



# Aplicación de Machine Learning para predecir y explicar el rendimiento académico universitario

## Application of Machine Learning to Predict and Explain University Academic Performance

Fabricio Vladimir Vinces-Vinces\*, Universidad Politécnica Estatal del Carchi y Universidad Nacional de Loja (Ecuador) (fabricio.vinces@unl.edu.ec)  
(<https://orcid.org/0000-0002-5912-6367>)  
Miguel Flores-Sánchez, Universidad Politécnica Nacional (Ecuador) (miguel.flores@epn.edu.ec)  
(<https://orcid.org/0000-0002-7742-1247>)

### RESUMEN

En el ámbito educativo, el rendimiento académico representa los resultados de procesos de evaluación y se relaciona con logros de aprendizaje. La identificación temprana de los factores que influyen en el rendimiento permite orientar intervenciones oportunas para prevenir la repitencia y el abandono estudiantil. Ante esto, la investigación tuvo como propósito aplicar modelos de Machine Learning para predecir y explicar el rendimiento académico, enfocándose particularmente en estudiantes con antecedentes de reprobación. Se utilizó un enfoque cuantitativo, con diseño no experimental y análisis ex post facto, basado en una población de 12211 estudiantes universitarios. La información se recopiló mediante un cuestionario de 32 ítems sobre aspectos sociodemográficos, socioeconómicos, emocionales, institucionales-académicos, autoeficacia y autocontrol, anclado a la opción matrícula del estudiante, y una base institucional con siete variables académicas. Se entrenaron tres algoritmos de clasificación supervisada: Random Forest, XGBoost y CatBoost. Además, se utilizó el método SHAP para interpretar los resultados del modelo. El procesamiento y análisis se realizó en Python utilizando Google Colab. CatBoost mostró el mejor desempeño, alcanzando un recall del 70 % para la clase "reprobada". Los indicadores más influyentes fueron: facultad, carrera, nivel o ciclo, estado emocional, atención docente y desempeño académico previo. Se concluye que la reprobación está influenciada, por variables académicas-institucionales, seguidas de emocionales, sociodemográficas y socioeconómicas; y, se destaca el valor del Machine Learning interpretativo (SHAP) para apoyar la toma de decisiones educativas.

### ABSTRACT

In the educational field, academic performance represents the outcomes of evaluation processes and is related to students' learning achievements. Early identification of the factors that influence performance allows for timely interventions to prevent course repetition and student dropout. In this regard, the objective of this study was to apply machine learning models to predict and explain academic performance, with a particular focus on students with a history of failing at least one course. A quantitative approach was used, with a non-experimental, ex post facto design, based on a population of 12,211 university students. Data were collected through a 32-item questionnaire covering sociodemographic, socioeconomic, emotional, institutional-academic, self-efficacy, and self-control aspects, linked to the student enrollment system, as well as an institutional database with seven academic variables. Three supervised classification algorithms were trained: Random Forest, XGBoost, and CatBoost. In addition, the SHAP method was used to interpret the model's outputs. Data processing and analysis were conducted using Python in the Google Colab environment. CatBoost showed the best performance, achieving a 70% recall for the "failed" class. The most influential indicators were faculty, academic program, academic level or cycle, emotional state, teacher support, and previous academic performance. It is concluded that academic failure is influenced primarily by institutional-academic variables, followed by emotional, sociodemographic, and socioeconomic factors. The value of interpretable machine learning (SHAP) is highlighted as a tool to support educational decision-making.

### PALABRAS CLAVE | KEYWORDS

Factores afectivos, inteligencia artificial, autocontrol, rendimiento académico, estudiantes universitarios, factores académicos  
Affective Factors, Artificial Intelligence, Self-control, Academic Performance, University Students, Academic Factors.

## 1. Introducción

La educación es el medio principal para el desarrollo integral del ser humano. La calidad de vida de las personas, en gran medida, está condicionada por la educación que esta reciba o haya recibido. Por lo que uno de los indicadores que permite tener evidencia sobre cuan bueno es un sistema educativo, es lo denominado rendimiento o desempeño académico de los estudiantes. Si bien el rendimiento académico es un constructo, un indicador de este es la suma de resultados de evaluaciones que un país u organismos aplican a los principales autores del ámbito educativo (Alam y Islam, 2022; Dorta-Guerra et al., 2019). Este concepto ha motivado investigaciones enmarcadas en detectar y cuantificar los factores que inciden sobre él, estas se describen en los apartados siguientes.

La educación universitaria está influenciada por diversos factores. En Bangladesh, Alam y Islam (2022) con información reportada por ochocientos estudiantes de dos universidades públicas, aplicando métricas estadísticas robustas, muestran que, entre los factores analizados, el nivel de educación y la profesión de los padres son fuertes predictores del rendimiento académico, adicionalmente, destacan que el buen uso de internet mejora el progreso académico del estudiante.

En España, Dorta-Guerra et al. (2019) demuestran que el mejor predictor del éxito académico de estudiantes universitarios en el su primer año de estudio, es el promedio de la calificación obtenida en bachillerato. Estos autores proponen un modelo lineal de regresión múltiple para identificar a estudiantes con riesgo de fracaso escolar y finalmente, consideran necesario la implementación de estrategias para aumentar el rendimiento académico. En la investigación de Xiang, Wan y Zhou (2019) concluyen que el aprendizaje se ve afectado por los métodos de enseñanza, entorno de aprendizaje, el apoyo afectivo de los profesores, entre otros. En Arteaga y Sandoval (2018), destacan como factor determinante la hora de inicio de clases, según estos autores, después de las 11am los estudiantes rinden mejor.

En Ecuador, Borja Naranjo et al. (2021) mediante un proceso cualitativo concluyen que la escasez económica, ser cabeza de hogar, las relaciones familiares, nivel de educación de la madre, las amistades y complejidad de la malla curricular, tienen gran incidencia en el logro de aprendizajes. En este país, el estudio de Poveda Garcés et al. (2023) encuentra que los factores relacionados con el rendimiento académico, que más se han analizado son: sociales, económicos, personales, académicos, institucionales y motivacionales.

Los párrafos anteriores explicitan que los factores sobre el rendimiento académico son diversos y estos condicionan la culminación de estudios. Según Bonilla-Marchán et al. (2020) en Ecuador, hay evidencia que la tasa de abandono de estudios de pregrado está entre el 12 % y 30 % en los tres primeros semestres.

En la provincia de Loja, Ecuador, se tiene evidencia que hay un alto porcentaje de estudiantes universitarios que reprueban asignaturas, esto se convierte en problemática importante en la educación. Por lo que esta investigación da respuesta a las siguientes preguntas: ¿Cuáles son las principales variables que impactan en el rendimiento académico de los estudiantes universitarios y que a partir de estas se pueda clasificarlos en aprobados y reprobados? ¿Cómo inciden las distintas variables en el rendimiento académico de los estudiantes universitarios? Entre todas las variables ¿Cuáles tienen mayor influencia en el rendimiento académico de los estudiantes universitarios?

Para dar respuesta a estas preguntas se trabajó con datos de 12211 estudiantes de una universidad pública de Ecuador, matriculados en el Periodo 2023-1(abril-agosto) de estos, 1541 reprobaron al menos una asignatura. Para obtener la información se aplicó un cuestionario con 32 ítems enmarcados en seis dimensiones: demográficos, socioeconómicos, académicos-institucionales, auto eficiencia, autocontrol y afectivos. La obtención de resultados se experimentó con tres algoritmos de clasificación de Machine Learning: XGBoost (Extreme Gradient Boosting), Random Forest (RF) y CatBoost (Categorical Boosting); y, para identificar el impacto de las variables, de manera interpretable, se utilizó el método de SHAP (SHapley Additive exPlanations).

Los resultados de esta investigación permiten la toma de decisiones informadas a los administradores de la educación universitaria, en el sentido que al identificar los factores que están causando pérdida de asignaturas, lo que puede ocasionar repitencia o abandono estudiantil se implementen programas que ayuden a mitigar dichos problemas. Por otro lado, aportará al cuarto Objetivo de Desarrollo sostenible (ODs), el cual busca una educación de calidad, así como al objetivo 7 del Plan Nacional de Desarrollo 2021-2025 de Ecuador, que pretende «potenciar las capacidades de la ciudadanía y promover una educación innovadora, inclusiva y de calidad en todos los niveles».

### 1.1. Rendimiento académico

La culminación de una carrera universitaria se asocia con el concepto de logro o éxito académico, y a la vez este se ve afectado por lo que se denomina rendimiento académico. Al expresar que un estudiante tiene bajo rendimiento implica que no aprueba ninguna materia, aprueba algunas materias o las aprueba con la mínima calificación. Lo antes mencionado resalta la importancia que tiene este concepto en el logro de una profesión.

El rendimiento académico también llamado desempeño académico (Sánchez et al., 2021) es resultado de «medir» procesos académicos. La intención de cuantificar o medir es inherente al ser humano. No es extraño que a lo largo de la historia se haya intentado medir lo que una persona sabe sobre un tema en particular. Según Alcaraz Salarirche (2016) esta intención data de 2000 a. C., encontrando mayor evidencia por el siglo V a. C. donde Sócrates y otros maestros utilizaron algo similar a lo que ahora llamamos cuestionarios; según este autor, por el siglo II a. C. en China, se utilizaban evaluaciones orales para selección de funcionarios.

El rendimiento académico trasciende con la llegada del modelo económico industrial, inicios del siglo XIX. Aquí se aplicaron métodos para la medición de la eficacia y desempeño de los trabajadores. Esto con el fin de seleccionar personal idóneo y así poder incrementar la productividad de calidad. Esta metodología con el pasar de los años se convirtió en el eje de muchos ámbitos, entre estos, el educativo (Morales Sánchez, Morales Sánchez y Holguín Quiñones, 2016). Dentro del ámbito educativo, el rendimiento académico representa los resultados obtenidos de procesos de evaluación y se lo relaciona con el logro de aprendizajes de los estudiantes.

La literatura muestra que no existe una definición general del constructo rendimiento académico. Sin embargo, la mayoría de los autores convergen que el rendimiento académico es el resultado del «aprendizaje, producto de la interacción didáctica y pedagógica entre el docente y estudiante» (Cardenas et al., 2020). Para Morales Sánchez et al. (2016) este concepto va «unido a la calidad y a la eficiencia del sistema y, de hecho, el rendimiento educativo se presenta normalmente, como un índice para valorar la calidad global del sistema...» (p.2). Estas acepciones revelan que este concepto tiene un carácter complejo y multidimensional.

Para este estudio, este concepto se lo relaciona con las calificaciones obtenidas por los estudiantes universitarios, teniendo claro que estas son resultado de factores endógenos, exógenos, entre otros. En Ecuador, para aprobar una asignatura o para obtener cualquier título académico se tiene que lograr una calificación de 7 sobre 10.

### 1.2. Dimensiones que inciden en el rendimiento académico

Autoeficacia, es uno de los mejores predictores del éxito académico. Se define como la creencia propia de poder hacer algo. En contexto universitario, viene a ser la creencia intrínseca del estudiante sobre su capacidad para abordar con éxito las diferentes actividades académicas (Alegre, 2014; González-Benito et al., 2021; Putwain, Sander y Larkin, 2013; Stajkovic et al., 2018; Tumino et al., 2020; Zimmerman, 2000).

Motivación, está relacionada con el logro, los estudiantes con mayor necesidad de logro tienen mayor rendimiento académico. Esta puede ser extrínseca o intrínseca, teniendo un mayor peso la segunda (Poveda Garcés et al., 2023; Steinmayr et al., 2019).

Autocontrol, en el ámbito académico, está relacionado con la autodisciplina, la autorregulación, el retraso de la gratificación y el control de los impulsos. El autocontrol es la capacidad de priorizar objetivos a largo plazo sobre la tentación de los impulsos a corto plazo. Aquí entra la procrastinación académica, que referencia al patrón de conducta caracterizado por la postergación de tareas, con el conocimiento previo de que tal comportamiento traerá repercusiones o consecuencias negativas (Duckworth et al., 2019; Sanchez Leon, 2023; Zumárraga-Espinosa y Cevallos-Pozo, 2022).

Actividades físicas, esta dimensión incluye la cantidad de ejercicio físico diario que realiza el estudiante. Hay evidencia de que los estudiantes que hacen ejercicio durante 60 minutos al día logran altos niveles de salud y rendimiento mental (Donnelly y Lambourne, 2011; González et al., 2023; Muñoz-Bullón, Sanchez-Bueno y Vos-Saz, 2017; Romanova et al., 2023).

Salud del sueño, la calidad y la cantidad de sueño se relacionan con la capacidad de aprendizaje y el rendimiento académico. El sueño insuficiente genera falta de atención, provoca habilidades académicas deficientes y esto repercute en el progreso académico (Arteaga y Sandoval, 2018; Sofyana, Wibowo y Agustiniingsih, 2022).

Socioeconómica, esta dimensión incluye variables que combinan aspectos sociales y económicos en las personas o grupos. Es ampliamente utilizada para analizar el rendimiento académico estudiantil (Bonilla-

Marchán et al., 2020; Borja Naranjo et al., 2021; Cardenas et al., 2020; Palacio Sprockel, Vargas Babilonia y Monroy Toro, 2020; Rodríguez-Hernández et al., 2021). Una variable trascendente en esta dimensión es el ingreso económico en la familia del estudiante.

Sociodemográfica, esta dimensión combina factores sociales y demográficos. En varias investigaciones utilizan las diferentes variables de esta dimensión, como covariables o variables intervinientes del rendimiento académico. Se destaca que estudiantes que provienen del sector rural, en los primeros años de universidad, presentan dificultades en el rendimiento académico (Abu Saa, Al-Emran y Shaalan, 2019; Al-Tameemi et al., 2023; Alam y Islam, 2022; Masa'Deh et al., 2021; Rodríguez-Hernández et al., 2021).

Afectiva, esta dimensión en sí misma es un constructo complejo y multidimensional. Uno de los pioneros en estudiar esta dimensión relacionándola con el aprendizaje, fue McLeod (1989, 1992). Este la define como la composición de creencias, actitudes y emociones. Los trabajos referenciados, destacan el impacto de las emociones en el rendimiento y éxito académico (Acosta-Gonzaga y Ramirez-Arellano, 2021; Alipour et al., 2024; Earl et al., 2024; Grøtan, Sund y Bjerkeset, 2019; Koppad, Gadad y Patil, 2023; Pekrun, 2024; Quílez-Robres et al., 2023; Tan et al., 2023; Viloría Hernández, Marquez Ortega y Santillan Briceño, 2020; Vitasari et al., 2010; Zhang, Peng y Chen, 2024).

Académica, esta dimensión también se analiza en diversos estudios como pedagógica o institucional. Está relacionada con factores externos al estudiante. En esta se incluyen variables como: ambientes de aprendizaje, acompañamiento académico, relación docente-estudiante, clima de aula, enseñanza del docente, notas de postulación a la universidad, entre otras (Alam y Islam, 2022; Borja Naranjo et al., 2021; Cardenas et al., 2020; Garbanzo Vargas, 2007; Gutiérrez-Monsalve, Garzón y Segura-Cardona, 2021; Martín Pavón, Sevilla Santo y Jenaro Río, 2018; Poveda Garcés et al., 2023; Rodríguez-Hernández, Kyndt y Cascallar, 2023; Rodríguez-Hernández et al., 2021). En este trabajo, se la denominó como académica-institucional.

Cognitiva, esta dimensión se relaciona con la memoria, con los procesos de adquisición de conocimiento, con el razonamiento, con el lenguaje, con la capacidad del individuo para asumir experiencias, entre otras (Barrera Hernández et al., 2020; Colom et al., 2007; Dodonova y Dodonov, 2012; Han et al., 2023; Molnár y Kocsis, 2023; Ren et al., 2020; Shi y Qu, 2022a, 2022b).

Es evidente que el rendimiento académico es un constructo que resulta de dimensiones complejas, tal como lo define Garbanzo Vargas (2007, p. 46), «El rendimiento académico es la suma de diferentes y complejos factores que actúan en la persona que aprende». Por lo que, se puede deducir que todos estos factores definen el estado del rendimiento académico de los estudiantes universitarios, que puede ser de manera general, aprobado o reprobado.

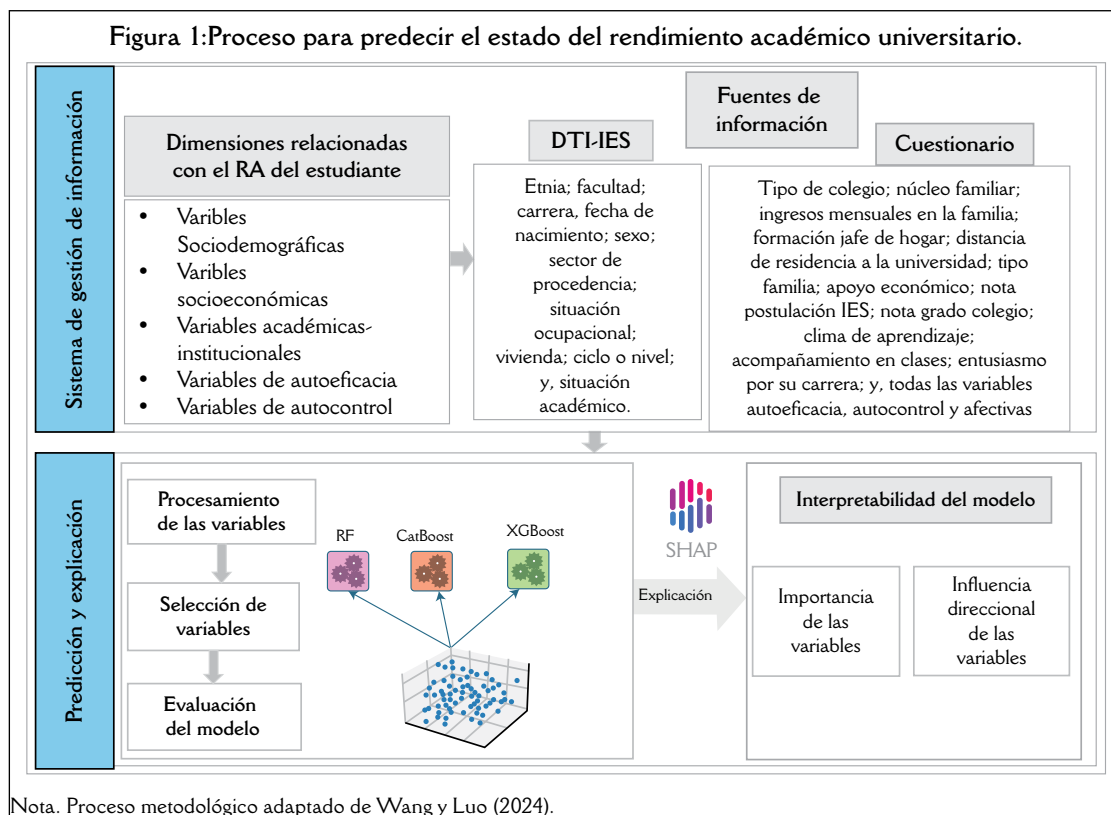
### 1.3. Modelos predictivos del rendimiento académico

Las primeras etapas de la investigación educativa se fundamentaron en métodos estadísticos convencionales, como ANOVA y regresiones. Además, el Modelado de Ecuaciones Estructurales (SEM) ha sido y sigue siendo ampliamente utilizado en investigaciones de índole educativo (Kocsis y Molnár, 2024; Molnár y Kocsis, 2023). Sin embargo, estos métodos a menudo han enfrentado limitaciones para hacer predicciones o clasificaciones confiables y precisas. En la actualidad, con el avance tecnológico se han empleado técnicas o algoritmos de Machine Learning, entre estos, árboles de decisión, redes neuronales, bosques aleatorios, algoritmos genéticos, algoritmos bayesianos, algoritmos de ensamble, SVM (Support Vector Machine), entre otros (Rodríguez-Hernández et al., 2021). Ante esta variedad de algoritmos, hay evidencia que XGBoost, Random Forest (RF) y CatBoost han arrojado buenas métricas de clasificación en contextos de rendimiento académico de estudiantes universitarios. Y un complemento interpretativo de estos algoritmos es el método SHapley Additive exPlanations (SHAP) (Calva Yaguana, 2020; Wang y Luo, 2024).

## 2. Metodología

La Figura 1 presenta la secuencia del proceso implementado para predecir el rendimiento académico, categorizado en dos clases: aprobado y reprobado. El procedimiento se inicia con la selección de dimensiones para las cuales se dispone de información: sociodemográfica, socioeconómica, académica-institucional, autoeficacia, autocontrol y aspectos afectivos. Aunque la revisión de la literatura sugiere otras dimensiones relevantes, este estudio se enfoca exclusivamente en las mencionadas. Los datos fueron recolectados a partir de dos fuentes: siete variables provenientes del Departamento de Tecnologías de la Información

(DTI) de la Institución de Educación Superior (IES) y 32 variables obtenidas mediante un cuestionario. Cabe señalar que el instrumento fue validado por expertos y sometido a prueba piloto para evaluar su consistencia interna, alcanzando un coeficiente de 0.76, medido mediante el alfa de Cronbach. Sin embargo, no se realizó una validación de constructo formal, dado que el objetivo del cuestionario fue recolectar variables observables con fines predictivos más que inferir dimensiones latentes.



El proceso de la Figura 1 avanzó en tres fases. La primera fase, selección de dimensiones y variables; la segunda fase, se centró en la implementación y ejecución de las tres técnicas de ML, esto en el entorno de Colab. Dado que el interés fue clasificar el estado académico del estudiante se evaluaron aplicando cuatro métricas de efectividad estándares de ML: Precision, Recall, F1-Score y Accuracy. En función de estas métricas se seleccionó el modelo óptimo; la fase final, es la de interpretabilidad del modelo, reflejando la importancia e influencia o impacto y dirección de las variables.

## 2.1. Selección de dimensiones y variables

La revisión de literatura evidencia diez dimensiones que constituyen el estado de rendimiento académico de los estudiantes, para este estudio se seleccionaron seis. A diferencia de otros estudios, aquí se analizan en conjunto. En la Tabla 1 se detallan las dimensiones con sus ítems. Ver información en el siguiente DOI externo <https://doi.org/10.6084/m9.figshare.28136354.v1>.

Con la combinación de los datos de las 39 variables que se detallaron en la Tabla 1, las técnicas de ML predicen el estado de rendimiento académico de los estudiantes. Las variables forman una matriz de vectores de entrada  $n$  por  $k$ , donde  $n$  es el número de individuos y  $k$  el número de variables, esta matriz se define como:

$$X = \begin{bmatrix} x_{1,1} & \cdots & x_{1,k} \\ \vdots & \ddots & \vdots \\ x_{n,1} & \cdots & x_{n,k} \end{bmatrix}; f(X) \approx Y_i$$

Donde:  $f(X)$  es la técnica de ML empujado; la  $X$  es la matriz de características; cada fila  $i$  es el vector de características de un individuo; la columna corresponde a las variables.  $Y_i$  es la variable por predecir, estado del rendimiento estudiantil (Aprobado o Reprobado). Este caso, es una variable dicotómica, con categorías o clases, aprobado o reprobado.

## 2.2. Entrenamiento y selección de modelo

Los algoritmos o técnicas de ML han sido utilizados para predecir rendimiento académico, por lo que se justifica seleccionar a RF, CatBoost y XGBoost. Y para interpretación se empleó SHAP, este método es independiente del algoritmo de ML. Random Forest, combina múltiples árboles de decisión, mejorando la precisión y reduciendo el sobreajuste mediante promedios o votación mayoritaria. CatBoost, Algoritmo que maneja eficazmente variables categóricas y es robusto frente a datos desbalanceados. XGBoost, Modelo que añade regularización para evitar sobreajuste, se destaca por su velocidad y precisión en problemas de clasificación y regresión. SHAP, Este método fusiona varios enfoques para proporcionar una explicación intuitiva del modelo. Se basa en la teoría de juegos (Lundberg et al., 2020).

Al aplicar las técnicas, es decir, ajustando parámetros y utilizando los datos, se habla de modelos. Para evaluar y seleccionar el modelo más pertinente se aplicaron 4 métricas: precisión, recall, f1-score y accuracy. En la Tabla 2 se describen a cada uno.

Precisión	Recall	F1-score	Accuracy
$\text{Precisión} = \frac{TP}{TP + FP}$ <p><b>TP:</b> Verdadero Positivos <b>FP:</b> Falsos Positivos Esta métrica se refiere a la proporción de verdaderos positivos.</p>	$\text{Recall} = \frac{TP}{TP + FN}$ <p><b>FN:</b> Falsos Negativos, es decir, son las instancias que fueron incorrectamente clasificadas como negativas. Mide la proporción de verdaderos positivos frente al total de casos realmente positivos.</p>	$F1 - score = 2 \times \frac{\text{Precisión} \times \text{Recall}}{\text{Precisión} + \text{Recall}}$ <p>Es la media armónica entre precisión y recall. Útil cuando hay desbalance entre clases.</p>	$\text{Acu} = \frac{TP + TN}{TP + TN + FP + FN}$ <p>Mide la proporción de predicciones correctas, tanto TP como TN, sobre el total de predicciones.</p>

## 2.3. Aplicación del modelado

Los datos para esta investigación corresponden a información de 12211 estudiantes de una universidad pública de Ecuador, correspondientes a cinco facultades y a 47 carreras. Estos se obtuvieron de dos fuentes: del Departamento de Tecnología e Información (DTI) de la universidad y mediante un cuestionario que se ancló al sistema de registro de matrícula del estudiante; los datos corresponden a las variables que se explicitaron en la Tabla 1. Para la aplicación del modelado se utilizó como principal biblioteca a Scikit-learn del software Python, entre otras. Se dividió de manera aleatoria a los datos en un 75 % para entrenamiento y validación y el 25 % restante para prueba. Cabe indicar que en esta investigación no se trabajó con una muestra, ya que se aplicó el cuestionario a la totalidad de la población objetivo (N=12 211), es decir, a todos los estudiantes matriculados en la IES durante el periodo de estudio. Por tanto, no se realizó un cálculo muestral, y el análisis se basa en datos poblacionales. Esta decisión permitió evitar los errores de estimación asociados a la inferencia muestral y proporcionó una visión más completa de las relaciones entre las variables analizadas. Además, al utilizar modelos de Machine Learning, disponer de un alto volumen de datos y un mayor número de variables favorece la precisión predictiva y la capacidad explicativa de los modelos entrenados.

## 3. Resultados

De los modelos de ML implementados, el algoritmo CatBoost presentó el mejor desempeño en la clasificación de la clase “reprobada”, priorizando la métrica de recall (sensibilidad), clave en estudios donde interesa minimizar los falsos negativos. En el conjunto de prueba, CatBoost alcanzó un recall del 70 %, es decir, identificó correctamente a 7 de cada 10 estudiantes reprobados. Esta capacidad predictiva es relevante en contextos educativos donde la intervención oportuna puede reducir el riesgo de abandono estudiantil.

La Tabla 3 resume el rendimiento de los modelos Random Forest, XGBoost y CatBoost, diferenciando entre datos de entrenamiento y prueba, y reportando métricas como precisión, recall, F1-score, exactitud (accuracy) y el número de observaciones por clase (support). En todos los modelos, el desempeño en datos



de prueba fue inferior al de entrenamiento, lo cual es esperable y evidencia generalización moderada. CatBoost mostró la mayor robustez por su recall para la clase minoritaria.

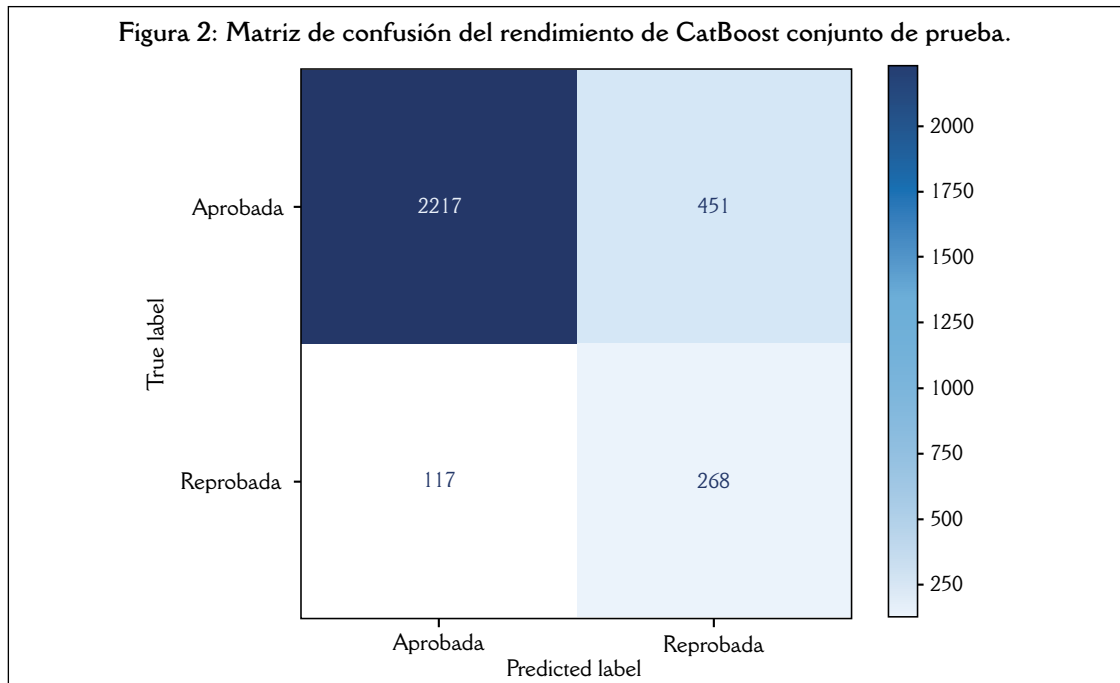
**Tabla 3: Rendimiento de cada uno de los modelos de ML utilizados.**

Modelo	Conjunto	Precisión (A/R)	Recall (A/R)	F1-Score (A/R)	Accuracy	Support
XGBoost	Entrenamiento	0.93/0.87	0.86/0.94	0.90/0.90	0.90	16004
RandomForest		0.96/0.38	0.81/0.78	0.88/0.51	0.81	9158
CatBoost		0.98/0.45	0.85/0.89	0.91/0.60	0.85	9158
XGBoost	Prueba	0.93/0.36	0.86/0.54	0.89/0.43	0.82	3053
RandomForest		0.94/0.31	0.80/0.63	0.86/0.42	0.78	3053
CatBoost		0.95/0.37	0.83/0.70	0.89/0.49	0.81	3053

Nota. XGBoost fue entrenado con el método SMOTE (Synthetic Minority Over-sampling Technique), de ahí que tiene 16004 instancias(support) en entrenamiento. Los valores A/R indican resultados para las clases Aprobada (A) y Reprobada(R), respectivamente.

Para comprender la métrica Recall, se coloca esta analogía: Contexto, 3 paralelos de 30 estudiantes. De estos supongamos que se sabe que reprueban 20 de 90, entonces, Recall del modelo CatBoost, es capaz de identificar 14 correctamente (70 % de 20). Los 6 restantes corresponden a falsos negativos. La Tabla 3 muestra los resultados de la predicción de cada uno de los modelos, pero no muestra los indicadores que tienen mayor influencia en dicha predicción. Para identificar estos indicadores se utilizó el modelo interpretativo SHAP, cuyos resultados se explicitan a partir de la Sección 3.1.

La Figura 2 presenta la matriz de confusión que evidencia tanto los verdaderos positivos como los errores del modelo. A pesar de los 117 falsos negativos, el modelo sigue siendo útil para priorizar estrategias preventivas.

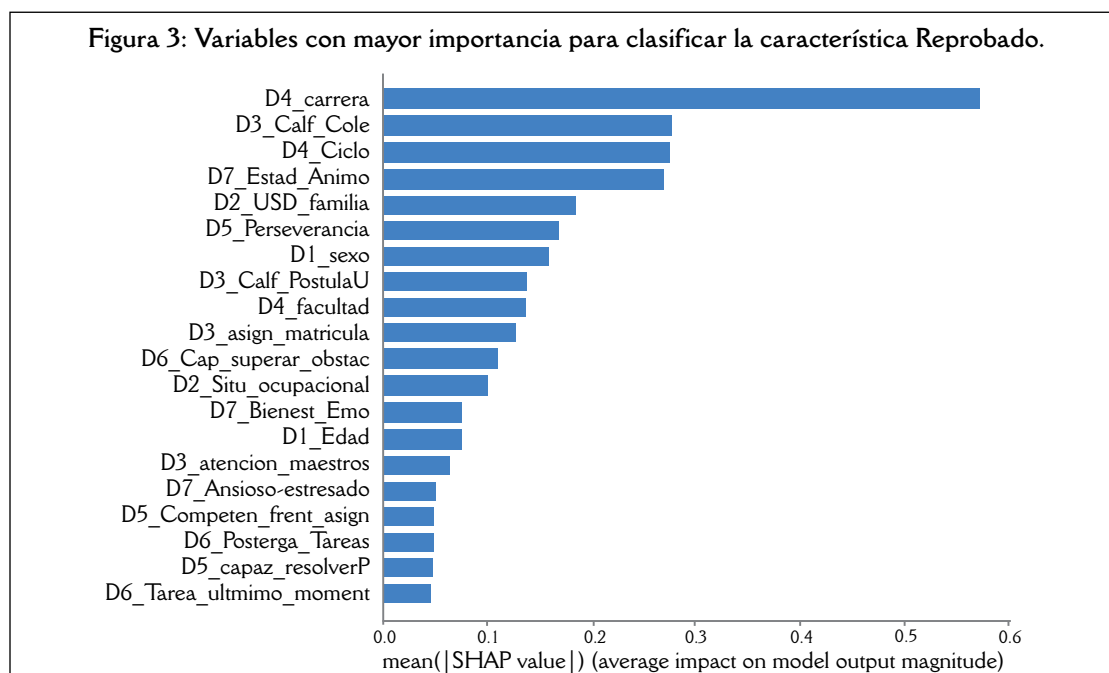


La matriz de confusión obtenida para el modelo CatBoost en el conjunto de prueba muestra un desempeño aceptable en la identificación de estudiantes reprobados, que es la clase de interés. El modelo clasificó correctamente a 268 estudiantes como reprobados (verdaderos positivos) y a 2217 estudiantes como aprobados (verdaderos negativos). Sin embargo, aún presenta 451 falsos positivos, es decir, estudiantes que aprobaron, pero fueron clasificados incorrectamente como reprobados, y 117 falsos negativos, estudiantes reprobados clasificados erróneamente como aprobados. En términos de sensibilidad (recall), el modelo

alcanza un 70 % para la clase “reprobada”, lo cual sugiere que logra identificar a la mayoría de los estudiantes reprobados, aunque persisten ciertos errores en la clasificación que podrían optimizarse.

### 3.1. Interpretabilidad del modelo CatBoost con SHAP

Para entender qué factores están detrás de las predicciones de la Tabla 3, se empleó el método SHAP. Este indica qué variables tienen mayor impacto en las predicciones del modelo, sin importar si ese impacto es positivo o negativo. La Figura 3 muestra un gráfico de barras con las variables de mayor impacto. Las más influyentes fueron: carrera, calificación del colegio, ciclo académico, estado de ánimo, ingresos familiares y perseverancia.

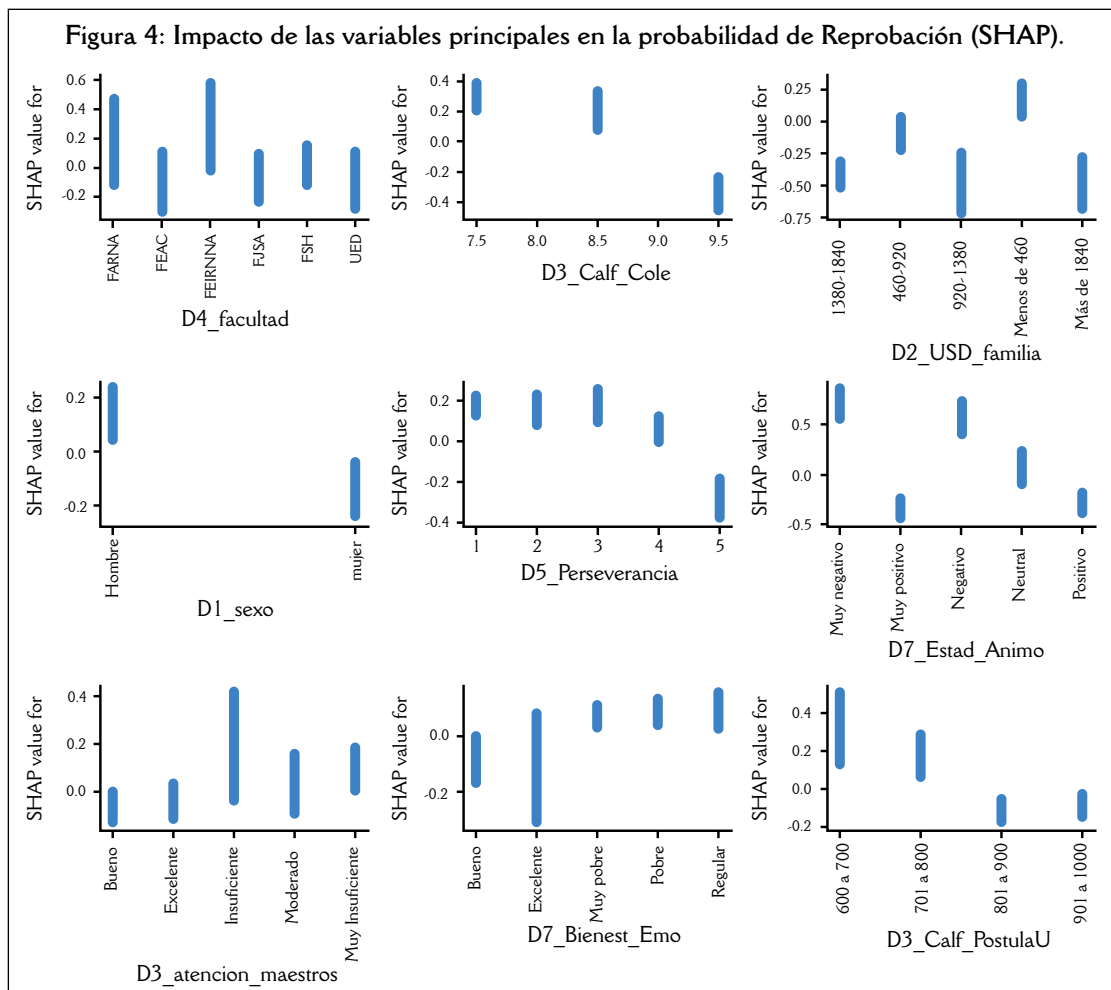


La Figura 3 permite identificar qué variables tienen una mayor influencia en las predicciones del modelo, para la clase reprobado. En general muestra que las dimensiones socioeconómicas, emocionales y de rendimiento académico previo, juegan un papel importante en el modelo, lo que sugiere que los factores derivados de estas están relacionados con la probabilidad de éxito o fracaso académico de los estudiantes.

De manera particular, se puede interpretar las seis primeras variables de la siguiente manera: D4\_carrera, variable con mayor impacto en el modelo, lo que sugiere que el tipo de carrera está fuertemente relacionado con el rendimiento académico o la probabilidad de reprobación; D3\_Calf\_Cole, la calificación del colegio tiene un impacto significativo, lo que indica que el rendimiento previo del estudiante en el colegio es buen predictor de su rendimiento académico actual; D4\_Ciclo, también tiene una gran influencia en la predicción. Esto podría reflejar la dificultad de ciertos ciclos o niveles académicos; D7\_Estad\_Animo, el estado de ánimo del estudiante afecta de manera considerable el rendimiento académico, lo que podría estar relacionado con factores emocionales; D2\_USD\_familia, el ingreso familiar en USD es relevante, lo que sugiere que el contexto socioeconómico del estudiante tiene un impacto en su rendimiento académico; D5\_Perseverancia, la perseverancia es una característica importante, lo que indica que los estudiantes con una actitud perseverante tienden a rendir mejor.

La Figura 4 es una trama de gráficos que muestran la dependencia de la variable objetivo frente a 9 variables de la Figura 3. En el eje vertical de la izquierda, el valor de SHAP indica el impacto en la probabilidad de la variable en clase de interés, reprobada. Si los puntos azules de alguna característica de la variable están hacia la parte positiva, indica que tiene alto impacto para la reprobación. Por su parte, si está hacia la parte negativa disminuye ese riesgo.





Las distintas facultades influyen de forma diversa en la probabilidad de reprobación. Facultades como FARNA (Facultad Agropecuaria y Recursos Naturales Renovables), FEIRNNA (Facultad de Energía y Recursos Naturales No Renovables) y FSH (Facultad de Salud Humana) se asocian con un mayor riesgo de reprobación, mientras que las demás indican lo contrario. Asimismo, las calificaciones altas del colegio y en la nota de postulación universitaria están relacionadas con una menor probabilidad de reprobación, mientras que calificaciones bajas en estos contextos aumentan dicho riesgo. En términos de ingreso familiar, los estudiantes de familias con menores ingresos muestran mayor riesgo de reprobación. El modelo también sugiere que las mujeres tienen menor riesgo de reprobación en comparación con los hombres. Además, baja perseverancia y poco bienestar emocional impactan en la reprobación. Por otro lado, un estado de ánimo negativo y una percepción insuficiente de la atención que dan los profesores incrementa el riesgo de reprobación, mientras que un estado de ánimo positivo y una buena percepción de la atención docente reducen dicho riesgo.

#### 4. Discusión y Conclusiones

Son diversas las variables que inciden en el rendimiento académico universitario, estas repercuten tanto en el éxito como en el fracaso estudiantil. Los hallazgos confirman que el rendimiento académico no es un fenómeno exclusivamente cognitivo, está influenciado por un conjunto de variables socioeconómicas, académicas-institucionales y emocionales. En línea con estudios previos, factores emocionales como el estado de ánimo y el bienestar tienen un papel determinante en el desempeño estudiantil (Alipour et al., 2024; Earl et al., 2024; Koppad et al., 2023; Pekrun, 2024; Rodríguez-Hernández et al., 2021). Asimismo,

variables académicas-institucionales como carrera, facultad, ciclo y calificaciones previas a la universidad, también son relevantes, esto coincide con evidencias reportadas por Tan et al. (2023), Wang y Luo (2024) y Zhang et al. (2024), que vinculan exigencias académicas con tasas de repitencia o deserción. La calificación del colegio y la nota de postulación inciden de manera directa al rendimiento académico. A mayor nota, mayor probabilidad de aprobar y viceversa.

Este estudio revela que las estudiantes mujeres presentan menor probabilidad de reprobación en comparación con sus pares varones. No obstante, investigaciones previas han señalado que las mujeres pueden experimentar mayores niveles de dificultades emocionales (Bacigalupe et al., 2020), lo cual parecería contradecir nuestros hallazgos, ya que, en nuestra muestra, un bienestar emocional regular, pobre o muy pobre se asocia con una mayor probabilidad de reprobación. Una posible explicación de esta aparente contradicción podría radicar en la habilidad diferencial para expresar y gestionar las emociones. Estudios como el de Fischer y LaFrance (2015) indican que las mujeres tienden a manifestar sus emociones con mayor facilidad, repercutiendo positivamente en su desempeño académico.

En este contexto y población de estudio, se evidencia que el modelo CatBoost, combinado con SHAP, no solo predice, sino que explica con precisión en este contexto y población de estudio qué variables están contribuyendo a la reprobación (Figura 3). La Figura 4 refleja que la atención que brindan los docentes a los estudiantes tributa a la categoría de reprobado. Este tipo de análisis permite diseñar sistemas de alerta temprana en las IES, con acciones diferenciadas por facultad, grupo sociodemográfico o estado emocional. Es decir, se incluya un modelo de ML, como CatBoost, que prediga la reprobación y se asignen profesionales expertos en los campos que corresponda para la atención direccionada al estudiante y oportuna. Esto permitirá bajar la tasa de repitencia y de abandono.

Como líneas futuras de investigación, se propone validar este modelo en otras universidades con características institucionales diversas. Además, se podría investigar la interacción entre factores intrínsecos y extrínsecos, como el estado emocional y la calidad del acompañamiento docente, para diseñar políticas educativas más integrales y personalizadas que promuevan el éxito académico.

## Referencias

- Abu Saa, A., Al-Emran, M. y Shaalan, K. (2019). Factors Affecting Students' Performance in Higher Education: A Systematic Review of Predictive Data Mining Techniques. *Technology, Knowledge and Learning*, 24(4), 567-598. <https://doi.org/10.1007/s10758-019-09408-7>
- Acosta-Gonzaga, E. y Ramirez-Arellano, A. (2021). The Influence of Motivation, Emotions, Cognition, and Metacognition on Students' Learning Performance: A Comparative Study in Higher Education in Blended and Traditional Contexts. *SAGE Open*, 11(2), 21582440211027561. <https://doi.org/10.1177/21582440211027561>
- Al-Tameemi, R. A. N., Johnson, C., Gitay, R., Abdel-Salam, A.-S. G., Hazaa, K. A., BenSaid, A., et al. (2023). Determinants of poor academic performance among undergraduate students—A systematic literature review. *International Journal of Educational Research Open*, 4, 100232. <https://doi.org/10.1016/j.ijedro.2023.100232>
- Alam, R. y Islam, R. (2022). Determinants of Academic Performance of the Students of Public Universities in Bangladesh. *Athens Journal of Education*, 9(4), 641-653. <https://doi.org/10.30958/aje.9-4-6>
- Alcaraz Salarirche, N. (2016). Aproximación Histórica a la Evaluación Educativa: De la Generación de la Medición a la Generación Ecléctica. *Revista Iberoamericana de Evaluación Educativa*, 8(1), 11-25. <https://doi.org/10.15366/rie2015.8.1.001>
- Alegre, A. A. (2014). Autoeficacia académica, autorregulación del aprendizaje y rendimiento académico en estudiantes universitarios iniciales. *Propósitos y Representaciones*, 2(1), 79-120. <https://doi.org/10.20511/pyr2014.v2n1.54>
- Alipour, N., Sangi, S., Babamiri, M. y Arman, P. (2024). Investigating the relationship between emotional intelligence and self-esteem with educational performance in paramedical students. *Medicina Clínica Práctica*, 7(1), 100398. <https://doi.org/10.1016/j.mcp.2023.100398>
- Arteaga, W. y Sandoval, J. (2018). Factores que intervienen en el rendimiento académico en la Universidad. *Acta Nova*, 8(4), 552-563. [http://www.scielo.org.bo/pdf/ran/v8n4/v8n4\\_a04.pdf](http://www.scielo.org.bo/pdf/ran/v8n4/v8n4_a04.pdf)
- Bacigalupe, A., Cabezas, A., Bueno, M. B. y Martín, U. (2020). El género como determinante de la salud mental y su medicalización. Informe SESPAS 2020. *Gaceta Sanitaria*, 34, 61-67. <https://doi.org/10.1016/j.gaceta.2020.06.013>
- Barrera Hernández, L. F., Vales-García, J. J., Sotelo-Castillo, M. A., Ramos Estrada, D. Y. y Ocaña Zúñiga, J. (2020). Variables cognitivas de los estudiantes universitarios: su relación con dedicación al estudio y rendimiento académico. *Psicumex*, 10(1), 61-74. <https://doi.org/10.36793/psicumex.v10i1.342>
- Bonilla-Marchán, A. M., Valdiviezo-Ortiz, J. A., Orosz, A. y Stefos, E. (2020). Estudiantes de pregrado en Ecuador: Un análisis de datos. *magis, Revista Internacional de Investigación en Educación*, 12(25), 187-204. <https://doi.org/10.11144/Javeriana.m12-25.used>
- Borja Naranjo, G. M., Martínez Benítez, J. E., Barreno Freire, S. N. y Haro Jácome, O. F. (2021). Factores asociados al rendimiento académico: Un estudio de caso. *Revista EDUCARE - UPEL-IPB - Segunda Nueva Etapa 2.0*, 25(3), 54-77. <https://doi.org/10.46498/reduipb.v25i3.1509>

- Calva Yaguana, K. P. (2020). *Modelo de predicción del rendimiento académico para el curso de nivelación de la Escuela Politécnica Nacional a partir de un modelo de aprendizaje Supervizado automatizado en R* [Tesis de Ingeniería Matemática]. <http://bibdigital.epn.edu.ec/handle/15000/20718>
- Cardenas, I., Vásquez, S., Verde, E. y Colque, E. (2020). Rendimiento académico: universo muy complejo para el quehacer pedagógico. *Muro de la Investigación*, 5(2), 53-65. <https://doi.org/10.17162/RMI.V5I2.1325>
- Colom, R., Escorial, S., Shih, P. C. y Privado, J. (2007). Fluid intelligence, memory span, and temperament difficulties predict academic performance of young adolescents. *Personality and Individual Differences*, 42(8), 1503-1514. <https://doi.org/10.1016/j.paid.2006.10.023>
- Dodonova, Y. A. y Dodonov, Y. S. (2012). Processing speed and intelligence as predictors of school achievement: Mediation or unique contribution? *Intelligence*, 40(2), 163-171. <https://doi.org/10.1016/j.intell.2012.01.003>
- Donnelly, J. E. y Lambourne, K. (2011). Classroom-based physical activity, cognition, and academic achievement. *Preventive Medicine*, 52, S36-S42. <https://doi.org/10.1016/j.ypmed.2011.01.021>
- Dorta-Guerra, R., Marrero, I., Abdul-Jalbar, B., Trujillo-González, R. y Torres, N. V. (2019). A new academic performance indicator for the first term of first-year science degrees students at La Laguna University: a predictive model. *FEBS Open Bio*, 9(9), 1493-1502. <https://doi.org/10.1002/2211-5463.12707>
- Duckworth, A. L., Taxer, J. L., Eskreis-Winkler, L., Galla, B. M. y Gross, J. J. (2019). Self-Control and Academic Achievement. *Annual Review of Psychology*, 70, 373-399. <https://doi.org/10.1146/annurev-psych-010418-103230>
- Earl, S. R., Bishop, D., Miller, K., Davison, E. y Pickerell, L. (2024). First-year students' achievement emotions at university: A cluster analytic approach to understand variability in attendance and attainment. *British Journal of Educational Psychology*, 94(2), 367-386. <https://doi.org/10.1111/bjep.12650>
- Fischer, A. y LaFrance, M. (2015). What Drives the Smile and the Tear: Why Women Are More Emotionally Expressive Than Men. *Emotion Review*, 7(1), 22-29. <https://doi.org/10.1177/1754073914544406>
- Garbanzo Vargas, G. M. (2007). Factores asociados al rendimiento académico en estudiantes universitarios, una reflexión desde la calidad de la educación superior pública. *Revista Educación*, 31(1), 43-63. <https://doi.org/10.15517/revedu.v31i1.1252>
- González-Benito, A., López-Martín, E., Expósito-Casas, E. y Moreno-González, E. (2021). Motivación académica y autoeficacia percibida y su relación con el rendimiento académico en los estudiantes universitarios de la enseñanza a distancia. *RELIEVE - Revista Electrónica de Investigación y Evaluación Educativa*, 27(2), 2. <https://doi.org/10.30827/relieve.v27i2.21909>
- González, W., Cerón, J., Fernández, E. y Mora, D. (2023). Relación entre el nivel de actividad física y el rendimiento académico en estudiantes de una institución universitaria. *Estudio multicéntrico. Retos*, 47, 775-782. <https://doi.org/10.47197/retos.v47.94795>
- Grøtan, K., Sund, E. R. y Bjerkeset, O. (2019). Mental Health, Academic Self-Efficacy and Study Progress Among College Students – The SHoT Study, Norway. *Frontiers in Psychology*, 10, 45. <https://doi.org/10.3389/fpsyg.2019.00045>
- Gutiérrez-Monsalve, J., Garzón, J. y Segura-Cardona, A. (2021). Factores asociados al rendimiento académico en estudiantes universitarios. *Formación Universitaria*, 14(1), 13-24. <https://doi.org/10.4067/S0718-50062021000100013>
- Han, J., Cui, N., Lyu, P. y Li, Y. (2023). Early-life home environment and child cognitive function: A meta-analysis. *Personality and Individual Differences*, 200, 111905. <https://doi.org/10.1016/j.paid.2022.111905>
- Kocsis, Á. y Molnár, G. (2024). Factors influencing academic performance and dropout rates in higher education. *Oxford Review of Education*, 51(3), 414-432. <https://doi.org/10.1080/03054985.2024.2316616>
- Koppad, S., Gadad, J. y Patil, P. (2023). Understanding the Influence of Student's Emotions in Academic Success. En *2023 2nd Edition of IEEE Delhi Section Flagship Conference (DELCON)* (pp. 1-6). IEEE. <https://doi.org/10.1109/DELCON57910.2023.10127402>
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., et al. (2020). From Local Explanations to Global Understanding with Explainable AI for Trees. *Nature Machine Intelligence*, 2(1), 56-67. <https://doi.org/10.1038/s42256-019-0138-9>
- Martín Pavón, M. J., Sevilla Santo, D. E. y Jenaro Río, C. (2018). Factores personales-institucionales que impactan el rendimiento académico en un posgrado en educación. *Revista de Investigación Educativa*, 27, 5-31. <https://doi.org/10.25009/CPUE.V0127.2556>
- Masa'Deh, R., AlAZzam, M., Al-Dweik, G., Masadeh, O., Hamdan-Mansour, A. M. y Basheti, I. A. (2021). Academic performance and socio-demographic characteristics of students: Assessing moderation effect of self-esteem. *International Journal of School & Educational Psychology*, 9(4), 318-325. <https://doi.org/10.1080/21683603.2021.1901811>
- McLeod, D. B. (1989). Beliefs, Attitudes, and Emotions: New Views of Affect in Mathematics Education. En D. B. McLeod y V. M. Adams (Eds.), *Affect and Mathematical Problem Solving: A New Perspective* (pp. 245-258). Springer New York. [https://doi.org/10.1007/978-1-4612-3614-6\\_17](https://doi.org/10.1007/978-1-4612-3614-6_17)
- McLeod, D. B. (1992). Research on affect in mathematics education: a reconceptualization. En G. Douglas (Ed.), *Handbook of research on mathematics teaching and learning. A project of the national council of teachers of mathematics* (pp. 575-596). The National Council of Teachers of Mathematics. <https://peterliljedahl.com/wp-content/uploads/Affect-McLeod.pdf>
- Molnár, G. y Kocsis, Á. (2023). Cognitive and non-cognitive predictors of academic success in higher education: a large-scale longitudinal study. *Studies in Higher Education*, 49(9), 1610-1624. <https://doi.org/10.1080/03075079.2023.2271513>
- Morales Sánchez, L. A., Morales Sánchez, V. y Holguín Quiñones, S. (2016). Rendimiento escolar. *Revista electrónica Humanidades, Tecnología y Ciencia del Instituto Politécnico Nacional*, 15, 1-5. [https://revistaelectronica-ipn.org/ResourcesFiles/Contenido/16/HUMANIDADES\\_16\\_000382.pdf](https://revistaelectronica-ipn.org/ResourcesFiles/Contenido/16/HUMANIDADES_16_000382.pdf)
- Muñoz-Bullón, F., Sanchez-Bueno, M. J. y Vos-Saz, A. (2017). The influence of sports participation on academic performance among students in higher education. *Sport Management Review*, 20(4), 365-378. <https://doi.org/10.1016/j.smr.2016.10.006>
- Palacio Sprockel, L. E., Vargas Babilonia, J. D. y Monroy Toro, S. L. (2020). Análisis bibliométrico de estudios sobre factores socioeconómicos en estudiantes universitarios. *Educación y Educadores*, 23(3), 355-375. <https://doi.org/10.5294/edu.2020.23.3.1>
- Pekrun, R. (2024). Control-Value Theory: From Achievement Emotion to a General Theory of Human Emotions. *Educational Psychology Review*, 36(3), 83. <https://doi.org/10.1007/s10648-024-09909-7>

- Poveda Garcés, D. A., Flores Murillo, C. R., Pazmiño Robles, L. G. y Yaguar Gutiérrez, S. P. (2023). Factores que influyen en el desempeño académico universitario. *Reciamuc*, 7(1), 381-389. [https://doi.org/10.26820/reciamuc/7.\(1\).enero.2023.381-389](https://doi.org/10.26820/reciamuc/7.(1).enero.2023.381-389)
- Putwain, D., Sander, P. y Larkin, D. (2013). Academic self-efficacy in study-related skills and behaviours: Relations with learning-related emotions and academic success. *British Journal of Educational Psychology*, 83(4), 633-650. <https://doi.org/10.1111/j.2044-8279.2012.02084.x>
- Quílez-Robres, A., Usán, P., Lozano-Blasco, R. y Salavera, C. (2023). Emotional intelligence and academic performance: A systematic review and meta-analysis. *Thinking Skills and Creativity*, 49, 101355. <https://doi.org/10.1016/j.tsc.2023.101355>
- Ren, X., Tong, Y., Peng, P. y Wang, T. (2020). Critical thinking predicts academic performance beyond general cognitive ability: Evidence from adults and children. *Intelligence*, 82, 101487. <https://doi.org/10.1016/j.intell.2020.101487>
- Rodríguez-Hernández, C. F., Kyndt, E. y Cascallar, E. (2023). A Cluster Analysis of Academic Performance in Higher Education through Self-Organizing Maps. En M. Cebral-Loureda, E. G. Rincón-Flores, y G. Sanchez-Ante (Eds.), *What AI Can Do: Strengths and Limitations of Artificial Intelligence* (pp. 115-134). CRC Press. <https://doi.org/10.1201/b23345-9>
- Rodríguez-Hernández, C. F., Musso, M., Kyndt, E. y Cascallar, E. (2021). Artificial neural networks in academic performance prediction: Systematic implementation and predictor evaluation. *Computers and Education: Artificial Intelligence*, 2, 100018. <https://doi.org/10.1016/j.caeai.2021.100018>
- Romanova, E., Kolokoltsev, M., Vorozheikin, A., Kononov, D., Vrachinskaya, T., Fedorov, V., et al. (2023). The dependence of the academic performance of university students on the level of their physical activity. *Journal of Physical Education and Sport*, 23(2), 404-409. <https://doi.org/10.7752/jpes.2023.02049>
- Sanchez Leon, A. F. (2023). Self-concept and academic performance of university students. *Universidad Ciencia y Tecnología*, 27(118), 61-68. <https://doi.org/10.47460/uct.v27i118.687>
- Sánchez, P., Ordonez-Morales, O., Barbosa, F. y Payán-Villamizar, C. M. (2021). *Estrategias para el acompañamiento y seguimiento estudiantil: La experiencia de ases en la Universidad del Valle*. Universidad del Valle. <https://www.researchgate.net/publication/358008138>
- Shi, Y. y Qu, S. (2022a). Analysis of the effect of cognitive ability on academic achievement: Moderating role of self-monitoring. *Frontiers in Psychology*, 13, 996504. <https://doi.org/10.3389/fpsyg.2022.996504>
- Shi, Y. y Qu, S. (2022b). The effect of cognitive ability on academic achievement: The mediating role of self-discipline and the moderating role of planning. *Frontiers in Psychology*, 13, 1014655. <https://doi.org/10.3389/fpsyg.2022.1014655>
- Sofyana, M., Wibowo, R. A. y Agustini Sih, D. (2022). Wake-up time and academic performance of university students in Indonesia: A cross-sectional study. *Frontiers in Education*, 7, 982320. <https://doi.org/10.3389/educ.2022.982320>
- Stajkovic, A. D., Bandura, A., Locke, E. A., Lee, D. y Sergent, K. (2018). Test of three conceptual models of influence of the big five personality traits and self-efficacy on academic performance: A meta-analytic path-analysis. *Personality and Individual Differences*, 120, 238-245. <https://doi.org/10.1016/j.paid.2017.08.014>
- Steinmayr, R., Weidinger, A. F., Schwinger, M. y Spinath, B. (2019). The Importance of Students' Motivation for Their Academic Achievement – Replicating and Extending Previous Findings. *Frontiers in Psychology*, 10, 464340. <https://doi.org/10.3389/fpsyg.2019.01730>
- Tan, G. X. D., Soh, X. C., Hartanto, A., Goh, A. Y. H. y Majeed, N. M. (2023). Prevalence of anxiety in college and university students: An umbrella review. *Journal of Affective Disorders Reports*, 14, 100658. <https://doi.org/10.1016/j.jadr.2023.100658>
- Tumino, M. C., Quinde, J. M., Lilian Noemí, C. y Melissa Raquel, V. (2020). Self-efficacy in university students: the role of academic empowerment. *IJERI: International Journal of Educational Research and Innovation*, (14), 211-224. <https://doi.org/10.46661/ijeri.4618>
- Viloria Hernández, E., Marquez Ortega, M. A. y Santillan Briceño, V. E. (2020). Anxiety and Academic Performance in University Students. *American International Journal of Contemporary Research*, 10(2), 8-12. <https://doi.org/10.30845/aijcr.v10n2p2>
- Vitasari, P., Wahab, M. N. A., Othman, A., Herawan, T. y Sinnadurai, S. K. (2010). The Relationship between Study Anxiety and Academic Performance among Engineering Students. *Procedia - Social and Behavioral Sciences*, 8, 490-497. <https://doi.org/10.1016/j.sbspro.2010.12.067>
- Wang, S. y Luo, B. (2024). Academic achievement prediction in higher education through interpretable modeling. *PLoS One*, 19(9), e0309838. <https://doi.org/10.1371/journal.pone.0309838>
- Xiang, J., Wan, Y. y Zhou, J. (2019). Factors Affecting the Learning Effect of Advanced Mathematics among Chinese College Students in Social Science Majors. *Eurasia Journal of Mathematics, Science and Technology Education*, 15(11), em1770. <https://doi.org/10.29333/ejmste/109607>
- Zhang, J., Peng, C. y Chen, C. (2024). Mental health and academic performance of college students: Knowledge in the field of mental health, self-control, and learning in college. *Acta Psychologica*, 248, 104351. <https://doi.org/10.1016/j.actpsy.2024.104351>
- Zimmerman, B. J. (2000). Self-Efficacy: An Essential Motive to Learn. *Contemporary Educational Psychology*, 25(1), 82-91. <https://doi.org/10.1006/ceps.1999.1016>
- Zumárraga-Espinosa, M. y Cevallos-Pozo, G. (2022). Autoeficacia, procrastinación y rendimiento académico en estudiantes universitarios de Ecuador. *Alteridad*, 17(2), 277-290. <https://doi.org/10.17163/ALT.V17N2.2022.08>