (kg), height (m), sitting height (cm), and waist circumference (cm).
 - b. Average pace: the time the person can walk a kilometer; they are a number in minutes and seconds format.
 - c. Average cadence: these are the steps per minute you can do; they are raw numbers.
 - d. Steps: these are all the steps the person has taken during the activity; they are raw numbers.
 - e. Calories: the calories the person has burned during the activity; they are numbers without formats.
 - f. Average speed: the average speed at which the person has moved during the activity in kilometers/hour; it is in number format with decimals without arrangements.
 - g. Average stride: it is the average distance taken by each step; they are numbers without formats.
 - h. Heart rate: these are the beats per minute the heart has given during the activity; they are numbers without formats.
 - i. Maximum heart rate: this is the maximum number of beats per minute the individual has given in the activity; they are numbers without formats.
2. Data cleaning: Data cleaning tasks allowed us to discover correct and sometimes eliminate erroneous data records or outliers and convert and standardize the data types necessary for processing in machine-learning algorithms. The Jupyter dashboard [23] was used with the Python 3 programming language, with its Pandas library; it is a rapid, robust, adaptable, and user-friendly open-source tool for data analysis and manipulation. The Seaborn library was used with its boxplot function to visualize the classes, as shown in Figure 1, where the high class has the highest proportion for both sexes. Points outside a boxplot are visual indicators of values that may be unusual or outliers compared to the rest of the data in the set.




Figure 1. Types of motor competence according to the tests the male and female schoolchildren carried out.

2.1.4. Modeling

When conducting a detailed analysis of the data source, it was determined that the classification output resulting from the motor competence tests is labeled as high, normal, and low. For this reason, the decision was made that the most appropriate type of prediction would be classification.

To do this, a comparison of popular supervised machine-learning techniques for a classification model will be conducted. According to the literature, the most used algorithms and optimizers are:

1. Decision tree: A non-parametric supervised technique that constructs a classification model as a tree structure, applicable for classification and regression tasks [24].
2. Random forest: It generates a set of decision trees by employing random resampling on the training set [25].
3. Support vector machine: Creates effective boundaries to separate datasets by solving a constrained quadratic optimization problem [26].
4. Naive Bayes: It is a probabilistic classifier based on Bayes' theorem, assuming strong independence within attributes of an instance [27].
5. Logistic regression: This type of regression analysis is used to predict the outcome of a categorical variable based on the independent or predictor variables [28]. While commonly recognized as a classifier, logistic regression can also be employed as a regressor to predict numeric values. Its adaptability allows it to address classification and regression problems, depending on the nature of the data and the analysis objectives [28].
6. Neuronal network: Most current neural network applications are concerned with pattern recognition problems. Artificial neural networks consist of assemblies of perceptrons designed for multi-layer feedforward networks [29].
7. K-nearest neighbors: It seeks to predict outputs by computing the distance between the test data and training points, subsequently selecting the K number of points closest to the test data [30].
8. Gradient boosted: This ensemble learning technique builds and combines several weak learning models to form a more robust model. The main idea is to correct the errors of the previous model by iteratively adding soft models. It focuses on fitting the residuals of the previous model using a gradient-based approach [31].
9. XGBoost: short for "eXtreme Gradient Boosting", is a specific implementation of gradient boosting. It was developed to be fast and efficient in terms of resource usage. It includes regularization, missing value handling, and a custom cost function [32].
10. LightGBM: Gradient boosting machines build sequential decision trees, with each tree constructed based on the errors of the preceding tree. In the end, predictions are made by summing the contributions of all these trees.
11. CatBoost: CatBoost stands for "Category" and "Boost"; it handles categorical, numeric, and text features. The CatBoost algorithm employs a symmetric tree or an oblivious tree structure [33].

Anaconda Navigator Software 2.5.1 was used with its Jupyter Notebook 6.5.2 with the Python 3 programming language and its Scikit-learn optimization library to compare supervised machine-learning techniques for classification.

With careful preparation of the input data, it will be imported in a specific CSV format, representing it as a table with the attributes selected in the "Data selection" section. Figure 2 shows the modeling developed to classify motor competence data, using information generated by smart bands. This encompasses data processing, modeling, comparisons with machine-learning algorithms, and achieving classification with optimization using hyperparameters in the study.




Figure 2. Modeling of data from the proposed study.

The percentiles were constructed using the LMS method [34]. The curves L represent skewness (lambda), M represents the median (mu), and S represents the coefficient of variation (sigma). The LMS method uses the Box–Cox transformation to fit the data distribution to a normal distribution by minimizing the effects of skewness.

For this purpose, the P25, P50, and P75 percentiles of males (Table 2) and females (Table 3) were created about the motor competence metrics: cadence (Figure 3), steps (Figure 4), speed (Figure 5), and stride (Figure 6) for schoolchildren males and females.

Table 2. Percentiles of motor competence metrics of schoolchildren males.



Metrics	Age					
	6–7	8–9	10–11	12–13	14–15	16–17
Cadence						
L	0.94	−0.22	0.22	0.33	0.85	1.52
M	28	96	60	63	49	29
S	0.72	0.42	0.46	0.50	0.55	0.53
P25	20	55	44	38.5	29	21
P50	28	96	60	63	49	29
P75	65.5	120	88	86.8	68	44
Steps						
L	1.33	−0.16	0.42	0.30	0.67	1.09
M	455	1437	884	1000	732	496
S	0.70	0.42	0.48	0.45	0.54	0.55
P25	299	772	628	690	470	309
P50	455	1437	884	1000	732	496
P75	796	1747	1179	1299	1097	726
Velocity						
L	0.85	0.19	0.80	0.33	0.93	1.85
M	1.62	4.69	3.08	3.15	2.28	1.16
S	0.70	0.47	0.53	0.52	0.63	0.61
P25	1.11	2.73	2.10	1.84	1.17	0.90
P50	1.62	4.69	3.08	3.15	2.28	1.16
P75	3.48	6.00	4.30	4.51	3.69	1.92
Stride						
L	−0.02	0.65	0.91	0.41	0.27	0.66
M	88	82	80	82	76	71
S	0.14	0.12	0.12	0.12	0.106	0.12
P25	74.5	76	74	76	71	66
P50	88	82	80	82	76	71
P75	97.5	90	86	87	83	78

Legend: P: percentile, L: (skewness, lambda), M: (median, mu), S: (coefficient of variation, sigma).

Table 3. Percentiles of motor competence metrics of schoolchildren females.

Metrics	Age					
Cadence	6–7	8–9	10–11	12–13	14–15	16–17
L	−0.06	−0.41	0.25	0.41	1.04	1.48
M	75	94	69	60	36	29
S	0.52	0.34	0.47	0.49	0.67	0.53
P25	40	68.75	33	35	20	20
P50	75	94	69	60	36	29
P75	108	111.3	89	84	60.5	44
Steps						
L	0.21	−0.24	0.58	0.54	0.99	1.29
M	941	1391	802	784	613	529
S	0.52	0.37	0.57	0.49	0.61	0.52
P25	615	989	462	578	426	359
P50	941	1391	802	784	613	529
P75	1584	1608	1233	1226	937	762
Velocity						
L	−0.06	−0.29	0.79	7.97	1.11	1.84
M	3.91	4.75	2.91	3.04	1.58	1.27
S	0.52	0.36	0.62	5.50	0.74	0.62
P25	2.15	3.33	1.52	1.77	0.94	0.92
P50	3.91	4.75	2.91	3.04	1.58	1.27
P75	5.41	5.69	4.16	4.26	3.09	1.78
Stride						
L	−2.97	1.47	1.11	0.79	0.27	0.57
M	84	82	78	77	76	71
S	0.24	0.10	0.11	0.11	0.09	0.12
P25	81	79	75	73	72	65.5
P50	84	82	78	77	76	71
P75	89.5	86.3	86.5	86	81.5	77.5

Legend: P: percentile, L: (skewness, lambda), M: (median, mu), S: (coefficient of variation, sigma).

**Figure 3.** Distribution of percentiles for the cadence in schoolchildren in both sexes.**Figure 4.** Distribution of percentiles for the number of steps in schoolchildren in both sexes.




Figure 5. Distribution of percentiles for the velocity in schoolchildren in both sexes.




Figure 6. Distribution of percentiles for the stride in schoolchildren in both sexes.

3. Evaluation and Results

For the Anaconda Navigator platform with Jupyter Notebook, different machine-learning techniques used in further research were modeled [35], which were decision tree, support vector machine, random forest, naive Bayes, logistic regression, k-nearest neighbors, neuronal network, gradient boosted, and smart bands. Of the data to model, 80% was used for training and 20% for testing.

Jupyter Notebook is a widely used tool in the machine-learning community, where you can import a set of libraries, train a dataset classification classifier, and evaluate the model by just using a few lines of code in Python with its library Scikit-learn.

Likewise, the optimization of hyperparameters with the Scikit-learn optimization library was used. Hyperparameters are parameters that are not directly learned by the learning algorithm. The basic hyperparameter tuning models are manual search, grid search, and random search. Random search was used for training since it allows us to find equal or better models in computing time.

The configuration used for the hyperparameters in the case of gradient boosted was the loss function to optimize with the “log_loss” option, the criterion with the process to measure the quality of a division with the “friedman_mse” option, the “learning_rate” with 0.1, “max_depth”: 3, “min_samples_leaf”: 1, “min_samples_split”: 2, “n_estimators”: 100, “random_state”: none, “subsample”: 1.0, “tol”: 0.0001, “validation_fraction”: 0.1, and with the other default parameters.

Next, the tests were carried out, and the results of the modeling that was executed for the different techniques that were previously chosen were obtained using the CSV file as input data and made up of the motor competence variables.

To evaluate the model [36], accuracy in Equation (1), recall in Equation (2), precision in Equation (3), and the f1-score in Equation (4) were used. For many classes C_i , fp_i represents false positive, tp_i true positive, fn_i false negative, and tn_i true negative.

$$Accuracy = \frac{tp_i + tn_i}{tp_i + tn_i + fp_i + fn_i} \quad (1)$$

$$Recall = \frac{\sum_{i=1}^l \frac{tp_i}{tp_i + fn_i}}{l} \quad (2)$$

$$Precision = \frac{\sum_{i=1}^l \frac{tp_i}{tp_i + fp_i}}{l} \quad (3)$$

$$F1 - score = 2 \times \frac{(Precision) \times (Recall)}{(Precision) + (Recall)} \quad (4)$$

Tables 4 and 5 compare the classical and optimized machine-learning techniques results with selected hyperparameters and the accuracy, f1-score, recall, and precision metrics for both schoolchildren males and females.

Table 4. Comparison of results of supervised machine-learning techniques in males.

Algorithm	DT	SVM	RF	NB	LR	KNN	MLP	GB	XGB	LGBM	CB
Accuracy	0.88	0.69	0.92	0.74	0.78	0.81	0.68	0.93	0.92	0.94	0.93
Accuracy optimized hyperparameter	0.87	0.82	0.92	0.75	0.79	0.85	0.70	0.95	0.91	0.94	0.93
f1-score	0.87	0.74	0.93	0.77	0.82	0.88	0.72	0.92	0.91	0.93	0.92
Recall	0.86	0.67	0.94	0.73	0.84	0.88	0.67	0.92	0.90	0.94	0.92
Precision	0.88	0.82	0.92	0.82	0.80	0.88	0.77	0.92	0.92	0.92	0.92

Legend: DT: decision tree, SVM: support vector machine, RF: random forest, NB: naïve Bayes, LR: Logistic Regression; KNN: k-nearest neighbors, MLP: multilayer perceptron, GB: gradient boosted, XGB: extreme gradient boosting, LGBM: light gradient boosting machine, CB: CatBoost.

Table 5. Comparison of results of supervised machine-learning techniques in females.

Algorithm	DT	SVM	RF	NB	LR	KNN	MLP	GB	XGB	LGBM	CB
Accuracy	0.86	0.68	0.88	0.71	0.78	0.72	0.72	0.84	0.87	0.88	0.90
Accuracy optimized hyperparameter	0.86	0.80	0.87	0.72	0.83	0.81	0.74	0.89	0.84	0.88	0.88
f1-score	0.91	0.68	0.92	0.76	0.89	0.88	0.82	0.93	0.92	0.90	0.93
Recall	0.97	0.61	0.94	0.69	0.94	0.92	0.86	0.92	0.86	0.91	0.94
Precision	0.86	0.76	0.89	0.83	0.85	0.82	0.78	0.94	0.94	0.89	0.92

Legend: DT: decision tree, SVM: support vector machine, RF: random forest, NB: naïve Bayes, LR: Logistic Regression; KNN: k-nearest neighbors, MLP: multilayer perceptron, GB: gradient boosted, XGB: extreme gradient boosting, LGBM: light gradient boosting machine, CB: CatBoost.

In the results of the previous tables, it can be identified that, for the classification techniques, those that gave the best results concerning accuracy for the case of males and females were gradient boosting, whose values were the highest, indicating a better adjustment to the estimated prediction with a value of 0.95. For the f1-score metrics, the algorithms gave similar values of 0.92 between males and females. In the case of *recall*, it was 0.92. The confusion matrix of the gradient boosting machine-learning algorithm with the highest score found is shown in Figure 7.




Figure 7. The confusion matrix of the gradient boosting machine-learning algorithm.

Figures 8 and 9 show a graph of the ROC-AUC curves of gradient boosting for males and females.




Figure 8. ROC-AUC curves of gradient boosting in males.




Figure 9. ROC-AUC curves of gradient boosting in females.

Observing the results of the ROC curves, in the case of male schoolchildren, the “Low” class shows an intense elevation towards the upper left corner of the graph and has a high area under the curve (AUC) of 0.98; this indicates that the model has a high sensitivity to detect the “Low” classification of motor competence. The false positive rate is low, suggesting the model does not misidentify many schoolchildren with the “Low” motor competence classification.

In the case of the female schoolchildren, the “High” class shows an intense elevation towards the upper left corner of the graph and has a high area under the curve (AUC) of 0.98; this indicates that the model has a high sensitivity to detect the classification “High” motor competence. The false positive rate is low, suggesting the model does not misidentify many schoolchildren with the “High” motor competence classification. On the other hand, the dark blue dotted line refers to the fact that the test has been bad, which is not the case of the study.

Deployment

A mobile app was developed in Android Studio using the Flutter framework. The code structure was organized by the best mobile application development practices and following the design pattern recommended by Flutter, which is the model-view-controller (MVC) design pattern. Firebase real-time database was used for storage.

The primary interfaces are shown in Figure 10, where you have the login screen and the options menu.




Figure 10. Initial interfaces of the mobile app.

Figure 11 shows the interface that allows entering the data corresponding to the student; the body mass index (BMI) will be able to be calculated automatically. Additionally, table is provided to identify the student's BMI classification. Likewise, the interface that allows entering the data captured with the smart band, such as speed, cadence, stride, and steps of the schoolchildren, is shown. It contains an Artificial Intelligence function that allows you to locate your position within the percentiles generated from the sample of schoolchildren.

The process was evaluated through the prototype of the Software Quality Systemic Model (SQSM). This model is planned based on six standardized international quality characteristics through a set of characteristic categories and metrics, which measure and evaluate the software quality of a product; this model is made into an instrument for measuring great value covering essential aspects of software quality.

It was carried out in the selected educational centers to evaluate the application's functionalities. The information collected meets expectations as it explains the population's needs.

Once the various interviewees were integrated, we proceeded with the evaluation method based on the Systemic Quality Model, which includes 11 categories. We have selected three specific classes related to the software: functionality, reliability, and usability because these apply to the case study. Table 6 shows a detailed description of each category with the interviews.

Considering the levels of satisfaction achieved in the categories of functionality, reliability, and usability, by calculating the arithmetic mean, it is observed that the degree of satisfaction of the application for the specialists of the educational centers is 77.09%. By contrasting this result with the quality level, it is evident that the application meets significant standards.




Figure 11. Calculation interfaces and use of AI to generate the value of your motor competence within the percentiles.

Table 6. Categories and characteristics according to the prototype of Software Quality Systemic Model (SQSM).

Characteristics	Subcharacteristics	Metrics	Percentage of Compliance	Quality Level
Functionality (FUN)	FUN. 1 Fit for purpose	20	84.00%	Satisfied
	FUN. 2 Accuracy	6	86.67%	Satisfied
	FUN. 3 Interoperability	4	86.67%	Satisfied
	FUN. 4 Security	3	53.33%	Does not satisfy
	Subtotal	33	81.88%	Satisfied
Usability (USA)	USA.1 Ease of Compression	5	90.00%	Satisfied
	USA. 2 Learning Capacity	8	92.00%	Satisfied
	USA. 3 Graphical Interface	4	95.00%	Satisfied
	USA. 4 Operability	3	52.00%	Does not satisfy
	Subtotal	20	82.73%	Satisfied
Reliability (RIA)	RIA. 1 Maturity	5	60.00%	Does not satisfy
	RIA. 2 Fault tolerance	4	90.00%	Satisfied
	RIA. 3 Recovery	2	50.00%	Does not satisfy
	Subtotal	11	69.09%	Does not satisfy
Total		64	77.09%	Satisfied

4. Discussion

The study's objective was to classify the motor competence of schoolchildren performed in a school using smart bands according to age range and sex, using machine-learning techniques optimized with hyperparameters acceptably for the classification indicated through the passing results in the tests carried out.

The results of the study have shown that according to the motor competence tests carried out, step cadence values obtained range from 96 to 29 steps in both sexes and the number of steps ranges from 1437 to 455, with speed from 4.75 to 1.16 and the stride from

88 to 71. Furthermore, it was verified that the measurements obtained decreased rapidly with age, being more pronounced in females than in males.

In this context, the cut-off points suggested in other recent research [37] were taken as a basis, where the study proposed percentiles of the number of steps in a day. The percentiles indicate <p25 below average, p25 to p75 average, and >p75 above average. In essence, percentiles, regardless of the method used, can be applied to establish improvement goals, especially for schoolchildren below the 25th percentile [38]. For example, the schoolchildren in this study classified below the p25th percentile in the tests performed showed higher BMI values.

Precisely, these results coincide with those found in [4], when it states that the measurements obtained decrease rapidly with age. This information could help promote strategies for developing physical activity in schoolchildren in educational centers to improve their performance. However, a limitation found in the study was the need for a broader set of tests to be performed.

Furthermore, the results of the study have shown that using machine-learning techniques such as those evaluated by Himi et al. [14,39], then optimized with hyperparameters like work carried out by Yadav et al. [38] and Yang et al. [40], they achieve reasonable classifications for schoolchildren according to their motor competence. It can also be seen that the naïve Bayes algorithm obtains the lowest results [41,42].

It was determined that the most suitable supervised machine-learning technique would be the gradient-boosted model, which has obtained the best accuracy of 0.95 with an f-score of 0.93, recall of 0.92, and precision of 0.94, which was used in works such as [43,44]. This has been corroborated by the ROC-AUC curves, where the “Low” classes for males and “High” for females show a substantial elevation towards the upper left corner of the graph and have a high area under the curve of 0.98; this indicates that the model has a high sensitivity to detect motor competence classification.

This study represents a significant contribution with the use of wearable devices for data capture and classification using machine-learning algorithms optimized with hyperparameters for motor competence in schoolchildren that can support people interested in finding more precise ways to evaluate motor competence with the support of technology.

5. Conclusions

In conclusion, smart bands have shown great potential to improve the motor competence of schoolchildren through machine learning and hyperparameters. The gradient-boosted algorithm is a good model for classifying schoolchildren. Motor competence is a crucial aspect of the development of children and adolescents, and smart bands can facilitate this process by providing personalized feedback. By harnessing the power of technology, smart bands can help children develop essential motor skills, leading to better physical health and overall well-being. As more research is conducted in this field, we expect to see more advancements in smart band technology, which will undoubtedly positively impact child development.

Finally, the mobile software product built based on the proposed model was validated using the prototype of the Software Quality Systemic Model (SQSM) based on three specific categories: functionality, reliability, and usability, obtaining 77.09%.

Expanding the determining attributes for classifying motor competence in schoolchildren is recommended in future work. Additionally, constructing the application of other classification algorithms is essential to compare results and assess efficiency, as well as deep learning. Different approaches, such as transfer learning, can be used to adapt domain data to train at high fidelity.

Author Contributions: Methodology, J.A.O.; Software, A.C.G. and C.A.L.; Validation, A.C.G. and C.A.L.; Formal analysis, J.S.-T.; Investigation, J.S.-T.; Writing—original draft, J.S.-T.; Writing—review & editing, M.Z.C. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by Catholic University of Santa María grant number 7995-CU-2022.

Institutional Review Board Statement: Anthropometric measurements and the utilization of the smart band followed the recommendations outlined by the local ethics committee (UCSM-096-2022) and adhered to the principles of the Declaration of Helsinki (World Medical Association) concerning ethical standards for human research (Universidad Católica de Santa María (096-07/10/2022)).

Informed Consent Statement: Informed consent was obtained from all subjects involved in the study.

Data Availability Statement: The data presented in this study are available on request from the corresponding author. The data is not publicly available due to the privacy of handling schoolchildren's data.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Dini Kounoudes, A.; Kapitsaki, G.M.; Katakis, I. Enhancing user awareness on inferences obtained from fitness trackers data. *User Model. User Adapt. Interact.* **2023**, *33*, 967–1014. [\[CrossRef\]](#) [\[PubMed\]](#)
2. Amor, J.D.; James, C.J. Validation of a Commercial Android Smartwatch as an Activity Monitoring Platform. *IEEE J. Biomed. Health Inform.* **2018**, *22*, 968–978. [\[CrossRef\]](#) [\[PubMed\]](#)
3. Al-Janabi, S.; Salman, A.H. Sensitive integration of multilevel optimization model in human activity recognition for smartphone and smartwatch applications. *Big Data Min. Anal.* **2021**, *4*, 124–138. [\[CrossRef\]](#)
4. Sulla-Torres, J.; Vidal-Espinoza, R.; Avendaño Llanque, C.; Calla Gamboa, A.; Zúñiga Carnero, M.; Cossio-Bolaños, M.; Gomez-Campos, R. Quantification of the Number of Steps in a School Recess by Means of Smart Bands: Proposal of Referential Values for Children and Adolescents. *Children* **2023**, *10*, 915. [\[CrossRef\]](#) [\[PubMed\]](#)
5. Weiss, G.M.; Yoneda, K.; Hayajneh, T. Smartphone and Smartwatch-Based Biometrics Using Activities of Daily Living. *IEEE Access* **2019**, *7*, 133190–133202. [\[CrossRef\]](#)
6. Cosoli, G.; Antognoli, L.; Scalise, L. Wearable Electrocardiography for Physical Activity Monitoring: Definition of Validation Protocol and Automatic Classification. *Biosensors* **2023**, *13*, 154. [\[CrossRef\]](#) [\[PubMed\]](#)
7. Alsareii, S.A.; Awais, M.; Alamri, A.M.; AlAsmari, M.Y.; Irfan, M.; Aslam, N.; Raza, M. Physical Activity Monitoring and Classification Using Machine Learning Techniques. *Life* **2022**, *12*, 1103. [\[CrossRef\]](#)
8. Ali, Y.A.; Awwad, E.M.; Al-Razgan, M.; Maarouf, A. Hyperparameter Search for Machine Learning Algorithms for Optimizing the Computational Complexity. *Processes* **2023**, *11*, 349. [\[CrossRef\]](#)
9. Wang, C.; Lizardo, O.; Hachen, D.S. Using Fitbit data to examine factors that affect daily activity levels of college students. *PLoS ONE* **2021**, *16*, e0244747. [\[CrossRef\]](#)
10. Sabry, F.; Eltaras, T.; Labda, W.; Alzoubi, K.; Malluhi, Q. Machine Learning for Healthcare Wearable Devices: The Big Picture. *J. Healthc. Eng.* **2022**, *2022*, 4653923. [\[CrossRef\]](#)
11. Zhou, M.; Fukuoka, Y.; Goldberg, K.; Vittinghoff, E.; Aswani, A. Applying machine learning to predict future adherence to physical activity programs. *BMC Med. Inform. Decis. Mak.* **2019**, *19*, 169. [\[CrossRef\]](#) [\[PubMed\]](#)
12. Creaser, A.V.; Frazer, M.T.; Costa, S.; Bingham, D.D.; Climes, S.A. The Use of Wearable Activity Trackers in Schools to Promote Child and Adolescent Physical Activity: A Descriptive Content Analysis of School Staff's Perspectives. *Int. J. Environ. Res. Public Health* **2022**, *19*, 14067. [\[CrossRef\]](#) [\[PubMed\]](#)
13. Site, A.; Nurmi, J.; Lohan, E.S. Systematic Review on Machine-Learning Algorithms Used in Wearable-Based eHealth Data Analysis. *IEEE Access* **2021**, *9*, 112221–112235. [\[CrossRef\]](#)
14. Himi, S.T.; Monalisa, N.T.; Whaiduzzaman, M.; Barros, A.; Uddin, M.S. MedAI: A Smartwatch-Based Application Framework for the Prediction of Common Diseases Using Machine Learning. *IEEE Access* **2023**, *11*, 12342–12359. [\[CrossRef\]](#)
15. Bischl, B.; Binder, M.; Lang, M.; Pielok, T.; Richter, J.; Coors, S.; Thomas, J.; Ullmann, T.; Becker, M.; Boulesteix, A.; et al. Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges. *WIREs Data Min. Knowl. Discov.* **2023**, *13*, e1484. [\[CrossRef\]](#)
16. Yagin, F.H.; Güllü, M.; Gormez, Y.; Castañeda-Babarro, A.; Colak, C.; Greco, G.; Fischetti, F.; Cataldi, S. Estimation of Obesity Levels with a Trained Neural Network Approach optimized by the Bayesian Technique. *Appl. Sci.* **2023**, *13*, 3875. [\[CrossRef\]](#)
17. Rivera, O.; Avilés, O.F.; Castillo-Castaneda, E. Classifying the physical activity indicator using machine learning and direct measurements: A feasibility study. *Acta Sci. Technol.* **2023**, *45*, e61317. [\[CrossRef\]](#)
18. Triwiyanto, T.; Pawana, I.P.A.; Purnomo, M.H. An Improved Performance of Deep Learning Based on Convolution Neural Network to Classify the Hand Motion by Evaluating Hyper Parameter. *IEEE Trans. Neural Syst. Rehabil. Eng.* **2020**, *28*, 1678–1688. [\[CrossRef\]](#)
19. Chapman, P.; Clinton, J.; Kerber, R.; Khabaza, T.; Reinartz, T.P.; Shearer, C.; Wirth, R. CRISP-DM 1.0: Step-by-step data mining guide. *PSS Inc.* **2000**, *9*, 1–73.
20. Freedman, D.S.; Berenson, G.S. Tracking of BMI z Scores for Severe Obesity. *Pediatrics* **2017**, *140*, e20171072. [\[CrossRef\]](#)
21. Fernández, J.R.; Redden, D.T.; Pietrobelli, A.; Allison, D.B. Waist circumference percentiles in nationally representative samples of African-American, European-American, and Mexican-American children and adolescents. *J. Pediatr.* **2004**, *145*, 439–444. [\[CrossRef\]](#) [\[PubMed\]](#)

22. Bayoumy, K.; Gaber, M.; Elshafeey, A.; Mhaimeed, O.; Dineen, E.H.; Marvel, F.A.; Martin, S.S.; Muse, E.D.; Turakhia, M.P.; Tarakji, K.G.; et al. Smart wearable devices in cardiovascular care: Where we are and how to move forward. *Nat. Rev. Cardiol.* **2021**, *18*, 581–599. [\[CrossRef\]](#) [\[PubMed\]](#)
23. Piazzentin Ono, J.; Freire, J.; Silva, C.T. Interactive data visualization in Jupyter notebooks. *Comput. Sci. Eng.* **2021**, *23*, 99–106. [\[CrossRef\]](#)
24. Safavian, S.R.; Landgrebe, D. A Survey of Decision Tree Classifier Methodology. *Electr. Eng.* **1991**, *21*, 660–674. [\[CrossRef\]](#)
25. Qi, Y. Random Forest for Bioinformatics. In *Ensemble Machine Learning: Methods and Applications*; Springer: Berlin/Heidelberg, Germany, 2012.
26. Cristianini, N.; Shawe-Taylor, J. *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*; Cambridge University Press: Cambridge, UK, 2000. [\[CrossRef\]](#)
27. Zhang, H.; Su, J. Naive Bayes for optimal ranking. *J. Exp. Theor. Artif. Intell.* **2008**, *20*, 79–93. [\[CrossRef\]](#)
28. Cheng, X.; Lin, S.Y.; Liu, J.; Liu, S.; Zhang, J.; Nie, P.; Fuemmeler, B.F.; Wang, Y.; Xue, H. Does physical activity predict obesity—A machine learning and statistical method-based analysis. *Int. J. Environ. Res. Public Health* **2021**, *18*, 3966. [\[CrossRef\]](#) [\[PubMed\]](#)
29. Bishop, C.M. *Neural Networks: A Pattern Recognition Perspective*. *Neural Networks*; Oxford University Press: Oxford, UK, 1996.
30. Cunningham, P.; Delany, S.J. k-Nearest Neighbour Classifiers—A Tutorial. *ACM Comput. Surv.* **2022**, *54*, 1–25. [\[CrossRef\]](#)
31. Friedman, J.H. Greedy function approximation: A gradient boosting machine. *Ann. Stat.* **2001**, *29*, 1189–1232. [\[CrossRef\]](#)
32. Liu, M.; Guo, C.; Guo, S. An explainable knowledge distillation method with XGBoost for ICU mortality prediction. *Comput. Biol. Med.* **2023**, *152*, 106466. [\[CrossRef\]](#)
33. Prokhorenkova, L.; Gusev, G.; Vorobev, A.; Dorogush, A.V.; Gulin, A. Catboost: Unbiased boosting with categorical features. In Proceedings of the 32nd Conference on Neural Information Processing Systems (NeurIPS 2018), Montréal, QC, Canada, 3–8 December 2018.
34. Cole, T.J. Establishing a standard definition for child overweight and obesity worldwide: International survey. *BMJ* **2000**, *320*, 1240–1243. [\[CrossRef\]](#)
35. Dai, R.; Lu, C.; Yun, L.; Lenze, E.; Avidan, M.; Kannampallil, T. Comparing stress prediction models using smartwatch physiological signals and participant self-reports. *Comput. Methods Programs Biomed.* **2021**, *208*, 106207. [\[CrossRef\]](#) [\[PubMed\]](#)
36. Sokolova, M.; Lapalme, G. A systematic analysis of performance measures for classification tasks. *Inf. Process. Manag.* **2009**, *45*, 427–437. [\[CrossRef\]](#)
37. Lammers, A.E.; Romanowski, A.L.; Baumgartner, H.; Diller, G.P.; Uebing, A. Reference Values for Wristband Accelerometry Data in Children Aged 6–11 Years of Age. *Front. Pediatr.* **2022**, *10*, 808372. [\[CrossRef\]](#) [\[PubMed\]](#)
38. Yadav, P.; Sharma, S.C.; Mahadeva, R.; Patole, S.P. Exploring Hyper-Parameters and Feature Selection for Predicting Non-Communicable Chronic Disease Using Stacking Classifier. *IEEE Access* **2023**, *11*, 80030–80055. [\[CrossRef\]](#)
39. Wang, J.; Xie, Z.; Li, Y.; Song, Y.; Yan, J.; Bai, W.; Zhou, T.; Qin, J. Relationship between Health Status and Physical Fitness of College Students from South China: An Empirical Study by Data Mining Approach. *IEEE Access* **2020**, *8*, 67466–67473. [\[CrossRef\]](#)
40. Yang, H.; Chen, Z.; Yang, H.; Tian, M. Predicting Coronary Heart Disease Using an Improved LightGBM Model: Performance Analysis and Comparison. *IEEE Access* **2023**, *11*, 23366–23380. [\[CrossRef\]](#)
41. Mannini, A.; Sabatini, A.M. Machine Learning Methods for Classifying Human Physical Activity from On-Body Accelerometers. *Sensors* **2010**, *10*, 1154–1175. [\[CrossRef\]](#)
42. Saez, Y.; Baldominos, A.; Isasi, P. A Comparison Study of Classifier Algorithms for Cross-Person Physical Activity Recognition. *Sensors* **2016**, *17*, 66. [\[CrossRef\]](#)
43. Zhang, B.; Ren, J.; Cheng, Y.; Wang, B.; Wei, Z. Health data driven on continuous blood pressure prediction based on gradient boosting decision tree algorithm. *IEEE Access* **2019**, *7*, 32423. [\[CrossRef\]](#)
44. Zhao, L.; Zhang, F.; Zhang, H.; Liang, Y.; Zhou, A.; Ma, H. Robust Respiratory Rate Monitoring Using Smartwatch Photoplethysmography. *IEEE Internet Things J.* **2023**, *10*, 4830–4844. [\[CrossRef\]](#)

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

B. Encuesta de Docentes

Marca temporal	Centro educativo I	Centro educativo II
1. ¿ Existe corrección al momento de ingresar algún dato incorrecto?	4	3
2. ¿ La búsqueda de alumnos es rápida?	5	5
3. ¿ La adaptación del programa a tus necesidades fue adecuado?	5	4
4. ¿ El aplicativo se adapta a diferentes tipos de alumnado?	5	5
5. ¿ Se identifican los objetivos de cada opción ?	5	4
6. ¿ El aplicativo identifica error de manejo y explica que se debe hacer ?	4	3
7. ¿ El contenido preciso y claro?	5	5
8. ¿ La información del app está actualizada?	5	5
9. ¿ Se indica que acción realizar?	5	4
10. ¿ Existe intercambio de información entre usuario y software?	4	4
11. ¿ Es intuitivo el software ?	5	5
12. ¿ Registrar accesos de usuario?	5	5
13. ¿ La información en pantalla le resulta suficiente?	5	4
14. ¿ Resulto un manejo fácil del software?	5	5
15. ¿ Se permite al usuario corregir una respuesta aceptada por el sistema?	4	5
16. ¿ La presentación general le resulta adecuada?	5	5
17. ¿ La gama de colores le parece agradable?	5	5
18. ¿ El color de fondo es adecuado y cómodo, para una correcta lectura?	5	5
19. ¿ Gráficos o imágenes se facilitan el manejo?	5	5
20. ¿ Tienes libertad de elecciones en diferentes pantallas ?	4	4
21. ¿ No surgió error alguno que obligue a detener el uso?	4	5
22. ¿ La velocidad de paso de información de una pantalla a otra es apropiada ?	4	5
23. ¿ Estaría dispuesto/a a utilizar este software en su práctica educativa?	Si	Si
24. ¿ Tiene algún comentario adicional o sugerencia para mejorar el software?	Interesante el software permite manejar rápidamente datos	Me ayudaría en mi actividades diarias y con la lista de mis alumnos

1: Muy en desacuerdo

2: Algo en desacuerdo

3: Ni en desacuerdo, ni de acuerdo

4: Algo de acuerdo

5: Muy en Acuerdo

C. Métricas (MOSCA)

ID	Categoría	Característica	Sub - Característica	Métrica	Formulación	Val
1	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿Existe en su interfaces o MenÚ Principal sobre la institución Auspiciante?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
2	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿Existe en las interfaces una opción de conexión para todo el contenido de la aplicación?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
3	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿Existe una forma de ayuda con la aplicación?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	4
4	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿Existe una barra de la derecha para acceder la información?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	1
5	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿Existe Botones o enlaces donde cumple su función?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
6	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿Existe una interfaz donde nos informa sobre la aplicación?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
7	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿El usuario puede disponer del aplicativo para enlazarlo con el internet?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
8	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿El nombre del software esta relacionado con el tema?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	1
9	Funcionalidad	FUN. 1 Ajuste de los propósitos	Funcionalidades generales	¿La estructura del software cumple con los funciones requeridas?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
10	Funcionalidad	FUN. 1 Ajuste de los propósitos	Requerimientos	¿Se menciona sobre los requerimientos básico para el aplicativo (software y Hardware)?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
11	Funcionalidad	FUN. 1 Ajuste de los propósitos	Requerimientos	¿Se enfatiza al cumplir los requerimientos básicos mínimos?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
12	Funcionalidad	FUN. 1 Ajuste de los propósitos	Requerimientos	¿Se puede utilizar usando en un entrono virtual?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	3
13	Funcionalidad	FUN. 1 Ajuste de los propósitos	Usuarios	¿Se indica sobre el perfil de usuario que utilizara el aplicativo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
14	Funcionalidad	FUN. 1 Ajuste de los propósitos	Usuarios	¿Realizan el objetivo principal del Aplicativo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
15	Funcionalidad	FUN. 1 Ajuste de los propósitos	Usuarios	¿El diseño del software esta diseñado para el entorno del usuario?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
16	Funcionalidad	FUN. 1 Ajuste de los propósitos	Diseño	¿El funcionamiento de opciones cumple con la estructura del diseño?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	4
17	Funcionalidad	FUN. 1 Ajuste de los propósitos	Diseño	¿Cada vez que se cambie una interfaz, existe una retroalimentación o recursos visuales?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	1
18	Funcionalidad	FUN. 1 Ajuste de los propósitos	Diseño	¿Los enunciados en el software no pasan mas de 14 letras?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
19	Funcionalidad	FUN. 1 Ajuste de los propósitos	Diseño	¿Existe la opción donde se puede regresar de interfaz?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
20	Funcionalidad	FUN. 1 Ajuste de los propósitos	Diseño	¿El texto en la app existe un interlineado, espacio y/o tamaño de letras adecuado?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
21	Funcionalidad	FUN. 2 Precisión		¿No existen problemas en las funciones incompletas en el aplicativo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
22	Funcionalidad	FUN. 2 Precisión		¿No existen problemas en las funciones incorrectas en el aplicativo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
23	Funcionalidad	FUN. 2 Precisión		¿Existe un resultado donde es incorrecto o incompleto?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	3
24	Funcionalidad	FUN. 2 Precisión		¿Pueden revertir fácilmente sus acciones?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
25	Funcionalidad	FUN. 2 Precisión		¿Existe mensajes de errores sobre los problemas detectados?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	3
26	Funcionalidad	FUN. 2 Precisión		¿Existe una validación de datos en el aplicativo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
27	Funcionalidad	FUN. 3 Interoperabilidad		¿Existe estabilidad entre el software y las interfaces?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
28	Funcionalidad	FUN. 3 Interoperabilidad		¿Existe estabilidad las interfaces y los colores establecidos?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
29	Funcionalidad	FUN. 3 Interoperabilidad		¿Existe estabilidad Entre el software y la base de datos (Firebase)?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	3
30	Funcionalidad	FUN. 4 Seguridad		¿Existe claves de seguridad en los usuarios ingresados?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	2
31	Funcionalidad	FUN. 4 Seguridad		¿Existe la complejidad del password para ingresar	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	1
32	Funcionalidad	FUN. 4 Seguridad		¿Los interfaces presentadas pueden ser solo manipuladas por los usuarios?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
33	Fiabilidad	FA. 1 Madurez		¿Se comprueba y resuelven sobre las falas detectadas?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	3
34	Fiabilidad	FA. 1 Madurez		¿Se comprueba sobre la conectividad con la red?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	1

35	Fiabilidad	FIA. 1. Madurez	¿Existe una manera donde se puede enviar los reclamos o fallas encontradas por el usuario?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	1
36	Fiabilidad	FIA. 1. Madurez	¿Las actualizaciones del Software se notifican a los usuarios?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
37	Fiabilidad	FIA. 1. Madurez	¿Se realizan encuestas sobre el aplicativo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
38	Fiabilidad	FIA. 2. Tolerancia a Fallos	¿Los Mensajes de Error son breves?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	3
39	Fiabilidad	FIA. 2. Tolerancia a Fallos	¿Los Mensajes de Error son gramaticalmente correctos?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
40	Fiabilidad	FIA. 2. Tolerancia a Fallos	¿Los mensajes de Error ayudan al usuario entender el problema?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
41	Fiabilidad	FIA. 2. Tolerancia a Fallos	¿Todos los mensaje de error tienen el mismo estilo de Texto?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
42	Fiabilidad	FIA. 3. Recuperación	¿El software tiene una recuperación de datos ante una caída?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	3
43	Fiabilidad	FIA. 3. Recuperación	¿El tiempo de caída se resuelve en la brevedad?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	2
44	Usabilidad	USA. 1. Facilidad de Compresión	¿No se necesita conocimiento previo de tecnología para utilizarlo adecuadamente?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
45	Usabilidad	USA. 1. Facilidad de Compresión	¿Para la compresión total del software solo se necesita 10 min?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
46	Usabilidad	USA. 1. Facilidad de Compresión	¿La interacción de información es fácil de usar?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
47	Usabilidad	USA. 1. Facilidad de Compresión	¿Solo se muestra texto necesario para la toma de decisiones?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
48	Usabilidad	USA. 1. Facilidad de Compresión	¿La navegación entre las interfaces es simple y visible?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
49	Usabilidad	USA. 1. Facilidad de Compresión	¿Los enunciados son consistente y naturales?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
50	Usabilidad	USA. 1. Facilidad de Compresión	¿Los botones son fáciles de identificar y ubicarlos?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
51	Usabilidad	USA. 1. Facilidad de Compresión	¿La opción para cerrar la aplicación, es fácil ubicarlo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	1
52	Usabilidad	USA. 2. Capacidad de Aprendizaje	¿Están distribuidos los contenidos apropiadamente por secciones donde se puedan ubicar fácilmente?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	4
53	Usabilidad	USA. 2. Capacidad de Aprendizaje	¿La información importantes aparecen al principio?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	4
54	Usabilidad	USA. 2. Capacidad de Aprendizaje	¿Los iconos, señales, o espacios nos ayuda a comparar sobre las instrucciones, errores o entrada de datos?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
55	Usabilidad	USA. 2. Capacidad de Aprendizaje	¿Las funcionalidades o actividades para ejecutarlos se utiliza menos de 4 clicks?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
56	Usabilidad	USA. 2. Capacidad de Aprendizaje	¿Es correcta la información sobre los enunciados?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
57	Usabilidad	USA. 3. Interfaz Grafica	¿La gama de colores principales están de acuerdo a la temática de la aplicación?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
58	Usabilidad	USA. 3. Interfaz Grafica	¿Existe un contraste en el texto con la interfaz de colores?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
59	Usabilidad	USA. 3. Interfaz Grafica	¿El diseño es visualmente atractivo para el usuario?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5
60	Usabilidad	USA. 3. Interfaz Grafica	¿Se incorporo para alternativas para que la interacción se facilite?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	4
61	Usabilidad	USA. 4. Operabilidad	¿Es satisfactorio el uso de barras, botones, iconos, y demás recursos?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	4
62	Usabilidad	USA. 4. Operabilidad	¿El usuario se mantiene informado sobre los avances del aplicativo?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	4
63	Usabilidad	USA. 4. Operabilidad	¿La información presentada se utiliza de manera respetuosa y buen trato?	5: Muy de acuerdo, 4: Algo de acuerdo, 3: Ni en desacuerdo, ni de acuerdo, 2: Algo en desacuerdo, 1: Muy en desacuerdo	5

D. Dictamen de comité de ética

COMITÉ DE ÉTICA INSTITUCIONAL DE INVESTIGACIÓN UCSM



DICTAMEN COMITÉ DE ETICA DE INVESTIGACION UNIVERSIDAD CATOLICA DE SANTA MARIA

Arequipa, 10 de julio de 2022

Investigador José Alfredo Sulla Torres

Presente. -

De mi especial consideración,

Me dirijo a usted para hacerle llegar el resultado de la evaluación del proyecto de investigación y dictamen del Comité Institucional de Ética de Investigación.

TÍTULO: Proyecto de Investigación: “Desarrollo de una herramienta cuantitativa para la evaluación de la competencia motora utilizando tecnología vestible en escolares de la provincia de Arequipa”.

Investigador a cargo de la investigación: José Alfredo Sulla Torres

TIPO Y DISEÑO: Estudio mixto de corte transversal (descriptivo-comparativo) y longitudinal (tendencia)

OBJETIVO: La investigación tiene como objetivo: Desarrollar una herramienta cuantitativa para la evaluación de la competencia motora utilizando tecnología vestible en escolares de la provincia de Arequipa.



PROCEDIMIENTOS: Recolección de datos.

COMITÉ DE ÉTICA INSTITUCIONAL DE INVESTIGACIÓN UCSM



DICTAMEN COMITÉ DE ETICA DE INVESTIGACION UNIVERSIDAD CATOLICA DE SANTA MARIA

SUJETOS DE ESTUDIO:

800 escolares de ambos sexos. La muestra será de tipo probabilística (estratificada) CI=95%.
El rango de edad a considerar será de 5 a 17 años.

RIESGO DEL ESTUDIO:

Mínimo

OBSERVACIONES, SUGERENCIAS:

Debe proteger confidencialidad de la data sensible

DICTAMEN:

DICTAMEN FAVORABLE
096 - 2022



Águeda Muñoz del Carpio Toia
Comité Institucional de Ética de la Investigación UCSM

Cualquier duda comunicarse a: comiteeticainvestigacionucsm@gmail.com