

## Modelo predictivo de las metas de aproximación al dominio: un análisis con inteligencia artificial<sup>1</sup>

### Predictive Model of Mastery-Approach Goals: An Analysis with Artificial Intelligence

 Francisco Quiñonez Tapia \*

 María de Lourdes Vargas Garduño\*\*

\* Universidad de Guadalajara, México

\*\*Universidad Michoacana de San Nicolás de Hidalgo, México

Cómo citar: Quiñonez, F. y Vargas, M. L. (2025). Modelo predictivo de las metas de aproximación al dominio: un análisis con inteligencia artificial. *Revista Electrónica de Investigación Educativa, Online First*.  
<https://doi.org/10.24320/redie.2025.27.of.6555>

#### Resumen

El objetivo del estudio fue predecir con Inteligencia Artificial (AI) las Metas de Aproximación al Dominio en estudiantes de secundaria a partir de las variables recuperadas por PISA en el 2018. La muestra se tomó de la base de datos de PISA de 2018; y estuvo integrada por 339560 participantes de 60 países. Metodológicamente, se utilizó el aprendizaje automático con el algoritmo *Super Learner* con 14 algoritmos candidatos; asimismo, se utilizó el aprendizaje profundo con una red neuronal de 107 parámetros. Los análisis arrojaron que el Apoyo emocional de los padres percibido por el estudiante, la Competitividad, Sentido de Vida, Autoeficacia y Conocimiento de la comunicación intercultural fueron predictores de las Metas de Aproximación al Dominio en los estudiantes de secundaria. La investigación contribuye al avance del estudio de

<sup>1</sup> *Primera versión*: Versión del autor aceptada para publicación el 6 de agosto de 2024.



los factores que influyen en las metas de aproximación del dominio en estudiantes de secundaria, con modelos de análisis que permiten avanzar en el desarrollo de la ciencia de la educación predictiva con IA.

**Palabras clave:** orientación a metas, necesidad de logro, comunicación intercultural, psicología educativa, objetivos educativos del estudiante

## **Abstract**

The objective of the study was to predict, using Artificial Intelligence, the Approach to Mastery Goals in high school students from the variables recovered by PISA in 2018. The sample was taken from the 2018 PISA database and was made up of 339,560 participants from seventy countries. Methodologically, automatic learning was used with the *Super Learner* algorithm with 14 candidate algorithms; likewise, deep learning was used with a neural network of 107 parameters. The analyzes showed that the emotional support of parents perceived by the student, Competitiveness, Meaning of Life, Self-efficacy and Knowledge of Intercultural Communication were predictors of the Approach to Mastery Goals in high school students. The research contributes to the advancement of the study of factors that influence the approach to mastery goals in high school students, with analysis models that allow progress in the development of the science of predictive education with artificial intelligence.

**Keywords:** goal orientation, achievement need, intercultural communication, educational psychology, student educational objectives

## Introducción

La teoría de metas de logro aborda los procesos motivacionales intrínsecos de los sujetos para el establecimiento de metas particulares en las tareas cognitivas, las cuales se asocian con el éxito y fracaso de las actividades que emprenden los sujetos (Dweck, 1986); de ahí la importancia de estudiar las metas de logro en la adolescencia, especialmente, las llamadas Metas de aproximación al dominio.

La adolescencia es una etapa fundamental, puesto que de las decisiones que se tomen en este periodo dependerá, en buena medida, la calidad de vida de la persona en su edad adulta. Al respecto, la motivación constituye un factor decisivo en el proceso de construcción de sí mismo, especialmente la motivación intrínseca. Si bien la temática asociada con las metas de aproximación al dominio en la adolescencia se ha problematizado mucho, resulta fundamental buscar formas más pertinentes para predecir el comportamiento de las adolescencias con respecto de dichas metas y hacer propuestas de intervención para fortalecerlas.

Diversos estudios se han realizado sobre las metas de aproximación al dominio, utilizando varios métodos; actualmente se ha ido destacando el empleo de la Inteligencia Artificial (IA) para predecir el desempeño académico de los estudiantes, el riesgo académico en estudiantes y la deserción escolar (Albreiki et al., 2021). Dado que no se han encontrado estudios que utilicen IA para predecir las Metas de Aproximación al Dominio en los estudiantes de secundaria, esta investigación plantea como objetivo: predecir con IA las Metas de Aproximación al Dominio en estudiantes de secundaria a partir de las variables recuperadas por PISA en el 2018. Los resultados podrán ser de utilidad para fortalecer el empleo de la IA en el ámbito educativo y para facilitar el diseño e implementación de

estrategias que permitan atender oportunamente casos de riesgo académico en estudiantes de secundaria y promover el fortalecimiento de las metas de aproximación al dominio y no solo las de aproximación al desempeño.

### **1.1 Contexto teórico: Metas de aproximación al dominio en la adolescencia**

Las metas de logro aluden a los comportamientos motivacionales intrínsecos que propician la energización, dirección del afecto y las cogniciones basadas en la competencia de los sujetos (Elliot, 1999). En este sentido, Dweck, (1986) planteó el modelo dicotómico de las metas de logro, que comprende: metas de aproximación al dominio y metas de aproximación al desempeño. Las metas de aproximación al dominio, denominadas también metas de aprendizaje, se caracterizan porque el aprendiz focaliza su esfuerzo en el desarrollo de una competencia o en la comprensión de una temática nueva, hasta llegar a dominar aquello que quiere aprender (Dweck, 1986). Asimismo, inciden en la mejora del rendimiento académico de los estudiantes (Alhadabi y Karpinski, 2020) y en la reducción de los niveles de ansiedad y depresión (Danthony et al., 2021). Los sujetos con metas de aproximación al dominio trabajan desde un enfoque de progreso y esfuerzo, no se preocupan por reconocer y mostrar determinadas incapacidades, demuestran su disposición para adquirir las nuevas habilidades y conocimientos, y utilizan los obstáculos como oportunidades para mejorar las estrategias de aprendizaje (Elliot y Harackiewicz, 1996). Por su parte, las metas de aproximación al desempeño se centran más en la obtención de juicios favorables y la evitación de juicios negativos hacia ellos; se caracterizan por un importante esfuerzo para evitar el fracaso, alcanzar el éxito y lograr el reconocimiento positivo (Elliot y Harackiewicz, 1996).

Con base en la bifurcación de este último tipo de metas, manteniendo las metas de aproximación al dominio, Elliot y Harackiewicz, (1996) plantean el modelo tricotómico compuesto por tres tipos de metas: las de aproximación al dominio, las de aproximación al desempeño y las de evitación. Así, como se ha mencionado en Quiñonez-Tapia y Vargas-Garduño (2023), se plantea un modelo jerárquico de las metas de logro que integra dos teorías: la de motivos de logro y la de metas de logro. Los motivos de logro permiten energizar y direccionar de manera general al sujeto en el contexto de competencia; entre ellos, destacan: la necesidad de logro en sí y la de evitación del fracaso (Elliot, 2006). Por otro lado, las metas de logro permiten al sujeto direccionar de manera específica la conducta en los entornos de competencia (Elliot, 1999), lo cual es relevante, puesto que la competencia se constituye en uno de los predictores de metas de aproximación al dominio en estudiantes (Alhadabi y Karpinski, 2020; Babenko y Oswald, 2019)

A partir del modelo tricotómico surgió el modelo 2x2, (ver figura 1), que considera dos categorías (dominio y desempeño), que se bifurcan en dos cada una (aproximación y evitación) (Elliot, 1999). Más tarde surgió el modelo 3x2, generado al desglosar las metas del modelo 2x2 en seis posibilidades (Elliot et al., 2011). Como se puede ver en la figura 2, se presentan tres categorías: la tarea, el sí mismo y la otredad; cada una de ellas, se subdivide en aproximación y evitación.

Figura 1. Modelo 2x2

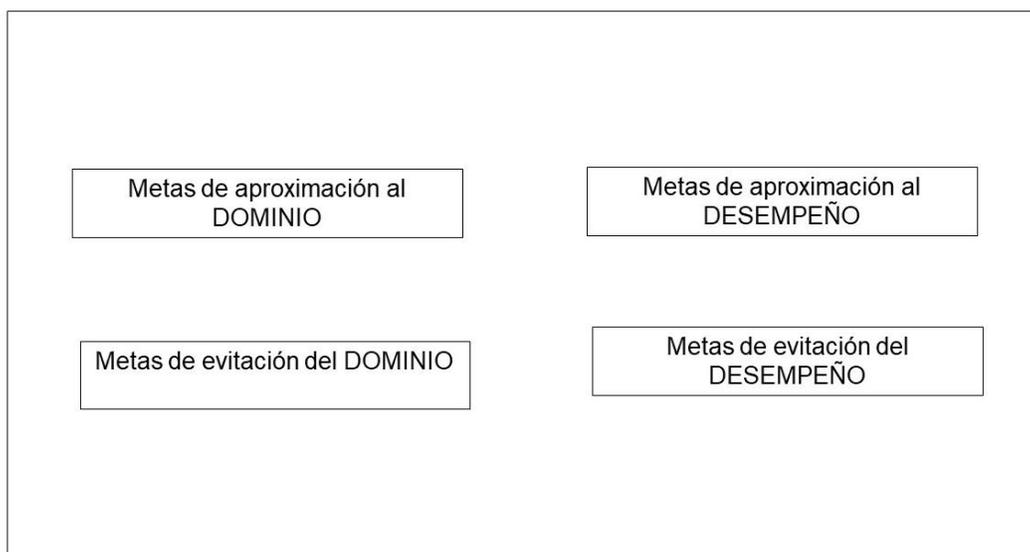
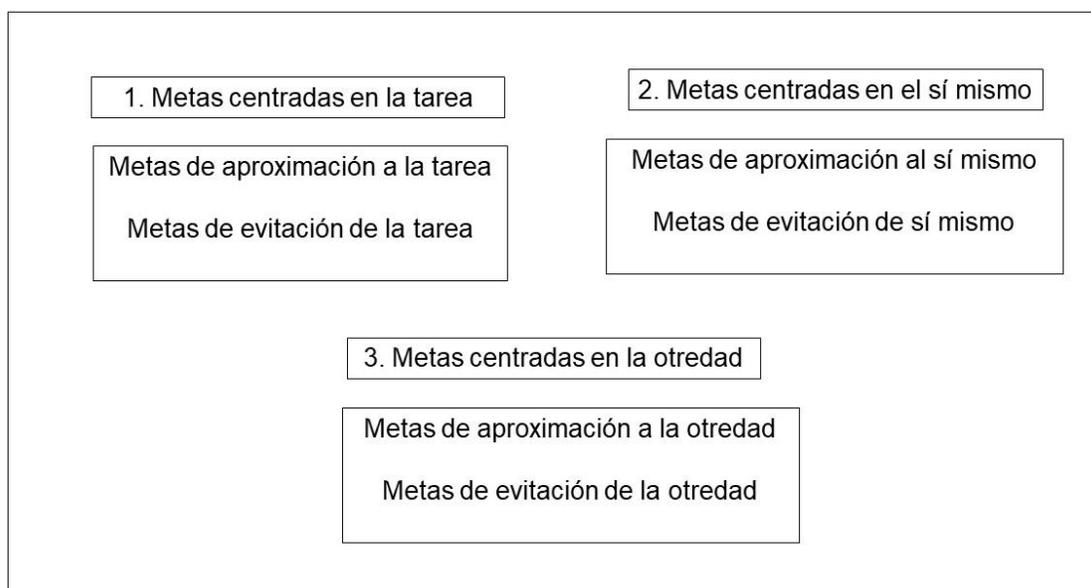


Figura 2. Modelo 3x2



Resulta relevante destacar que las metas de aproximación al dominio han tenido efectos positivos en el área académica (Alhadabi y Karpinski, 2020) y en el bienestar de los estudiantes, ya que mejoraron las emociones positivas de amor, interés, alegría, orgullo y satisfacción (Datu et al., 2022); disminuyeron la tensión y el aburrimiento en el

estudiantado (Jaitner et al., 2019) e incrementaron su bienestar subjetivo y académico (Li et al., 2021).

Existen factores personales y contextuales que inciden positivamente en las metas de aproximación al dominio. En este sentido, la autoeficacia y la necesidad de competencia (Ariani, 2022), el sentido de vida (Steger y Dik, 2009), la motivación autodeterminada, el clima motivacional percibido por los estudiantes y el clima enfatizado por los maestros hacia el dominio de las tareas (Jaitner et al., 2019) fueron predictores de las metas de aproximación al dominio en estudiantes.

## **1.2 Rol de la Inteligencia Artificial en la predicción educativa**

Actualmente, no existe una definición consensuada acerca de la Inteligencia Artificial (Dignum, 2019). Por tanto, para este estudio, se define la Inteligencia Artificial como “la disciplina que estudia y desarrolla artefactos computacionales que exhiben alguna(s) faceta(s) del comportamiento inteligente” (Dignum, 2019, p. 10) .

El campo de estudio de la IA tiene dos subcampos: Aprendizaje Automático (*Machine Learning*) y Aprendizaje Profundo (*Deep Learning*). El Aprendizaje Automático permite a las máquinas, mediante determinados algoritmos, aprender de los datos sin ser programados explícitamente a partir del establecimiento previo de una teoría e hipótesis (Torra et al., 2019). Además, el Aprendizaje Automático permite hacer predicciones, clasificaciones e identificaciones de patrones y estructuras en los datos; de esta manera, las máquinas aprenden a tomar decisiones con los nuevos datos que se les proporcionan (Lyre, 2020).

El Aprendizaje Automático puede ser Supervisado, no Supervisado y por Refuerzo. El Aprendizaje Automático Supervisado requiere de un conjunto de datos de entrenamiento

etiquetados que permite a la máquina aprender de los datos de entrada y salida (Janiesch et al., 2021). En el Aprendizaje Automático no Supervisado, el objetivo es que la máquina encuentre patrones y estructuras en los datos sin etiquetas o especificaciones preexistentes (Janiesch et al., 2021). El Aprendizaje Automático por Refuerzo consiste en que las máquinas aprenden interactuando con los datos no etiquetados y su entorno, con un objetivo establecido y con una función que reformula, penaliza o recompensa el aprendizaje en cada movimiento hasta reducir el error y lograr la tarea específica deseada (Torra et al., 2019).

Por otro lado, el Aprendizaje Profundo es un avance del Aprendizaje Automático, que se inspira en las redes neuronales del ser humano: neuronas interconectadas transmitiendo información para la construcción de conocimiento orientado a una tarea específica (Dignum, 2019); por tanto, puede definirse como una forma de IA que, mediante algoritmos, va entrenando al ordenador para que procese información de modo tal que emule al cerebro humano, lo que le permite establecer reconocimiento de patrones complejos de distinto tipo y facilita las predicciones.

La Inteligencia artificial (AI) en el campo de la educación es incipiente y plantea un gran potencial para contribuir a que las ciencias de la educación, en su conjunto, realicen investigación predictiva (Hilbert et al., 2021). En este sentido, la IA se ha utilizado para proporcionar un aprendizaje personalizado al adaptar procesos y recursos a las condiciones de los usuarios o mediante apoyos tutoriales (Webb et al., 2021). Además, la IA se ha aplicado en los procesos de evaluación, retroalimentación y la generación de planes de intervención personalizados que permitieron mejorar el desempeño y evitar la deserción escolar al identificar estudiantes en etapas tempranas de riesgo (Albreiki et al.,

2021), para así llegar a desarrollar una educación de precisión (Luan y Tsai, 2021). Sin embargo, la limitación que tiene el enfoque de IA para ser aplicado en cualquier área y específicamente en la educación es que se requiere de grandes conjuntos de datos confiables.

En términos de generación de grandes conjuntos de datos en el área de educación, la Organización para la Cooperación y el Desarrollo Económico (OECD) a través del Programa Internacional de Evaluación de Alumnos (PISA) en el 2018, realizó evaluaciones a estudiantes de 15 años de 79 países, y construyó una base de datos con información de 612004 estudiantes sobre los resultados en Lectura, Matemáticas y Ciencias. Además, la base de PISA en el 2018 incluye información de sobre las Metas de Aproximación al Dominio, utilizando 40 variables con información acerca de su capital económico, social y cultural, actitudes hacia el aprendizaje, hábitos dentro y fuera de la escuela y en el entorno familiar, clima escolar, interés, motivación, entre otras. No obstante, no se emplearon técnicas de IA para su análisis.

## **II. Método**

### **2.1 Participantes y procedimiento**

#### **2.1.1 Base de Datos**

Recuperamos la base de datos de PISA en el 2018 (OECD, 2018) con 612004 casos. Elegimos los resultados obtenidos por los estudiantes en las 42 escalas (OECD, 2019).

#### **2.1.2 Selección de características**

Seleccionamos las mejores características para predecir las Metas de Aproximación al Dominio (MAD) con los modelos de *Machine Learning* y *Deep Learning* con dos métodos de filtro: la correlación de Pearson y de Spearman. La correlación de Pearson y de Spearman arrojaron que las mejores características para predecir las Metas de

Aproximación al Dominio ( $r > .35$ ,  $p < .01$ ;  $\rho = .34$ ,  $p < .01$ ) fueron cinco: el Apoyo emocional de los padres percibido por el estudiante (EMOSUPS), Competitividad (COMPETE), Sentido de Vida (EUDMO), Autoeficacia (RESILIENCE), Conocimiento de la comunicación intercultural (AWACOM). En consecuencia, se cumple el criterio en *Machine Learning* y *Deep Learning* de seleccionar las mejores características para predecir la variable de interés a partir de aquellas variables con mayores valores de correlación bivariada. Además, la selección de las mejores características permite el control de variables externas que pudieran influir en los resultados al generar un sobreajuste de los modelos de regresión, lo que traería como consecuencia una alta precisión en la predicción en el entrenamiento y una baja predicción en la validación. Por lo tanto, las 37 variables restantes de la base de datos fueron controladas al ser eliminadas.

### 2.1.3 Datos ausentes

De la base de datos original, eliminamos los casos con datos ausentes.

### 2.1.4 Participantes

La muestra quedó conformada por 339560 estudiantes ( $M_{\text{edad}} = 15.79$ ,  $DE = .29$ ): 173596 (51.1%) fueron mujeres y 165564 (48.9%) fueron hombres. La muestra por país de residencia se muestra en la tabla 1.

Tabla 1. País de residencia de los participantes

País	n	%
Albania	5509	1.6
Azerbaiyán (Bakú)	3298	1.0
Argentina	7452	2.2
Australia	10431	3.1
Austria	5284	1.6
Bosnia y Herzegovina	4975	1.5
Brasil	6286	1.9
Brunei Darussalam	4924	1.5
Bulgaria	3417	1.0
Bielorrusia	5231	1.5
Chile	5066	1.5
China Taipéi (Teipéi Chino)	6932	2.0

País	n	%
Colombia	5265	1.6
Costa Rica	5971	1.8
Croacia	5445	1.6
República Dominicana	1496	0.4
Estonia	4706	1.4
Francia	4629	1.4
Alemania	2500	0.7
Grecia	5333	1.6
Hong Kong	5491	1.6
Hungría	4230	1.2
Islandia	2362	0.7
Indonesia	11152	3.3
Irlanda	4547	1.3
Italia	8574	2.5
Kosovo	3940	1.2
Kazajistán	15376	4.5
Jordania	7429	2.2
República de Corea	6460	1.9
Letonia	4461	1.3
Lituania	5440	1.6
Macao	3710	1.1
Malasia	5769	1.7
Malta	2695	0.8
México	4050	1.2
Moldavia	4771	1.4
Montenegro	5074	1.5
Marruecos	2467	0.7
Panamá	1840	0.5
Perú	2471	0.7
Filipinas	6190	1.8
Polonia	5007	1.5
Portugal	4879	1.4
Rumania	4418	1.3
Rusia	6144	1.8
Arabia Saudita	4841	1.4
Serbia	4470	1.3
Eslovaquia	4663	1.4
Eslovenia	5056	1.5
España	26377	7.8
Suiza	3681	1.1
Tailandia	8056	2.4
Emiratos Árabes Unidos	16079	4.7
Turquía	6359	1.9
Ucrania	5144	1.5
Reino Unido	2403	0.7
Uruguay	2827	0.8
Región de Moscú (RUS)	1675	0.5
Tataristán (RUS)	4832	1.4

## 2.2 Instrumentos

Dado que la correlación de Pearson y de Spearman arrojaron como mejores características: el Apoyo emocional de los padres percibido por el estudiante, la Competitividad, el Sentido de Vida, Autoeficacia, el Conocimiento de la comunicación

intercultural para predecir las Metas de Aproximación al Dominio, a continuación, se reportan los instrumentos utilizados para medir dichos predictores:

Para medir el Apoyo emocional de los padres percibido por el estudiante, se utilizó la Escala EMOSUPS (OECD, 2019), misma que consiste en tres reactivos con escala de tipo Likert de cuatro puntos ( $\alpha = .89$ ; estructura de un factor: SRMR = .00; RMSEA = .000; CFI = 1.000; TLI = 1.000).

Se utilizó la Escala COMPETE (OECD, 2019) para medir competitividad, es decir, el disfrute de los estudiantes por competir con sus pares teniendo el deseo de ganar y ser el mejor de todos (competitividad; ver Spence y Helmreich, 1983). Consta de tres reactivos con escala de tipo Likert de cuatro puntos ( $\alpha = .77$ ; estructura de un factor: SRMR = .00; RMSEA = .000; CFI = 1.000; TLI = 1.000).

La Escala EUDMO (OECD, 2019) se empleó para medir el Sentido de Vida; recupera información sobre el grado de comprensión que tiene un estudiante sobre su vida con un significado y propósito, de tal manera que genere la sensación de que la vida importa (Steger, 2009). Consiste en tres reactivos con escala de tipo Likert de cuatro puntos ( $\alpha = .85$ ; estructura de un factor; SRMR = .00; RMSEA = .000; CFI = 1.000; TLI = 1.000).

Se utilizó la Escala RESILIENCE (OECD, 2019) para medir la Autoeficacia y recuperar información sobre las creencias que tienen los estudiantes sobre sus propias capacidades para realizar alguna tarea en específico (Bandura, 1978). Está constituida por cinco reactivos de tipo Likert de cuatro puntos ( $\alpha = .78$ ; estructura de un factor: SRMR = .020; RMSEA = .115; CFI = .980; TLI = .960).

Se empleó la escala AWACOM (OECD, 2020) para medir el Conocimiento de la comunicación intercultural, que alude a la capacidad de los estudiantes para comunicarse

efectivamente en distintas situaciones, incluso con personas que hablan un idioma distinto (OECD, 2020). Consiste en siete reactivos tipo Likert de cuatro puntos ( $\alpha = .90$ ; estructura de un factor: SRMR = .021; RMSEA = .132; CFI = .980; TLI = .971).

Para evaluar las Metas de Aproximación al Dominio utilizamos las puntuaciones de las Escalas MASTGOAL y WORKMAST. El análisis de confiabilidad de las puntuaciones de los participantes a la Escala de Metas de Aproximación al Dominio. La Escala MASTGOAL (OECD, 2019) consiste en tres reactivos de tipo Likert de cinco puntos ( $\alpha = .86$ ; estructura de un factor: SRMR = .00; RMSEA = .000; CFI = 1.000; TLI = 1.000). Se utilizó la Escala WORKMAST (OECD, 2019) para medir las Metas de Dominio de las Tareas. La escala consiste en tres reactivos de tipo Likert de cuatro puntos ( $\alpha = .76$ ; estructura de un factor: SRMR = .00; RMSEA = .000; CFI = 1.000; TLI = 1.000).

Además, las puntuaciones individuales obtenidas a partir de los instrumentos fueron transformadas a una escala de 0 a 1, donde 0 indica la media de la OECD y 1.0 la desviación estándar en los países de la OECD.

Finalmente, las escalas son de auto informe, y esto pudiera tener la limitación de generar sesgos en las respuestas, debido al fenómeno de deseabilidad social de los participantes. Asimismo, otra posible limitación de algunas escalas es que están construidas con tres reactivos y esto pudiera subrepresentar el constructo que se mide, aunque los análisis de las escalas basados en la Teoría de la Respuesta al Ítem reportados por la OECD (2019) y los análisis de confiabilidad y validez de constructo reportados en el estudio, arrojaron evidencias de confiabilidad y validez.

### 2.3 Análisis de los datos

Una vez que seleccionamos las mejores características para predecir las Metas de Aproximación al Dominio, analizamos los datos con *Machine Learning* con el algoritmo *Super Learner*.

*Super Learner* es un algoritmo de conjunto que permite aplicar varios algoritmos candidatos a un conjunto de datos, y encuentra el algoritmo óptimo o una combinación óptima ponderada de algoritmos a partir de la validación cruzada para el aprendizaje y predicción (van der Laan et al., 2007). Utilizamos el *Super Learner* porque resuelve el problema práctico de que, por lo general, es imposible determinar a priori cuál algoritmo funcionará mejor para la predicción (Golmakani y Polley, 2020). De esta forma, el *Machine Learning*, al no partir de modelos teóricos preexistentes y basarse fundamentalmente en la experimentación de los datos a partir del ensayo y error, y específicamente en el metamodelo de *Super Learner*, necesita utilizar la mayor cantidad de algoritmos disponibles para encontrar el algoritmo o la combinación de algoritmos que arrojen el mejor rendimiento para la predicción (Golmakani y Polley, 2020; van der Laan et al., 2007). Asimismo, la optimización de los hiperparámetros de los algoritmos candidatos siguió la misma lógica de experimentación, y no es posible que exista una justificación teórica y metodológica preexistente.

Por lo tanto, los algoritmos que utilizamos en *Super Learner* fueron: *Linear Regresión*, *Decision Tree Regressor*, *Random Forest Regressor*, *Extra Trees Regressor*, *K- Nearest Neighbors Regressor*, *Support Vector Regressor*, *Least Angle Regression*, *Bayesian Ridge Regression*, *Tweedie Regressor*, *Theil Sen Regressor*, *Huber Regressor*, *Baggin Regressor*, *Ada Boost Regressor*, *Gradient Boosting Regressor*. Los hiperparámetros de los algoritmos para *Ada Boost Regressor* y *Baggin Regressor* se realizaron con *Linear*

*Regression* y 200 estimadores; *Support Vector Regressor* con *gamma* igual a *scale*; *Decision Tree Regressor*, con cuatro arboles; *Random Forest Regressor* y *Extra Trees Regressor* con 200 estimadores, con cuatro arboles; *K Neighbors Regressor* con 10 vecinos; *Gradient Boosting Regressor* con 100 estimadores. Los demás hiperparámetros de los algoritmos fueron los establecidos por defecto.

Evaluamos el rendimiento de los algoritmos con el método de validación cruzada con 10 subconjuntos (*k-fold*). La validación cruzada permitió dividir, de forma aleatoria, el total de los datos en 10 subconjuntos, aproximadamente de igual tamaño. En cada iteración, uno de los subconjuntos de datos fue usado para evaluar y el resto para el entrenamiento. Asimismo, en cada iteración, el algoritmo seleccionó de manera estricta distintos subconjuntos de datos para evaluar, de manera que no pudieran repetirse los subconjuntos utilizados en las iteraciones anteriores. Finalmente, en la validación cruzada se estimaron los errores obtenidos en cada iteración, y posteriormente se obtuvo la media de los errores obtenidos en todas las iteraciones.

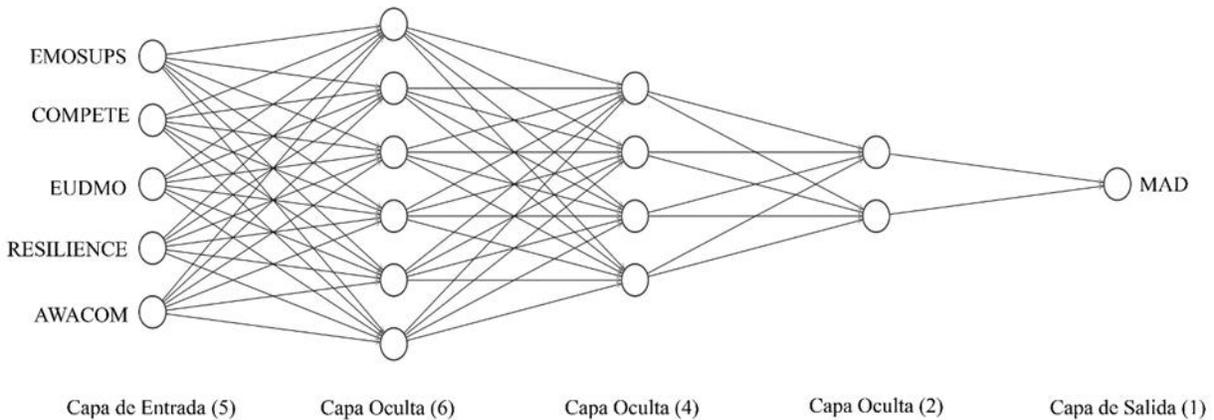
Por lo tanto, se seleccionó la validación cruzada porque es el método acorde para evaluar el rendimiento de predicción del algoritmo *Super Learner*. Además, es un estimador más robusto para el riesgo esperado o pérdida y arroja una métrica más generalizable en contraste con el error obtenido solo con una división del conjunto de datos para la evaluación y entrenamiento (Jung, 2022). Finalmente, con la validación cruzada se garantizó que los datos utilizados para entrenar fueran independientes de los datos utilizados para evaluar el rendimiento de la predicción (Montesinos et al., 2022).

Asimismo, utilizamos las métricas de Varianza Explicada, el Coeficiente de Determinación ( $R^2$ ), Error Cuadrático Medio (MSE) y Error Absoluto Medio (MAE). La varianza nos

permitió determinar qué tan lejos estuvieron los valores de las predicciones de la media de los valores reales. El  $R^2$  permitió determinar cómo se ajustaron los datos al modelo de regresión y determinar la proporción de la varianza que logró explicarse. Finalmente, el MSE y MAE permitieron calcular la variación media general de la diferencia entre el valor predicho y el valor real. Estas métricas nos permiten evaluar el rendimiento de la predicción de las Metas de Aproximación al Dominio a partir del Apoyo emocional de los padres percibido por el estudiante (EMOSUPS), Competitividad (COMPETE), Sentido de Vida (EUDMO), Autoeficacia (RESILIENCE), Conocimiento de la comunicación intercultural (AWACOM), Metas de Aproximación al Dominio (MAD). Los valores superiores de la Varianza Explicada y  $R^2$ , y valores aproximados al cero de MSE y MAE indican el mejor rendimiento de los algoritmos.

Además, analizamos dichas variables independientes usando *Deep Learning* con una Red Neuronal Artificial para predecir la variable dependiente Metas de Aproximación al Dominio (ver figura 3). Se eligió la arquitectura de una Red Neuronal Artificial de tipo Perceptrón Multicapa, debido a que este tipo de red permite instrumentar el algoritmo de la propagación del error hacia atrás, de tal manera que la red aprende la asociación entre los patrones de los datos de entrada y salida en cada neurona, (Jiang, 2021), y cada neurona oculta pasa información hacia y desde elementos que están interconectados (Hastie et al., 2009). Además, el tipo de aprendizaje que se instrumenta en la red Perceptrón Multicapa es supervisado y es acorde al tipo de datos continuos, estructurados y etiquetados con los que se llevó a cabo el presente estudio.

Figura 3. Red neuronal para predecir la Metas de Aproximación al Dominio



La Red Neuronal Artificial (ver figura 3) diseñada en este estudio arrojó 107 parámetros entrenados. Utilizamos la activación sigmoideal en la capa de entrada y en las ocultas, debido a que el algoritmo de la propagación del error hacia atrás requiere que la función sea continua y derivable para calcular el error de las neuronas (Hastie et al., 2009). Para compilar la red neuronal, utilizamos el Error Cuadrático Medio (MSE), ya que permite evaluar la adaptación de la red neuronal para realizar la predicción (Hastie et al., 2009). Asimismo, utilizamos el optimizador Adam porque se basa en estimaciones adaptativas de momentos de orden inferior denominados gradientes de primer orden (Kingma y Ba, 2015). Evaluamos la red neuronal con dos métodos: (a) División de la base de datos por porcentaje, 80 % para entrenamiento y 20% para validación, con un random state de 42 y (b) Validación cruzada con cinco subconjuntos (*k-fold*). En ambos métodos de evaluación se utilizaron 150 épocas y un batch size de 10. Los demás hiperparámetros fueron los establecidos por defecto.

La capa de entrada corresponde al número de variables dependientes que se seleccionaron en el estudio y la capa de salida alude a la variable a predecir. El número

de las capas ocultas, de las neuronas en cada capa, las épocas y el tamaño de *batch size* se establecieron de forma arbitraria, a partir del ensayo y error. De esta manera se valoraron varias arquitecturas de la red neuronal, con base en el rendimiento que tuvieron en el conjunto de datos de validación para la predicción de las Metas de Aproximación del Dominio, a partir de las cinco características predictoras.

Finalmente, realizamos los análisis con Python y las librerías de NumPy, Pandas y scikit-learn, Keras y matplotlib.

### **III. Resultados**

Las estadísticas descriptivas y las correlaciones de las variables de estudio son presentadas en la tabla 2. Los análisis arrojaron que las puntuaciones de las escalas se encuentran dentro de la media ponderada y la desviación estándar de los estudiantes de los países de la OECD ( $M = 0.000$ ,  $DE = 1.000$ ); de ahí que, aunque aparentemente en nuestro estudio hay valores diferentes a la media establecida por la OECD, en realidad todos los que están entre 0 y 1, corresponden a la media reportada por la OECD. Los resultados indican correlaciones positivas y estadísticamente significativas entre las variables del estudio. El análisis correlacional de la variable a predecir en este estudio de Metas de Aproximación al Dominio (MAD) arrojó correlaciones de Pearson positivas y estadísticamente significativas mayores a .35 ( $p < .01$ ) y las correlaciones de Spearman positivas estadísticamente significativas mayores a .34 ( $p < .01$ ) con las variables predictoras.

Tabla 2. Estadísticas descriptivas y correlaciones para las variables de estudio

Variable	M	DE	1	2	3	4	5	6	7	8
1. Apoyo Emocional de los Padres Percibido por el Estudiante	-0.020	1.000	1	.165**	.270**	.328**	.296**	.303**	.319**	.365**
2. Competitividad	0.088	1.000	.165**	1	.216**	.308**	.180**	.236**	.354**	.348**
3. Sentido de Vida	0.174	0.977	.267**	.255**	1	.426**	.180**	.343**	.335**	.398**
4. Autoeficacia	0.091	1.000	.318**	.321**	.434**	1	.333**	.367**	.421**	.459**
5. Conocimiento de la Comunicación Intercultural	0.005	0.996	.281**	.193**	.180**	.335**	1	.285**	.349**	.369**
6. Metas de Aprendizaje	0.130	1.04	.293**	.235**	.349**	.390**	.277**	1	.419**	.837**
7. Motivación para Dominar las Tareas	0.160	1.00	.311**	.378**	.351**	.428**	.335**	.419**	1	.827**
8. Metas de Aproximación al Dominio	0.285	1.731	.359**	.362**	.416**	.485**	.363**	.836**	.848**	1

Nota: Correlaciones de Pearson en negritas. Correlaciones de Spearman en cursivas.

\*\*  $p < .01$ .

### 3.1 Predicción de las Metas de Aproximación del Dominio con *Machine Learning* y *Deep Learning*

Para predecir las Metas de Aproximación al Dominio con técnicas de IA establecimos la siguiente función:

$$\hat{y} = f(x_1, x_2, x_3, x_4, x_5)$$

Donde:

$\hat{y}$  = Metas de Aproximación del Dominio

$x_1$  = Apoyo Emocional de los Padres Percibido por el Estudiante (EMOSUPS)

$x_2$  = Competitividad (COMPETE)

$x_3$  = Sentido de Vida (EUDMO)

$x_4$  = Autoeficacia (RESILIENCE)

$x_5$  = Conocimiento de la Comunicación Intercultural (AWACOM)

A continuación, se reportan los resultados que se obtuvieron con la función anterior, y que fue analizada con modelos de regresión de *Machine Learning* y *Deep Learning*.

### 3.1.1 Aprendizaje Automático (*Machine Learning*)

Los resultados de las evaluaciones de los modelos que predicen las Metas de Aproximación al Dominio a partir las cinco variables predictoras, se muestran en la Tabla 3. Se incluye el MSE, MAE, Varianza Explicada y  $R^2$ . Los resultados indican que el *Super Learner* predijo el 39.5 % de la varianza. Asimismo, se observa que el MSE (1.807) y el MAE (1.048) de la predicción de las Metas de Aproximación al Dominio en el *Super Learner* fue menor en comparación con los modelos base.

Tabla 3. Evaluación del Metamodelo *Super Lerner* y modelos base que predicen las Metas de Aproximación al Dominio

Modelos	$R^2$	Varianza Explicada	MSE	MAE
Super Lerner	0.395	0.395	1.807	1.048
Gradient Boosting Regressor (GB)	0.390	0.390	1.847	1.052
Support Vector Regressor (SVR)	0.382	0.383	1.851	1.052
Linear Regression (LR)	0.378	0.378	1.864	1.069
Least Angle Regression (LARS)	0.378	0.378	1.864	1.069
Bayesian Ridge Regression (BRR)	0.378	0.378	1.864	1.069
Bagging Regressor (BR)	0.378	0.378	1.864	1.069
Theil Sen Regressor (TSR)	0.376	0.374	1.872	1.068
Huber Regressor (HR)	0.376	0.376	1.870	1.066
Ada Boost Regressor (AB)	0.367	0.368	1.901	1.090
Extra Trees Regressor (ET)	0.346	0.347	1.959	1.112
Tweedie Regressor (TR)	0.340	0.340	1.981	1.122
Random Forest Regressor (RF)	0.338	0.337	1.988	1.113
K- Nearest Neighbors Regressor (KNN)	0.334	0.334	1.999	1.103
Decision Tree Regressor (CART)	0.309	0.309	2.063	1.136

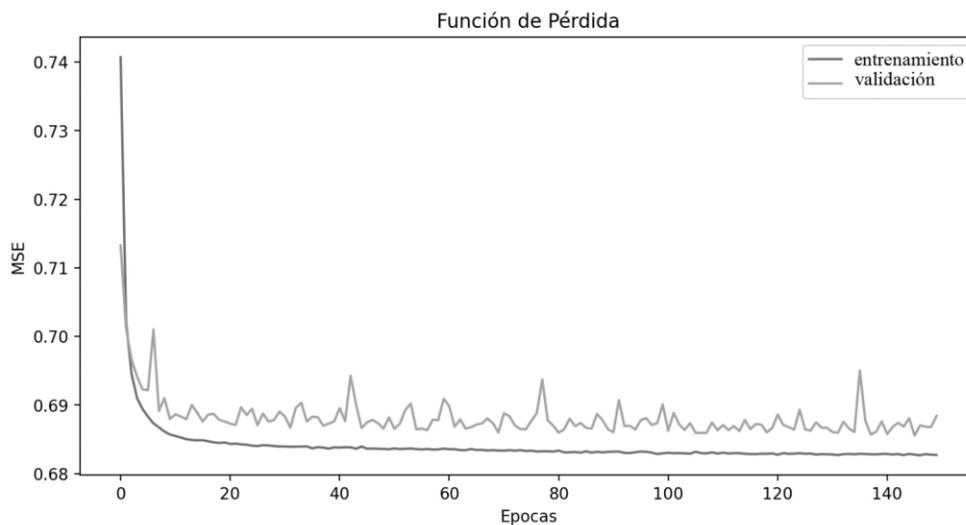
*Super Learner* resultó con el mejor desempeño para la predicción, debido a que fue diseñado para absorber el aprendizaje de los algoritmos candidatos, encontrar el algoritmo o combinación óptima de algoritmos que se desempeñaron mejor para la predicción. Si se

busca aumentar la efectividad del desempeño de las predicciones del *Super Learner* es requisito mínimo hacer uso de la mayor cantidad de algoritmos disponibles.

### 3.1.2 Aprendizaje Profundo (*Deep Learning*)

Las curvas de pérdida del error para predecir la Metas de Aproximación al Dominio, con la red neuronal diseñada (ver figura 3), a partir de las variables predictoras, se muestran en la figura 4. Los resultados muestran que las curvas de entrenamiento y validación siguen una línea descendente que indican pérdida de error para predecir la Metas de Aproximación al Domino a partir de las variables seleccionadas. Finalmente, en la época 150, los valores del MSE de la red neuronal fueron de 1.829 y 1.837 en el entrenamiento y validación respectivamente.

Figura 4. Curvas de pérdida del error para predecir las Metas de Aproximación al Dominio en los modelos de entrenamiento y validación de la red neuronal



El análisis de evaluación de la red neuronal para predecir las Metas de Aproximación al Dominio con el método de validación cruzada arrojó una media de línea base del MSE de 1.833.

Finalmente, es importante mencionar que la convergencia de la red neuronal se ve

afectada porque se espera que en cada época aumente la tasa de aprendizaje y disminuya el error de la predicción. Para intentar mejorar en futuras iteraciones se sugiere lo siguiente: (a) seguir experimentando con el mayor número posible de neuronas en las capas ocultas, para de esta manera garantizar que el modelo sea flexible para identificar la no linealidad de los datos; (b) activar la disminución de la tasa de aprendizaje en cada época, para evitar el sobreajuste y lograr el aprendizaje óptimo; y (c) experimentar con distintos valores en los hiperparámetros de las épocas y el de *batch size*.

### **Discusión y conclusiones**

Analizamos con Inteligencia Artificial (IA) los predictores de las Metas de Aproximación al Dominio de los estudiantes de secundaria, a partir de los datos que recuperó PISA en el 2018. Encontramos evidencia de que el Apoyo Emocional de los padres percibido por el estudiante, la Competitividad, el Sentido de Vida, la Autoeficacia y el Conocimiento de la comunicación intercultural fueron predictores positivos de las Metas de Aproximación al Dominio en los estudiantes de secundaria.

Reportamos que la percepción que tienen los estudiantes sobre el apoyo que obtienen de los padres tuvo un efecto positivo en las Metas de Aproximación al Dominio. Sin embargo, no encontramos estudios previos que analizaran la relación entre estas dos variables. Además, existen evidencias de que el apoyo de los padres ha tenido un efecto positivo en el desarrollo académico de los estudiantes (Rickert y Skinner, 2022). De esta manera, consideramos que nuestros resultados contribuyen a evidenciar el papel que tiene los padres de familia en los procesos de enseñanza-aprendizaje de sus hijos.

Por otro lado, aportamos evidencias de que el grado de Sentido de Vida del estudiante, tuvo un efecto positivo en las Metas de Aproximación al Dominio. No hemos encontrado

estudios sobre las relaciones que tienen ambas variables; sin embargo, es de esperarse la relación entre ellas, ya que en ambos constructos implica que el sujeto establezca propósitos; en el Sentido de Vida, se establece un propósito general y en las Metas de Aproximación al Dominio se establecen propósitos específicos. Además, el Sentido de Vida se considera una dimensión del bienestar subjetivo; y sí existen evidencias de que el bienestar subjetivo tiene efectos positivos en las Metas de Aproximación al Dominio (Li et al., 2021). Por lo tanto, nuestros hallazgos aportan evidencias para ampliar la teoría de Metas de Aproximación al Dominio desde el Sentido de Vida los sujetos.

Por otro lado, nuestros resultados difieren con otros autores en que la competitividad, no tuvo un efecto positivo en las Metas de Aproximación al Dominio (Elliot y McGregor, 2001; Harackiewicz et al., 1997). Consideramos que nuestros resultados difieren con lo reportado por dichos investigadores debido al contexto histórico de la población estudiada, ya que existen 17 y 21 años de diferencia entre nuestro estudio y los estudios de Elliot y McGregor (2001) y Harackiewicz et al. (1997), respectivamente. Además, consideramos que las diferencias también radican en el tipo de análisis que se utilizaron en dichas investigaciones. Sin embargo, dado que los motivos de logro y las metas de logro, se integran en un factor general denominado Metas de Aproximación al Dominio (Elliot y Thrash, 2001), nuestros resultados coinciden con las evidencias de correlación entre la Competitividad y la Motivación para Dominar las Tareas (Harackiewicz et al., 1997). Además, coincidimos con Guo et al. (2023) al encontrar correlaciones y efectos positivos de la competitividad sobre las Metas de Aproximación al Dominio.

Asimismo, nuestros resultados apoyan las evidencias de que la autoeficacia tuvo un impacto positivo en las Metas de Aproximación al Dominio (Ariani, 2022). No

encontramos estudios que reporten los efectos del Conocimiento de la comunicación intercultural sobre las Metas de Aproximación al Dominio. De esta manera, nuestros resultados aportan un nuevo elemento teórico para el estudio y comprensión de las metas de logros, específicamente para la comprensión de los factores que inciden en la Metas de Aproximación al Dominio en los estudiantes de secundaria.

Nuestros resultados tienen varias implicaciones prácticas. Recomendamos al profesorado incluir en su práctica docente actividades que fortalezcan en sus estudiantes, la autoeficacia, la motivación al logro y la comunicación intercultural, que han sido predictores de fortalecimiento de Metas de Aproximación al Dominio y, como se ha encontrado en nuestro estudio, esto favorece la permanencia escolar. Asimismo, recomendamos a los padres de familia se involucren en las actividades de aprendizaje de sus hijos, los apoyen a realizarlas y las refuercen. A los psicólogos, les recomendamos trabajar con los estudiantes la Autoeficacia y el Sentido de Vida de manera general, y a promover el equilibrio entre Competencia con sus pares y colaboración, a partir del establecimiento de las Metas de Aproximación al Dominio necesarias para el desarrollo académico.

A los directores de las instituciones educativas, les recomendamos que impulsen programas y actividades extracurriculares que vinculen a los padres de familia, los docentes, directivos y estudiantes para fortalecer Sentido de Vida, Autoeficacia, Competitividad, Apoyo de los Padres a las actividades escolares de los estudiantes y la Comunicación intercultural. A los encargados del diseño y la implementación de las políticas públicas en educación, les recomendamos que generen políticas públicas educativas que promuevan la creación de programas de intervención y planes de estudio

con ejes transversales de interculturalidad y desarrollo psicológico de los estudiantes con temas de autoeficacia, sentido de vida, competitividad y vínculos familiares. Asimismo, consideramos el uso de IA para hacer estudios, al menos anuales, en las instituciones educativas de nivel básico para que puedan detectarse oportunamente cuáles son las condiciones de las Metas de Aproximación al Dominio en el estudiantado y se diseñen intervenciones oportunas.

Nuestro estudio tiene varias fortalezas. Primero, los resultados contribuyen al desarrollo teórico de las Metas de Aproximación al Dominio desde los factores personales de los estudiantes. Segundo, es el primer estudio de las Metas de Aproximación al Dominio en el que se utilizan métodos de análisis predictivos fundamentados en la IA con el uso de 14 algoritmos que permiten mayor precisión en la predicción y la replicabilidad de los resultados. Tercero, realizamos los análisis con el tamaño de muestra más grande que se ha reportado en el mundo para el estudio de las Metas de Aproximación al Dominio y que incluye a participantes de secundaria de 60 países, lo que permite generalizar los resultados.

En contraste, nuestro estudio tiene varias limitaciones. Primero, no se aborda todo el constructo teórico de metas de logro y solo se abordan las Metas de Aproximación al Dominio. En este sentido, recomendamos en futuras investigaciones abordar los demás tipos de metas de logro para conocer, comprender y aportar factores personales que tienen efectos en todos los tipos de metas de logro. Segundo, nuestro estudio solo incluye a participantes de 15 años que se encuentran en secundaria; por tanto, recomendamos que en las siguientes investigaciones se incluyan a todos los estudiantes que cursen el nivel de secundaria; además, se realicen estudios y se validen los

instrumentos de este estudio para poblaciones diversas con el fin de conocer los factores personales que inciden en las metas de logro en distintas etapas y contextos del ser humano. Tercero, hoy en día, el uso del aprendizaje profundo (*Deep Learning*) aún tiene la limitación de la interpretabilidad de los resultados, la transparencia y explicabilidad de los análisis de los modelos. En consecuencia, recomendamos tener cautela con el uso de los resultados del análisis con el aprendizaje profundo (*Deep Learning*). A partir de dichas limitaciones, sugerimos a otros investigadores, implementar análisis con estudiantes mexicanos abarcando los tres grados de secundaria, para tener más claros elementos que permitan conocer la situación de adolescentes mexicanos. Lo mismo podríamos recomendar a investigadores de otros países, para ampliar la información y facilitar con ello, la toma de decisiones para mejorar las condiciones que favorezcan el logro de Metas de Aproximación al Dominio.

En conclusión, los predictores de las Metas de Aproximación al Dominio fueron: el Apoyo Emocional de los padres percibido por el estudiante, la Competitividad, el Sentido de Vida, la Autoeficacia y el Conocimiento de la Comunicación Intercultural de los estudiantes de secundaria de 60 países que participaron en las evaluaciones de PISA en el 2018. En consecuencia, contamos con conocimientos que contribuyen a la generación de políticas públicas y educativas, proyectos y programas específicos de trabajo docente y psicológico con los estudiantes, docentes, directivos y padres de familia para mejorar el desarrollo académico de los estudiantes.

---

#### Contribución de autoría

**Francisco Quiñonez Tapia:** Concepción y diseño, Recopilación de datos, Análisis e interpretación de datos, Metodología, Redacción del artículo.

**Vilma María Pérez Viñas:** Concepción y diseño, Recopilación de datos, Análisis e interpretación de datos, Metodología, Redacción del artículo.

#### Declaración de no conflicto de intereses

Los autores declaran no tener conflicto de intereses.

#### Fuente de financiamiento

No existe fuente de financiamiento para este artículo.

---

## Referencias

- Albreiki, B., Zaki, N. y Alashwal, H. (2021). A Systematic literature review of student' performance prediction using machine learning techniques. *Education Sciences*, 11(9), 552. <https://doi.org/10.3390/educsci11090552>
- Alhadabi, A. y Karpinski, A. C. (2020). Grit, self-efficacy, achievement orientation goals, and academic performance in University students. *International Journal of Adolescence and Youth*, 25(1), 519-535. <https://doi.org/10.1080/02673843.2019.1679202>
- Ariani, D. W. (2022). How achievement goals affect students' well-being and the relationship model between achievement goals, academic self-efficacy and affect at school. *Journal of Applied Research in Higher Education*, 14(1), 111-134. <https://doi.org/10.1108/jarhe-08-2020-0273>
- Babenko, O. y Oswald, A. (2019). The roles of basic psychological needs, self-compassion, and self-efficacy in the development of mastery goals among medical students. *Medical Teacher*, 41(4), 478-481. <https://doi.org/10.1080/0142159X.2018.1442564>

- Bandura, A. (1978). Self-efficacy: Toward a unifying theory of behavioral change. *Advances in Behaviour Research and Therapy*, 1(4), 139-161. [https://doi.org/10.1016/0146-6402\(78\)90002-4](https://doi.org/10.1016/0146-6402(78)90002-4)
- Danthony, S., Mascret, N. y Cury, F. (2021). The relationships between the 3 x 2 achievement goal model and test anxiety in Physical Education. *European Physical Education Review*, 27(3), 559-573. <https://doi.org/10.1177/1356336X20971325>
- Datu, J. A. D., Valdez, J. P. M. y Yang, W. (2022). La vida comprometida académicamente de los estudiantes orientados al dominio: Orden causal entre emociones positivas, metas de dominio y compromiso académico. *Revista de Psicodidáctica*, 27(1), 1-8. <https://doi.org/10.1016/j.psicod.2021.02.001>
- Dignum, V. (2019). What Is Artificial Intelligence? En *Responsible Artificial Intelligence: How to Develop and Use AI in a Responsible Way* (pp. 9-34). Springer International Publishing. [https://doi.org/10.1007/978-3-030-30371-6\\_2](https://doi.org/10.1007/978-3-030-30371-6_2)
- Dweck, C. S. (1986). Motivational processes affecting learning. *American Psychologist*, 41(10), 1040-1048. <https://doi.org/10.1037/0003-066X.41.10.1040>
- Elliot, A. J. (1999). Approach and avoidance motivation and achievement goals. *Educational Psychologist*, 34(3), 169-189. [https://doi.org/10.1207/s15326985ep3403\\_3](https://doi.org/10.1207/s15326985ep3403_3)
- Elliot, A. J. (2006). The Hierarchical Model of Approach-Avoidance Motivation. *Motivation and Emotion*, 30(2), 111-116. <https://doi.org/10.1007/s11031-006-9028-7>
- Elliot, A. J. y Harackiewicz, J. M. (1996). Approach and avoidance achievement goals and intrinsic motivation: A mediational analysis. *Journal of Personality and Social Psychology*, 70(3), 461-475. <https://doi.org/10.1037/0022-3514.70.3.461>

- Elliot, A. J. y McGregor, H. A. (2001). A 2 X 2 achievement goal framework. *Journal of Personality and Social Psychology*, 80(3), 501-519. <https://doi.org/10.1037/0022-3514.80.3.501>
- Elliot, A. J., Murayama, K. y Pekrun, R. (2011). A 3 x 2 achievement goal model. *Journal of Educational Psychology*, 103(3), 632-648. <https://doi.org/10.1037/a0023952>
- Elliot, A. J. y Thrash, T. M. (2001). Achievement Goals and the Hierarchical Model of Achievement Motivation. *Educational Psychology Review*, 13(2), 139-156. <https://doi.org/10.1023/A:1009057102306>
- Golmakani, M. K. y Polley, E. C. (2020). Super learner for survival data prediction. *Journal Ff Biostatistics*, 16(2), 20190065. <https://doi.org/10.1515/ijb-2019-0065>
- Guo, J., Elliot, A. J., Marsh, H. W., Murayama, K., Basarkod, G., Parker, P. D. y Dicke, T. (2023). Mastery-approach goals: A large-scale cross-cultural analysis of antecedents and consequences. *Journal of Personality and Social Psychology*, 125(2), 397-420. <https://doi.org/10.1037/pspp0000436>
- Harackiewicz, J. M., Barron, K. E., Carter, S. M., Lehto, A. T. y Elliot, A. J. (1997). Predictors and consequences of achievement goals in the college classroom: Maintaining interest and making the grade. *Journal of Personality and Social Psychology*, 73(6), 1284-1295. <https://doi.org/10.1037/0022-3514.73.6.1284>
- Hastie, T., Tibshirani, R. y Friedman, J. (2009). *The Elements of Statistical Learning*. Springer New York. <https://doi.org/10.1007/978-0-387-84858-7>

- Hilbert, S., Coors, S., Kraus, E., Bischl, B., Lindl, A., Frei, M., Wild, J., Krauss, S., Goretzko, D. y Stachl, C. (2021). Machine learning for the educational sciences. *Review of Education*, 9(3), e3310. <https://doi.org/10.1002/rev3.3310>
- Jaitner, D., Rinas, R., Becker, C., Niermann, C., Breithecker, J. y Mess, F. (2019). Supporting Subject Justification by Educational Psychology: A Systematic Review of Achievement Goal Motivation in School Physical Education. *Frontiers in Education*, 4. <https://www.frontiersin.org/articles/10.3389/feduc.2019.00070>
- Janiesch, C., Zschech, P. y Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jiang, H. (2021). *Machine Learning Fundamentals: A Concise Introduction*. Cambridge University Press. <https://doi.org/10.1017/9781108938051>
- Jung, A. (2022). *Machine Learning: The Basics*. Springer Nature. <https://doi.org/10.1007/978-981-16-8193-6>
- Kingma, D. P. y Ba, J. (2015). *Adam: A Method for Stochastic Optimization*. 1-15. <http://arxiv.org/abs/1412.6980>
- Li, Q., Zhao, J., Tian, J., Sun, T., Zhao, C., Guo, H., Zhu, L., Gao, R., Yang, L., Cao, D. y Zhang, S. (2021). The Association Among Achievement Goal Orientations, Academic Performance, and Academic Well-Being Among Chinese Medical Students: A Cross-Sectional Study. *Frontiers in Psychology*, 12. <https://www.frontiersin.org/articles/10.3389/fpsyg.2021.694019>
- Luan, H. y Tsai, C.-C. (2021). A Review of Using Machine Learning Approaches for Precision Education. *Educational Technology y Society*, 24(1), 250-266. JSTOR.

- Lyre, H. (2020). The State Space of Artificial Intelligence. *Minds and Machines*, 30(3), 325-347. <https://doi.org/10.1007/s11023-020-09538-3>
- Montesinos, O. A., Montesinos, A. y Crossa, J. (2022). *Multivariate Statistical Machine Learning Methods for Genomic Prediction*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-89010-0>
- OECD. (2019). *PISA 2018 Results (Volume III)*. <https://doi.org/10.1787/acd78851-en>
- OECD. (2020). *PISA 2018 Results (Volume VI)*. <https://doi.org/10.1787/d5f68679-en>
- Quiñonez-Tapia, F. y Vargas-Garduño, M. de L. (2023). Entusiasmo del profesorado, Instrucción Adaptativa y Metas de Aproximación al Dominio desde el punto de vista de estudiantes de Secundaria. *Revista de Investigación en Educación*, 21(3), 451-465. <https://doi.org/10.35869/reined.v21i3.4981>
- Rickert, N. P. y Skinner, E. A. (2022). Parent and teacher involvement and the development of students' academic engagement: A growth curve analysis over four time points. *Journal of Adolescence*, 94(2), 224-239. <https://doi.org/10.1002/jad.12019>
- Spence, J. T. y Helmreich, R. L. (1983). Achievement-related motives and behavior. En *Achievement and achievement motives: Psychological and sociological approaches* (pp. 10-74). Freeman.
- Steger, M. F. (2009). Meaning in Life. En S. J. Lopez y C. R. Snyder (Eds.), *The Oxford Handbook of Positive Psychology* (p. 0). Oxford University Press. <https://doi.org/10.1093/oxfordhb/9780195187243.013.0064>

- Steger, M. F. y Dik, B. J. (2009). If One is Looking for Meaning in Life, does it Help to Find Meaning in Work? *Applied Psychology: Health and Well-Being*, 1(3), 303-320. <https://doi.org/10.1111/j.1758-0854.2009.01018.x>
- Torra, V., Karlsson, A., Steinhauer, H. J. y Berglund, S. (2019). Artificial Intelligence. En A. Said y V. Torra (Eds.), *Data Science in Practice* (pp. 9-26). Springer International Publishing. [https://doi.org/10.1007/978-3-319-97556-6\\_2](https://doi.org/10.1007/978-3-319-97556-6_2)
- van der Laan, M. J., Polley, E. C. y Hubbard, A. E. (2007). *Super Learner*. 6(1). <https://doi.org/10.2202/1544-6115.1309>
- Webb, M. E., Fluck, A., Magenheim, J., Malyn-Smith, J., Waters, J., Deschênes, M. y Zagami, J. (2021). Machine learning for human learners: Opportunities, issues, tensions and threats. *Educational Technology Research and Development*, 69(4), 2109-2130. <https://doi.org/10.1007/s11423-020-09858-2>