



Principales variables que predicen la competencia motora: análisis con árboles de clasificación

Main variables predicting motor skills: analysis with classification trees

Autores

Angel Anibal Mamani-Ramos ¹
 Edgar Froilan Damian-Núñez ¹
 Edgar Eloy Carpio-Vargas ²
 Indalecio Mujica-Bermúdez ³
 Carlos Manuel Pérez-Reátegui ⁴
 Luis Martin Botton-Estrada ¹
 Jorge Alber Quisocala-Ramos ¹
 Henry Quispe-Cruz ²
 Carlos Vidal Cutimbo-Quispe ²
 Jhony Ruben Rodriguez-Mamani ²
 Rosario Patricia Palomino-Crisóstomo ⁵
 Willy Roger Cutipa-Salluca ²
 Kandy Faviola Tuero-Chirinos ²
 Naysha Sharon Villanueva-Alvaro ²
 Jhonny Jesús Lava-Gálvez ¹

¹ Universidad Nacional Mayor de San Marcos (Perú)

² Universidad Nacional del Altiplano de Puno (Perú)

³ Universidad Nacional de San Cristóbal de Huamanga (Perú)

⁴ Universidad Nacional de la Amazonía Peruana (Perú)

⁵ Universidad Nacional de Educación Enrique Guzmán y Valle (Perú)

Autor de correspondencia:
 Angel Anibal Mamani-Ramos
 amamanir@unmsm.edu.pe

Cómo citar en APA

Mamani-Ramos, A. A., Damian-Núñez, E. F., Carpio-Vargas, E. E., Mujica-Bermúdez, I., Pérez-Reátegui, C. M., Botton-Estrada, L. M., Quisocala-Ramos, J. A., Quispe-Cruz, H., Cutimbo-Quispe, C. V., Rodriguez-Mamani, J. R., Palomino-Crisóstomo, R. P., Cutipa-Salluca, W. R., Tuero-Chirinos, K. F., Villanueva-Alvaro, N. S., & Lava-Gálvez, J. J. (2025). Principales variables que predicen la competencia motora: análisis con árboles de clasificación. *Retos*, 68, 318–330. <https://doi.org/10.47197/retos.v68.113> 239

Resumen

Introducción: La competencia motora es una variable que marca la vida del ser humano. Por tal razón, realizar estudios de predicción que expliquen el comportamiento de esta es trascendental.

Objetivo: El propósito del estudio fue explorar las principales variables que predicen la competencia motora según el análisis con árboles de clasificación.

Método: Participaron 291 niños peruanos de 6 a 10 años ($M=8.35$; $DE=1.29$), a quienes se les aplicó el test de desarrollo motor grueso; una prueba de matemática y lectura; un cuestionario sociodemográfico; y se les realizó las mediciones de masa corporal y estatura.

Resultados: Los resultados de predicción presentaron un modelo inicial con 22 nodos terminales con el 65.52 % de precisión, y un modelo optimizado con 10 nodos terminales con el 68.34 % de precisión.

Discusión: Este es el primer estudio que aplica el aprendizaje automático mediante el modelo árbol de clasificación en base a la metodología CRISP-DM para explorar las principales variables que predicen la competencia motora en niños de 6 a 10 años.

Conclusiones: Este estudio confirma que el aprendizaje automático mediante el modelo árbol de clasificación en base a la metodología CRISP-DM puede predecir la competencia motora en niños de 6 a 10 años con una precisión de 68.34 %, siendo las horas de práctica de actividad física al día la variable más importante, además de las horas de uso de dispositivos con pantalla al día y la masa corporal de siete variables.

Palabras clave

Competencia motora; actividad física; dispositivos con pantalla; masa corporal; niños; CRISP-DM.

Abstract

Introduction: Motor skills is a variable that marks the life of the human being. For this reason, predictive studies that explain the behavior of this variable are transcendental.

Objective: The purpose of this study was to explore the main variables that predict motor skills according to classification tree analysis.

Methods: A total of 291 Peruvian children aged 6 to 10 years ($M=8.35$; $SD=1.29$) participated in the study. They underwent a gross motor development test; a mathematics and reading test; a sociodemographic questionnaire; and body mass and height measurements.

Results: The prediction results showed an initial model with 22 terminal nodes with 65.52% accuracy, and an optimized model with 10 terminal nodes with 68.34% accuracy.

Discussion: This is the first study that applies machine learning by means of the classification tree model based on the CRISP-DM methodology to explore the main variables that predict motor skills in children aged 6 to 10 years.

Conclusions: This study confirms that machine learning using classification tree modeling based on CRISP-DM methodology can predict motor skills in children aged 6 to 10 years with an accuracy of 68.34 %, with hours of physical activity practice per day being the most important variable, in addition to hours of screen device use per day and body mass of seven variables.

Keywords

Motor skills; physical activity; display devices; body mass; children; CRISP-DM.

Introducción

De acuerdo con Mamani-Ramos et al. (2024), la competencia motora es un constructo que puede beneficiar o perjudicar doblemente el bienestar presente y futuro de los niños de todas las culturas. Este beneficio o perjuicio se presenta de forma escalonada. El primero, que es el principal, estriba en el fomento o limitación de la participación en actividades físicas dentro y fuera de la escuela (Duncan et al., 2022). Y como efecto de la participación o no en actividades físicas, se presenta el segundo beneficio o perjuicio. Al ser la actividad física un beneficio, los niños podrán adoptar estilos de vida más activos y saludables (Godoy-Cumillaf et al., 2024); tener mejores habilidades cognitivas, socioemocionales y mayor confianza (Bautista et al., 2020; Mamani-Ramos et al., 2020; Zhang et al., 2024); e involucrarse activamente en su hogar, escuela y entornos comunitarios a través del juego, el deporte y la danza (Griffiths et al., 2018; Rodríguez-Briceño et al., 2022). Todo niño que cuente con los beneficios descritos u otros, en definitiva, podrá llevar a cabo una vida sana y placentera de por vida (John et al., 2024). Por el contrario, al presentarse la inactividad física como perjuicio, es muy probable que todos los beneficios se presenten de forma inversa (Guthold et al., 2018). Además, se aumentará el riesgo de contraer enfermedades no transmisibles (diabetes mellitus tipo 2, hipertensión, obesidad, entre otras) (Aoyama et al., 2022; Gao et al., 2021).

En efecto, la competencia motora es una variable que marca la vida del ser humano (Mamani-Ramos et al., 2024); por tal razón, realizar estudios de predicción que expliquen el comportamiento de esta variable es trascendental. Según estudios recientes en Irlanda (Behan et al., 2019; Philpott et al., 2020), Bélgica y Estados Unidos (Brian et al., 2018), Inglaterra (Duncan et al., 2019), Brasil (Nobre et al., 2018) y Perú (López, 2024; Montoya, 2023; Reyes, 2023; Sánchez, 2023); por un lado, se reportó una preocupación por la disminución de la competencia motora; y por otro, se reportó un incremento preocupante en el nivel de competencia motora por debajo del promedio. De acuerdo con Salami et al. (2024), esta situación se debe a la influencia de varios factores como las horas de práctica de actividad física al día, las horas de uso de dispositivos con pantalla al día, la masa corporal, la lectura, la estatura, la edad y el nivel socioeconómico.

A continuación, presentamos el sustento teórico de las variables de predicción descritas; es decir, explicaremos cómo estas interaccionan con la variable dependiente, que es la competencia motora, a partir de propuestas teóricas y hallazgos previos. Primero, la actividad física y la competencia motora siguen un proceso de participación cíclica según lo propuesto por Stodden et al. (2008) en su modelo conceptual de desarrollo. Este modelo describe que la participación en actividades físicas de forma regular en la infancia conlleva a un mayor nivel de competencia motora que alienta e impulsa a que los niños continúen participando en actividades físicas con mayor compromiso y regularidad durante toda su vida con el fin de mantenerse saludables. En concordancia a la situación problemática reportada en el acápite anterior y en contraste con el modelo conceptual descrito, se podría entender que el motivo por el que 81 % de adolescentes no cumplen con los 60 minutos diarios de actividad física para la salud (Guthold et al., 2020), se debería en parte al nivel de su competencia motora que presentaron estos cuando eran niños. Segundo, en la actualidad, el tiempo excesivo frente a los dispositivos con pantalla viene generando retrasos en el desarrollo de los niños (Hill et al., 2016). En Canadá al ingresar a la escuela, 1 de cada 4 niños muestra déficits y retrasos en los resultados de desarrollo, como las habilidades motoras, la salud socioemocional, entre otras (Madigan et al., 2019). Tercero, la prevalencia del sobrepeso y la obesidad entre los niños y los jóvenes es un problema de salud mundial (Lopes et al., 2022). Al respecto, los investigadores señalan que un alto porcentaje de masa corporal en niños tiene un efecto negativo en la competencia motora (Banjevic et al., 2022). Cuarto, las habilidades lectoras son la base del rendimiento académico (Sutapa et al., 2024). Según los estudios de Batez et al. (2021) y Macdonald et al. (2018), se ha confirmado que el rendimiento académico está asociado a la competencia motora. Los resultados del estudio de Kujawa et al. (2023) han demostrado mediante imágenes de resonancia magnética que la actividad física y la lectura activan las mismas regiones cerebrales. De ahí la existencia de una asociación entre la competencia motora y la lectura (Macdonald et al., 2018, 2020). Quinto, el retraso del crecimiento en la niñez representa uno de los obstáculos más impactantes para el desarrollo humano, lo que ha propiciado algunas consecuencias como la disminución del desarrollo cognitivo, el motor y el lenguaje (Organización Mundial de la Salud, 2014). Según Sania et al. (2019), los niños con déficit de desarrollo pierden un 19.8 % de sus ingresos en la edad adulta, con un costo global estimado

de US\$177 mil millones solo por retrasos en el crecimiento. Sexto, el nivel socioeconómico es una variable que potencialmente tiende a conducir disparidades en la competencia motora. Según los hallazgos encontrados por Gosselin et al. (2021), los niños que pertenecen a niveles socioeconómicos más desfavorecidos tienden a presentar una competencia motora más pobre frente a niños ubicados en un mejor nivel socioeconómico. Y séptimo, por lo general se ha demostrado que la competencia motora sigue una trayectoria de desarrollo (Allen et al., 2017); es decir, esta mejora a medida que aumenta la edad. De acuerdo con Salami et al. (2024), la edad se asocia positivamente con la competencia motora.

En la actualidad, el aprendizaje automático es una de las metodologías inteligentes que ha mostrado resultados prometedores en los dominios de la clasificación y la predicción (Bunker y Thabtah, 2019), que permite manejar grandes cantidades de variables de entrada (Bzdok et al., 2018). Según una revisión en Scopus, PubMed y Taylor y Francis, al momento de redactar el artículo no se encontró ninguno que haya evaluado la predicción de la competencia motora, solo se encontró algunos con relación al campo deportivo-recreativo para predecir las victorias/derrotas (Geurkink et al., 2021), el riesgo de lesiones (Rommers et al., 2020), el rendimiento físico (Bongiovanni et al., 2021), las apuestas (Bunker y Thabtah, 2019), las habilidades técnicas del fútbol (Duncan et al., 2024) y la participación en actividades recreativas (Lee y Kang, 2024). El modelo de aprendizaje automático que se utilizó en este estudio fue el árbol de clasificación (decisión), debido a que maneja bien las variables numéricas y categóricas (Silva et al., 2024). En la línea de este modelo se utilizó la metodología CRISP-DM (CRoss-Industry Standard Process for Data Mining). Esta metodología se describe en términos de un modelo de proceso jerárquico, consistente en conjuntos de tareas descritas en cuatro niveles de abstracción (fase, tarea genérica, tarea especializada e instancia de proceso) (Chapman et al., 2000). CRISP-DM desglosa el ciclo de vida de un proyecto de minería de datos en seis fases: comprensión del negocio, comprensión de datos, preparación de datos, modelado, evaluación y despliegue (Sharma et al., 2000). Según Schröer et al. (2021), la metodología CRISP-DM, en su mayoría de casos, es utilizada en el ámbito de la salud y la educación.

Desde el panorama descrito, el presente estudio tuvo como objetivo explorar las principales variables que predicen la competencia motora según el análisis con árboles de clasificación, de manera que la competencia motora se trabaje adecuadamente en los colegios de educación primaria.

Método

Participantes

Este estudio transversal predictivo involucró a 291 niños peruanos ($M=8.35$; $DE=1.29$; niños 51.2 %; niñas 48.8 %) de cuatro colegios (3 públicos y 1 privado) de educación primaria pertenecientes a las regiones naturales de la costa, la sierra y la selva. Todos ellos presentaban un desarrollo normal y una asistencia regular al colegio. El tipo de muestreo utilizado fue no probabilístico por conveniencia, dada la disposición de la institución y de los padres de familia. Se contó con la aprobación del Comité de Ética de la Facultad de Medicina de la Universidad Nacional Mayor de San Marcos (N.º 0068-2022). Al tratarse de menores de edad, todos los niños participantes contaban con la autorización expresa (firmada) de sus padres/tutores y dieron su asentimiento verbal para formar parte de la experiencia.

Instrumentos y procedimiento

Para evaluar la competencia motora se utilizó el test de desarrollo motor grueso, tercera edición, de versión peruana (Mamani-Ramos et al., 2023). Para las mediciones de masa corporal y estatura se utilizó la estación de pesaje y medición de transmisión inalámbrica con línea de Frankfurt Seca 284 (bascula división 50g; tallímetro división 1mm). Para calcular el índice de masa corporal para la edad se tomó en cuenta el software AnthroPlus de la Organización Mundial de la Salud (WHO, 2023). Para evaluar el desempeño escolar se utilizó una prueba que incluyó lectura y matemática por edades. La prueba fue elaborada por dos expertas que laboraban en el Ministerio de Educación. Esta prueba presentó una validez de contenido (adecuación y pertinencia de los ítems a los factores, claridad de lenguaje y relevancia) con valores adecuados (Validez de Kappa de Fleiss = 0.94), donde participaron para ello 5 jueces expertos con más de 10 años experiencia en formación de educación primaria. Finalmente, para conocer la edad, el sexo, el medio natural, las horas de uso de dispositivos con pantalla al día, las horas de práctica

de actividad física al día, la satisfacción por el juego motor y el nivel socioeconómico se aplicó un cuestionario sociodemográfico.

Los instrumentos fueron aplicados entre marzo y septiembre de 2023. La aplicación del TGMD-3, las mediciones de masa corporal y estatura, y la aplicación de la prueba de desempeño escolar (lectura y matemática) se realizaron en las clases de Educación Física con la presencia de los profesores. El cuestionario sociodemográfico fue completado por los padres/tutores en sus hogares. La sistematización y procesamiento de la información fue desarrollado en el laboratorio de los investigadores.

La variable dependiente y las variables predictoras descritas líneas arriba fueron de tipo categórico y numérico (Tabla 1).

El análisis de datos se desarrolló en base a la metodología CRISP-DM (Chapman et al., 2000; Firdaus et al., 2023; Schröer et al., 2021; Sharma et al., 2000; Wirth & Hipp, 2000) mediante el software R y las librerías dplyr, tidyr, ggplot2, ggpubr, tree, ISLR, randomForest, caret y magrittr. Las fases de la metodología CRISP-DM se desarrollaron como a continuación se detalla.

1. Comprensión del negocio

Esta fase consistió en determinar el problema o la consulta por resolver. En esa línea, el objetivo del estudio fue explorar las principales variables que predicen la competencia motora según el análisis con árboles de clasificación, de manera que la competencia motora sea trabajada adecuadamente en los colegios de educación primaria.

2. Comprensión de los datos

Esta fase consistió en analizar y describir los datos con el fin de responder al problema o a la consulta por resolver. Este conjunto de datos consideró 13 atributos para el análisis predictivo de la competencia motora, los mismos que fueron de tipo categórico y numérico (Tabla 1). Los atributos presentan cuatro características principales. La primera responde a las características corporales, como la masa corporal, la estatura y el índice de masa corporal para la edad. La segunda está relacionada con el desempeño escolar, enfatizando la lectura y la matemática. La tercera está asociada a las referencias personales y de la familia, como la edad, el sexo, el medio natural y el nivel socioeconómico. Y la cuarta, está relacionada al uso y disfrute del tiempo dentro y fuera de las escuelas, como las horas de uso de dispositivos con pantalla al día, las horas de práctica de actividad física al día y la satisfacción por el juego motor. Más características de los datos se precisa en el subapartado de participantes.

Tabla 1. Características de las variables estudiadas

Variables	Categorías	Tipo
Dependiente		
Competencia motora	Retraso, al límite del retraso, por debajo del promedio, promedio, por encima del promedio, superior y avanzado.	Categórico
Predictoras		
Masa corporal	Kilogramos	Númérico
Estatura	Centímetros	Númérico
Índice de masa corporal	Delgadez severa, delgadez, normal, sobrepeso y obesidad	Categórico
Desempeño escolar	Vigesimal	Númérico
Lectura	Vigesimal	Númérico
Matemática	Vigesimal	Númérico
Edad	Años cumplidos	Númérico
Sexo	Hombre y mujer	Categórico
Medio natural	Costa, sierra y selva	Categórico
Nivel socioeconómico	E, D, C, B y A	Categórico
Horas de uso de dispositivos con pantalla al día	Número de horas	Númérico
Horas de práctica de actividad física al día	Número de horas	Númérico
Satisfacción por el juego motor	No, a veces y sí	Categórico

3. Preparación de los datos

Esta fase comprendió la limpieza (detección de datos ausentes mediante la función "ColSums(is.na(datos))" e identificación de datos atípicos de las variables cuantitativas a través de diagramas de caja), la transformación (escalamiento de los resultados cuantitativos mediante la función "scale" debido a que

se contó con diferentes unidades de medida) y el balanceo (balanceado de datos mediante el algoritmo de balanceo) de datos, lo que ha permitido que la base de datos estuviera libre de errores y lista para su uso.

4. Modelado

Esta fase consistió en construir el modelo. Para ello, primero, se dividieron los datos en dos partes, una parte fue designada para el entrenamiento del modelo (tomando 80% de los datos) y la otra para la evaluación del modelo (tomando 20% de los datos). Segundo, se estableció la importancia de las variables de predicción utilizando el algoritmo “Random Forest”, considerando el punto de corte en 7.0 (Donges, 2024). Tercero, se realizaron las predicciones iniciales del modelo mediante los “Árboles Tree”. Y cuarto, se optimizó el modelo utilizando la función “prune.missclas()”, con lo cual se obtuvo el árbol de predicción final. Este procedimiento se enmarca en el algoritmo aprendizaje automático.

5. Evaluación

Esta fase consistió en valorar la capacidad predictiva del modelo mediante la “matriz de confusión” que conllevó al cálculo de porcentaje de precisión del modelo. La exactitud del modelo se calculó mediante la métrica “Accuracy”.

6. Despliegue

Esta fase consistió en reportar el informe final de los resultados, donde se dan a conocer nuevos hallazgos sobre las principales variables que predicen el comportamiento de la competencia motora.

Resultados

Los resultados descriptivos tanto de la variable dependiente como de las variables predictoras se presentaron como sigue: respecto de la competencia motora, más de la mitad de los niños participantes se encontraron en el nivel promedio (64.9 %), seguido por los niveles por debajo del promedio (17.53 %), por encima del promedio (9.28 %), al límite del retraso (5.15 %) y retraso (3.09 %), respectivamente. Con relación a las variables predictoras, se reportó, por un lado, una masa corporal $M=32.36\pm9.14$ kilogramos; una estatura $M=130.6\pm9.57$ centímetros; un puntaje de lectura $M=13.26\pm4.41$, matemática $M=13.91\pm4.45$ y DE $M=13.08\pm4.64$ en el sistema vigesimal; una edad $M=8.35\pm1.29$ años; un uso de dispositivos con pantalla al día $M=1.66\pm1.31$ horas; y una práctica de actividad física al día $M=1.45\pm1.06$ horas en los niños participantes. Por otro lado, primero, un poco más de la mitad de los niños reportaron un índice de masa corporal para la edad normal (50.52 %), seguido de sobrepeso (23.02 %), obesidad (22.34 %), delgadez (3.78 %) y delgadez severa (0.34 %). Segundo, la participación de los hombres (51.20 %) fue mayor por una mínima diferencia frente a las mujeres (48.80 %). Tercero, la mayor cantidad de niños participantes fueron de la costa (43.99 %), seguido por los de la sierra (29.21 %) y la selva (26.80 %), respectivamente. Cuarto, casi la mitad de los niños participantes pertenecían al nivel socioeconómico E (46.05 %), seguido de los niveles D (26.46 %), B (14.78 %), C (9.97 %) y A (2.75 %), respectivamente. Y quinto, al jugar gran parte de los niños mostraban satisfacción (85.22 %), algunos a veces (13.40 %) y pocos no (1.37 %).

En la información descrita líneas arriba no se encontraron datos ausentes en ninguna de las variables, tampoco se encontraron datos atípicos (ningún dato excedió el 3.0 veces por encima o por debajo del rango intercuartílico). Las variables predictoras de tipo numérico (masa corporal, estatura, lectura, matemática, desempeño escolar, edad, horas de uso de dispositivos con pantalla al día y horas de práctica de actividad física al día) fueron transformadas en una unidad de medida escalada (entre 0 y 1) con el fin de controlar el efecto diferenciado de las unidades de medida. La variable competencia motora tras el balanceo todas sus categorías alcanzaron 58 registros, excepto una que alcanzó 59.

El modelo de predicción de la competencia motora se halló con 233 datos (80 %) para el entrenamiento y 58 datos (20 %) para la evaluación de este. La importancia de las variables predictoras se determinó mediante el algoritmo Random Forest utilizando 500 árboles con tres variables de partición y con un error OBB (error obtenido al clasificar las observaciones que no fueron incluidas en el conjunto de datos de entrenamiento Bootstrap) de 39.22 % y una precisión de 68.78 % (Tabla 2). Como el punto de corte fue 7.0 para señalar las variables predictoras más importantes, las variables medio natural, índice de


masa corporal, sexo y satisfacción por el juego motor resultaron como no relevantes. Así, quedaron para la predicción nueve variables.

Tabla 2. Importancia de las variables predictoras

Posición	Variable	Importancia
1	Masa corporal	16.70989
2	Estatura	16.74581
3	Lectura	11.52047
4	Matemática	13.56722
5	Desempeño escolar	11.46375
6	Nivel socioeconómico	9.44529
7	Horas de uso de dispositivos con pantalla al día	8.68389
8	Horas de práctica de actividad física al día	8.55312
9	Edad	7.32234
10	Medio natural	6.88470
11	Índice de masa corporal	5.59256
12	Sexo	3.43009
13	Satisfacción por el juego motor	3.41538

Los resultados de predicción desarrollado mediante árboles Tree presentaron un modelo inicial y un modelo optimizado. El modelo inicial presentó 22 nodos terminales con el 65.52 % de precisión y el 34.48 % de error. La variable predictora más influyente sobre la competencia motora en este modelo fue las horas de práctica de actividad física al día (Figura 1). Debido al gran volumen de nodos, se observó un sobre ajuste en el comportamiento de las variables predictoras, lo que podría conducir a una incorrecta identificación de los nodos y a aumentar el error de predicción del modelo. Por tal razón, se desarrolló un modelo optimizado. Este último presentó 10 nodos terminales con el 68.34 % de precisión y el 31.66 % de error, pudiendo alcanzar el modelo una precisión de 72.34 %. En este modelo la variable predictora más influyente sobre la competencia motora también fue las horas de práctica de actividad física al día (Figura 2), seguido de las horas de uso de dispositivos con pantalla al día y la masa corporal. Las variables menos importantes para explicar la variabilidad de la competencia motora fueron la lectura, la estatura, el nivel socioeconómico y la edad.


Figura 1. Árbol de predicción Tree de la competencia motora modelo inicial.



Abreviaturas: HAFD = Horas de práctica de actividad física al día; HDCD = Horas de uso de dispositivos con pantalla al día; MC = Masa corporal; ED = Edad; MAT = Matemática; LEC = Lectura; NS = Nivel socioeconómico; EST = Estatura; Pr = Promedio; LRe = Al límite del retraso; Re = Retraso; DPr = Por debajo del promedio; EPr = Por encima del promedio.

Según el modelo optimizado, primero, los niños que presentan una competencia motora en retraso, por un lado, son niños que practican menos de 1.5 horas de actividad física al día, utilizan menos de 1.5 horas los dispositivos con pantalla al día, tienen una masa corporal mayor a 34.875 kilogramos y tienen una edad menor a 8.5 años. Por otro lado, son niños que practican menos de 1.5 horas de actividad física al día, utilizan más de 1.5 horas los dispositivos con pantalla al día, tienen un puntaje menor a 17.5 en lectura y pertenecen a los niveles socioeconómicos B, D y E. Por último, son niños que practican menos de 1.5 horas de actividad física al día, utilizan más de 1.5 horas los dispositivos con pantalla al día, tienen un puntaje mayor al 17.5 en lectura.

Figura 2. Árbol de predicción Tree de la competencia motora modelo optimizado.



Abreviaturas: HAFD = Horas de práctica de actividad física al día; HDCD = Horas de uso de dispositivos con pantalla al día, MC = Masa corporal; ED = Edad; MAT = Matemática; LEC = Lectura; NS = Nivel socioeconómico; EST = Estatura; Pr = Promedio; LRe = Al límite del retraso; Re = Retraso; DPr = Por debajo del promedio; EPr = Por encima del promedio.

Segundo, los niños que presentan una competencia motora al límite del retraso, por un lado, son niños que practican menos de 1.5 horas de actividad física al día, utilizan menos de 1.5 horas los dispositivos con pantalla al día, tienen una masa corporal menor a 34.875 kilogramos y tienen una edad mayor a 6.5 años. Por otro lado, son niños que practican más de 1.5 horas de actividad física al día y tienen una masa corporal menor a 20.75 kilogramos. Tercero, los niños que presentan una competencia motora por debajo del promedio, por un lado, son niños que practican menos de 1.5 horas de actividad física al día, utilizan más de 1.5 horas los dispositivos con pantalla al día, tienen un puntaje menor al 17.5 en lectura y pertenecen a los niveles socioeconómicos A y C. Por otro lado, son niños que practican más de 1.5 horas de actividad física al día, tienen una masa corporal mayor a 20.75 kilogramos y tienen una estatura mayor a 140.05 centímetros. Cuarto, los niños que presentan una competencia motora promedio, por un lado, son niños que practican menos de 1.5 horas de actividad física al día, utilizan menos de 1.5 horas los dispositivos con pantalla al día, tienen una masa corporal menor a 34.875 kilogramos y tienen una edad menor a 6.5 años. Por otro lado, son niños que practican menos de 1.5 horas de actividad física al día, utilizan menos de 1.5 horas los dispositivos con pantalla al día, tienen una masa corporal mayor a 34.875 kilogramos y tienen una edad mayor a 8.5 años. Y quinto, los niños que presentan una competencia motora por encima del promedio, son niños que practican más de 1.5 horas de actividad física al día, tienen una masa corporal mayor a 20.75 kilogramos y tienen una estatura menor a 140.05 centímetros.

Discusión

Este es el primer estudio que aplica el aprendizaje automático mediante el modelo árbol de clasificación en base a la metodología CRISP-DM para explorar las principales variables que predicen la competencia motora en niños de 6 a 10 años. Este estudio identifica variables de impacto importantes como la masa corporal, la estatura, la lectura, el nivel socioeconómico, las horas de uso de dispositivos con pantalla al día, las horas de práctica de actividad física al día y la edad, para predecir la competencia motora. Las horas de práctica de actividad física al día fue la variable más influyente para predecir la competencia motora. Los árboles Tree lograron una precisión del 68.34 % con las horas de práctica de actividad física al día, las horas de uso de dispositivos con pantalla al día, la masa corporal, la lectura, la estatura, el nivel socioeconómico y la edad como predictores. Desde un análisis más exhaustivo y teniendo como criterio principal una influencia más directa en la variabilidad de la competencia motora, se identificó a las horas

de práctica de actividad física al día, las horas de uso de dispositivos con pantalla al día y la masa corporal como las variables más influyentes. En ese sentido, procederemos a sustentar y discutir la influencia de estas tres variables.

Primero, el impacto de influencia de las horas de práctica de actividad física al día en la variabilidad de la competencia motora se sustenta en el modelo conceptual de desarrollo de Stodden et al. (2008). Este modelo explica que en la medida en que los niños participen más en actividades físicas en la infancia podrán obtener un mejor nivel de competencia motora; por consiguiente, reforzarán el compromiso de participar con mayor interés en actividades físicas durante toda la vida para mantenerse saludables. Contrastando con los resultados obtenidos, el nodo terminal, que expresó una competencia motora por encima del promedio, involucró a niños que practican más de 1.5 horas de actividad física al día. Por el contrario, los nodos terminales que expresaron una competencia motora promedio, por debajo del promedio, al límite del retraso y en retraso, casi en su totalidad involucraron a niños que practican menos de 1.5 horas de actividad física al día. Estos resultados corroboran la lógica del modelo conceptual de desarrollo de Stodden et al. (2008). En respuesta a esta lógica Barnett et al. (2023), Costa et al. (2024) y Godoy-Cumillaf et al. (2024) implementaron programas de actividad física en las escuelas con el fin de obtener mejoras en la competencia motora de los niños. Los resultados de estos estudios reportaron mejoras significativas en la competencia motora. En la misma línea, Moon et al. (2024) en su estudio de revisión han corroborado el impacto beneficioso de la intervenciones de la actividad física en la mejora de la competencia motora en niños. Dada la importancia de la actividad física sobre la variabilidad de la competencia motora, en los Estados Unidos, los Centros para el Control y la Prevención de Enfermedades, con el fin de incrementar los niveles de actividad física, implementaron el programa integral de actividad física escolar. Este programa consideró cinco componentes: (1) Educación Física de calidad, (2) actividad física durante la escuela, (3) actividad física antes y después de la escuela, (4) participación del personal y (5) participación familiar y comunitaria (Centers for Disease Control and Prevention, 2019). En el Perú, a partir del año 2022, el Gobierno, mediante el Ministerio de Educación, ha establecido la práctica de 10 minutos de actividad física diaria, de forma obligatoria en las escuelas y de forma opcional en los centros laborales a nivel nacional, de acuerdo con la Política Nacional de la Actividad Física, Recreación, Deporte y Educación Física (Ministerio de Educación de Perú, 2022). Indiscutiblemente, la actividad física al brindar una experiencia de movimiento promueve que los patrones de movimiento incorporen otros y perfeccionen los ya existentes.

Segundo, con relación al impacto de influencia de las horas de uso de dispositivos con pantalla al día en la variabilidad de la competencia motora, dos de los tres nodos terminales que expresaron una competencia motora en retraso y el nodo que expresó una competencia motora por debajo del promedio involucraron a niños que utilizan más de 1.5 horas los dispositivos con pantalla al día, que a su vez practican menos de 1.5 horas de actividad física al día. Estos resultados corroboran los hallazgos encontrados por Madigan et al. (2019), quienes encontraron una asociación direccional entre el tiempo frente a la pantalla y el desarrollo infantil, dentro de ello la competencia motora. De acuerdo con Hill et al. (2016), y Hosokawa y Katsura (2018), el tiempo sin control frente a la pantalla interfiere con las oportunidades importantes para practicar y dominar habilidades motoras, interpersonales y de comunicación. Common Sense Media (2017) señala que, a partir del 2017, el 98 % de niños estadounidenses menores de 0-8 años viven en un hogar con un dispositivo conectado a Internet y, en promedio, pasan más de dos horas al día frente a las pantallas. En la línea de González-Sanmamed et al. (2023) y Kelly et al. (2018), los dispositivos con pantalla (teléfonos inteligentes y tabletas digitales) son ahora omnipresentes en las vidas de los niños, lo que ha dado lugar a un estilo de vida sedentario que viene limitando la realización actividades de juego al aire libre.

Tercero, respecto del impacto de influencia de la masa corporal en la variabilidad de la competencia motora, los nodos terminales relacionados a una masa corporal >34.875 kilogramos que expresaron una competencia motora en retraso y en promedio involucraron a niños con tendencia a sobrepeso y obesidad. Los nodos terminales relacionados a una masa corporal <34.875 kilogramos que expresaron una competencia motora en promedio y al límite del retraso involucraron a niños con tendencia a sobrepeso. El nodo terminal relacionado con una masa corporal <20.75 kilogramos, que expresó una competencia motora al límite del retraso, involucró a niños con tendencia a delgadez. Finalmente, el nodo terminal relacionado con una masa corporal >20.75 kilogramos, que expresó una competencia motora por encima del promedio, involucró a niños con peso normal. Estos resultados van en la línea de Lopes et al. (2022), quienes afirman que los niños con sobrepeso y obesidad tienden a presentar niveles inferiores



de competencia motora. Al respecto, Banjevic et al. (2022) manifiestan que un alto porcentaje de masa corporal y la obesidad infantil tienen un efecto negativo en la competencia motora. Los mismos autores expresan que los niños con sobrepeso tienden a evitar las actividades físicas, lo que estaría provocando una disminución de la competencia motora.

En general, los resultados de este estudio evidenciaron cuatro aspectos fundamentales: (1) que cuanto mayor tiempo se dedique a la participación en actividades físicas en la infancia se obtendrán niveles más altos de competencia motora o viceversa, (2) que el uso excesivo de los dispositivos con pantalla generarán niveles más bajos de competencia motora, (3) que la masa corporal adecuada para la edad ofrecerá niveles más altos de competencia motora o viceversa y (4) no perder de vista el impacto de influencia de la lectura, la estatura, el nivel socioeconómico y la edad sobre la competencia motora.

Los resultados presentados representan una contribución importante para profesores de Educación Física, investigadores, profesionales de salud y otros interesados en el tema, por lo siguiente: se les brinda un panorama general del comportamiento de la competencia motora y se les da a conocer las principales variables que vienen influyendo en el comportamiento de esta con orden de importancia en niños del contexto peruano. A partir de estos resultados podrán establecer directrices, por un lado, para fortalecer las variables que vienen favoreciendo en lograr una competencia motora apropiada para la edad con tendencia a desarrollarla más. Por otro, para reconducir o hacer frente a las variables que vienen impidiendo lograr una competencia motora apropiada para la edad.

Este estudio presenta limitaciones. No hubo proporcionalidad entre la distribución de los colegios públicos y privados para la muestra por falta de disposición de los colegios, por lo tanto, los resultados deberían manejarse con cautela. En ese sentido, los estudios futuros sobre este tema deben considerar muestras más grandes e incluir submuestras proporcionalmente. Otra limitación es que no se consideró a niños de preescolar de tres a cinco años, por lo que, las conclusiones a las cuales se arribó aquí no deben inferirse para niños de preescolar.

Conclusiones

Este estudio confirma que el aprendizaje automático mediante el modelo árbol de clasificación en base a la metodología CRISP-DM puede predecir la competencia motora en niños de 6 a 10 años con una precisión del 68.34 %, siendo las horas de práctica de actividad física al día la variable más importante, además de las horas de uso de dispositivos con pantalla al día y la masa de siete variables. Sería muy interesante que en futuros estudios se incluyeran otras variables predictoras, de manera que se pueda tener una visión más amplia a la hora de elaborar y desarrollar los programas de Educación Física en educación primaria con el fin de lograr en más de la mitad de población infantil escolar una competencia motora por encima del promedio a más.

Referencias

- Allen, K. A., Bredero, B., Van, T., Ulrich, D. A., & Simons, J. (2017). Test of Gross Motor Development-3 (TGMD-3) with the Use of Visual Supports for Children with Autism Spectrum Disorder: Validity and Reliability. *Journal of Autism and Developmental Disorders*, 47(3), 813-833. <https://doi.org/10.1007/s10803-016-3005-0>
- Aoyama, T., Hikihara, Y., Watanabe, M., Wakabayashi, H., Hanawa, S., Omi, N., Takimoto, H., & Tanaka, S. (2022). Association between age of achieving gross motor development milestones during infancy and body fat percentage at 6 to 7 years of age. *Maternal and Child Health Journal*, 26(2), 415-423. <https://doi.org/10.1007/s10995-021-03238-9>
- Banjevic, B., Aleksic, D., Aleksic Veljkovic, A., Katanic, B., & Masanovic, B. (2022). Differences between Healthy-Weight and Overweight Serbian Preschool Children in Motor and Cognitive Abilities. *International Journal of Environmental Research and Public Health*, 19(18), 11325. <https://doi.org/10.3390/ijerph191811325>
- Barnett, L. M., Jerebine, A., Keegan, R., Watson-Mackie, K., Arundell, L., Ridgers, N. D., Salmon, J., & Dudley, D. (2023). Validity, Reliability, and Feasibility of Physical Literacy Assessments Designed for



- School Children: A Systematic Review. *Sports Medicine*, 53(10), 1905–1929. <https://doi.org/10.1007/s40279-023-01867-4>
- Batez, M., Milošević, Ž., Mikulić, I., Sporiš, G., MačAk, D., & Trajković, N. (2021). Relationship between motor competence, physical fitness, and academic achievement in young school-aged children. *BioMed Research International*, 2021, 6631365. <https://doi.org/10.1155/2021/6631365>
- Bautista, A., Moreno-Núñez, A., Vijayakumar, P., Quek, E., & Bull, R. (2020). Gross motor teaching in preschool education: where, what and how do Singapore educators teach? *Journal for the Study of Education and Development*, 43(2), 443–482. <https://doi.org/10.1080/02103702.2019.1653057>
- Behan, S., Belton, S., Peers, C., O'Connor, N. E., & Issartel, J. (2019). Moving Well-Being Well: Investigating the maturation of fundamental movement skill proficiency across sex in Irish children aged five to twelve. *Journal of Sports Sciences*, 37(22), 2604–2612. <https://doi.org/10.1080/02640414.2019.1651144>
- Bongiovanni, T., Trecroci, A., Cavaggioni, L., Rossi, A., Perri, E., Pasta, G., Iaia, F. M., & Alberti, G. (2021). Importance of anthropometric features to predict physical performance in elite youth soccer: a machine learning approach. *Research in Sports Medicine*, 29(3), 213–224. <https://doi.org/10.1080/15438627.2020.1809410>
- Brian, A., Bardid, F., Barnett, L. M., Deconinck, F. J. A., Lenoir, M., & Goodway, J. D. (2018). Actual and Perceived Motor Competence Levels of Belgian and United States Preschool Children. *Journal of Motor Learning and Development*, 6(s2), S320–S336. <https://doi.org/10.1123/jmld.2016-0071>
- Bunker, R. P., & Thabtah, F. (2019). A machine learning framework for sport result prediction. *Applied Computing and Informatics*, 15(1), 27–33. <https://doi.org/10.1016/j.aci.2017.09.005>
- Bzdok, D., Altman, N., & Krzywinski, M. (2018). Statistics versus machine learning. *Nature Methods*, 15(4), 233–234. <https://doi.org/10.1038/nmeth.4642>
- Centers for Disease Control and Prevention. (2019). *Increasing Physical Education and Physical Activity: A Framework for Schools* 2019. https://www.cdc.gov/healthyschools/physicalactivity/pdf/2019_04_25_PE-PA-Framework_508tagged.pdf
- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). *CRISP-DM 1.0 Step-by-step data mining guide*. SPSS Inc.
- Common Sense Media. (2017). *The Common Sense Census: Media Use by Kids Age Zero to Eight, 2017*. <https://www.commonsensemedia.org/research/the-common-sense-census-media-use-by-kids-age-zero-to-eight-2017>
- Costa, J. A., Vale, S., Cordovil, R., Rodrigues, L. P., Cardoso, V., Proença, R., Costa, M., Neto, C., Brito, J., Guilherme, J., & Seabra, A. (2024). A school-based physical activity intervention in primary school: effects on physical activity, sleep, aerobic fitness, and motor competence. *Frontiers in Public Health*, 12(February), 1–10. <https://doi.org/10.3389/fpubh.2024.1365782>
- Donges, N. (2024). *Random Forest: A Complete Guide for Machine Learning. All you need to know about the random forest model in machine learning*. Built In. <https://builtin.com/data-science/random-forest-algorithm>
- Duncan, M. J., Eyre, E. L. J., Clarke, N., Hamid, A., & Jing, Y. (2024). Importance of fundamental movement skills to predict technical skills in youth grassroots soccer: A machine learning approach. *International Journal of Sports Science & Coaching*, 19(3), 1042–1049. <https://doi.org/10.1177/17479541231202015>
- Duncan, M. J., Martins, C., Ribeiro Bandeira, P. F., Issartel, J., Peers, C., Belton, S., O'Connor, N. E., & Behan, S. (2022). TGMD-3 short version: Evidence of validity and associations with sex in Irish children. *Journal of Sports Sciences*, 40(2), 138–145. <https://doi.org/10.1080/02640414.2021.1978161>
- Duncan, M. J., Roscoe, C. M., Noon, M., Clark, C. C., O'Brien, W., & Eyre, E. L. (2019). Run, jump, throw and catch: How proficient are children attending English schools at the fundamental motor skills identified as key within the school curriculum? *European Physical Education Review*, 26(4), 814–826. <https://doi.org/10.1177/1356336X19888953>
- Firdaus, M., Izzah, A. N., Kairan, O., Sofea, N. N., Naim, N., & Maisarah, N. (2023). The prediction of student's academic performance using RapidMiner. *Indonesian Journal of Electrical Engineering and Computer Science*, 32(1), 363–371. <https://doi.org/10.11591/ijeecs.v32.i1.pp363-371>



- Gao, Z., Wen, X., Fu, Y., Lee, J. E., & Zeng, N. (2021). Motor skill competence matters in promoting physical activity and health. *BioMed Research International*, 2021, 9786368. <https://doi.org/10.1155/2021/9786368>
- Geurkink, Y., Boone, J., Verstockett, S., & Bourgois, J. G. (2021). Machine Learning-Based Identification of the Strongest Predictive Variables of Winning and Losing in Belgian Professional Soccer. *Applied Sciences*, 11(5), 2378. <https://doi.org/10.3390/app11052378>
- Godoy-Cumillaf, A., Fuentes-Merino, P., Giakoni-Ramírez, F., Duclos-Bastías, D., Bruneau-Chávez, J., & Merellano-Navarro, E. (2024). The Effects of a Physical Activity Intervention on Adiposity, Physical Fitness and Motor Competence: A School-Based, Non-Randomized Controlled Trial. *Children*, 11(1), 137. <https://doi.org/10.3390/children11010137>
- González-Sanmamed, M., Losada-Puente, L., Rebollo-Quintela, N., & Rodríguez-Machado, E. (2023). Uso de los dispositivos móviles en la infancia: Oportunidades y peligros. *Psychology, Society & Education*, 15(3), 1–9. <https://doi.org/10.21071/pse.v15i3.16103>
- Gosselin, V., Leone, M., & Laberge, S. (2021). Socioeconomic and gender-based disparities in the motor competence of school-age children. *Journal of Sports Sciences*, 39(3), 341–350. <https://doi.org/10.1080/02640414.2020.1822585>
- Griffiths, A., Toovey, R., Morgan, P. E., & Spittle, A. J. (2018). Psychometric properties of gross motor assessment tools for children: a systematic review. *BMJ Open*, 8(10), e021734. <https://doi.org/10.1136/bmjopen-2018-021734>
- Guthold, R., Stevens, G. A., Riley, L. M., & Bull, F. C. (2018). Worldwide trends in insufficient physical activity from 2001 to 2016: a pooled analysis of 358 population-based surveys with 1·9 million participants. *The Lancet Global Health*, 6(10), e1077–e1086. [https://doi.org/10.1016/S2214-109X\(18\)30357-7](https://doi.org/10.1016/S2214-109X(18)30357-7)
- Guthold, R., Stevens, G. A., Riley, L. M., & Bull, F. C. (2020). Global trends in insufficient physical activity among adolescents: a pooled analysis of 298 population-based surveys with 1·6 million participants. *The Lancet Child and Adolescent Health*, 4(1), 23–35. [https://doi.org/10.1016/S2352-4642\(19\)30323-2](https://doi.org/10.1016/S2352-4642(19)30323-2)
- Hill, D., Ameenuddin, N., Reid, Y., Cross, C., Hutchinson, J., Levine, A., Boyd, R., Mendelson, R., Moreno, M., & Swanson, W. S. (2016). Media and Young Minds. *Pediatrics*, 138(5), e20162591. <https://doi.org/10.1542/peds.2016-2591>
- Hosokawa, R., & Katsura, T. (2018). Association between mobile technology use and child adjustment in early elementary school age. *PLOS ONE*, 13(7), e0199959. <https://doi.org/10.1371/journal.pone.0199959>
- John, A., Wainwright, N., Goodway, J. D., & Williams, A. (2024). The Relationship between Physical Activity and Motor Competence of Foundation Phase Children in Wales during the School Day. *Children*, 11(6), 629. <https://doi.org/10.3390/children11060629>
- Kelly, L., Connor, S. O., Harrison, A. J., Chéilleachair, N. J. N., Kelly, L., Connor, S. O., Harrison, A. J., Chéilleachair, N. J. N., Kelly, L., & Connor, S. O. (2018). Does fundamental movement skill proficiency vary by sex , class group or weight status ? Evidence from an Irish primary school setting Does fundamental movement skill proficiency vary by sex , class group or weight status ? Evidence from an Irish primary . *Journal of Sports Sciences*, 00(00), 1–9. <https://doi.org/10.1080/02640414.2018.1543833>
- Kujawa, M. J., Marcinkowska, A. B., Grzywińska, M., Waśkow, M., Romanowski, A., Szurowska, E., Winklewski, P. J., & Szarmach, A. (2023). Physical activity and the brain myelin content in humans. *Frontiers in Cellular Neuroscience*, 17. <https://doi.org/10.3389/fncel.2023.1198657>
- Lee, S., & Kang, M. (2024). A Data-Driven Approach to Predicting Recreational Activity Participation Using Machine Learning. *Research Quarterly for Exercise and Sport*, 29(3), 1–13. <https://doi.org/10.1080/02701367.2024.2343815>
- Lopes, O., Malina, R., & Lopes, V. (2022). Variation in physical activity, fitness and motor competence according to weight status of 12-15 years youngsters from Cabo Verde. *Cuadernos de Psicología Del Deporte*, 22(2), 294–306. <https://doi.org/10.6018/cpd.458471>
- López, D. (2024). *Habilidades motrices fundamentales en niños de un colegio privado del distrito de San Juan de Lurigancho, Lima* [Tesis de licenciatura, Universidad Nacional Mayor de San Marcos]. <https://cybertesis.unmsm.edu.pe/item/ef8d4517-1ea0-4fd9-9b9d-7932b62b5362>
- Macdonald, K., Milne, N., Orr, R., & Pope, R. (2018). Relationships between Motor Proficiency and Academic Performance in Mathematics and Reading in School-Aged Children and Adolescents:



- A Systematic Review. *International Journal of Environmental Research and Public Health*, 15(8), 1603. <https://doi.org/10.3390/ijerph15081603>
- Macdonald, K., Milne, N., Orr, R., & Pope, R. (2020). Associations between motor proficiency and academic performance in mathematics and reading in year 1 school children: a cross-sectional study. *BMC Pediatrics*, 20(1), 69. <https://doi.org/10.1186/s12887-020-1967-8>
- Madigan, S., Browne, D., Racine, N., Mori, C., & Tough, S. (2019). Association Between Screen Time and Children's Performance on a Developmental Screening Test. *JAMA Pediatrics*, 173(3), 244–250. <https://doi.org/10.1001/jamapediatrics.2018.5056>
- Mamani-Ramos, A. A., Damian-Núñez, E. F., Torres-Cruz, F., Dextre-Mendoza, C. W., Alcarraz-Curi, M., Quisocala-Ramos, J. A., Mamani-Cari, Y. A., Roncal-Serpa, F. R., Quispe-Cruz, H., Paucar-Pancca, A., & Montoya-Castillo, P. M. (2023). Propiedades psicométricas de la versión peruana del Test de Desarrollo Motor Grueso – Tercera Edición. *Retos*, 50, 1180–1187. <https://doi.org/10.47197/retos.v50.100031>
- Mamani-Ramos, A. A., Damian-Núñez, E. F., Yabar-Geldres, I. A., Quisocala-Ramos, J. A., Zavala-Bustios, R., Soria-Villanueva, L. M., Soto-Zedano, F. A., Diaz-Barboza, M. A., Vivar-Cueva, J. A., Quispe-Cruz, H., Sardón-Ari, D. L., Tapia-Centellas, Y. Y., Cutimbo-Quispe, C. V., & Rodríguez-Mamani, J. R. (2024). Correlaciones entre la competencia motora con el medio natural, la actividad física, y la satisfacción por el juego motor en niños peruanos. *Retos*, 60, 695–703. <https://doi.org/10.47197/retos.v60.108272>
- Mamani-Ramos, A. A., Dextre-Mendoza, C. W., Lava, J. J., Ticona, G., Quispe, L. M., Torres-Cruz, F., Quisocala, J. A., & Fuentes-López, J. D. (2020). Gross motor development in preschoolers on the islands of Lake Titicaca (3810 m.a.s.l.), Puno, Peru (Desarrollo motor grueso en preescolares de las islas del lago Titicaca (3810 m s. n. m.), Puno, Perú). *Retos*, 39(39), 592–597. <https://doi.org/10.47197/retos.v0i39.79522>
- Ministerio de Educación de Perú. (2022). *Decreto Supremo N° 014-2022-Minedu*. El Peruano. <https://www.gob.pe/institucion/minedu/normas-legales/3490243-014-2022-minedu-parte-1>
- Montoya, P. M. (2023). *Desarrollo motor grueso y nivel socioeconómico en niños de dos instituciones de educación primaria de Lima, Perú* [Tesis de licenciatura, Universidad Nacional Mayor de San Marcos]. <https://hdl.handle.net/20.500.12672/20405>
- Moon, J., Webster, C. A., Stodden, D. F., Brian, A., Mulvey, K. L., Beets, M., Egan, C. A., McIntosh, L. I. F., Merica, C. B., & Russ, L. (2024). Systematic review and meta-analysis of physical activity interventions to increase elementary children's motor competence: a comprehensive school physical activity program perspective. *BMC Public Health*, 24(1), 826. <https://doi.org/10.1186/s12889-024-18145-1>
- Nobre, G. C., Valentini, N. C., & Nobre, F. S. S. (2018). Fundamental motor skills, nutritional status, perceived competence, and school performance of Brazilian children in social vulnerability: Gender comparison. *Child Abuse & Neglect*, 80, 335–345. <https://doi.org/10.1016/j.chiabu.2018.04.007>
- Organización Mundial de la Salud. (2014). Metas mundiales de nutrición 2025 Documento normativo sobre retraso del crecimiento. *WHO*, 9, 1–12.
- Philpott, C., Donovan, B., Belton, S., Lester, D., Duncan, M., Chambers, F., & O'Brien, W. (2020). Investigating the Age-Related Association between Perceived Motor Competence and Actual Motor Competence in Adolescence. *International Journal of Environmental Research and Public Health*, 17(17), 6361. <https://doi.org/10.3390/ijerph17176361>
- Reyes, E. (2023). *Desarrollo motor grueso y estado nutricional en niños de educación primaria de una institución pública del distrito de San Martín de Porres, Lima* [Tesis de licenciatura, Universidad Nacional Mayor de San Marcos]. <https://cybertesis.unmsm.edu.pe/handle/20.500.12672/20780>
- Rodríguez-Briceño, D., Castro-Vilugrón, F., Díaz-Alvarado, M., & Carcamo-Oyarzun, J. (2022). La competencia motriz en estudiantes chilenos de 3° y 4° de educación básica. Aprendizajes esperados versus realidad. *Retos*, 45, 515–524. <https://doi.org/10.47197/RETOS.V44I0.91095>
- Rommers, N., Rössler, R., Verhagen, E., Vandecasteele, F., Verstockt, S., Vaeyens, R., Lenoir, M., D'Hondt, E., & Witvrouw, E. (2020). A Machine Learning Approach to Assess Injury Risk in Elite Youth Football Players. *Medicine & Science in Sports & Exercise*, 52(8), 1745–1751. <https://doi.org/10.1249/MSS.0000000000002305>



- Salami, S., Ribeiro, P. F., Rahymian, M., Shamsipour, P., Luz, L., de Lucena, C. M., Hardy, L. L., & Duncan, M. J. (2024). Associations between Biological Maturation, Chronological Age, Body Mass Index, Sex, and Motor Competence in Prepubertal Children: A Network Analysis. *Children*, 11(9), 1143. <https://doi.org/10.3390/children11091143>
- Sánchez, A. (2023). *Desarrollo motor grueso y desempeño escolar en niños de educación primaria de una institución particular del distrito de San Isidro, Lima* [Tesis de licenciatura, Universidad Nacional Mayor de San Marcos]. <https://cybertesis.unmsm.edu.pe/handle/20.500.12672/20404>
- Sania, A., Sudfeld, C. R., Danaei, G., Fink, G., McCoy, D. C., Zhu, Z., Fawzi, M. C. S., Akman, M., Arifeen, S. E., Barros, A. J. D., Bellinger, D., Black, M. M., Bogale, A., Braun, J. M., van den Broek, N., Carrara, V., Duazo, P., Duggan, C., Fernald, L. C. H., ... Fawzi, W. (2019). Early life risk factors of motor, cognitive and language development: a pooled analysis of studies from low/middle-income countries. *BMJ Open*, 9(10), e026449. <https://doi.org/10.1136/bmjopen-2018-026449>
- 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>
- Sharma, A., Cogley, A. C., & Tonon, S. S. (2000). The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing*, 5(4), 13–22. <https://acortar.link/1HUYE>
- Silva, J. C., Coelho, J., & Miguéis, V. L. (2024). Factors influencing the use of information and communication technologies by students for educational purposes. *Education and Information Technologies*, 29(8), 9313–9353. <https://doi.org/10.1007/s10639-023-12132-6>
- Stodden, D. F., Langendorfer, S. J., Goodway, J. D., Robertson, M. A., Rudisill, M. E., Garcia, C., & Garcia, L. E. (2008). A developmental perspective on the role of motor skill competence in physical activity: An emergent relationship. *Quest*, 60(2), 290–306. <https://doi.org/10.1080/00336297.2008.10483582>
- Sutapa, Y. G., Puspita, I. D., Amir, A., Haetami, M., Sinulingga, A., Ngurah, I. G. P., Syam, A., Dewintha, R., & Wijaya, C. (2024). Does being physically active and engaged affect reading ability? A review of the literature. *Retos*, 61, 598–605. <https://doi.org/10.47197/retos.v61.109559>
- Wirth, R., & Hipp, J. (2000). CRISP-DM: towards a standard process model for data mining. *Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining*, 29-39. *Proceedings of the Fourth International Conference on the Practical Application of Knowledge Discovery and Data Mining*, 24959, 29–39. https://www.researchgate.net/publication/239585378_CRISP-DM_Towards_a_standard_process_model_for_data_mining
- World Health Organization. (2023). *Growth reference data for 5-19 years*. WHO. <https://www.who.int/tools/growth-reference-data-for-5to19-years/application-tools>
- Zhang, D., Chen, S., Xin, F., Drenowatz, C., Hu, X., & Tang, Y. (2024). Associations between fundamental movement skills and accelerometer-measured physical activity in Chinese children: the mediating role of cardiorespiratory fitness. *PeerJ*, 12(6), e17564. <https://doi.org/10.7717/peerj.17564>

Datos de los/as autores/as y traductor/a:

Angel Anibal Mamani-Ramos	amamanir@unmsm.edu.pe	Autor/a
Edgar Froilan Damian-Núñez	edamiann@unmsm.edu.pe	Autor/a
Edgar Eloy Carpio-Vargas	ecarpio@unap.edu.pe	Autor/a
Indalecio Mujica-Bermúdez	indalecio.mujica@unsch.edu.pe	Autor/a
Carlos Manuel Pérez-Reátegui	carlos.perez34.cpr@gmail.com	Autor/a
Luis Martin Botton-Estrada	martin_botton@yahoo.es	Autor/a
Jorge Alber Quisocala-Ramos	marsichejo@gmail.com	Autor/a
Henry Quispe-Cruz	hquispe@unap.edu.pe	Autor/a
Carlos Vidal Cutimbo-Quispe	cvcutimbo@unap.edu.pe	Autor/a
Jhony Ruben Rodriguez-Mamani	jrodriguez@unap.edu.pe	Autor/a
Rosario Patricia Palomino-Crisóstomo	rpatriaciapc22@gmail.com	Autor/a
Willy Roger Cutipa-Salluca	rogercitosamsung@gmail.com	Autor/a
Kandy Faviola Tuero-Chirinos	kftuero@unap.edu.pe	Autor/a
Naysha Sharon Villanueva-Alvaro	naysha.villanueva@unap.edu.pe	Autor/a
Jhonny Jesús Lava-Gálvez	jhonny.lavag@gmail.com	Autor/a

