Conciencia Digital

ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

www.concienciadigital.org

Estrategia algorítmica para evaluar, agrupar y predecir perfiles de aprendizaje de física universitaria con robótica educativa

Algorithmic strategy to assess, cluster, and predict university physics learning profiles with educational robotics

[1] Andrés Santiago Martínez-León https://orcid.org/0000-0002-8598-7304
Universidad Estatal Amazónica, Puyo, Ecuador.
amartinez@uea.edu.ec

[2] Amaury Pérez-Martínez https://orcid.org/0000-0003-3978-7982
Universidad Estatal Amazónica, Puyo, Ecuador.
amperez@uea.edu.ec

[3] Estela Guardado-Yordi https://orcid.org/0000-0002-0515-6720
Universidad Estatal Amazónica, Puyo, Ecuador.
e.guardadoy@uea.edu.ec

[4] Reni Danilo Vinocunga-Pillajo https://orcid.org/0000-0001-6698-7846
Universidad Estatal Amazónica, Puyo, Ecuador.
rd.vinocungap@uea.edu.ec

[5] Andrea Margarita López-López https://orcid.org/0000-0003-2603-6979
Universidad de las Fuerzas Armadas, ESPE, Sangolquí, Ecuador.
amlopez13@espe.edu.ec

Artículo de Investigación Científica y Tecnológica
Enviado: 13/06/2026
Revisado: 17/09/2026
Aceptado: 21/10/2026
Publicado: 11/11/2026
DOI: **https://doi.org/10.33262/concienciadigital.v9i4.3823**

Cítese: Martínez León, A. S., Pérez Martínez, A., Guardado Yordi, E., Vinocunga Pillajo, R. D., & López López, A. M. (2026). Estrategia algorítmica para evaluar, agrupar y predecir perfiles de aprendizaje de física universitaria con robótica educativa. ConcienciaDigital, 9(4), 216-232. https://doi.org/10.33262/concienciadigital.v9i4.3823

CONCIENCIA DIGITAL, *es* una revista multidisciplinar, **trimestral,** que se publicará en soporte electrónico tiene como **misión** contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. https://concienciadigital.org
La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec

Esta revista está protegida bajo una licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 International. Copia de la licencia: https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es

Conciencia Digital

ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

www.concienciadigital.org

Palabras claves:
Robótica educativa, enseñanza de la física, mecánica newtoniana, análisis de conglomerados, predicción del aprendizaje.

Resumen

Introducción. La robótica educativa permite explorar principios físicos mediante plataformas programables; sin embargo, las diferencias individuales de interacción pueden quedar ocultas en los promedios de grupo. **Objetivo.** Se diseñó una estrategia algorítmica para evaluar el aprendizaje conceptual de la mecánica newtoniana, identificar perfiles de interacción y predecir categorías de ganancia mediante una plataforma robótica omnidireccional. **Metodología.** Se estableció un enfoque metodológico y de propuesta algorítmica basada en: preparación de los datos, cálculo del cambio normalizado individual y comparación entre guías, agrupamiento k-means con variables de interacción, caracterización de los perfiles, clasificación de la ganancia y predicción con random forest. El procedimiento se verificó mediante datos simulados de un grupo de control y otro experimental, con 30 estudiantes por grupo, en un entorno reproducible de Google Colab, y se evaluó con múltiples conjuntos simulados mediante la recuperación de perfiles, la estabilidad del agrupamiento y la exactitud del modelo. **Resultados.** En el escenario simulado, las medianas del cambio normalizado fueron 0,55 en el grupo experimental y 0,25 en el control. Se recuperaron tres perfiles de interacción con ganancias diferenciadas (0,83; 0,59 y 0,14), y el modelo predictivo superó a la clase mayoritaria (0,76 frente a 0,40). El agrupamiento fue estable en el 98 % de los 50 conjuntos simulados. **Conclusiones.** La estrategia permitió examinar patrones de interacción sin atribuir estilos de aprendizaje a los estudiantes. Sus resultados corresponden a una demostración con datos simulados; la utilidad educativa deberá comprobarse con estudiantes reales y un instrumento de evaluación validado. **Área de estudio general:** Ciencias Físicas. **Área de estudio específica:** Aprendizaje automático y ciencia de datos aplicados a la enseñanza de la física. **Tipo de estudio:** Artículo original.

Keywords:
Educational robotics, physics instruction, Newtonian

Abstract

Introduction. Educational robotics enables the exploration of physical principles through programmable platforms; however, individual differences in interaction can be hidden by group averages. **Objective**. An algorithmic strategy was designed to

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

mechanics, cluster analysis, learning prediction.

assess conceptual learning of Newtonian mechanics, identify interaction profiles, and predict gain categories using an omnidirectional robotic platform. **Methodology.** A methodological and algorithmic-proposal approach was established, based on: data preparation, calculation of individual normalized change and comparison between guides, k-means clustering with interaction variables, profile characterization, gain classification, and prediction with random forest. The procedure was verified using simulated data from a control group and an experimental group, with 30 students per group, in a reproducible Google Colab environment, and was evaluated with multiple simulated datasets through profile recovery, clustering stability, and model accuracy. **Results.** In the simulated scenario, the medians of normalized change were 0.55 in the experimental group and 0.25 in the control group. Three interaction profiles with differentiated gains (0.83, 0.59, and 0.14) were recovered, and the predictive model outperformed the majority class (0.76 versus 0.40). Clustering was stable in 98% of the 50 simulated datasets. **Conclusions**. The strategy made it possible to examine interaction patterns without attributing learning styles to students. Its results correspond to a demonstration with simulated data; its educational usefulness must be verified with real students and a validated assessment instrument.
General area of study: Physical Sciences. **Specific area of study**: Machine learning and data science applied to physics teaching. **Type of study:** Original article.

1. Introducción

En la actualidad, la incorporación de la robótica como instrumento didáctico se ha afianzado en la educación, permitiendo a los estudiantes construir, programar y observar plataformas cuyo comportamiento depende de principios físicos. Los robots móviles se consideran plataformas flexibles para enseñar temas de mecánica, electrónica y software (Arvin et al., 2019). Sin embargo, la robótica también exige conocimientos previos que dificultan la curva inicial de aprendizaje (Yang et al., 2024).

La difusión de la robótica en el aula universitaria en gran medida depende de su accesibilidad. Arvin et al. (2019) señalan que el costo y la complejidad de las interfaces y herramientas limitan su adopción, y proponen como alternativa un robot móvil abierto

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

y de bajo costo. En esta línea se desarrollaron brazos robóticos de impresión 3D para la enseñanza (López-Neri et al., 2023; Zhou et al., 2020), robots BEAM que integran la reutilización de componentes electrónicos (Boya-Lara et al., 2022) y dispositivos con microcontroladores para controlar experimentos de mecánica (Růžicka et al., 2018).

En el ámbito universitario, los conceptos de mecánica se abordaron con distintas plataformas. Eliza et al. (2025) desarrollaron un juego educativo con un robot seguidor de línea para el aprendizaje del movimiento rectilíneo con estudiantes de educación en ciencias, reportando una mejor comprensión conceptual, participación y motivación. Aksit (2026) presentó una lección efectiva basada en el modelo 5E con el kit mBot2 para trabajar conceptos de desplazamiento, velocidad, aceleración y gráficas de movimiento con docentes de ciencias y matemáticas en formación. La cinemática de brazos robóticos se ha utilizado como caso de enseñanza mediante simulaciones en software especializado, con un efecto significativo en el aprendizaje de los estudiantes (Zhou et al., 2020), y mediante un diseño instruccional que abarca los niveles concreto, representacional y abstracto para construir el concepto de espacio de trabajo (López-Neri et al., 2023). Los sistemas dinámicos y de control se introdujo a través de un robot de péndulo invertido de dos ruedas concebido para estudiantes de ingeniería de control (Shariati et al., 2019), y el control de movimiento y los sistemas embebidos, mediante un prototipo robótico en un laboratorio de pregrado (Martínez-Prado et al., 2019). En hidromecánica, un microcontrolador gobierna válvulas y sensores de flujo en un dispositivo construido por estudiantes (Růžicka et al., 2018), y Boya-Lara et al. (2022) reportan mejoras en los conocimientos y habilidades STEM de estudiantes de ingeniería en dominios eléctrico, electrónico y mecánico.

Las modalidades de interacción y las estrategias didácticas son diversas. Verner et al. (2020) expusieron a estudiantes de ingeniería industrial a manipuladores robóticos en modos virtual y físico, evaluaron su conciencia espacial y su interés por la robótica. Por su parte, Yang et al. (2024) demostraron que la realidad mixta facilitó la curva de aprendizaje. En el plano didáctico, la robótica se ha combinado con el aprendizaje basado en proyectos (Růžicka et al., 2018), el modelo de enseñanza (Aksit, 2026), la gamificación (Eliza et al., 2025), y las aplicaciones móviles en la educación superior, donde se evidencian avances en la eficiencia de la enseñanza de la física (Nasriddinov et al., 2026).

Sin embargo, la evidencia del aporte de la robótica al mejoramiento de los conceptos de la física universitaria se encuentra dispersa entre plataformas, temáticas y modalidades de interacción. Una revisión sistemática reciente analizó estudios sobre robótica aplicada al aprendizaje de la física, y concluyó que esta mejoraba competencias como el pensamiento computacional, resolución de problemas y creatividad, pero no el rendimiento académico, debido a la falta de una implementación sostenida en las aulas (Manu et al., 2025). Finalmente, gran parte de los estudios considerados deja en segundo

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

plano la heterogeneidad entre estudiantes, considerando que no todos interactúan con el robot ni aprenden de la misma manera.

En este contexto, el análisis del aprendizaje basado en datos educativos ofrece herramientas para abordar la heterogeneidad. Por ejemplo, Aldowah et al. (2019) concluyeron que determinadas técnicas se ajustan mejor a determinados problemas de aprendizaje, y que estos métodos pueden respaldar estrategias centradas en el estudiante. En robótica educativa, Scaradozzi et al. (2020) aplicaron un algoritmo K-means a los registros de programación de estudiantes que resolvían una tarea con robots LEGO Mindstorms EV3, e identificaron trayectorias de resolución distintas, asociando los perfiles de aprendizaje con el logro de una tarea de programación, no con la ganancia de comprensión de un concepto físico.

En consecuencia, el presente trabajo propone una estrategia algorítmica de evaluación, agrupamiento y predicción de perfiles de aprendizaje de estudiantes universitarios sobre conceptos de física a partir del uso de plataformas robóticas. El estudio es de carácter metodológico y la estrategia algorítmica es su aporte principal. Su funcionamiento se valida mediante una demostración con datos simulados y no pretende generalizar resultados. Los perfiles de aprendizaje se interpretan como tipos de interacción y no como estilos de aprendizaje.

2. Metodología

El presente trabajo responde a un enfoque metodológico y de propuesta algorítmica basada en tres etapas: diseño de la estrategia a partir de la literatura, formulación de las reglas de decisión y demostración con datos simulados. El escenario de referencia contrasta el aprendizaje de conceptos de la mecánica newtoniana a través de una guía experimental tradicional y una mediada por el uso de una plataforma omnidireccional.

El escenario referencial supone dos grupos de 30 estudiantes: un grupo de control que trabaja con la guía tradicional, y un grupo experimental que trabaja con la guía mediada por una plataforma robótica, todos con formación de bachillerato en ciencias exactas y asignados al azar. Se considera la aplicación de un pretest y un postest con calificación automática a ambos grupos.

La evaluación del aprendizaje conceptual alcanzado por los estudiantes responde a una versión del *Force Concept Inventory* (Han et al., 2015), adaptada por docentes del área de física a partir de los conceptos que el robot omnidireccional permite abordar: cinemática vectorial en el plano, primera ley de Newton e inercia, superposición de fuerzas y la segunda ley de Newton en dos dimensiones.

Asimismo, para el grupo experimental se registran cuatro variables de interacción: tiempo total de uso, número de parámetros distintos probados, número de intentos y tiempo hasta la primera modificación de un parámetro. La variable de resultado es el cambio normalizado individual (Marx & Cummings, 2007), de tal forma que la comparación de ganancias entre perfiles no esté determinada por el propio agrupamiento.

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

Conciencia Digital
ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original
www.concienciadigital.org

La estrategia algorítmica se implementó como un flujo de trabajo reproducible en un cuaderno de *Google Colab* que simula el comportamiento de ambos grupos (https://github.com/robotics-projects-maker/Robotics-in-Education.git). Para el grupo con robot se generó una estructura de tres perfiles de interacción, definida por las medias y dispersiones de las variables de interacción y de la ganancia. Se evaluaron métricas, tales como recuperación de perfiles, estabilidad de agrupamiento y exactitud del modelo, repitiendo el procedimiento con múltiples conjuntos simulados.

3. Resultados

La **Figura 1** describe la estrategia algorítmica, la cual parte de los datos de los estudiantes y se organiza en seis pasos. Los pasos 1 y 2 se aplican a los dos grupos (control y experimental) y los pasos 3 a 6, solo al grupo experimental por cuanto es el que registra variables de interacción entre el estudiante y la plataforma robótica. El flujo del grupo de control concluye posterior al paso 2 y aporta su información a los resultados, mientras que el del grupo experimental continúa hacia los pasos subsiguientes.

En el paso 1 se asignan códigos anónimos, se tratan los valores faltantes sin eliminar casos (R1) y se estandarizan las variables de interacción para que ninguna pese más que otra por su escala. En el paso 2 se calcula el cambio normalizado individual (Marx & Cummings, 2007), que extiende al estudiante la ganancia de Hake (1998) y admite valores negativos cuando hay retroceso, de modo que permite analizar la heterogeneidad que un promedio de grupo oculta. Se verifica que los grupos fueran comparables en el pretest y se compara la ganancia entre guías con pruebas no paramétricas y tamaños del efecto.

En el paso 3 se agrupa a los estudiantes del grupo experimental con el algoritmo *k-means* para identificar perfiles (Scaradozzi et al., 2020). Se usan solo las variables de interacción, de modo que la ganancia no determine los perfiles y su comparación posterior no sea circular. El número de perfiles se limita según el tamaño del grupo, de modo que cada uno conserve un mínimo de estudiantes, y se elige con el coeficiente de silueta (Rousseeuw, 1987) (R2). El algoritmo *k-means* se repite con distintos datos simulados y solo se interpreta un arreglo estable (R3), según el remuestreo *bootstrap*. En el paso 4 se describen los perfiles por sus variables de interacción y se contrasta su ganancia con una prueba no paramétrica y su tamaño del efecto. La biblioteca scikit-learn ofrece implementaciones de los algoritmos de aprendizaje automático incluidos en este procedimiento (Pedregosa et al., 2011).

En el paso 5 la ganancia se clasifica en las categorías baja, media y alta. Si una categoría queda con muy pocos estudiantes, se fusionan en dos para que el modelo sea estimable (R4). En el paso 6, se aplica un algoritmo Random Forest (Breiman, 2001), el cual predice la categoría a partir de las variables de interacción. Su exactitud se estima con validación cruzada estratificada repetida, que reduce la variabilidad de una sola partición entre entrenamiento y prueba, y se compara con la de un modelo que siempre predice la clase mayoritaria. Si el modelo no la supera, se reporta sin interpretación (R5).

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

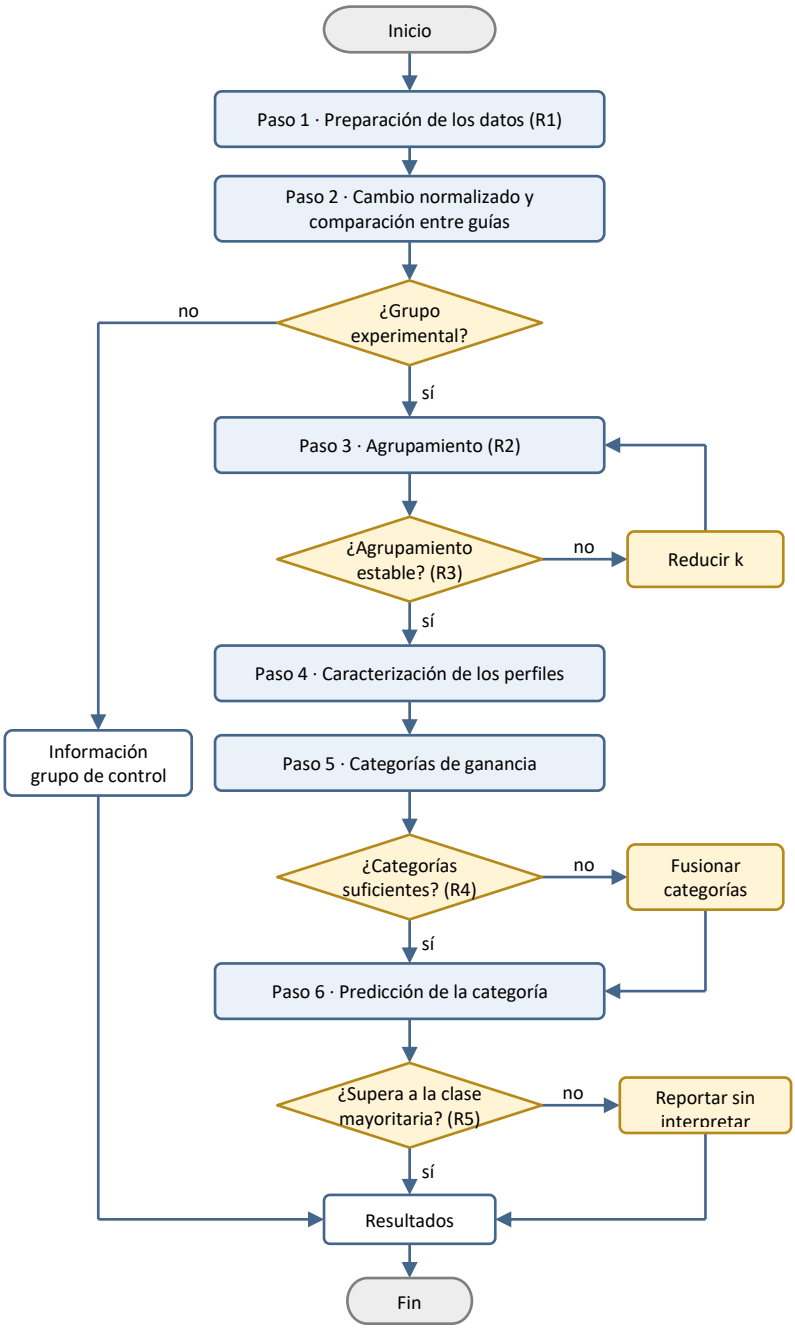
ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

www.concienciadigital.org

Además de la separación por grupos, tres controles evitan interpretar resultados poco fiables: la estabilidad del agrupamiento (R3), la suficiencia de las categorías (R4) y el desempeño del modelo (R5).

Figura 1

Diagrama de flujo de la estrategia algorítmica



Sea n el número de estudiantes del grupo experimental, $m=5$ el tamaño mínimo admitido por perfil, $k_{máx} = \min(4, \lfloor n/m \rfloor)$ el número máximo de perfiles, y $\tau=0{,}8$ el umbral de

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

www.concienciadigital.org

estabilidad. Los umbrales de estas variables son valores de partida que el investigador puede ajustar con justificación:

- R1. Preparación de los datos. Los valores faltantes se imputan con la mediana de cada variable. Se reporta la proporción imputada y no se elimina ningún caso sin justificarlo.
- R2. Número de perfiles. Si $n < 2m$, no se agrupa y el análisis se limita a lo descriptivo. En caso contrario, se evalúan valores de k entre 2 y $k$máx y se elige el que maximice la silueta media, siempre que cada perfil tenga al menos m estudiantes y sea interpretable.
- R3. Estabilidad del agrupamiento. Se repite el agrupamiento con distintos datos simulados y se calcula el índice de Rand ajustado medio entre ellas. Si es menor que τ, se reduce k y se repite el procedimiento. Si la inestabilidad persiste con el menor k, se reporta como limitación. El índice de Rand ajustado utilizado para comparar particiones fue descrito por Hubert & Arabie (1985).
- R4. Suficiencia de las categorías de ganancia. Se usan las categorías bajas (< 0,3), media (0,3–0,7) y alta (> 0,7). Si alguna tiene menos de m estudiantes, se fusionan de forma limitada (< 0,3) y sustancial (≥ 0,3). Si alguna categoría tiene menos estudiantes que pliegues de validación el modelo no se ajusta.
- R5. Desempeño del modelo. El modelo solo se interpreta si su exactitud media supera a la de la clase mayoritaria y el intervalo percentil del 95 % de la diferencia entre repeticiones excluye el cero. De lo contrario, los resultados se reportan sin interpretar el modelo.

A continuación, se simula un escenario y se presentan sus principales resultados. Los parámetros generales de la simulación se presentan en la **Tabla 1**, y los correspondientes a los perfiles previstos del grupo experimental se detallan en la **Tabla 2**.

Tabla 1

Parámetros generales del escenario simulado

Elemento	Valor
Grupos	Control (n = 30), y experimental (n = 30)
Sesiones	3 sesiones de 60 minutos en ambos grupos
Pretest	Media prevista de 60 % y desviación de 10 puntos, igual en ambos grupos
Agrupamiento	k-means con k entre 2 y 4; estabilidad con 50 conjuntos simulados
Validación del modelo	Validación cruzada estratificada de 5 pliegues, 20 repeticiones
Conjuntos simulados	50 conjuntos simulados para garantizar la robustez

Los datos no corresponden a estudiantes reales. La **Tabla 1** resume los parámetros generales del escenario y la **Tabla 2** muestra los de los perfiles del grupo experimental.

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

www.concienciadigital.org

Tabla 2

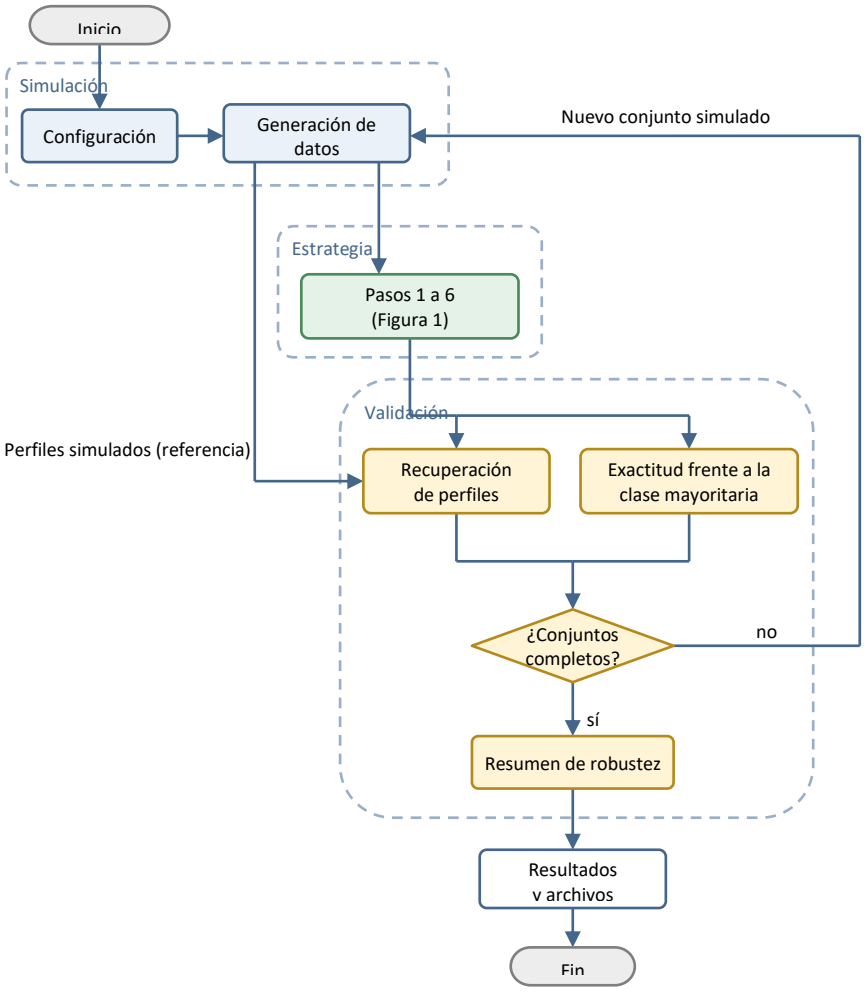
Parámetros de los perfiles del grupo experimental (media y desviación)

Perfil simulado	n	Contacto (min)	Parámetros	Intentos	1.er cambio (min)	Ganancia
Exploración sistemática	8	165 (10)	10 (1,2)	25 (3)	3 (1)	0,90 (0,15)
Exploración moderada	12	120 (12)	6 (1,4)	13 (3)	7 (2,4)	0,65 (0,15)
Interacción mínima	10	60 (12)	3 (1,2)	6 (2,4)	14 (3,6)	0,20 (0,15)

La **Figura 2** resume el flujo del cuaderno de *Google Colab*, que somete la estrategia de la **Figura 1** a una prueba con datos simulados. En la etapa de simulación se configuran los supuestos del escenario y se generan los datos de ambos grupos, junto con los perfiles de interacción que sirven de referencia. En la etapa de estrategia se aplican los pasos 1 a 6 a esos datos. En la etapa de validación se evalúan dos criterios: la recuperación de los perfiles de referencia por el agrupamiento *k-means* y la exactitud del *random forest* frente a la clase mayoritaria. El ciclo se repite con nuevos conjuntos simulados hasta completar el número previsto.

Figura 2

Flujo del cuaderno de Google Colab en la demostración



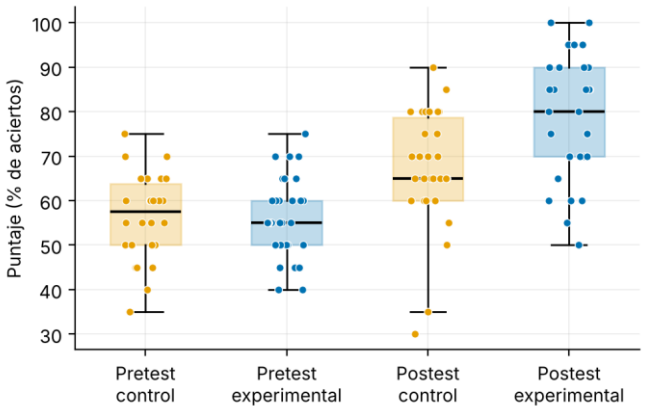
Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

Conciencia Digital
ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original
www.concienciadigital.org

Los grupos partieron de un nivel comparable con valores de la mediana de los pretest equivalentes a 55,0 % en el grupo experimental y de 57,5 % en el de control (**Figura 3**). En el postest las medianas fueron de 80,0 % y 65,0 %, respectivamente.

Figura 3

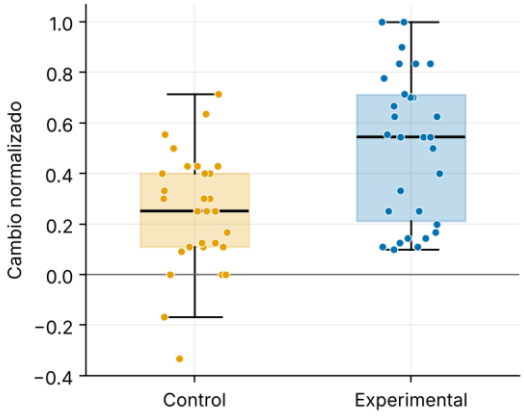
Pretest y postest por grupo



El cambio normalizado individual (**Figura 4**), tuvo una mediana de 0,55 en el grupo experimental y de 0,25 en el de control, resultando en que la mitad de los estudiantes experimentales recuperó más del 55 % de la mejora posible, frente al 25 % en el control.

Figura 4

Cambio normalizado individual por grupo



La silueta fue máxima con k = 3 (0,53). Los valores k = 2 y k = 4 se descartaron por inestabilidad (R3) y por generar un perfil con un número menor al mínimo de estudiantes (R2) respectivamente. Con k = 3 el agrupamiento fue estable y recuperó por completo los perfiles simulados. Los perfiles definidos por su grado de contacto con la plataforma robótica mostraron medianas de cambio normalizado de 0,83 (alta interacción), 0,59

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

Conciencia Digital
ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original
www.concienciadigital.org

(media) y 0,14 (baja), y la diferencia fue significativa (Kruskal-Wallis: $p < 0,001$; $\varepsilon^2 = 0,75$). A continuación, la **Tabla 3** muestra una descripción detallada de los perfiles definidos por simulación:

Tabla 3

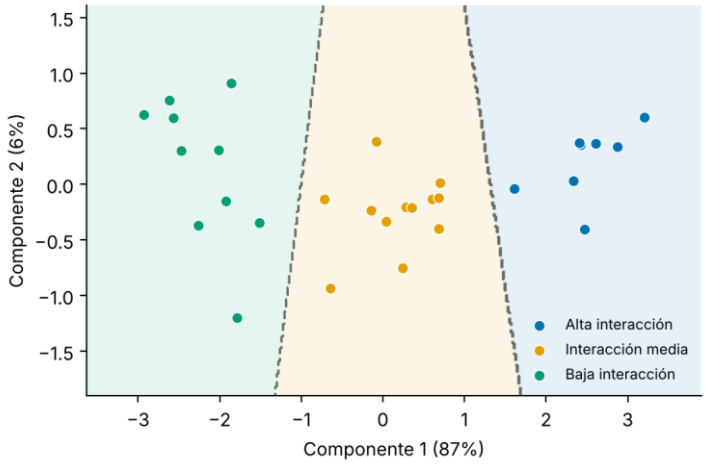
Caracterización de los perfiles hallados en el grupo experimental

Perfil hallado	n	Contacto (min)	Parámetros	Intentos	1.er cambio (min)	Cambio (mediana)
Alta interacción	8	165,2	10,4	25,6	2,5	0,83
Interacción media	12	125,0	5,9	13,9	5,9	0,59
Baja interacción	10	59,4	3,4	5,2	11,3	0,14

La **Figura 5** presenta la distribución de los estudiantes del grupo experimental en tres perfiles identificados mediante el algoritmo k-means, considerando las variables asociadas con la interacción con la plataforma robótica. Se identificaron ocho estudiantes con alta interacción, doce con interacción media y diez con baja interacción. Las diferencias entre los perfiles estuvieron relacionadas con el tiempo de contacto con la plataforma, el número de parámetros explorados, los intentos realizados y el tiempo transcurrido hasta la primera modificación.

Figura 5

Perfiles hallados por k-means



La **Figura 6** muestra las diferencias del cambio normalizado individual entre los tres perfiles identificados, con medianas de 0,83 para alta interacción, 0,59 para interacción media y 0,14 para baja interacción. Estos valores evidenciaron una asociación entre el nivel de interacción con la plataforma robótica y la ganancia conceptual obtenida en la simulación. Posteriormente, mediante los umbrales establecidos en R4, se clasificaron doce estudiantes en la categoría de ganancia media, diez en la baja y ocho en el alta.

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

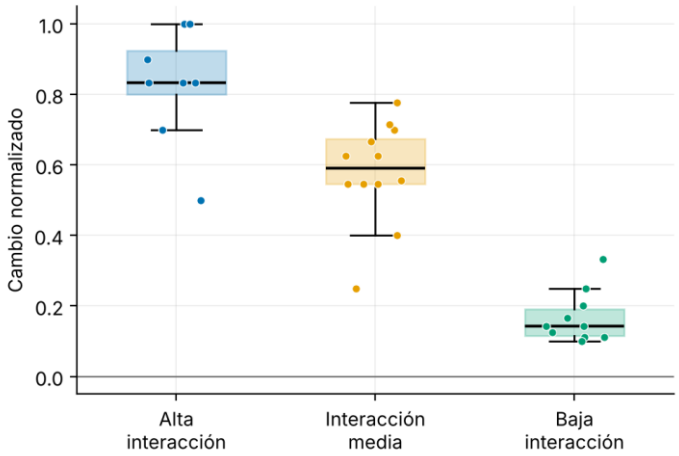
ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

www.concienciadigital.org

Debido a que las tres categorías cumplieron con el número mínimo de estudiantes establecido, no fue necesario realizar su agrupación en categorías más amplias.

Figura 6

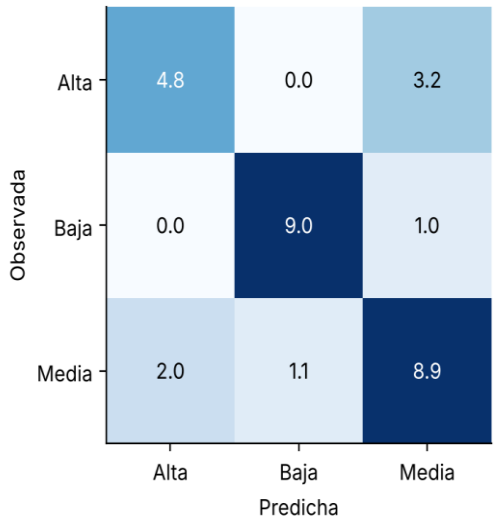
Cambio normalizado por perfil de interacción



El random forest alcanzó una exactitud media de 0,76 frente a 0,40 de la clase mayoritaria, cumpliendo de esta manera con R5. La matriz de confusión (**Figura 7**), indica un mejor desempeño medio en las categorías baja (9,0 de 10) y media (8,9 de 12) que en la alta (4,8 de 8). Los valores de la matriz corresponden al promedio de 20 repeticiones, como se muestra en la **Figura 7**.

Figura 7

Matriz de confusión del random forest



Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

Conciencia Digital
ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original
www.concienciadigital.org

Para describir la variabilidad entre simulaciones, el procedimiento se repitió con 50 conjuntos simulados. En el 86 % de ellos se eligió el número de perfiles fijado y recuperó los perfiles con una mediana del índice de Rand ajustado de 1,00, con un mínimo de 0,39 en los casos desfavorables. El agrupamiento fue estable en el 98 % de los conjuntos, solo en el 4 % fue necesario fusionar categorías y el *random forest* superó a la clase mayoritaria en el 98 %, con una exactitud media de 0,67 frente a 0,40.

4. Discusión

La demostración con datos simulados mostró que, bajo los supuestos definidos, la estrategia algorítmica propuesta cumple su función, permitiendo detectar la diferencia entre guías, recuperar los perfiles, predecir la categoría de ganancia y medir el nivel de acierto del modelo. En 50 conjuntos simulados, el procedimiento identificó el número correcto de perfiles en el 86 % de los casos y fue estable en el 98 %, aunque en el peor la recuperación de los perfiles fue de solo 0,39 en el índice de Rand ajustado.

Asimismo, el aporte propuesto en el presente trabajo frente a los análisis basados en promedios de grupo (Manu et al., 2025), consiste en que incorpora la heterogeneidad individual mediante el cambio normalizado y los perfiles de interacción. Así también, frente a la identificación de perfiles en robótica educativa (Scaradozzi et al., 2020), la propuesta presentada vincula estrechamente esos perfiles con la ganancia de comprensión de un concepto físico.

El alcance de la demostración está acotado por cuatro condiciones: 1. Los resultados dependen de los supuestos del escenario simulado; 2. Para un grupo con 30 estudiantes, el número de perfiles estimables es relativamente reducido; 3. La validez del test de evaluación debe documentarse antes de aplicar la estrategia con estudiantes reales; 4. Los perfiles describen la interacción del estudiante con la plataforma robótica y no estilos de aprendizaje, y su relación con la ganancia no sería causal, pues el contacto depende de la participación y la motivación del estudiante.

5. Conclusiones

- En este trabajo se propone una estrategia algorítmica reproducible para analizar el aprendizaje de la física con robótica, la cual integra el cambio normalizado individual, identificación de perfiles de interacción y predicción de la categoría de ganancia, con criterios que establecen las condiciones de interpretación de resultados. En la demostración con datos simulados se verificó que el flujo permita la recuperación de la estructura de referencia y se mantenga estable en las repeticiones. En lo posterior, la estrategia permitirá determinar para qué tipo de estudiantes y bajo qué forma de trabajo funciona de mejor manera una guía mediada por el uso de plataformas robóticas, así como también podrá replicarse en otros cursos y conceptos, sustituyendo la etapa de simulación por datos propios. Como trabajo futuro se plantea aplicar esta estrategia con estudiantes reales, con

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

aval de un comité de ética institucional y un test de conocimientos validado, comparar otros algoritmos de agrupamiento y ampliar los conceptos evaluados.

6. Conflicto de intereses

Los autores declaran que no existe conflicto de intereses en relación con el artículo presentado.

7. Derechos de autor (copyright)

Los autores son los titulares de los derechos de autor (patrimoniales y/o de explotación) de los contenidos de la revista (*copyright*).

8. Declaración de contribución de los autores

Los autores declaran haber participado de manera equitativa y sustancial en la realización de esta investigación. Conceptualización: ASML, APM, RDVP; Investigación: ASML, AMLL, RDVP; Metodología: AMP, EGY; Supervisión: APM; Validación; EGY, AMLL; Escritura borrador original: ASML, AMLL; Redacción revisión y edición: APM. Todos los autores participaron en la generación de los resultados y conclusiones, así como en la elaboración y aprobación del documento final.

Divulgación de la delegación a la IA generativa

La responsabilidad del manuscrito final recae íntegramente en los autores.

Las herramientas GAI no figuran como autores y no asumen responsabilidad por los resultados finales.

Declaración presentada por: Andrés Santiago Martínez León.

9. Costos de financiamiento

No existió financiamiento para el presente trabajo

10. Referencias bibliográficas

Aksit, O. (2026). Computational thinking meets robotics: using mBot2 to explore kinematics concepts in physics classrooms. *Science Activities, 63*(1), Article 2615961. https://doi.org/10.1080/00368121.2026.2615961

Aldowah, H., Al-Samarraie, H., y Fauzy, W. M. (2019). Educational data mining and learning analytics for 21st century higher education: a review and synthesis. *Telematics and Informatics, 37*, 13–49. https://doi.org/10.1016/j.tele.2019.01.007

Arvin, F., Espinosa, J., Bird, B., West, A., Watson, S., & Lennox, B. (2019). Mona: an affordable open-source mobile robot for education and research. *Journal of Intelligent & Robotic Systems, 94*, 761–775. https://doi.org/10.1007/s10846-018-0866-9

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

Boya-Lara, C., Saavedra, D., Fehrenbach, A., & Márquez-Araque, A. (2022). Development of a course based on BEAM robots to enhance STEM learning in electrical, electronic, and mechanical domains. *International Journal of Educational Technology in Higher Education, 19*, Article 7. https://doi.org/10.1186/s41239-021-00311-9

Breiman, L. (2001). Random forests. *Machine Learning, 45*(1), 5–32. https://doi.org/10.1023/A:1010933404324

Eliza, F., Hakiki, M., Muhtaj, M., Putri, D. A., Hidayah, Y., Fricticarani, A., Fakhri, J., Arpannudin, I., Subroto, D. E., Sussolaikah, K., Hamid, M. A., Fadli, R., & Ramadhan, M. A. (2025). Game-D: development of an educational game using a line follower robot on straight motion material. *International Journal of Information and Education Technology*, *15*(1). https://doi.org/10.18178/ijiet.2025.15.1.2217

Hake, R. R. (1998). Interactive-engagement versus traditional methods: a six-thousand-student survey of mechanics test data for introductory physics courses. *American Journal of Physics*, *66*(1), 64–74. https://doi.org/10.1119/1.18809

Han, J., Bao, L., Chen, L., Cai, T., Pi, Y., Zhou, S., Tu, Y., y Koenig, K. (2015). Dividing the force concept inventory into two equivalent half-length tests. *Physical Review Special Topics - Physics Education Research, 11*(1), 010112. https://doi.org/10.1103/PhysRevSTPER.11.010112

Hubert, L., & Arabie, P. (1985). Comparing partitions. *Journal of Classification*, *2*(1), 193–218. https://doi.org/10.1007/BF01908075

López-Neri, E., Luque-Vega, L. F., González-Jiménez, L. E., & Guerrero-Osuna, H. A. (2023). Design and implementation of a robotic arm for a MoCap system within extended educational mechatronics framework. *Machines*, *11*(9), Article 893. https://doi.org/10.3390/machines11090893

Manu, F. A., Ramaila, S., & Ramnarain, U. (2025). The role of Arduino-assisted robotics coding application in physics learning: a systematic review. *International Journal of Science, Mathematics and Technology Learning, 32*(2), 189–211. https://doi.org/10.18848/2327-7971/CGP/v32i02/189-211

Martínez-Prado, M. A., Rodríguez-Reséndiz, J., Gómez-Loenzo, R. A., Camarillo-Gómez, K. A., & Herrera-Ruiz, G. (2019). Towards a new tendency in embedded systems in mechatronics for the engineering curricula. *Computer Applications in Engineering Education, 27*, 603–614. https://doi.org/10.1002/cae.22101

Marx, J., & Cummings, K. (2007). Normalized change. *American Journal of Physics, 75*(1), 87–91. https://doi.org/10.1119/1.2372468

Nasriddinov, D. K., Alimova, S., Chorieva, M. J., Kenjayeva, X., y Ochilova, F. B. (2026). Pedagogical experimental work on the effectiveness of teaching physics based on mobile applications and robotics elements. *Natural Resources for Human Health, 6*(5S), 353–361. https://doi.org/10.53365/nrfhh.577

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research, 12*, 2825–2830. https://jmlr.org/papers/v12/pedregosa11a.html

Rousseeuw, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics, 20*, 53–65. https://doi.org/10.1016/0377-0427(87)90125-7

Růžicka, M., Rejthárek, M., & Major, Š. (2018). Project-based learning in basic course of technical physics: Computer-controlled experiments and Agros2D modeling. *WSEAS Transactions on Applied and Theoretical Mechanics, 13*, 46–52. https://wseas.com/journals/articles.php?id=2475

Scaradozzi, D., Cesaretti, L., Screpanti, L., y Mangina, E. (2020). Identification of the students learning process during education robotics activities. *Frontiers in Robotics and AI, 7*, Article 21. https://doi.org/10.3389/frobt.2020.00021

Shariati, A., Shamekhi, A. H., Ghaffari, A., Gholampour, S., & Motaghed, A. (2019). Conceptual design algorithm of a two-wheeled inverted pendulum mobile robot for educational purposes. *Mechanics of Solids, 54*, 614–621. https://doi.org/10.3103/S0025654419040162

Verner, I. M., Cuperman, D., Gamer, S., & Polishuk, A. (2020). Exploring affordances of robot manipulators in an introductory engineering course. *International Journal of Engineering Education, 36*(5), 1691–1707. https://www.ijee.ie/1atestissues/Vol36-5/22_ijee3981.pdf

Yang, L., Xiao, S., Wang, T., Shi, Y., y Driggs-Campbell, K. (2024). Robotics via experiential active learning with immersive technology: a pedagogical framework designed for engineering curricula. *IEEE Access, 12*, 65706–65715. https://doi.org/10.1109/ACCESS.2024.3393473

Zhou, D., Xie, M., Xuan, P., y Jia, R. (2020). A teaching method for the theory and application of robot kinematics based on MATLAB and V-REP. *Computer Applications in Engineering Education, 28*, 239–253. https://doi.org/10.1002/cae.22188.

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/

ISSN: **2600-5859**
Vol. 9 No. 4 pp. 216 – 232 octubre - diciembre 2026
Revista multidisciplinar
Artículo original

www.concienciadigital.org

El artículo que se publica es de exclusiva responsabilidad de los autores y no necesariamente reflejan el pensamiento de la **Revista Conciencia Digital.**

El artículo queda en propiedad de la revista y, por tanto, su publicación parcial y/o total en otro medio tiene que ser autorizado por el director de la **Revista Conciencia Digital.**

Esta revista está protegida bajo una licencia Creative Commons en la 4.0 International. Copia de la licencia: http://creativecommons.org/licenses/by-nc-sa/4.0/