



Universitat d'Alacant
Universidad de Alicante

Factores Motivacionales, Emocionales y Socioeconómicos Asociados al
Rendimiento Académico y Abandono en la Educación Superior: Estudio
en dos Universidades del Ecuador

Jack Iván Vidal Chica



Tesis **Doctorales**

UNIVERSIDAD de ALICANTE

Unitat de Digitalització UA

Unidad de Digitalización UA



Universitat d'Alacant
Universidad de Alicante

DEPARTAMENTO DE PSICOLOGÍA EVOLUTIVA Y DIDÁCTICA

FACULTAD DE EDUCACIÓN

**Factores Motivacionales, Emocionales y Socioeconómicos Asociados al
Rendimiento Académico y Abandono en la Educación Superior: Estudio
en dos Universidades del Ecuador.**

JACK IVÁN VIDAL CHICA

Tesis presentada para aspirar al grado de

DOCTOR POR LA UNIVERSIDAD DE ALICANTE

DOCTORADO EN INVESTIGACIÓN EDUCATIVA

Dirigida por:

Dra. Raquel Gilar Corbi

Dr. Efstathios Stefos

Este trabajo se ha desarrollado dentro del proyecto subvencionado por la Secretaría de Educación Superior, Ciencia, Tecnología e Innovación, SENESCYT (Ecuador) y el Programa de las Naciones Unidas para el Desarrollo (PNUD), Ref: PIC-18-INE-EPN-002.

Enero 2023

Índice

1	Agradecimientos.....	5
2	Resumen	7
3	Abstract	11
SECCIÓN PRIMERA.....		15
4	Introducción.....	15
4.1	Contexto.....	15
4.2	El análisis de Rendimiento Académico	16
4.3	Ciencia de Datos en la Investigación Educativa	19
5	Objetivos.....	23
5.1	Objetivo General	23
5.2	Objetivos	23
6	Hipótesis.....	24
7	Método.....	24
7.1	Participantes	24
7.2	Medidas.....	25
7.2.1	Medidas para el Estudio 1 en UNAE.....	25
7.2.2	Medidas para el Estudio 2 en EPN	26
7.2.3	Medidas para el Estudio 3 en EPN	28
8	Procedimiento	29
9	Análisis de datos y resumen de resultados	30
9.1	Estudio 1	30

9.1.1	Análisis de Tablas de Contingencia	30
9.1.2	Análisis de regresión logística.....	32
9.1.3	Redes Neuronales Artificiales	32
9.2	Estudio 2	34
9.2.1	Análisis de regresión logística.....	34
9.2.2	Análisis de curvas ROC	35
9.3	Estudio 3	39
9.3.1	Comparación de Perfiles	39
9.3.2	Análisis de Redes Neuronales	43
SECCIÓN SEGUNDA		45
10	Resultados: Trabajos Publicados.....	45
SECCIÓN TERCERA.....		59
11	Discusión	59
12	Conclusiones	70
13	Referencias.....	74

1 Agradecimientos

A Dios, por permitirme estar con vida y de la mano de su hijo Jesucristo levantarme para bañado de su espíritu poder seguir caminando en busca de ser una mejor persona para gloria de su nombre.

A mis directores de tesis, doctora Raquel Gilar, y doctor Efstathios Stefos, por el apoyo permanente y por compartir su sabiduría de forma desinteresada con el fin de contribuir en la formación de grandes profesionales.

A la Universidad de Alicante y todo su equipo que apoyan al desarrollo del Ecuador en estos procesos de formación y mejoramiento científico, especialmente al doctor Juan Luis Castejón por toda su labor y su acertada gestión en beneficio de la educación a nivel mundial.

A mis padres, Araldo y Emma por estar siempre a mi lado siendo ejemplos de vida que me han impulsado a ser mejor cada día.

A mis compañeras de vida, Karen y Desirée a quienes Dios puso en mi camino para enseñarme que la vida es bella y que la debemos disfrutar en las buenas y en las malas, a esa vocecita en mi mente que me acompaña en las madrugadas: *"tu puelesh papá"*.

A mi gran amigo, Tarquino Sánchez Almeida, por todo su apoyo y consejos que me han ayudado a ser un mejor profesional.

A todos mis familiares, amigos, compañeros de trabajo que de una u otra forma influyeron para que pueda salir adelante en este proyecto de vida.

2 Resumen

A nivel mundial existe una permanente preocupación por el abandono y la deserción en la educación superior, Ferreyra et al. (2017) en un estudio realizado con el apoyo del banco mundial concluye que solamente el 50% de estudiantes universitarios en Latinoamérica y el Caribe logran graduarse; se observa que los estudios al respecto en la región han aumentado, Munizaga et al. (2018) realizó una revisión de publicaciones realizadas entre 1990 y 2016, se seleccionaron 81 artículos de 10 países de la región, en los cuales se identificaron 111 variables relacionadas con el abandono, se resalta que todos estos estudios incluyen información obtenida de los sistemas informáticos de las universidades, pocos trabajos realizaron encuestas adicionales, y ninguno realizó encuestas orientadas a identificar la influencia de la inteligencia emocional, los objetivos de aprendizaje y atribuciones causales. Es en este aspecto que se encuentra un déficit investigativo en el cual se enfoca el presente trabajo, realizando un análisis en dos universidades del Ecuador, la Universidad Nacional de Educación (UNAE) y la Escuela Politécnica Nacional (EPN), las cuales se encuentran en entornos geográficos muy diferentes al igual que su enfoque, siendo la una orientada a formar profesores y la otra orientada a formar ingenieros; de la UNAE no existen estudios hasta el momento que analicen el tema de la deserción o abandono estudiantil, en cuanto a la EPN se tienen dos investigaciones que analizan la correlación con la nota de acceso a la educación superior y datos socioeconómicos obtenidos de la plataforma informática institucional.

El objetivo del estudio en la Universidad Nacional de Educación fue determinar qué variables sociodemográficas están asociadas con un mayor éxito de egreso en los estudios universitarios del ámbito de la educación, así como la puesta a prueba de un modelo que permita predecir el éxito/fracaso en el egreso en función de esas variables sociodemográficas. Los participantes de este estudio fueron 285 estudiantes egresados de la promoción 2015-2019, quienes son el 88.07% de los alumnos que ingresaron durante el año 2015. Los datos se obtuvieron de los registros informáticos existentes en la

administración de la Universidad Nacional de Ecuador con el permiso otorgado por los responsables de la institución. Se empleó un diseño predictivo y comparativo, y se realizaron análisis de asociación mediante tablas de contingencia para describir cómo se relacionan y agrupan los datos en función de las diferentes variables estudiadas; al someter a prueba un modelo predictivo de la deserción académica mediante regresión logística, solo la variable género fue estadísticamente significativa, obteniendo una exactitud de clasificación de 0,881. Mientras que mediante el modelo de redes neuronales artificiales (RNA), todas las variables resultaron estadísticamente significativas, siendo la de mayor importancia el índice de vulnerabilidad. Obteniéndose una exactitud de clasificación de 0,903. Por lo que se puede indicar que el modelo de RNA hizo una mejor predicción del abandono de la variable dependiente egresa/no egresa. Esto podría indicar que los métodos de aprendizaje automático son capaces de hallar relaciones entre variables que no son posible detectar mediante los métodos tradicionales. De los resultados del presente trabajo se desprende que la tasa de egreso en la Universidad Nacional de Educación (Ecuador) es muy alta, lo que hace interesante analizar las características de esta universidad y de su modelo pedagógico

En el caso de la Escuela Politécnica Nacional los estudios tienen como objetivo identificar los factores asociados con el éxito o fracaso académico en dos trabajos realizados con 1071 y 624 estudiantes que ingresaron al curso de nivelación. Los datos se recopilaron a partir de los registros informáticos existentes de la universidad con el permiso del personal administrativo responsable, adicionalmente se aplicó una prueba diagnóstica de habilidades matemáticas y de lenguaje y comunicación. Para analizar factores adicionales se aplicaron cuestionarios de orientación a metas académicas de Skaalvik, de estrategias motivadas de aprendizaje (MSLQ) y escala de rasgos de meta estado de ánimo (TMMS); adicionalmente en el segundo estudio de la EPN se aplicó la escala de atribuciones causales multidimensionales.

En el primer estudio de la EPN se utilizó un modelo predictivo y se realizó un análisis de regresión logística binaria a través del procedimiento de regresión selección hacia adelante (step-forward) basado en el estadístico de Wald para analizar la capacidad predictiva de las variables relacionadas con la inteligencia emocional, las habilidades sociocognitivas motivacionales y autorreguladas, la orientación a objetivos y el rendimiento académico previo. Para determinar el punto de corte para la mejor potencia discriminatoria de cada una de las variables, se ha utilizado un análisis de la curva de características operativas del receptor (ROC). Los resultados indican que las variables que son significativas en la predicción del éxito o fracaso académico son las dos medidas de rendimiento académico, la variable de atención emocional, y los objetivos de enfoque de desempeño y la variable de autoeficacia motivacional. Adicionalmente, el mayor poder predictivo se muestra por la medida de rendimiento académico previo obtenida a través de la prueba de conocimientos realizada al inicio del curso universitario.

En el segundo estudio de la EPN se utilizaron técnicas de comparación de perfiles, y redes neuronales artificiales, para analizar los perfiles característicos de los estudiantes que aprobaron el curso de nivelación y los que abandonaron. Los resultados mostraron diferencias significativas entre los perfiles de los estudiantes que aprobaron y los que abandonaron con respecto a las variables relacionadas con el rendimiento académico previo y los aspectos motivacionales y atribucionales. Las redes neuronales artificiales corroboraron la importancia de estas variables en la predicción del abandono en el siguiente orden: prueba matemática (100%), grado de acceso (88,2%), objetivos de evitación del rendimiento (autodestructivo, no querer ser juzgado negativamente por los demás) (76%), motivación intrínseca (74,3%), autoeficacia (66,5%), evitación de metas de trabajo académicas realizar tareas con mínimo esfuerzo (57,7%), prueba de lenguaje (54,8%), ansiedad por la prueba (48,6%) y facilitar la atribución de alto rendimiento (47,3%).

En esta investigación, se revelan las variables clave que predicen si un estudiante continúa o abandona la educación superior, permitiendo la identificación de estudiantes en posible riesgo de abandono y promoviendo así iniciativas para proporcionar un apoyo académico adecuado y mejorar la retención de estudiantes. Estos hallazgos permiten abrir un camino para desarrollar políticas educativas nuevas y efectivas para combatir el problema de deserción, especialmente en contextos socioeconómicos vulnerables donde la implementación de intervenciones y un mayor apoyo podrían ser determinantes para la coherencia en todo el sistema educativo superior; cabe indicar que la inversión económica requerida para la implementación de estas políticas puede ser cubierta con creces si se compara con las pérdidas que genera el abandono en educación superior.



Universitat d'Alacant
Universidad de Alicante

3 Abstract

Worldwide there is a permanent concern about abandonment and dropout in higher education, Ferreyra et al. (2017) in a study carried out with the support of the World Bank concludes that only 50% of university students in Latin America and the Caribbean manage to graduate; it is observed that studies in this regard in the region have increased, Munizaga et al. (2018) conducted a review of publications made between 1990 and 2016, 81 articles were selected from 10 countries in the region, in which 111 variables related to abandonment were identified, it is highlighted that all these studies include information obtained from the computer systems of universities, few papers conducted additional surveys, and none conducted surveys aimed at identifying the influence of emotional intelligence, learning objectives, and causal attributions. It is in this aspect that there is a research deficit in which the present work focuses, carrying out an analysis in two universities in Ecuador, the National University of Education (UNAE) and the National Polytechnic School (EPN), which are in very different geographical environments as well as their approach, one being oriented to train teachers and the other oriented to train engineers; of the UNAE there are no studies so far that analyze the issue of student desertion or abandonment, as for the EPN there are two investigations that analyze the correlation with the grade of access to higher education and socioeconomic data obtained from the institutional computer platform.

The objective of the study at the National University of Education was to determine which sociodemographic variables are associated with greater graduation success in university studies in the field of education, as well as the testing of a model that allows predicting success/failure in graduation based on these sociodemographic variables. The participants of this study were 285 students graduated from the 2015-2019 class, who are 88.07% of the students who entered during the year 2015. The data were obtained from the computer records existing in the administration of the National University of Ecuador with the permission granted by those responsible for the institution. A predictive and

comparative design was used, and association analysis was performed using contingency tables to describe how the data are related and grouped according to the different variables studied; when testing a predictive model of academic dropout by logistic regression, only the gender variable was statistically significant, obtaining a classification accuracy of 0.881. While using the model of artificial neural networks (RNA), all the variables were statistically significant, the most important being the vulnerability index. Obtaining a classification accuracy of 0.903. The RNA model made a better prediction of the abandonment of the dependent variable egress /not egress. This could indicate that machine learning methods can find relationships between variables that cannot be detected by traditional methods. From the results of this study, the graduation rate at the National University of Education (Ecuador) is very high, which makes it interesting to analyze the characteristics of this university and its pedagogical model.

In the case of the National Polytechnic School, the studies aim to identify the factors associated with academic success or failure in two works carried out with 1071 and 624 students who entered the leveling course. The data were collected from the existing computer records of the university with the permission of the responsible administrative staff, additionally a diagnostic test of mathematical and language and communication skills was applied. To analyze additional factors, questionnaires were applied to orientation to Skaalvik's academic goals, motivated learning strategies (MSLQ) and meta mood trait scale (TMMS); additionally, in the second study of the EPN, the scale of multidimensional causal attributions was applied.

In the first study of the EPN, a predictive model was used, and a binary logistic regression analysis was carried out through the step-forward regression procedure based on the statistic or Wald to analyze the predictive capacity of the variables related to emotional intelligence, motivational socio cognitive skills and self-regulated, goal orientation and previous academic performance. To determine the cut-off, point for the best discriminatory power of each of the variables, an analysis of the receiver's operational characteristic curve (ROC) has been used. The results indicate that the variables that

are significant in predicting academic success or failure are the two measures of academic performance, the emotional attention variable, and the performance focus objectives and the motivational self-efficacy variable. Additionally, the greatest predictive power is shown by the measure of previous academic performance obtained through the knowledge test carried out at the beginning of the university course.

In the second study of the EPN se used techniques of comparison of profiles, and artificial neural networks, to analyze the characteristic profiles of the students who passed the leveling course and those who dropped out. The results showed significant differences between the profiles of the students who passed and those who dropped out with respect to the variables related to previous academic performance and motivational and attributional aspects. Artificial neural networks corroborated the importance of these variables in the prediction of abandonment in the following order: mathematical test (100%), degree of access (88.2%), performance avoidance objectives (self-destructive, not wanting to be judged negatively by others) (76%), intrinsic motivation (74.3%), self-efficacy (66.5%), avoidance of academic work goals perform tasks with minimal effort (57.7%), language test (54.8%), test anxiety (48.6%) and facilitating high-performance attribution (47.3%).

In this research, the key variables that predict whether a student continues or leaves higher education are revealed, allowing the identification of students at possible risk of dropping out and thus promoting initiatives to provide adequate academic support and improve student retention. These findings open a path to develop new and effective educational policies to fight the problem of desertion, especially in vulnerable socioeconomic contexts where the implementation of interventions and greater support could be decisive for coherence throughout the higher education system; it should be noted that the economic investment required for the implementation of these policies can be more than covered compared to the losses generated by dropping out of higher education.

SECCIÓN PRIMERA

4 Introducción

El presente trabajo de investigación trata sobre el estudio de factores motivacionales, emocionales y socioeconómicos asociados al rendimiento académico y abandono en la educación superior, este trabajo se realizó en dos universidades del Ecuador: la Universidad Nacional de Educación (UNAE), y la Escuela Politécnica Nacional (EPN), la propuesta se encuentra conformada por tres artículos que analizan la problemática del rendimiento académico en busca de identificar factores relacionados.

4.1 Contexto

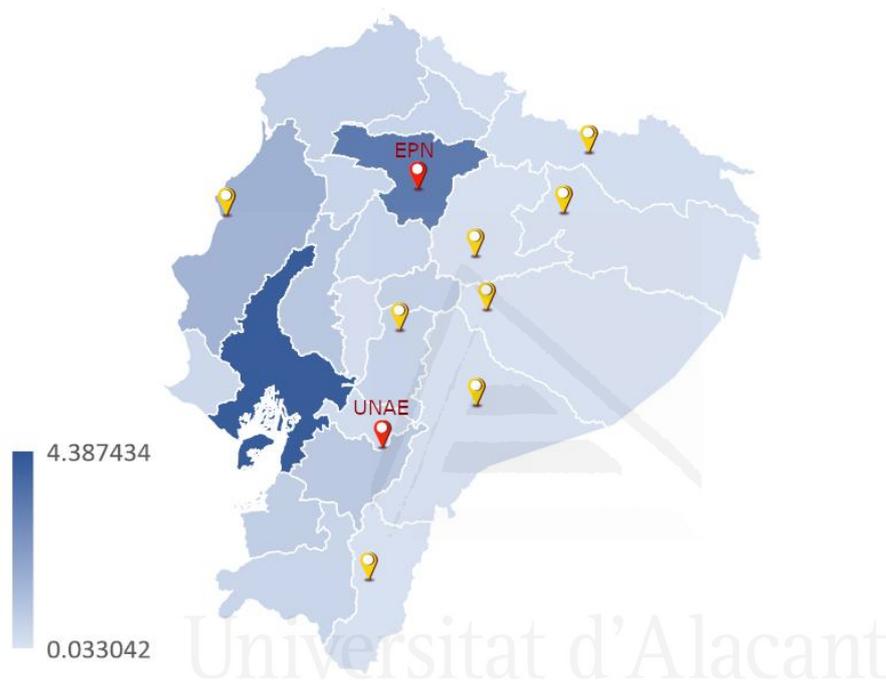
La Universidad Nacional de Educación es una institución joven creada a finales de 2013, en el ámbito de la Educación, es parte de un grupo de cuatro universidades emblemáticas creadas por el gobierno del Ecuador con el objetivo de fortalecer el sistema de educación superior en áreas específicas. La UNAE, se encuentra ubicada en el centro sur del Ecuador, y al momento dispone de ocho centros de apoyo (Figura 1).

La Escuela Politécnica Nacional fue fundada el 30 de agosto de 1869, fue concebida como el primer centro de docencia e investigación científica del Ecuador, como órgano integrador del país y como ente generador del desarrollo nacional. Al momento oferta 27 carreras tanto de ingenierías, ciencias y tecnologías superiores. La EPN tiene una única sede ubicada en la segunda provincia con mayor población del Ecuador (ver Figura 1), en la ciudad más poblada del Ecuador, Quito. Al momento la EPN tiene alrededor de 9000 estudiantes en modalidad presencial.

En la EPN se realizaron dos estudios (1013 y 624 muestras) con estudiantes que ingresaron al curso de nivelación. En la UNAE se utilizó la información académica, de nueve semestres de 285 estudiantes, de la cohorte que ingresó en abril de 2015. La modalidad de estudio es presencial en todos los casos.

Figura 1

Mapa Densidad Poblacional Ecuador Continental



Nota: La figura muestra la ubicación de la sede principal de la UNAE, sus centros de apoyo, y la sede principal de la EPN según la densidad poblacional del Ecuador. Datos tomados del INEC (Instituto Nacional de Estadística y Censos, 2020)

4.2 El análisis de Rendimiento Académico

Cabe indicar que la pandemia COVID 19 ha influido en el análisis de rendimiento académico debido a la suspensión de la modalidad presencial. Existen estudios en los cuales la modalidad virtual (o a distancia) implementada de manera forzosa en las universidades ha generado un incremento importante en las calificaciones de los estudiantes (Sánchez-Almeida et al., 2021), pero se generan dudas sobre el aprendizaje; al respecto existen evidencias que demuestran la poca relación entre la

forma de evaluar y el aprendizaje de un estudiante en concreto (Betancur & González, 2009), la solución a esta problemática se podría encontrar en las buenas prácticas de enseñanza implementadas por el docente, las cuales independientemente de la modalidad de estudio lograrán los resultados de aprendizaje esperados (Yen et al., 2018).

Es necesario recalcar que el hecho de que un estudiante tenga un rendimiento académico elevado no implica que tenga éxito académico, siendo este definido como la obtención del título universitario. Vincent Tinto un destacado investigador en temas de abandono explica que el rendimiento académico y el abandono son parámetros que están íntimamente relacionados con la dinámica del entorno de las instituciones de educación superior, la cual se basa en características específicas como son: la ubicación geográfica, la modalidad de estudios, el tipo de carrera, etc. (Tinto & Cullen, 1973).

En una ponencia presentada en el VIII Congreso Internacional de Psicología y Educación (CIPE 2016), se realiza una revisión de investigaciones realizadas referentes a variables e implicaciones en el rendimiento académico, los investigadores agrupan las variables en: organizativas a nivel de centro de estudios y de aula, relativas al docente, relativas al contexto familiar (García-Martín & Cantón, 2016).

A nivel de centro de estudios existe relación entre el rendimiento académico del alumnado y el desarrollo curricular de los centros educativos, el ejercicio de cargos académicos y los años de docencia del profesorado son variables que presentan diferencias en la práctica curricular, lo que repercute en el rendimiento escolar del alumnado (Moreno et al., 2010). Por otra parte, las características del currículum influyen en el progreso escolar de los estudiantes universitarios, pues éstos rendían más y finalizaban antes los estudios cuando se disminuía la carga por examen y el número de materias (Jansen, 2004).

A nivel de aula, el tiempo de exposición de los estudiantes a los medios visuales tienen efectos indirectos en el rendimiento académico dependiendo del nivel educativo, a nivel de escuelas un mayor uso de éstos puede dar lugar a problemas de comportamiento, el contenido de los medios determina tanto el rendimiento como otros factores familiares y personales del alumno (Sharif et al., 2010). En educación media, los adolescentes que dedicaban al uso de tecnologías de la Información y la Comunicación más de las dos horas diarias recomendadas presentaban medias académicas más bajas que aquellos que sí cumplían las recomendaciones, a mayor uso de medios audiovisuales menor rendimiento escolar (Puig Gimeno et al., 2015), en una comparativa tienen mejor rendimiento académico quienes usan sus apuntes para estudiar versus los que usan YouTube (Halpern et al., 2020). A nivel universitario el efecto es contrario los recursos tecnológicos multimediales pasan de ser un distractor a herramientas que aportan a la generación del conocimiento, en un estudio realizado con estudiantes de la carrera de Ingeniería en Informática de la Universidad Popular Autónoma del Estado de Puebla, se demostró que el uso de objetos de aprendizaje mejora el rendimiento académico y la tasa de aprobación de las asignaturas (Urbina Nájera, 2019). Respecto al clima de aula y la relación entre iguales; la calidad de la amistad entre iguales, el apoyo de los amigos y el comportamiento en el aula tiene efectos en el rendimiento escolar (Perdue et al., 2009).

En cuanto a las variables que se relacionan con el docente, el nivel educativo, la calidad de la docencia según las prácticas en clase y la experiencia ayudan a los alumnos a alcanzar niveles más altos de rendimiento (Wenglinsky, 2002). En el ambiente universitario la evaluación continua tiene un efecto positivo en el rendimiento académico (Albalade et al., 2011). También existen variables que influyen negativamente en los estudiantes como los discursos de los docentes que atribuyen el bajo rendimiento o el fracaso escolar a la falta de interés del alumno, al déficit familiar y a la patologización de la diversidad (Tarabini, 2015).

Dentro del contexto familiar variables tales como el nivel socioeconómico familiar, el nivel educativo de los padres, la estructura familiar, el clima familiar, las relaciones padres-hijos, estilo educativo, las expectativas y los recursos y ambiente culturales tienen relación directa en el rendimiento académico del alumnado (Barca Lozano et al., 2012). Para que el ámbito familiar favorezca el rendimiento académico es necesario alcanzar ciertos objetivos como crear climas afectivos que favorezcan el equilibrio emocional del alumno, establecer relaciones padres-hijos democráticas y de respeto, ofrecer modelos de identificación en la asunción de responsabilidades y aceptación de límites (Ruiz De Miguel, 2001).

4.3 Ciencia de Datos en la Investigación Educativa

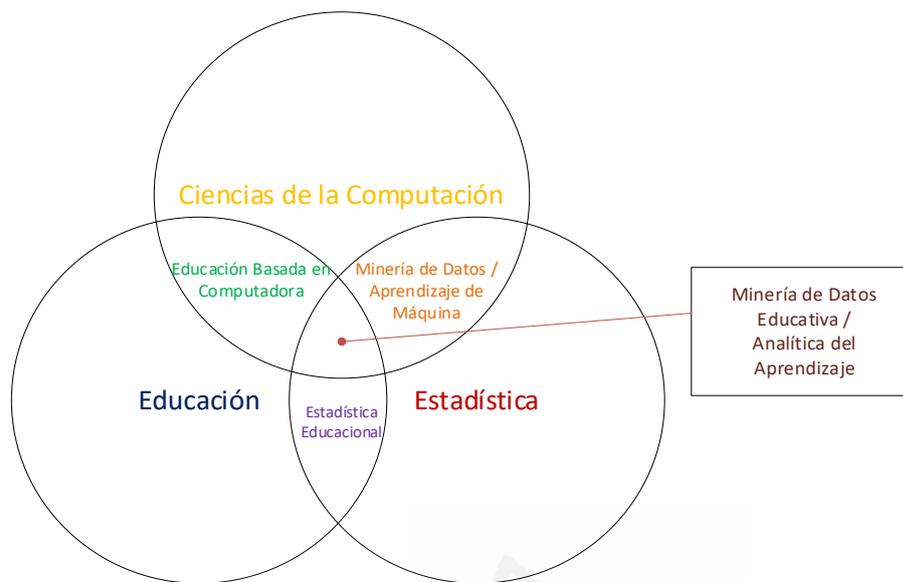
Los análisis sobre los factores que influyen en el rendimiento académico en la actualidad se realizan con base en el uso de la computación y la estadística, las cuales al ser utilizadas en el ámbito de la educación han generado en conjunto dos tendencias: Minería de Datos Educativa y Analítica del Aprendizaje (EDM y LA por sus siglas en inglés).

La Figura 2 muestra cómo se interrelacionan la educación basada en computadora, la estadística educativa, y la minería de datos junto con aprendizaje de máquina para generar estas dos tendencias que son muy utilizadas en los diversos análisis del rendimiento académico.

En respuesta a estas dos tendencias se generaron dos comunidades: la Sociedad internacional de Minería de Datos Educativa (<http://www.educationaldatamining.org/>) fundada en julio de 2011 y la Sociedad de Investigación en Analítica del Aprendizaje (<https://www.solaresearch.org/>) constituida el 11 de abril de 2013.

Figura 2

Relaciones entre la Computación, Educación y Estadística.



Nota: Figura tomada de (Romero & Ventura, 2020)

La Tabla 1 muestra una comparativa entre estas dos tendencias, se pueden observar tanto similitudes como diferencias entre los dos conceptos.

A pesar de que la minería de datos educativa y la analítica del aprendizaje tienen mucho en común, existen algunas diferencias, el enfoque de la LA se encuentra en el proceso de aprendizaje y todas sus particularidades, lo cual se ha facilitado por el incremento de la educación en línea que permite la recolección de datos de lo que acontece en el aula (virtual), las interacciones en aplicaciones de redes sociales entre estudiantes y con el docente, la participación en las actividades del aula, etc.; las herramientas y algoritmos matemáticos utilizados usualmente son los mismos que en EDM.

Tabla 1

Breve Comparación entre LA y EDM

Característica	Analítica del Aprendizaje	Minería de Datos Educativa
Descubrimiento	Aprovechar el juicio humano es la clave, el descubrimiento automatizado es una herramienta para lograr esta meta	El descubrimiento automatizado es la clave, el juicio humano es una herramienta para lograr esta meta
Reducción & Holismo	Mayor énfasis en entender los sistemas como un todo, en su completa complejidad	Mayor énfasis en reducción a componentes, su análisis individual y de sus relaciones
Orígenes	Tiene un fuerte origen en la semántica web, "currículo inteligente", predicción de rendimiento, e intervención sistémica	Tiene fuerte origen en el software educativo y modelado estudiantil, con una comunidad significativa de predicción de resultados en cursos
Adaptación & Personalización	Mayor enfoque en informar y empoderar instructores y estudiantes.	Mayor enfoque en adaptación automatizada (por ejemplo, por la computadora sin humanos en el bucle)
Técnicas & Métodos	Análisis de redes sociales, sentimientos, influencia analítica, análisis del discurso, predicción de éxito en el aprendizaje, análisis de conceptos, modelos de sensibilización.	Clasificación, agrupamiento, modelado bayesiano, minería de relaciones, descubrimiento con modelos, visualización.

Nota: Datos tomados de (Siemens & Baker, 2012)

En el presente trabajo se utilizaron técnicas de Minería de Datos Educativa, en el análisis del rendimiento académico de una cohorte de estudiantes de UNAE se usan análisis por tablas de contingencia, regresión logística, y redes neuronales artificiales. Para el caso de la EPN, se utilizan regresión logística, redes neuronales artificiales (RNA) y análisis de curvas de Característica Operativa del Receptor (ROC siglas del inglés).

Una tabla de contingencia es una tabla de frecuencias en la que se relacionan dos o más variables cualitativas, es una técnica básica destinada a la lectura y estudio de las relaciones entre unas pocas variables, entre dos y tres habitualmente; su uso es extendido en los trabajos sociológicos y, en general, en tratamiento de datos de

encuesta, donde es habitual que la mayoría de las variables sean cualitativas. La interpretación inicial de la posible asociación entre las variables requiere una fundamentación estadística que se establece mediante la prueba de chi cuadrado cuyo resultado determinará la significación estadística de la relación, el análisis se completa con el cálculo de otros estadísticos destinados a establecer la fuerza de la asociación, ya sea a nivel global, entre variables, o nivel local, en casillas concretas para combinaciones de categorías o valores concretos de estas variables (López-Roldán & Fachelli, 2015).

El análisis de curvas de Característica Operativa del Receptor es una representación gráfica de pares de valores, la especificidad y la sensibilidad, siendo su gran ventaja su simplicidad, puesto que es una representación visual directa del rendimiento del modelo analizado, basado en todas las posibles salidas (Mourão & Braga, 2016). La sensibilidad cuantifica la proporción de individuos que presentan el evento de interés y que el modelo los clasifica correctamente (Valle Benavides, 2017), en el caso del análisis en el campo académico puede ser la predicción del éxito académico; de otro lado la especificidad cuantifica la proporción de estudiantes que no presentan éxito académico, es decir cuantifica el fracaso académico que fue correctamente clasificado por el modelo.

La regresión logística es un instrumento estadístico cuyo uso comenzó a popularizarse en la década de los 80, gracias a la generalización del uso de las computadoras, su ámbito de aplicación es tanto explicativo como predictivo, especialmente cuando se tiene una variable dependiente dicotómica (Chitarroni, 2002), por ejemplo, el evento de que un estudiante egrese o no de una carrera. La comparación de modelos utilizando el cociente de verosimilitud permite identificar el mejor modelo de regresión logística, si a partir de este coeficiente no se puede demostrar que un modelo resulta mejor que el otro, se considerará como el más adecuado, el más sencillo (De La Fuente Fernández, 2011).

Las redes neuronales artificiales (RNA) son algoritmos que pueden resolver problemas complejos imitando con ciertas limitaciones la funcionalidad del cerebro humano. La principal aplicación de las redes neuronales es la clasificación de datos, por ejemplo, un estudiante egresa (valor de 1) si la salida de la red es mayor que cero, o un estudiante no egresa (valor de 0) si la salida es menor o igual a cero. Las RNA se organizan por niveles o capas, siendo la más conocida la denominada perceptrón multicapa (PM); estas redes tienen dos funciones definidas: de activación y de salida, las cuales pueden ser de varios tipos, resaltándose el uso de la función sigmoide.

Las variables de entrada de una red neuronal (x_i) son multiplicadas por un peso (w_i), siendo el sumatorio de todos estos valores el impulso nervioso de la neurona ($f(X)$); este impulso se ajusta mediante un valor de sesgo (b), para poder obtener una clasificación más precisa en la salida $z = f(X) = b + \sum_{i=0}^n x_i w_i$. (Sierra Ramos, 2022).

5 Objetivos

5.1 Objetivo General

El objetivo general de esta investigación es proponer y validar empíricamente un modelo que permita explicar y predecir el rendimiento académico de los alumnos universitarios, identificando los factores que lo afectan positivamente.

5.2 Objetivos

El objetivo general derivamos los dos siguientes objetivos:

- Analizar cómo se relacionan entre sí las variables relativas a factores sociodemográficos, educativos y de rendimiento previo de los estudiantes universitarios, así como analizar cuáles son las que contribuyen significativamente a la explicación del éxito académico y el abandono escolar.

- Analizar si existen diferencias en el perfil de estudiantes de alto rendimiento y de bajo rendimiento en función de variables sociodemográficas, educativas y de rendimiento previo.

6 Hipótesis

La hipótesis general de partida es la siguiente:

Es posible aplicar un modelo predictivo del rendimiento académico en las carreras de la Universidad Nacional de Educación del Ecuador, y la Escuela Politécnica Nacional considerando las variables sociodemográficas, educativas y de rendimiento previo.

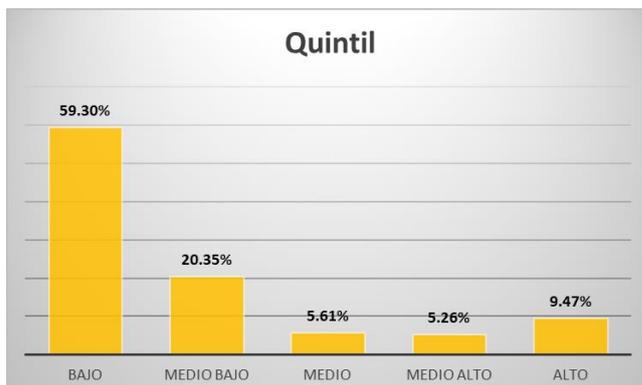
7 Método

7.1 Participantes

En el primer estudio, los participantes fueron los estudiantes que ingresaron en abril de 2015 a la Universidad Nacional de Educación en dos cohortes, 285 estudiantes en modalidad presencial; de estos estudiantes el 79.65% pertenecen a los dos quintiles más bajos en cuanto a la situación económica, tal como se observa en la Figura 3. En cuanto al sexo el 53.68% son mujeres, según la etnia el 95.09% mestizos, 1.75% indígenas, 1.40% montubios, 1.40% afrodescendientes, y 0.35% blancos. El 2.11% de los estudiantes tiene discapacidad; en cuanto al estado civil el 85.26% solteros, 12.28% casados, 1.40% en unión libre, y 1.05% divorciados; y acorde al número de hijos 11.93% un hijo, 1.75% dos hijos, y 0.35% tres hijos.

Figura 3

Distribución por Quintil Estudiantes de la UNAE



Nota: Elaboración propia

El segundo estudio realizado en la EPN utilizó con una muestra de 1071 estudiantes que ingresaron al curso de nivelación, en este caso la distribución por género es mayoritariamente masculina con un 72%, en cuanto al estado civil el 98.79% son solteros y un 97.67% no tienen hijos.

El tercer estudio también realizado en la EPN se realizó con 624 estudiantes que ingresaron al curso de nivelación, de los cuales el 71% son hombres, un 99.49% solteros, y un 96.75% no tienen hijos.

7.2 Medidas

7.2.1 Medidas para el Estudio 1 en UNAE

Los datos referentes a las diversas variables consideradas en el estudio se obtendrán del sistema de administración estudiantil de la UNAE y de la Secretaría de Educación Superior, Ciencia, Tecnología e Innovación (SENESCYT).

Las variables analizadas fueron las siguientes: Género (hombre o mujer), Etnia (Indígena, Mestizo, Montubio, Afrodescendiente o Blanco), Discapacidad (si presentaban algún tipo de discapacidad o no), Estado civil (Soltero, Casado, Unión libre o Divorciado), Número de hijos (de 0 a 3), Quintil variable que indica la clasificación de

nivel sociodemográfico, mide entre otros aspectos el riesgo de exclusión social, los posibles valores son: Bajo, Medio bajo, Medio, Medio alto, Alto) y Egresada-no egresada variable que indica si el estudiante egresa o no de la titulación.

7.2.2 Medidas para el Estudio 2 en EPN

Rendimiento Académico Previo. Se utilizaron dos promedios para evaluar esta variable. Estos son: a) Nota de postulación, la cual es la nota obtenida por el alumno en la prueba de acceso a la universidad. Se califica sobre un total de 1000 puntos, donde una puntuación más alta implica un mejor rendimiento. b) Puntuación de las pruebas diagnósticas; esto se basa en una prueba realizada al inicio del curso universitario. La prueba consta de 80 ítems, de los cuales 55 ítems corresponden a habilidades matemáticas y 25 ítems a habilidades de lenguaje y comunicación.

Orientación a Metas. En este aspecto se utilizó el Cuestionario de Orientación a Metas Académicas de Skaalvik (Skaalvik, 1997) para evaluar los objetivos del enfoque de aprendizaje y logro. Este instrumento evalúa cuatro subescalas: (1) metas de aprendizaje (o tarea de enfoque), (2) metas de enfoque de desempeño (o superación personal), (3) metas de evitación del desempeño (o autodefensa) y (4) metas de evitación de logros asociadas con el trabajo académico. Incluye 22 elementos de tipo Likert, con cinco opciones de respuesta. Este instrumento se ha utilizado en una serie de estudios sobre estudiantes universitarios (Rodríguez et al., 2001; Suárez Riveiro et al., 2001; Valle et al., 2010) y se ha demostrado que es una escala confiable y válida para la evaluación de objetivos académicos. Según Valle et al. el índice de fiabilidad en las dimensiones: metas de aproximación a la tarea (*learning goals*) presentan un alfa de Cronbach = .85 con 6 ítems y metas de aproximación al rendimiento, o de mejora del yo (*performance-approach goals*) presenta un alfa de Cronbach = .89 con 5 ítems. El coeficiente alfa de Cronbach es la forma más sencilla y conocida de medir la consistencia interna y es la primera aproximación a la validación del constructo de una escala (Oviedo & Campo-Arias, 2005).

Habilidades Sociocognitivas Motivacionales y Autorreguladas. Para este factor se ha utilizado el Cuestionario de Estrategias Motivadas de Aprendizaje (MSLQ) (Pintrich & De Groot, 1990). El cuestionario abreviado contiene 44 ítems que se responden con una escala tipo Likert en la que el rango está entre 1 y 7. El cuestionario se divide en dos partes; es decir, estrategias de motivación y aprendizaje autorregulado. Estos, a su vez, se dividen en subescalas. El apartado de motivación se divide en autoeficacia (que implica qué tan competentes se sienten los alumnos sobre su desempeño), motivación intrínseca (que implica el nivel de compromiso personal que los alumnos tienen con las obligaciones académicas, más allá de cumplir con las evaluaciones durante el periodo escolar), y ansiedad ante las evaluaciones (esto incluye el nivel de ansiedad que experimentan los alumnos ante situaciones de evaluación académica). Las estrategias de aprendizaje autorregulado se dividen en el uso de estrategias metacognitivas (esto incluye el nivel de gestión de recursos y estrategias metacognitivas utilizadas para los procesos académicos) y la autorregulación (esto incluye el nivel de autonomía y autodisciplina que poseen los estudiantes para llevar a cabo los procesos académicos). Pintrich y De Groot informaron índices de confiabilidad para la motivación como $\alpha = 0.75$ (ansiedad antes de las evaluaciones) y $\alpha = 0.89$ (autoeficacia), y para las estrategias de aprendizaje autorreguladas como $\alpha = 0.74$ (autorregulación) y $\alpha = 0.83$ (uso de estrategias cognitivas). Una revisión realizada por Mayer, Faber y Xu indica que el MSLQ es el instrumento más utilizado para evaluar la motivación en contextos educativos, convirtiéndose en un instrumento estándar en la investigación en el campo de la motivación y la autorregulación (Schunk, 2005).

Inteligencia Emocional. Este factor se midió usando la escala rasgos de meta estado de ánimo (*Trait Meta-Mood Scale* TMMS) basada en el modelo de inteligencia emocional de Salovey y Mayer, es una medida de autoanálisis y consta de tres dimensiones con índices psicométricos adecuados (Salovey et al., 1995). Estos son la atención emocional, la claridad de los sentimientos y las reparaciones del estado de

ánimo. En un estudio realizado con la versión modificada al español, se obtuvo la siguiente fiabilidad para cada componente: atención $\alpha = 0,90$, claridad $\alpha = 0,90$, y reparación $\alpha = 0,86$ (Fernandez-Berrocal et al., 2004).

Éxito / Fracaso Académico. Esto implica evaluar si un estudiante ha aprobado el curso de nivelación académica o no.

7.2.3 Medidas para el Estudio 3 en EPN

En este estudio se utilizan algunos de los instrumentos del estudio 2 para medir las variables: Rendimiento académico previo, orientación a metas, habilidades sociocognitivas motivacionales y autorreguladas, inteligencia emocional. Además, se analizan las siguientes variables:

Atribuciones Causales. La escala de Atribuciones Causales Multidimensionales (Peralbo Uzquiano et al., 2004) es una escala de autoinforme con 24 ítems, que se responden en una escala de tipo Likert (1-5). La escala permite obtener 6 indicadores de atribuciones causales en las dimensiones interna/externa, estable/inestable y controlable/incontrolable, y cuatro causas atribucionales: habilidad, esfuerzo, suerte/azar y dificultad de las tareas. Con ellos se obtienen 6 tipos diferenciales de Estilos o Patrones Atribucionales:

- Atribución a la Facilidad de los Materiales del Alto Rendimiento Académico;
- Atribución a la alta capacidad académica del rendimiento académico;
- Atribución a los Docentes del bajo rendimiento académico;
- Atribución a la baja capacidad académica del rendimiento académico;
- Atribución a Bajo Esfuerzo de bajo rendimiento académico;
- Atribución al esfuerzo de alto rendimiento académico.

En cuanto a la fiabilidad, el alfa de Cronbach de la escala total es .775.

Abandono. Esto implica evaluar si un estudiante ha abandonado el curso de nivelación académica o no.

8 Procedimiento

Los datos del primer estudio realizado en la UNAE se obtuvieron, una vez autorizado por la autoridad responsable de la universidad, de los registros informáticos existentes en la administración de Universidad. Todos los datos se trataron de forma anónima

En el segundo estudio se analizaron los datos de 1071 estudiantes de primer año matriculados en EPN, correspondientes a toda la cohorte que ingresó a la universidad en 2018B (segundo semestre). La EPN es una universidad de ingeniería que recibe aproximadamente el 2% del total de estudiantes de todas las universidades del Ecuador. Los datos fueron recolectados de los registros informáticos existentes con el permiso previo del personal académico de la institución, se manejaron de forma anónima.

El tercer estudio utilizó datos de 624 estudiantes matriculados en el curso de nivelación de EPN. Los datos sobre el rendimiento académico previo y la deserción escolar se recopilaban de los informes informáticos existentes en EPN. Los datos sobre orientación a objetivos, habilidades sociocognitivas motivacionales y autorreguladas, inteligencia emocional y atribuciones causales se recogieron en dos sesiones colectivas, en las que los participantes respondieron a los cuatro instrumentos supervisados por los investigadores (Figura 4). Este estudio fue aprobado por el comité de ética. Todos los participantes dieron su consentimiento informado por escrito de conformidad con la Declaración de Helsinki.

Figura 4

Procedimiento del tercer estudio en EPN



Nota: Elaboración propia

9 Análisis de datos y resumen de resultados

9.1 Estudio 1

9.1.1 Análisis de Tablas de Contingencia

Se realizó análisis de asociación mediante tablas de contingencia para describir cómo se relacionan y agrupan los datos en función de las diferentes variables estudiadas, se analizaron las características de los perfiles de egreso de los estudiantes en comparación con los que no consiguen egresar

El mayor porcentaje de egresados corresponde a las mujeres (56.97%). Mientras que los estudiantes que no consiguen egresar son mayoritariamente hombres (70.59%). En relación con la etnia se comprueba que todos los alumnos indígenas, montubios, y afrodescendientes finalizaron sus estudios, siendo los mestizos, que pertenecen a la etnia mayoritaria, los que presentan la mayor tasa de abandono.

El 83.33% de estudiantes con discapacidad egresaron; en relación con la variable Estado Civil el 82.85% de los casados, y el 75% de los alumnos en unión libre finalizaron sus estudios. Acorde a la variable número de hijos, los resultados muestran que el

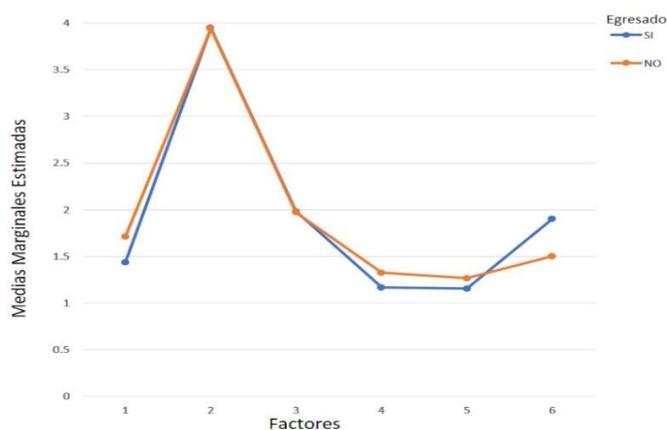
79.41% de los alumnos con un hijo, el 80% de los alumnos con dos hijos, y el 100% de las personas con tres hijos finalizaron sus estudios exitosamente.

En relación con la variable Quintil, los resultados muestran que el 85.80% de los alumnos de quintil bajo, y el 87.93% de los alumnos de quintil medio bajo finalizaron sus estudios exitosamente.

La Figura 5 representa una comparación de medias de las variables independientes analizadas, con el objetivo de visualizar la mayor o menor influencia en los grupos de estudiantes que egresan o no egresan. Se puede observar que en el grupo de estudiantes que egresan hay un mayor porcentaje de mujeres que en el grupo que no egresa, también en el grupo que egresa están la mayoría de los estudiantes que señalaron ser solteros, adicionalmente a los que presentan un menor número de hijos, perteneciendo mayoritariamente a quintiles más bajos. Respecto a la variable Etnia y Discapacidad no se mostraron mayores diferencias respecto a la condición final de egresados o no de los estudiantes.

Figura 5

Medias Marginales para Egresados



Nota: 1= género; 2= etnia; 3= discapacidad; 4= estado civil; 5= número de hijos; 6= quintil; Azul= egresa; Verde= no egresa. Elaboración propia programa SPSS

9.1.2 *Análisis de regresión logística*

Se utilizó un modelo predictivo y se realizó un análisis de regresión logística por pasos (estadístico de Wald). Este modelo permite estimar la probabilidad de ocurrencia de un evento, en contraposición a no ocurrir, en presencia de uno o más predictores.

Adicionalmente, se analizó la ponderación de cada una de las variables independientes sobre la probabilidad de éxito o fracaso académico.

El estadístico R² de Nagelkerke estimó un valor de ajuste del modelo de 0.06. Y el modelo estimó correctamente el 88.1% de los casos. La odd ratio fue menor a 1 para la variable sexo, lo que indica que la probabilidad de egresar de la titulación es 3.17 veces menor para los hombres.

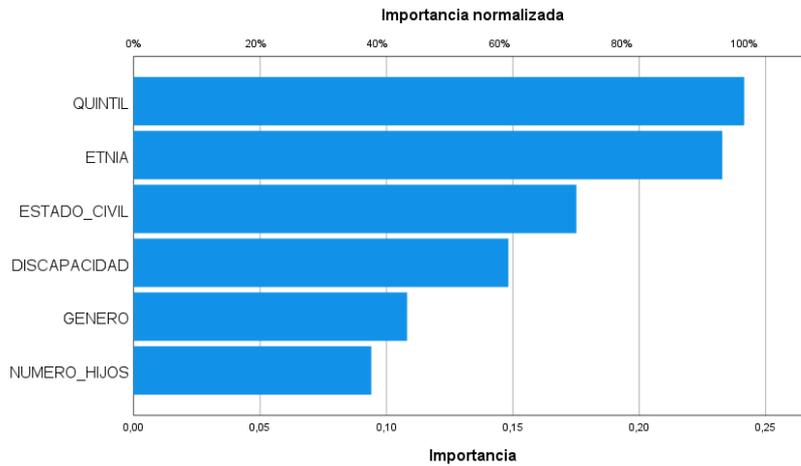
9.1.3 *Redes Neuronales Artificiales*

Se emplearon redes neuronales artificiales para predecir las tasas de abandono de los estudiantes de la Universidad Nacional de Educación, teniendo en cuenta las variables de tipo sociodemográfico. La variable dependiente fue "egresa-no egresa" y los factores fueron género, etnia, discapacidad, estado civil, número de hijos y quintil.

Primero, los datos se dividieron en conjuntos de entrenamiento (70%) y prueba (30%), utilizando un proceso de muestreo aleatorio. A continuación, se modeló una red neuronal artificial a partir del conjunto de datos de entrenamiento. Una vez que se obtuvo la máxima precisión de clasificación del modelo se evaluó la red neuronal en el conjunto de prueba y determinó la importancia relativa de cada variable en el modelo (Helal et al., 2018; Teoh et al., 2006; Vandamme et al., 2007) (ver Figura 6).

Figura 6

Importancia relativa de las variables independientes

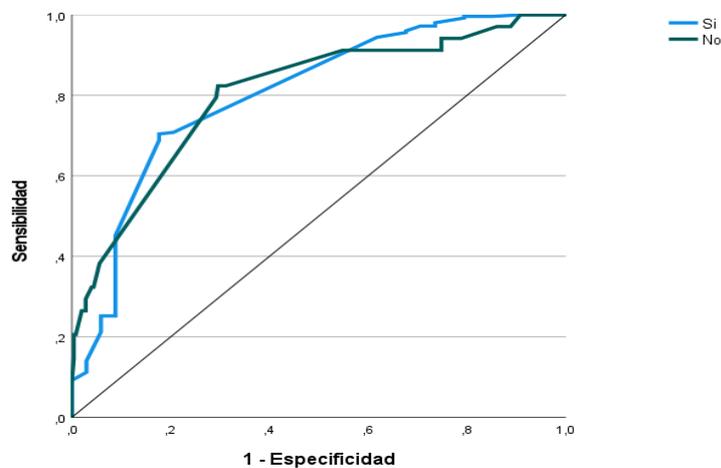


Nota: Elaboración Propia, programa SPSS

El desempeño de cada modelo se evaluó mediante la precisión de la clasificación y el área bajo la curva (ROC), tal como se muestra en la Figura 7, la cual proporciona una medida agregada del desempeño en todos los umbrales de clasificación posibles (Cawley & Talbot, 2010; Juba & Le, 2019).

Figura 7

Representación gráfica del área bajo la curva del modelo RNA



Nota: Elaboración Propia, programa SPSS

9.2 Estudio 2

9.2.1 *Análisis de regresión logística*

Se utilizó un modelo predictivo y se realizó un análisis de regresión logística binaria a través del procedimiento de regresión paso a paso basado en la estadística de Wald para analizar la capacidad predictiva de las variables relacionadas con el rendimiento académico previo, la inteligencia emocional, la motivación y las metas académicas sobre el éxito o fracaso académico de los estudiantes. Adicionalmente, se analizó la ponderación de cada una de las variables independientes sobre la probabilidad de éxito o fracaso académico.

Las variables independientes (covariables) para el análisis fueron puntajes de desempeño previos (puntaje de prueba de diagnóstico y puntaje de acceso a la universidad), inteligencia emocional (atención emocional, claridad de sentimientos y reparaciones del estado de ánimo), objetivos académicos (objetivos de aprendizaje, objetivos de enfoque de desempeño, objetivos de evitación de desempeño y objetivos de evitación de logros asociados con el trabajo académico) y motivación (autoeficacia, motivación intrínseca, ansiedad antes de las evaluaciones, uso de estrategias metacognitivas, y autorregulación). La variable dependiente incluía la variable dicotómica aprobar o reprobar.

Se utilizó la prueba de Hosmer y Lemeshow para evaluar la bondad de ajuste del modelo arrojó valores satisfactorios; por lo tanto, se puede concluir que el modelo se ajusta bien a los datos. La estadística R^2 de Nagelkerke estimó un valor de ajuste del modelo de 0,46, y el modelo estimó correctamente el 88,4% de los casos. Los niveles de odd ratio fueron superiores a 1 para las variables de metas de atención y rendimiento, lo que indica que la probabilidad de fracaso académico aumenta 1,22 veces por cada punto que aumenta la puntuación de atención y 1,38 veces por cada punto que aumenta la puntuación de las metas de rendimiento. Los niveles de la razón impar fueron inferiores a 1 para las variables, puntuación de la prueba diagnóstica, puntuación de acceso a la

universidad y motivación-autoeficacia, lo que indica que la probabilidad de fracaso académico disminuye 5,29 veces por cada punto que aumenta la puntuación en la prueba diagnóstica, 1,47 veces por cada punto que aumenta la puntuación de acceso a la universidad y 1,47 veces por cada punto que aumenta la variable motivación-autoeficacia.

9.2.2 Análisis de curvas ROC

Este análisis resume la capacidad predictiva de un modelo de regresión logística a través del concepto de sensibilidad. En este estudio, el fracaso o éxito académico se define como la variable de estado, y las cinco variables identificadas como significativas por el análisis logístico se definen como variables de contraste.

Para representar la capacidad discriminativa de cada una de las variables de contraste, se estimó el área bajo el parámetro de la curva ROC (AUC). El gráfico de la curva ROC ilustra la relación de verdaderos positivos (sensibilidad, eje Y) frente a la relación de falsos positivos (especificidad, eje X). Por lo tanto, la variable tendrá mejor poder discriminativo cuantos mayores sean los verdaderos positivos y menores sean los falsos positivos.

Los valores de AUC para cada una de las variables identificadas son significativas en el análisis logístico. Las dos variables con mejores valores predictivos incluyen las asociadas al rendimiento académico previo, que son la puntuación en las pruebas diagnósticas, con un AUC = 0,986 (IC: 0,980-0,992), y la puntuación de acceso a la universidad, con un AUC = 0,826 (IC: 0,790-0,863). La puntuación de la prueba diagnóstica tiene el mayor poder discriminatorio.

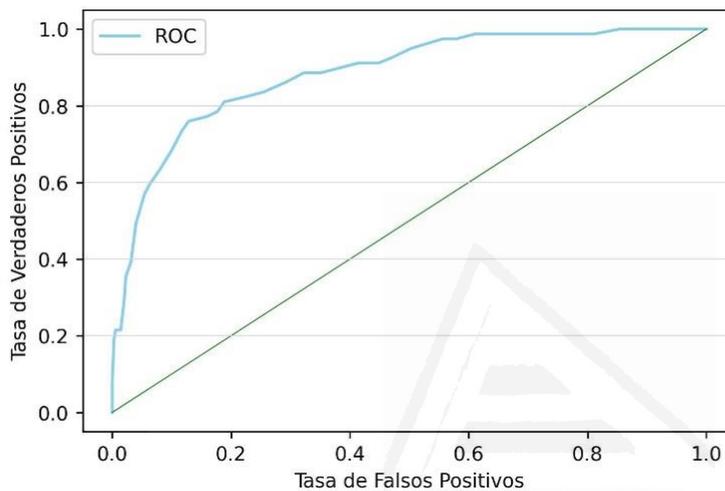
Para determinar el punto de corte en el que se alcanza la mayor sensibilidad y especificidad, se utilizó la prueba de Youden (sensibilidad + especificidad-1). Esto estipula el punto de corte con la mayor sensibilidad y especificidad juntas.

9.2.2.1 Evaluación Diagnóstica

Para el puntaje de la prueba diagnóstica, el valor de 1.13 tuvo el mayor poder discriminativo para detectar el fracaso académico con una sensibilidad del 95% y una especificidad del 50%.

Figura 8

Curva ROC para la variable evaluación diagnóstica



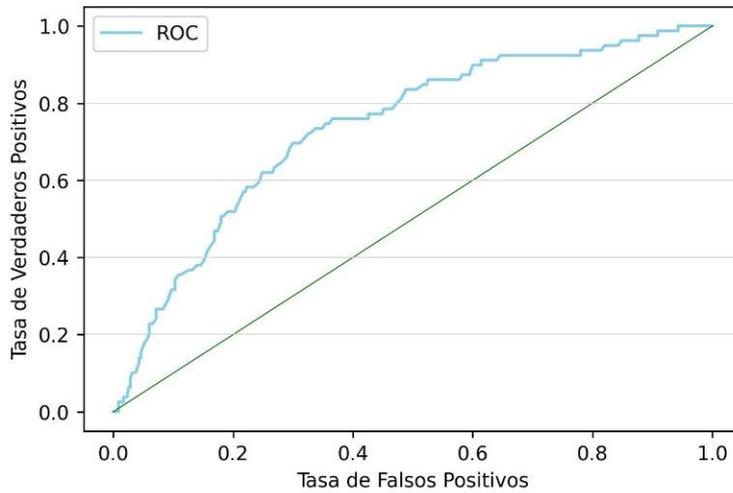
Nota: Elaboración propia, realizada en Python

9.2.2.2 Nota de acceso a la Universidad

Para el puntaje de acceso a la universidad, el valor de 0.527 tuvo el mayor poder discriminativo para detectar el fracaso académico con una sensibilidad del 85% y una especificidad del 72%.

Figura 9

Curva ROC para la variable nota de acceso a la Universidad



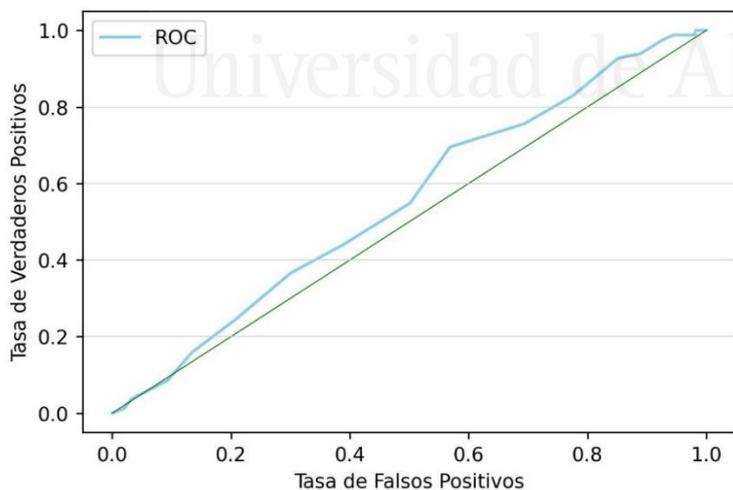
Nota: Elaboración propia, realizada en Python

9.2.2.3 Auto eficacia

Para la autoeficacia, el valor de $-0,69$ tuvo el mayor poder discriminativo para detectar el fracaso académico con una sensibilidad del 90% y una especificidad del 25%.

Figura 10

Curva ROC para la variable auto eficacia



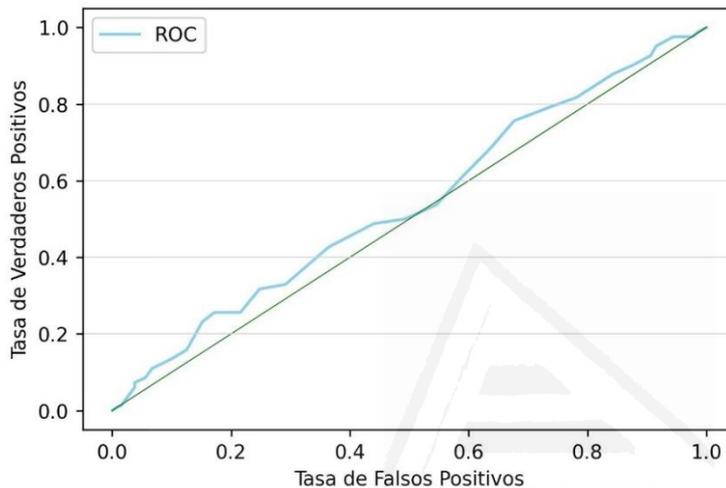
Nota: Elaboración propia, realizada en Python

9.2.2.4 Atención emocional

Para la atención emocional, el valor de $-0,06$ tuvo el mayor poder discriminativo para detectar el fracaso académico con una sensibilidad del 54% y una especificidad del 53%.

Figura 11

Curva ROC para la variable atención emocional



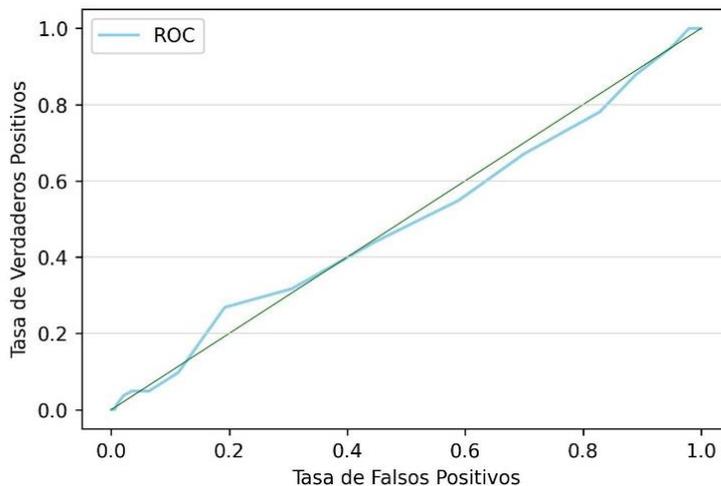
Nota: Elaboración propia, realizada en Python

9.2.2.5 Metas enfocadas al desempeño

Para los objetivos de enfoque de desempeño, el valor de $-0,80$ tuvo el mayor poder discriminativo para detectar el fracaso académico con una sensibilidad del 80% y una especificidad del 30%.

Figura 12

Curva ROC para la variable metas enfocadas al desempeño



Nota: Elaboración propia, realizada en Python

9.3 Estudio 3

9.3.1 Comparación de Perfiles

Los estudiantes que abandonaron pertenecientes al Grupo 2 obtuvieron puntajes más bajos que los estudiantes del Grupo 1 (aprobado) en el Ser Bachiller, Prueba de Lenguaje, Prueba matemática, metas de aprendizaje, valores intrínsecos, autoeficacia, uso de estrategia cognitivas y atribución del bajo rendimiento al profesor.

Se utilizó como covariables el GLM de medidas repetidas, incluyendo género, estado civil y segmento de población; las variables relacionadas con el Rendimiento Académico Previo, la Orientación a Objetivos, las Habilidades Sociocognitivas Motivacionales y Autorreguladas, la Inteligencia Emocional y las atribuciones Causales como factores intrasujetos independientes; y la variable Abandono (aprobado o abandono) como factor entre sujetos para analizar si hubo una diferencia significativa entre los grupos. Los resultados de la prueba M de Box no mostraron homogeneidad de la matriz de varianza-covarianza ($F = 1,21$; $df = 1177928,509$; $p = 0,01$). La violación de esta suposición tiene un efecto mínimo si los grupos son aproximadamente iguales en tamaño. La prueba de Mauchly fue significativa, por lo que las pruebas de los efectos

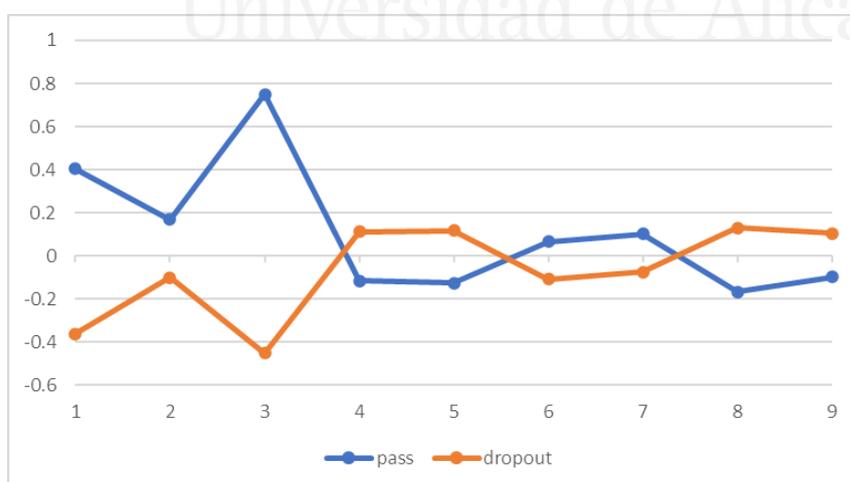
intrasujetos se proporcionan con los índices corregidos (límite inferior, que es el más estricto).

El perfil de los dos grupos fue diferente, y sólo la covariable de género fue significativa. La potencia observada fue adecuada; sin embargo, el tamaño del efecto fue pequeño. La estimación de los parámetros y la prueba *t* para verificar qué variables eran significativamente diferentes dentro del perfil confirmaron que hubo diferencias estadísticamente significativas, obteniendo puntajes más altos para los estudiantes que abandonaron en las siguientes variables: metas de evitación del rendimiento, evitación de las metas de trabajo académico, ansiedad ante las pruebas y atribución de alto rendimiento en las instalaciones. Además, en forma de puntuaciones más altas para los estudiantes que aprobaron el curso, se obtuvieron diferencias significativas en las siguientes variables: calificación de acceso, prueba de idioma, prueba matemática, motivación intrínseca y autoeficacia.

La Figura 13 muestra una representación gráfica de los perfiles de ambos grupos (abandono/aprobación) con las variables estadísticamente significativas.

Figura 13

Representación gráfica de perfiles de estudiantes que abandonan y aprueban

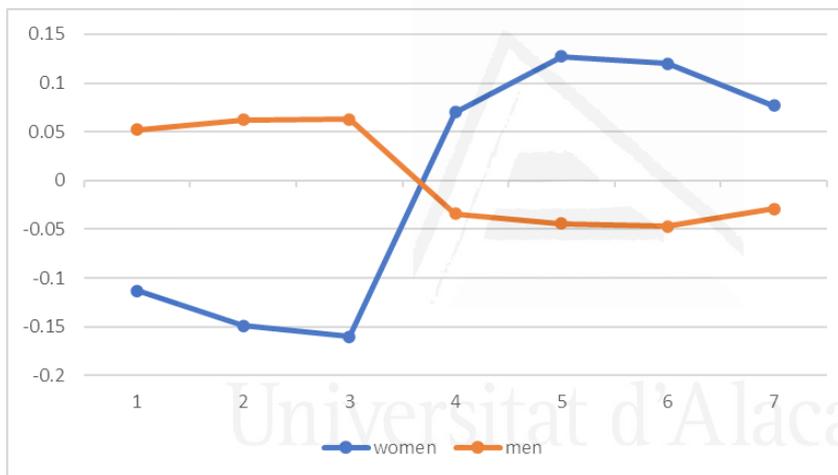


Nota: 1= nota de acceso; 2= test de lenguaje; 3= test de matemáticas; 4= objetivos de evasión del rendimiento; 5= objetivos de evasión del trabajo académico; 6= motivación intrínseca; 7= autoeficacia; 8= test ansiedad; 9= atribución del alto rendimiento a la facilidad. Elaboración propia programa SPSS

Además, la covariable de género fue significativa para las siguientes variables (Figura 14): comprensión emocional, objetivos de enfoque de desempeño y facilidad de atribución de alto rendimiento, siendo los hombres los que obtuvieron los puntajes más altos. Las variables: objetivos de aprendizaje, ansiedad ante las pruebas, estrategias metacognitivas y autorregulación obtuvieron los puntajes más altos en las mujeres. La Figura 14 muestra una representación gráfica de los perfiles de ambos grupos (mujeres/hombres) con las variables estadísticamente significativas.

Figura 14

Representación gráfica de perfiles de mujeres y hombres.

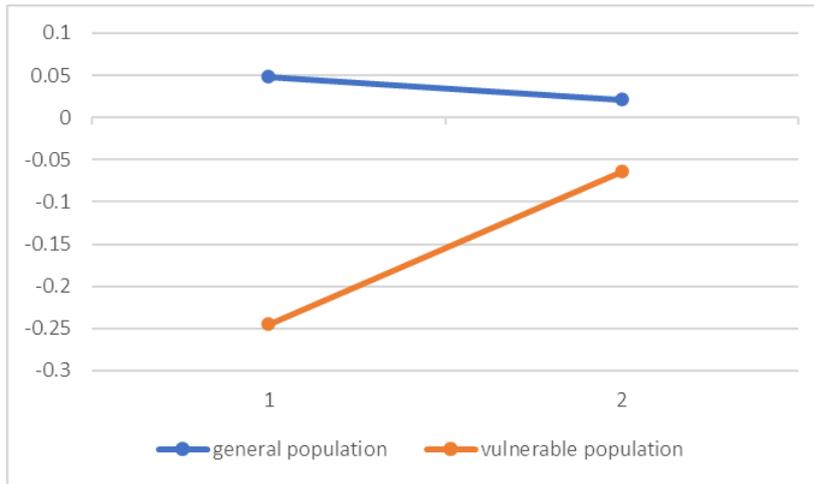


Nota: 1= comprensión emocional; 2= objetivos enfocados al rendimiento; 3= atribución del alto rendimiento a la facilidad; 4= objetivos de aprendizaje; 5= test de ansiedad; 6= estrategias metacognitivas; 7= autorregulación. Elaboración propia programa SPSS

El segmento poblacional covariable fue significativo para las variables test matemático y autoeficacia, siendo el grupo de participantes identificados como población vulnerable la obteniendo la puntuación más baja en estas variables. La Figura 15 muestra una representación gráfica de los perfiles de ambos grupos (población vulnerable/población general) con las variables estadísticamente significativas

Figura 15

Representación gráfica de perfiles población vulnerable y población general

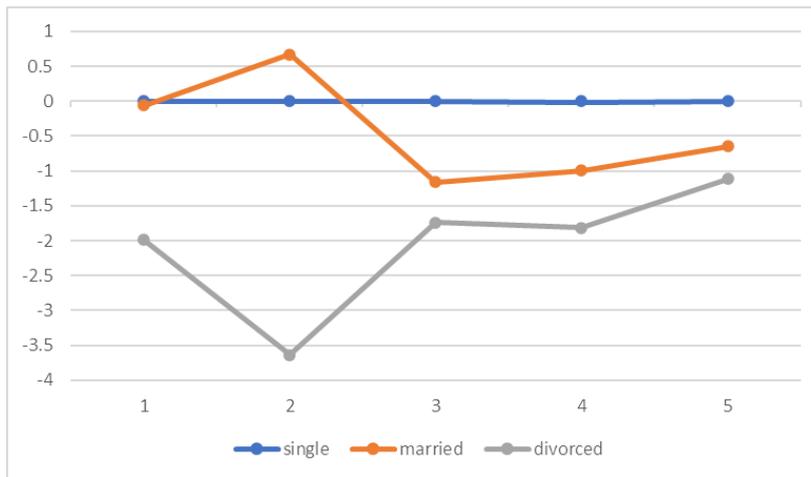


Nota: 1= test matemático; 2= autoeficacia. Elaboración propia programa SPSS

La covariable del estado civil fue significativa para las variables atención emocional, regulación emocional, atribución de alto rendimiento de facilidad, atribución de bajo rendimiento de baja capacidad y atribución de bajo rendimiento de los maestros, y los participantes declararon que estaban divorciados obtuvieron la puntuación más baja en estas variables. La Figura 16 muestra una representación gráfica de los perfiles de los tres grupos según el estado civil (soltero/casado/divorciado) con las variables estadísticamente significativas.

Figura 16

Representación gráfica de los perfiles de estado civil



Nota: 1= atención emocional; 2= regulación emocional; 3= atribución del alto rendimiento a la facilidad; 4= atribución del bajo rendimiento al profesor; 5= atribución del bajo rendimiento a la baja capacidad. Elaboración propia programa SPSS.

9.3.2 Análisis de Redes Neuronales

Se utilizaron redes neuronales artificiales (ANN) para predecir la tasa de abandono precoz en la EPN, teniendo en cuenta las variables que fueron significativas en el análisis de comparación de perfiles entre los alumnos que aprobaron el curso de nivelación y los alumnos que abandonaron. Estas variables fueron la calificación de acceso, la prueba de lenguaje, la prueba matemática, los objetivos de evitación del rendimiento, la evitación de los objetivos de trabajo académico, la motivación intrínseca, la autoeficacia, la ansiedad por la prueba y la atribución de alto rendimiento de facilidad. La variable dependiente fue "success / dropout".

En primer lugar, los datos se dividieron en conjuntos de entrenamiento (70%) y prueba (30%) utilizando un proceso de muestreo aleatorio. A continuación, se modeló un ANN a partir del conjunto de datos de entrenamiento empleando un algoritmo de entrenamiento de descenso de gradiente. Una vez obtenida la máxima precisión de clasificación del modelo, se evaluó la red neuronal y se determinó la importancia relativa de cada variable en el modelo. El rendimiento del modelo se evaluó utilizando el área

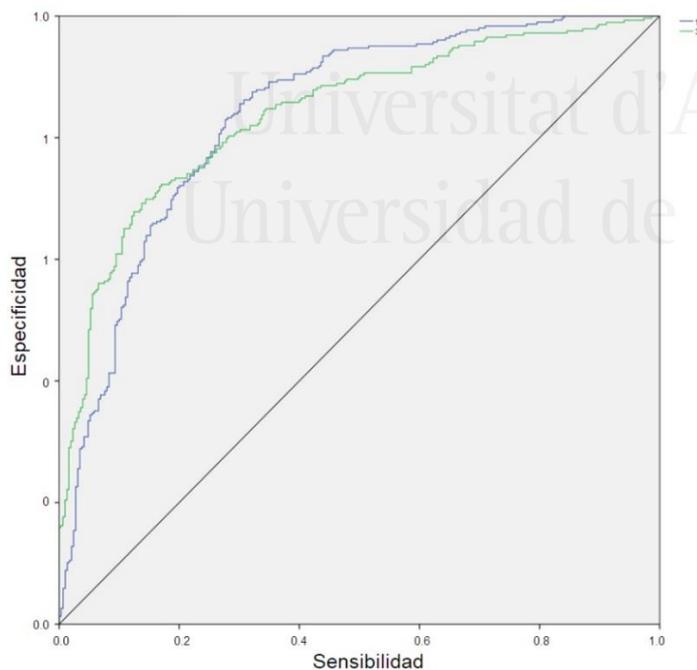
bajo la curva (AUC), que proporciona una medida agregada del rendimiento en todos los umbrales de clasificación posibles.

En el modelo ANN, todas las variables fueron significativas y se clasificaron de mayor a menor importancia en el siguiente orden: prueba matemática (100%), grado de acceso (88,2%), objetivos de evitación del rendimiento (76%), motivación intrínseca (74,3%), autoeficacia (66,5%), evitación de objetivos de trabajo académico (57,7%), prueba de lenguaje (54,8%), ansiedad ante la prueba (48,6%) y facilidad de atribución de alto rendimiento (47,3%).

Al analizar el área bajo la curva, se encuentra un valor de 0.839, lo que indica que el modelo tenía buena capacidad discriminativa (Figura 17).

Figura 17

Representación gráfica del área bajo la curva para el modelo ANN con la variable dependiente abandono.



Nota: línea azul 1= no abandono; línea verde 3= abandono. Elaboración propia programa SPSS

SECCIÓN SEGUNDA

10 Resultados: Trabajos Publicados

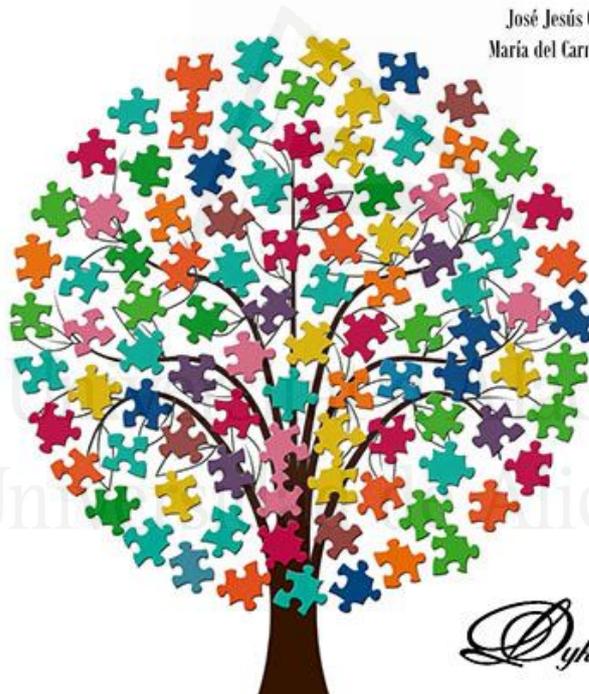
1. Vidal, J., Gilar Corbí, R., & Stefos, E. (2021). Rendimiento académico y variables socioeconómicas asociadas: Modelo de predicción en la Universidad nacional de educación (Ecuador). En *Innovación docente e investigación en educación: Nuevos enfoques en la metodología docente*. Dykinson. <http://digital.casalini.it/9788411220040>.
2. Gilar-Corbi, R., Pozo-Rico, T., Castejón, J.-L., Sánchez, T., Sandoval-Palis, I., & Vidal, J. (2020). Academic Achievement and Failure in University Studies: Motivational and Emotional Factors. *Sustainability*, 12(23), 9798. <https://doi.org/10.3390/su12239798>.
3. Vidal, J., Gilar-Corbi, R., Pozo-Rico, T., Castejón, J.-L., & Sánchez-Almeida, T. (2022). Predictors of University Attrition: Looking for an Equitable and Sustainable Higher Education. *Sustainability*, 14(17), 10994. <https://doi.org/10.3390/su141710994>

INNOVACIÓN DOCENTE E INVESTIGACIÓN EN EDUCACIÓN:

NUEVOS ENFOQUES EN LA METODOLOGÍA DOCENTE

COMPS.

Ana Belén Barragán Martín
María del Mar Molero Jurado
África Martos Martínez
María del Mar Simón Márquez
José Jesús Gázquez Linares
María del Carmen Pérez-Fuentes



Dykinson, S.L.

Vidal, J., Gilar Corbí, R., & Stefos, E. (2021). Rendimiento académico y variables socioeconómicas asociadas: Modelo de predicción en la Universidad nacional de educación (Ecuador). En *Innovación docente e investigación en educación: Nuevos enfoques en la metodología docente*. Dykinson. <http://digital.casalini.it/9788411220040>.

RESUMEN

En las regiones de América Latina y el Caribe, la retención y el abandono de los estudiantes son realidades distintas y negativas en todos los niveles educativos. Tradicionalmente, las posibles razones del abandono se centraban en las características de los estudiantes y de cómo se relacionaban con las instituciones, aunque posteriormente se ha puesto el énfasis en la responsabilidad que tienen las instituciones al momento de atender y dar una respuesta educativa adecuada a un grupo masivo y heterogéneo de estudiantes. En Ecuador, se han realizado varios estudios para determinar qué variables se relacionan con el fracaso académico y el abandono de los estudiantes en la universidad. En este contexto, factores socioeconómicos como el ingreso mensual familiar, el tipo de escuela, el tipo de vivienda e incluso el género se han identificado como componentes que interviene en el fenómeno del fracaso estudiantil. Al mismo tiempo, el gobierno y las universidades han propuesto políticas de acción afirmativa para ayudar a los estudiantes a superar las dificultades provocadas por la influencia de estos factores. Por lo tanto, identificar estos factores y analizar su influencia en el rendimiento académico es un proceso importante para identificar tempranamente a los estudiantes en riesgo y, en consecuencia, implementar acciones correctivas en el proceso educativo. En base a la literatura previa revisada, el objetivo del presente trabajo fue determinar qué variables sociodemográficas están asociadas con un mayor éxito de egreso en los estudios universitarios en la Universidad Nacional de Educación, que es una de las universidades de referencia en Ecuador en el campo de la formación en educación, así como la puesta a prueba de un modelo que permita predecir el éxito/fracaso en el egreso en función de esas variables sociodemográficas.



Universitat d'Alacant
Universidad de Alicante



Gilar-Corbi, R., Pozo-Rico, T., Castejón, J.-L., Sánchez, T., Sandoval-Palis, I., & Vidal, J. (2020). Academic Achievement and Failure in University Studies: Motivational and Emotional Factors. *Sustainability*, 12(23), 9798. <https://doi.org/10.3390/su12239798>.

Universitat d'Alacant
Universidad de Alicante

RESUMEN

Las universidades tienen el compromiso de ofrecer una educación de calidad; sin embargo, a menudo se observa un alto índice de fracaso académico en el primer año de estudios. Considerando el impacto que la motivación y los aspectos emocionales pueden tener en el compromiso de los estudiantes con el estudio y, por lo tanto, en su rendimiento académico, logro y bienestar, este estudio tiene como objetivo identificar los factores asociados al éxito o fracaso académico en 1071 estudiantes que ingresan a la Escuela Politécnica Nacional (Quito, Ecuador).

Los datos fueron recopilados a partir de los registros informáticos existentes en la universidad, con el permiso del personal administrativo responsable. Se ha utilizado un modelo predictivo y se ha realizado un análisis de regresión logística binaria mediante el procedimiento de regresión por pasos basado en el estadístico de Wald para analizar la capacidad predictiva de las variables relacionadas con la inteligencia emocional, las habilidades sociocognitivas motivacionales y autorreguladas, la orientación a metas y el rendimiento académico previo (medido por las notas de acceso a la universidad y a través de una prueba de conocimientos realizada al inicio del curso académico universitario). Para determinar el punto de corte para el mejor poder discriminatorio de cada una de las variables, se ha utilizado un análisis de curvas de características operativas del receptor (ROC). Los resultados indican que las variables que resultan significativas en la predicción del éxito o el fracaso académico son la variable de atención emocional, la variable de metas de aproximación al rendimiento y autoeficacia motivacional. Además, el mayor poder predictivo lo muestra la medida de rendimiento académico previo obtenida a través de la prueba de conocimientos realizada al inicio del curso universitario.



Universitat d'Alacant
Universidad de Alicante



Vidal, J., Gilar-Corbi, R., Pozo-Rico, T., Castejón, J.-L., & Sánchez-Almeida, T. (2022). Predictors of University Attrition: Looking for an Equitable and Sustainable Higher Education. *Sustainability*, 14(17), 10994. <https://doi.org/10.3390/su141710994>

Universitat d'Alacant
Universidad de Alicante

RESUMEN

El fracaso y el abandono de los estudios universitarios son cuestiones que preocupan a todas las naciones por los costes personales, sociales y económicos que ello conlleva. Dado que el fenómeno del abandono es complejo y en él intervienen numerosos factores, revertirlo implicaría un enfoque integral mediante intervenciones dirigidas a los factores identificados como clave en la decisión de abandonar los estudios. Por lo tanto, el objetivo principal de este trabajo es determinar el perfil de los estudiantes que ingresan a la EPN (institución de educación superior STEM) para analizar las características que diferencian a los estudiantes que abandonan temprano en su carrera y los que permanecen en la universidad. Una muestra de 624 estudiantes que accedieron a la EPN (un curso obligatorio al inicio de sus estudios) participó en el estudio. El 26,6% de los participantes eran mujeres, el 50,7% de los participantes aprobaron el curso. Se analizaron los datos referentes a las variables sociales, económicas y académicas. Se utilizaron técnicas de comparación, y redes neuronales artificiales, para comparar los perfiles característicos de los estudiantes que aprobaron el curso de nivelación y los que abandonaron. Los resultados mostraron diferencias significativas entre los perfiles de los alumnos que aprobaron y los que abandonaron con respecto a las variables relacionadas con el rendimiento académico previo y los aspectos motivacionales y atribucionales. Las redes neuronales artificiales corroboraron la importancia de estas variables en la predicción del abandono. En esta investigación, se revelan las variables clave que predicen la continuidad o el abandono de la educación superior, lo que permite identificar a los estudiantes en situación de riesgo y, por lo tanto, promover iniciativas para proporcionar un apoyo académico adecuado y mejorar la retención de los estudiantes.



Universitat d'Alacant
Universidad de Alicante

SECCIÓN TERCERA

11 Discusión

El objetivo general de esta investigación es proponer y validar empíricamente un modelo que permita explicar y predecir el rendimiento académico de los alumnos universitarios, identificando los factores que lo afectan positivamente, para ello se realizaron estudios con datos obtenidos de la Universidad Nacional de Educación del Ecuador, y la Escuela Politécnica Nacional considerando las variables sociodemográficas, educativas y de rendimiento previo.

Estos factores consideran las desigualdades existentes entre los estudiantes que ingresan la educación superior y las existentes dentro del grupo que finalizan la carrera de manera exitosa, siendo la reducción de estas desigualdades un objetivo estratégico al momento en diferentes países (Agencia Ejecutiva en el ámbito Educativo, Audiovisual y Cultural, 2012). A continuación, se discuten los resultados obtenidos en función de los dos objetivos planteados.

11.1 Analizar cómo se relacionan entre sí las variables relativas a factores sociodemográficos, educativos y de rendimiento previo de los estudiantes universitarios, así como analizar cuáles son las variables que contribuyen significativamente a la explicación del éxito académico y del abandono escolar.

Las variables que se analizaron fueron género, rendimiento académico previo, orientación a metas, motivación, habilidades sociocognitivas autorreguladas, inteligencia emocional y estado civil. Las técnicas utilizadas para estos análisis fueron

tablas de contingencia, regresión logística, redes neuronales artificiales (RNA) y análisis de curvas de Característica Operativa del Receptor (ROC siglas del inglés).

En el primer trabajo, el análisis mediante RNA concluyó que todas las variables resultaron estadísticamente significativas en la predicción del egreso, siendo la de mayor importancia el índice de vulnerabilidad. Obteniéndose una exactitud de clasificación de 0,903. Por lo que se puede indicar que el modelo de RNA hizo una mejor predicción del abandono de la variable dependiente egresa/no egresa. Esto podría indicar que los métodos de aprendizaje automático son capaces de hallar relaciones entre variables que no son posibles de detectar mediante los métodos tradicionales.

En el segundo trabajo aplicando RNA, todas las variables fueron significativas en la predicción del éxito académico, clasificándose de mayor a menor importancia en el siguiente orden: prueba matemática (100%), nota de examen de acceso a la educación superior (88,2%), objetivos de evitación del rendimiento (autodestructivo, no querer ser juzgado negativamente por los demás) (76%), motivación intrínseca (74,3%), autoeficacia (66,5%), evitación de metas de trabajo académicas realizar tareas con mínimo esfuerzo (57,7%), prueba de lenguaje (54,8%), ansiedad por la prueba (48,6%) y facilitar la atribución de alto rendimiento (47,3%).

En el segundo trabajo se confirmó parcialmente la hipótesis de que los estudiantes con puntuaciones de inteligencia emocional más altas tienen una mayor probabilidad de éxito académico. En un estudio que buscó caracterizar la investigación sobre la intención de abandono en estudiantes universitarios en los últimos 5 años, se revisaron 15 estudios empíricos cuantitativos, concluyendo que la inteligencia emocional es una de las variables menos relacionadas con la intención de abandono (Sáez et al., 2019). Este hallazgo no está en línea con lo que se ha evidenciado con frecuencia en la literatura científica, ya que la inteligencia emocional ha demostrado ser una variable clave en la adaptación y prevención del abandono universitario (de Oliveira et al., 2021; Mtshweni, 2022; Pennington et al., 2018; Topham & Moller, 2011; Turner et al., 2017;

van Rooij et al., 2017, 2018). Es posible que el estudio realizado requiera una evaluación más profunda de la inteligencia emocional de los estudiantes, considerando diferentes modelos explicativos para esta variable (modelos de habilidad, modelos basados en competencias y modelos mixtos) y tal vez incluyendo otra selección de instrumentos de medición. De esta manera, sería posible captar las diferencias que se pueden esperar entre un nivel óptimo de inteligencia emocional y la disminución de la deserción escolar. Además, una muestra más grande de participantes incluidos en el estudio sería otra estrategia para arrojar luz sobre estos resultados. Con esto se puede explicar por qué no se demostró la hipótesis del tercer trabajo referente a si los estudiantes que tienen puntuaciones más bajas en inteligencia emocional tienen una mayor probabilidad de abandono, dado que no se encontraron diferencias significativas en estas variables entre los grupos.

Respecto a las relaciones entre sí que se establecen entre las variables incluidas en la presente Tesis doctoral, queremos señalar que en el primer estudio realizado, la covariable del estado civil fue significativa en relación a las variables atención emocional, regulación emocional, facilidad de atribución de alto rendimiento y atribución de bajo rendimiento de los maestros, con los participantes que se declararon divorciados con una puntuación más baja en estas variables, mientras que los participantes casados obtuvieron una puntuación más baja para la variable atribución de bajo rendimiento de baja capacidad. No hay estudios previos que muestren resultados similares, y es posible que una muestra más grande de participantes pueda difuminar los resultados sin indicar ninguna importancia en este sentido.

Al respecto de la variable género, en el tercer trabajo se define una hipótesis sobre si las estudiantes tienen menos probabilidades de abandonar, en este caso los resultados indicaron que la covariable de género fue significativa en la comparación de perfiles; sin embargo, el porcentaje de mujeres de la muestra que abandonaron la lista fue el mismo que el de las mujeres que aprobaron el curso de nivelación. Existieron diferencias

significativas de género en las variables comprensión emocional, objetivos de enfoque de desempeño y atribución de alto rendimiento, con los hombres obteniendo los puntajes más altos. Las variables metas de aprendizaje, ansiedad ante los exámenes, estrategias metacognitivas, mujeres y autorregulación obtuvieron puntuaciones más altas en las mujeres. En el caso del componente de metas de enfoque de desempeño, se debe considerar que, en un estudio realizado en otra universidad de la misma ciudad, pero con una muestra con 61,67% de mujeres, se obtuvo un equilibrio de género en el mismo componente, posiblemente indicando que la distribución de género de los estudiantes de EPN podría ser el diferenciador en este resultado (Barreno et al., 2020). Analizando el componente facilitar la atribución de alto rendimiento, el resultado indicó que, para los estudiantes varones que abandonaron, la facilidad de las asignaturas se relacionó con la obtención de buenas calificaciones; en otras palabras, los estudiantes con enfoques superficiales sostuvieron que la facilidad de la asignatura es responsable del alto rendimiento. Este es un tipo de atribución externa en términos del lugar de causalidad; es estable en la dimensión estable-inestable y es incontrolable (Barca Lozano et al., 2004). En las variables metas de aprendizaje, ansiedad ante las pruebas, estrategias metacognitivas y autorregulación, las mujeres obtuvieron puntuaciones más altas. Este resultado coincide con el de otros estudios, como el de Valle et al. (2015), que realizaron un estudio con 632 estudiantes universitarios, el 70% de los cuales eran mujeres, obteniendo una puntuación alta para la primera variable referida a la meta de aprendizaje. La variable test ansiedad se analizó en 323 estudiantes de una universidad de Estados Unidos, y se obtuvo una puntuación más alta en mujeres. Además, los autores relacionaron esto, junto con las estrategias cognitivas y la autorregulación, con el problema de la procrastinación en estudiantes de educación superior (Rodarte-Luna & Sherry, 2008). Otros estudios recientes encontraron diferencias en las variables de género claramente relacionadas con la deserción, como las competencias previamente adquiridas o las habilidades académicas (Aina et al., 2022; Niessen & Neumann, 2022; Wild, 2022).

Respecto a las variables motivacionales y atribucionales, en el tercer trabajo se analizó la relación del rendimiento académico y abandono con atribuciones a causas externas e incontrolables, los resultados confirmaron esta relación, ya que los estudiantes que abandonaron puntuaron significativamente más en estas causas, atribuyendo un alto rendimiento a la facilidad de las tareas; en otras palabras, según ellos, es la facilidad de las asignaturas lo que permite a los estudiantes lograr un buen rendimiento académico. Esto significa que, en general, para aquellos alumnos cuyo rendimiento académico depende de la facilidad de la asignatura, el rendimiento de los alumnos que obtienen buenas notas se debe a que la asignatura es fácil. Este es un tipo de atribución externa en términos del lugar de causalidad; es estable en la dimensión estable-inestable y no es controlable en la dimensión control-sin control. En un estudio sobre atribuciones causales en 787 estudiantes universitarios en la República Dominicana, se observó que las atribuciones causales externas (a sujetos, profesores y suerte) fueron aquellas con mayor poder discriminativo y capacidad predictiva para el bajo rendimiento académico (Fernández et al., 2015). Este resultado es consistente con lo evidenciado en la literatura anterior ya que los estudiantes que atribuyen el éxito académico a factores como la suerte o la facilidad de la tarea (en lugar de causas como el esfuerzo o la perseverancia) están inmersos en una actitud de indefensión caracterizada por atribuir un rendimiento óptimo a causas externas e incontrolables y concluyendo que la posibilidad de alcanzar metas no está relacionada con la participación del individuo o su perseverancia, con lo cual el riesgo de abandono académico es muy alto ante este tipo de atribución (Del Bonifro et al., 2020; Diseth & Samdal, 2014; Jang & Liu, 2012; Pekrun & Linnenbrink-Garcia, 2012; Putwain et al., 2013; Yu et al., 2021).

Los datos revelan que los estudiantes con puntajes más altos en los objetivos de enfoque de desempeño tienen más probabilidades de enfrentar el fracaso académico. En cuanto a la relación entre las metas académicas y el rendimiento, algunos autores (Bong, 2009; Midgley et al., 2001) consideran que estas dos variables cambian a medida

que los estudiantes avanzan por el sistema educativo. Por lo tanto, el aprendizaje o dominio de metas será más beneficioso en los cursos primarios que muestren una relación positiva con el rendimiento académico (Paulick et al., 2013), mientras que perderían importancia a nivel secundario y universitario, donde las relaciones serían más débiles (Valle et al., 2015).

En el segundo trabajo no se encontraron diferencias significativas en el factor de metas enfocadas al desempeño entre los estudiantes que abandonaron y los que aprobaron el curso. Este resultado se puede relacionar con el de un estudio en una universidad de los Estados Unidos que mostró que los estudiantes que tenían buenos resultados académicos obtuvieron los puntajes más bajos en las metas variables de evitación del rendimiento, mientras que aquellos con bajo rendimiento obtuvieron puntajes altos, debilitando su orientación a las metas (Hsieh et al., 2007), esto coincide con el resultado obtenido en el tercer trabajo en el cual los resultados indicaron que los estudiantes que abandonaron obtuvieron puntajes más altos en las variables metas para evitación de rendimiento. En cuanto a los problemas académicos y la deserción derivada del objetivo de completar tareas con un esfuerzo mínimo durante los estudios universitarios, algunos estudios incluso predijeron futuros problemas de agotamiento en el entorno laboral (Salmela-Aro et al., 2009).

En el tercer trabajo se analizó la hipótesis referente a si aquellos estudiantes que tienen puntuaciones más bajas en motivación y estrategias de aprendizaje autorreguladas tienen una mayor probabilidad de abandono, los resultados indicaron que los estudiantes que abandonaron obtuvieron puntuaciones significativamente más bajas en los factores de estrategias de aprendizaje autorreguladas, valor intrínseco y autoeficacia mientras que obtuvieron puntuaciones más altas en el factor negativo de la sección de motivación "prueba de ansiedad". Este resultado indicó una fuerte relación entre la motivación y las estrategias de aprendizaje autorreguladas, que se ha encontrado en otros estudios, como los realizados en tres universidades colombianas (Granados López

& Gallego López, 2016). Estos hallazgos son consistentes con estudios previos ya que otros estudios también mostraron que los estudiantes que abandonaron durante el inicio de la carrera universitaria obtuvieron puntajes más altos en objetivos de evitación del desempeño y evitación del trabajo, mientras que aquellos que fueron capaces de lograr un buen rendimiento académico mostraron altos niveles de aprendizaje autorregulado, autoeficacia, evaluación de la importancia de las tareas por su propio valor intrínseco, y una mayor resistencia a la procrastinación de las tareas académicas (Ariani & Susilo, 2018; Dompnier et al., 2013; Hernandez et al., 2013; Kim et al., 2021; Schickel & Ringeisen, 2022; Senko, 2019; Yu et al., 2021). Además, la ansiedad por la evaluación académica se ha asociado con frecuencia con un peor rendimiento académico (Crouzevialle & Butera, 2016; Roos et al., 2021; Scrimin et al., 2014).

En el segundo trabajo coinciden los resultados referentes a que los estudiantes que obtienen puntuaciones más bajas en autoeficacia tienen más probabilidades de sufrir fracaso académico. Además, la investigación ha indicado que es importante desarrollar la autoeficacia de los estudiantes en los programas de educación superior para desarrollar los conocimientos, habilidades y competencias requeridos, ya que la autoeficacia de los estudiantes desempeña un papel de predicción y mediación en los logros, la motivación y el aprendizaje (van Dinther et al., 2011).

En la presente Tesis Doctoral, el primer factor identificado con el rendimiento académico es el socioeconómico, el cual se evidencia como un factor predominante varias décadas atrás. Desde la década de 1990, la administración educativa estadounidense ha recopilado y sistematizado los resultados de los programas de intervención con estudiantes desfavorecidos en la educación superior (Chaney et al., 1995) y ha promovido la implementación de nuevos programas (Chaney et al., 1998; Haskins & Rouse, 2013). En Latinoamérica se tienen resultados alentadores gracias a propuestas de apoyo principalmente desde países de la comunidad europea, como el proyecto

MISEAL (Medidas para la inclusión social y equidad en Instituciones de Educación Superior en América Latina), en estas propuestas el factor económico es preponderante.

En este sentido en el primer trabajo las variables que fueron incluidas en el modelo de predicción RNA fueron, por orden de importancia quintil, etnia, estado civil, discapacidad, género y número de hijos, lo que denota la mayor importancia del factor económico en el grupo de estudiantes con bajo rendimiento académico que derivan en abandono.

La covariable del segmento poblacional fue significativa para las variables prueba matemática y autoeficacia, siendo el grupo de participantes identificados como población vulnerable la que obtuvo la puntuación más baja en estas variables, lo que es consistente con estudios previos que identificaron la vulnerabilidad y la exclusión social como factores de riesgo académico para los nuevos estudiantes universitarios (Berger & Archer, 2016; Phan & Ngu, 2020; Sini et al., 2018). Esto deriva en que la situación socio económica influya en un bajo nivel académico en las pruebas de ingreso a la universidad y en los test de conocimientos previos realizados convirtiéndose en un segundo factor preponderante.

Existen varios estudios que relacionan el rendimiento académico previo con el éxito académico y el abandono. Lin et al. (2012) encontraron que el promedio de calificaciones (GPA) obtenido en la educación secundaria es uno de los factores predictivos del éxito académico para los estudiantes de primer año. También propusieron algunas intervenciones interesantes para revertir las posibilidades de fracaso académico, incluidos cursos de inglés correctivos, trabajos en el campus y residencia en el campus, ya que encontraron que estas intervenciones tienen un impacto positivo en la retención.

En otro estudio, Cortés y Palomar (2008) encontraron que los estudiantes que tenían mejores resultados en el campo de la ciencia también tenían mejores calificaciones en

los estudios secundarios. Castrillón (2018) encontró correlaciones significativas entre el rendimiento actual y la calificación obtenida en la educación secundaria. Rojas (2013) encontró que los mejores predictores de rendimiento en la universidad fueron las calificaciones obtenidas en la educación secundaria y en el examen de ingreso a la universidad. Rodrigo et al. (2012) confirmaron que el fracaso académico se relaciona con una menor puntuación en la prueba de acceso a la universidad e incluye una variable que se asocia en gran medida a este fracaso: la dedicación de los estudiantes a los estudios a tiempo parcial. En la mayoría de los estudios, el rendimiento previo se ha medido utilizando las calificaciones de ingreso a la universidad y/o las calificaciones en los estudios de secundaria.

En los trabajos segundo y tercero se incluye la variable de calificación de acceso a la universidad y también otra medida de rendimiento previo que no se ha utilizado en la literatura existente (pero que se considera altamente explicativa), quizás debido a la dificultad asociada a su obtención; este factor es el rendimiento previo medido al inicio de la universidad a través de una prueba realizada antes de iniciar los estudios universitarios que evalúa el nivel de conocimiento de los estudiantes (relacionado con los conocimientos específicos que se consideran clave para los estudios a cursar).

Las hipótesis en los dos estudios se confirman, los estudiantes que tengan puntuaciones más altas en el rendimiento académico previo tendrán una menor probabilidad de fracaso académico, siendo esta variable la de mayor poder predictivo respecto al éxito/fracaso académico. Por lo tanto, se propone la realización de estas pruebas diagnósticas al inicio de los estudios universitarios para identificar a los estudiantes con mayor riesgo de fracaso y, por lo tanto, aplicar medidas de prevención en el ámbito educativo, como cursos de refuerzo, en línea con la propuesta de Lin et al. (2012).

La única variable relacionada con la inteligencia emocional que fue significativa para predecir el fracaso académico es la atención emocional. Los estudiantes que sufrieron fracaso académico tuvieron los puntajes más altos en atención emocional. Una

puntuación demasiado alta en atención emocional puede ser perjudicial ya que implica una atención excesiva a las emociones e incluso puede indicar un bloqueo o dificultad para percibir correctamente el resto de los estímulos, lo que podría perjudicar el rendimiento académico. Como se dijo anteriormente, la competencia emocional tiene un impacto en el rendimiento académico (Kastberg et al., 2020; Kotsou et al., 2018; Nelis et al., 2011). Las emociones negativas se asocian con el bajo rendimiento (De Castella et al., 2013), y la atención emocional excesiva puede afectar el rendimiento académico, como lo han demostrado los datos analizados. Por esta razón, es necesario que las instituciones universitarias y las reformas educativas incluyan el desarrollo de competencias emocionales, porque la mejora de estas competencias ha demostrado ser necesaria para el desarrollo de los estudiantes. Las competencias emocionales ayudarán a los estudiantes universitarios a enfrentar desafíos, promover el espíritu empresarial y lograr el éxito académico y profesional (Brez et al., 2020; Eesley & Lee, 2021; Gilar et al., 2018; Gilar-Corbi et al., 2019; Tinajero et al., 2020; Valdivia-Salas et al., 2020). Como implicación práctica de estos hallazgos, se propone que la educación y la formación asociadas a los aspectos emocionales de los estudiantes universitarios se incluyan en los primeros cursos para potenciar y desarrollar estos atributos en los estudiantes para evitar el fracaso académico (Gilar-Corbi et al., 2019; Gilar-Corbí et al., 2018; Gilar, Pozo, Sánchez, Castejon 2018; Pozo-Rico et al., 2017) .

11.2 Analizar si existen diferencias en el perfil de estudiantes de alto rendimiento y de bajo rendimiento en función de variables sociodemográficas, educativas y de rendimiento previo.

Uno de los diferenciadores principales identificados en cuanto a la comparativa entre perfiles de estudiantes de alto y bajo rendimiento es el de la situación socioeconómica. En el estudio tercero realizado con estudiantes de la EPN al validar la hipótesis referente a si los estudiantes que pertenecen a segmentos de población más desfavorecidos

tienen una mayor probabilidad de abandono, se encontró que la covariación del segmento poblacional no fue significativa, sin embargo, cabe indicar que, este análisis debe considerar el entorno geográfico al que pertenece la universidad, la EPN está ubicada en la capital del país y la segunda ciudad más grande de Ecuador. En 2020, la tasa de deserción escolar en la educación superior debido a la situación económica fue de 16,3% a nivel nacional, pero fue mayor en sectores rurales (25,2%) (Núñez et al., 2020). En este sentido los estudiantes de los sectores rurales son una minoría en EPN, al contrario de lo que sucede en UNAE.

En cuanto al género en el modelo predictivo de deserción académica, realizado en el primer estudio en UNAE, mediante regresión logística, se encontró que esta variable es estadísticamente significativa; se obtuvo una exactitud de clasificación de 0,881.

Una interesante línea de investigación futura al respecto fue considerada en estudios como el de Vooren et al. (2022), donde las estudiantes universitarias, a pesar de mostrar menores tasas de deserción escolar en el primer año (específicamente en programas STEM, como fue el caso del presente estudio), tenían menos probabilidades de graduarse finalmente en comparación con los hombres. Sin embargo, si evaluamos el desempeño laboral en la década posterior a la graduación, las mujeres obtuvieron un nivel óptimo de desempeño, exactamente el mismo que los hombres. Por estas razones, el estudio antes mencionado concluyó que las mujeres se forman igualmente bien en la educación superior a largo plazo (Vooren et al., 2022).

Uno de los valores añadidos que aporta el presente estudio es entender cómo funcionan mejor las variables, respecto al manejo de la ansiedad ante los exámenes y el uso de estrategias cognitivas óptimas, en el caso de las mujeres para ayudarlas (lo mismo que los estudiantes varones, pero teniendo en cuenta su propio estilo de afrontamiento del aprendizaje) en carreras de este campo del conocimiento (Ingenierías en el caso de la EPN y Educación en el caso de la UNAE), evitando así el abandono precoz, la persistencia a lo largo de toda la carrera universitaria, y facilitando una mejora en el

rendimiento posterior al salir del aula, en el caso de todos los alumnos, independientemente de su género.

12 Conclusiones

El presente trabajo logra conjugar el análisis en dos Instituciones de Educación Superior que tienen dos enfoques diferentes, la una orientada a carreras en el ámbito de la educación y la otra en temas de ingeniería y ciencias. La diferencia en la ubicación geográfica de las universidades tiene implicaciones en varios ámbitos, como tiempo de traslado mayor del hogar a la IES, o la existencia de distractores que disminuyen la concentración en los estudios. Estas especificidades se reflejan en el porcentaje de repetición y abandono; la repetición en los estudios realizados en la EPN (82.73% y 67.6%) es en promedio 6 veces mayor que el abandono en toda una carrera de la UNAE (11.93%). Adicionalmente si se considera en EPN una tasa de repetición promedio de 74.5% en una cohorte estándar de 1500 estudiantes, se generan pérdidas económicas al estado de algo más de USD 200000, lo cual justifica promover inversiones para mitigar esta problemática.

Diversos estudios han indicado que, para determinar la permanencia en la universidad y el éxito académico, es imperativo el desarrollo de programas de apoyo académico donde la autoeficacia se divulgue como un factor clave para asegurar la motivación y articular el comportamiento sociocognitivo autorregulado (Bandura & Schunk, 1981; Barouch-Gilbert, 2016; Becker & Gable, 2009)

Según Frawley et al. (2017), la autoeficacia debe ser una consideración clave en los programas que tienen como objetivo apoyar a los estudiantes que enfrentan dificultades en la educación superior y sería útil para avanzar en la inversión y el apoyo del programa existente en este sector. La evidencia sugiere que existe la necesidad de ofrecer más asistencia para prevenir el alto fracaso académico en estudiantes con más dificultades,

especialmente al comienzo de la educación universitaria. Este período inicial es crítico porque, en él, los estudiantes se enfrentan a nuevas situaciones y contextos que desafiarán sus habilidades y recursos (Aljohani et al., 2019; Baneres et al., 2019; Macfadyen & Dawson, 2010). Adicionalmente las relaciones sociales de un estudiante con sus compañeros, profesores y el entorno social son de vital importancia; es fundamental lograr un equilibrio entre la adaptación y el apoyo sociales (Bernardo et al., 2016; European Commission et al., 2015)

Como muestran los resultados, dado el impacto del rendimiento académico previo y los aspectos socioemocionales (Gilar-Corbi et al., 2018, 2019; Gilar, Pozo, Sánchez, Castejón, 2018; Pozo-Rico et al., 2017) y motivacionales (Bandura & Schunk, 1981; Barouch-Gilbert, 2016; Becker & Gable, 2009) en el éxito o fracaso académico, sería importante implementar acciones que mejoren estos para reducir las posibilidades de fracaso académico. Por lo tanto, mejorar la calidad de la enseñanza ofrecida en las instituciones de educación superior, y hacerlas más equitativas y sostenibles, es imperativo tratar de proporcionar a los estudiantes los recursos y estrategias necesarias para completar con éxito su formación, y también para garantizar que los buenos profesionales potenciales no se pierdan.

En este contexto, las intervenciones del gobierno y la universidad deben apuntar a mitigar las dificultades económicas de los estudiantes, a través de ayudas económicas o el fortalecimiento de programas de becas. Por otro lado, en cuanto a los factores académicos, los esfuerzos deben enfocarse en ofrecer apoyo académico antes de iniciar los estudios universitarios, así como programas de tutoría entre pares durante el transcurso de la carrera para que las tasas de reprobación e incluso deserción de los estudiantes disminuyan.

Según Cabrera et al. (2006) existe un consenso general en aceptar que las tasas de deserción escolar son un indicador de una baja calidad de la educación universitaria, ya que se entiende que la universidad no ha podido implementar los mecanismos

adecuados para que los estudiantes puedan alcanzar las metas académicas. Sin embargo, hay múltiples factores involucrados en la deserción que no dependen de la universidad, como las condiciones económicas de los estudiantes, la salud mental, los cambios de interés y otros factores. Comprender las necesidades de los estudiantes y monitorear cualquier cambio notable son críticos en el proceso de revertir la deserción. Además, sugerimos que el momento clave para implementar acciones que eviten el abandono es antes de la matrícula para que los estudiantes puedan tomar decisiones vocacionales de acuerdo con sus verdaderos intereses y con el nivel óptimo de autoconocimiento con respecto a sus fortalezas. Del mismo modo, a lo largo de su carrera universitaria, es necesario dotar al alumnado de estrategias formativas que respondan a sus necesidades reales y/o a las áreas de mejora detectadas.

En el presente estudio se identificaron aspectos socioeconómicos y psicoeducativos involucrados en la deserción universitaria. Aunque algunos de estos factores no están determinados directamente por la universidad, es importante que la universidad cuente con herramientas para detectarlos e implementar mejoras o programas de actuación para intervenir en relación con las cuestiones detectadas como relevantes para el abandono del alumnado, permitiendo revertir el proceso. Por estas razones, la identificación temprana de la deserción universitaria puede proporcionar un gran valor para mejorar el éxito estudiantil y la efectividad institucional. En esta línea, la presente investigación demuestra la importancia de crear acciones exitosas y políticas educativas clave al inicio de la carrera universitaria de un estudiante, así como asegurar una evolución académica favorable a lo largo de sus estudios, aspirando así a buscar continuamente la excelencia en la provisión de educación superior.

La investigación realizada es un trabajo pionero en términos de explorar el efecto de pertenecer a una población más desfavorecida, la influencia del género, el rendimiento académico previo, los puntajes en inteligencia emocional, las atribuciones académicas (especialmente si se trata de causas externas e incontrolables), los puntajes en términos

de metas de logro y motivación y estrategias de aprendizaje autorregulado, todas las cuales son variables clave importantes para predecir la deserción en el contexto de la educación superior en Sudamérica.

A la luz de estos hallazgos, se podrían desarrollar políticas educativas nuevas y efectivas para responder a los mecanismos subyacentes y, por lo tanto, combatir este gravísimo problema de deserción escolar, especialmente en contextos socioeconómicos vulnerables donde la implementación de intervenciones y un mayor apoyo podrían ser determinantes para la coherencia en todo el sistema educativo superior.

De hecho, los criterios de calidad utilizados para evaluar los servicios prestados por la universidad podrían estar fuertemente influenciados por el impacto de las variables incluidas en este estudio. Esto está necesariamente relacionado con los importantes desafíos educativos entre los estudiantes vulnerables.

En línea con los hallazgos de este estudio, se necesita más investigación para comprender los recursos que sean más útiles para los estudiantes con un alto nivel de riesgo social con el fin de prevenir la deserción escolar y garantizar la integración de dichos recursos en las políticas de nivel universitario, así como su implementación. Existe una necesidad urgente de aplicar nuevas medidas diseñadas para brindar apoyo a los grupos desfavorecidos de estudiantes a través de las variables clave identificadas en la evidencia proporcionada en este estudio, como los importantes efectos de la motivación y el aprendizaje autorregulado, el empoderamiento de la inteligencia emocional y el impacto de las atribuciones académicas adaptativas, ya que esto podría representar una estrategia útil para promover la progresión y el rendimiento académico. Este trabajo podría contribuir a garantizar que los objetivos de la educación superior puedan realizarse de acuerdo con altos estándares de calidad y respondiendo a las demandas y necesidades de los estudiantes más vulnerables.

13 Referencias

- Agencia Ejecutiva en el ámbito Educativo, Audiovisual y Cultural. (2012). *Cifras clave de la educación en Europa 2012*. <https://sede.educacion.gob.es/publivena/cifras-clave-de-la-educacion-en-europa-2012/ensenanza-union-europea/15849>
- Aina, C., Mussida, C., & Lombardi, G. (2022). Are Business and Economics Alike? *Italian Economic Journal*. <https://doi.org/10.1007/s40797-021-00177-w>
- Albalade, D., Fageda, X., & Perdiguero, J. (2011). *Éxito académico, características personales y proceso de Bolonia: Una aproximación econométrica*. <http://diposit.ub.edu/dspace/handle/2445/24367>
- Aljohani, N. R., Daud, A., Abbasi, R. A., Alowibdi, J. S., Basher, M., & Aslam, M. A. (2019). An integrated framework for course adapted student learning analytics dashboard. *Computers in Human Behavior*, 92, 679-690. <https://doi.org/10.1016/j.chb.2018.03.035>
- Ariani, D. W., & Susilo, Y. S. (2018). Why Do It Later? Goal Orientation, Self-efficacy, Test Anxiety, on Procrastination. *Journal of Educational, Cultural and Psychological Studies (ECPS Journal)*, 17, Art. 17. <https://doi.org/10.7358/ecps-2018-017-wahy>
- Bandura, A., & Schunk, D. H. (1981). Cultivating competence, self-efficacy, and intrinsic interest through proximal self-motivation. *Journal of Personality and Social Psychology*, 41(3), 586-598. <https://doi.org/10.1037/0022-3514.41.3.586>
- Baneres, D., Rodríguez-Gonzalez, M. E., & Serra, M. (2019). An Early Feedback Prediction System for Learners At-Risk Within a First-Year Higher Education Course. *IEEE Transactions on Learning Technologies*, 12(2), 249-263. <https://doi.org/10.1109/TLT.2019.2912167>
- Barca Lozano, A., Mascarenhas, S. A. do N., Brenlla-Blanco, J.-C., & Fraga, H. M. (2012). Contextos de aprendizaje, determinantes familiares y rendimiento

- escolar en el alumnado de educación secundaria de Galicia. *Amazónica*, 8(1), 370-412.
- Barca Lozano, A., Peralbo Uzquiano, M., & Brenlla Blanco, J. C. (2004). Atribuciones causales y enfoques de aprendizaje: La escala SIACEPA. *Psicothema*, 16(1), 94-103.
- Barouch-Gilbert, A. (2016). Academic Probation: Student Experiences and Self-Efficacy Enhancement. *Journal of Ethnographic & Qualitative Research*, 10(3), 153-164.
- Barreno, S. N., Veas, A., Navas, L., & Castejón, J. L. (2020). Psychometric Properties of the Spanish Version of the Goal Orientation Scales in Ecuadorian Undergraduate Students. *Frontiers in Psychology*, 11. <https://www.frontiersin.org/article/10.3389/fpsyg.2020.597934>
- Becker, S., & Gable, R. (2009). The Relationship of Self-Efficacy and GPA, Attendance, and College Student Retention. *NERA Conference Proceedings 2009*. https://opencommons.uconn.edu/nera_2009/26
- Berger, N., & Archer, J. (2016). School socio-economic status and student socio-academic achievement goals in upper secondary contexts. *Social Psychology of Education*, 19(1), 175-194. <https://doi.org/10.1007/s11218-015-9324-8>
- Bernardo, A., Esteban, M., Fernández, E., Cervero, A., Tuero, E., & Solano, P. (2016). Comparison of Personal, Social and Academic Variables Related to University Drop-out and Persistence. *Frontiers in Psychology*, 7. <https://www.frontiersin.org/articles/10.3389/fpsyg.2016.01610>
- Betancur, M. R., & González, D. C. (2009). Rendimiento y calificación, dos aspectos problemáticos de la evaluación en la universidad. *Revista Virtual Universidad Católica del Norte*, 27, 1-21.
- Bong, M. (2009). Age-related differences in achievement goal differentiation. *Journal of Educational Psychology*, 101(4), 879-896. <https://doi.org/10.1037/a0015945>
- Brez, C., Hampton, E. M., Behrendt, L., Brown, L., & Powers, J. (2020). Failure to Replicate: Testing a Growth Mindset Intervention for College Student Success.

- Basic and Applied Social Psychology*, 42(6), 460-468.
<https://doi.org/10.1080/01973533.2020.1806845>
- Cabrera, L., Benítez, J. T. B., Afonso, M. G., & Pérez, P. Á. (2006). Un estudio transversal retrospectivo sobre prolongación y abandono de estudios universitarios. *RELIEVE - Revista Electrónica de Investigación y Evaluación Educativa*, 12(1), Art. 1. <https://doi.org/10.7203/relieve.12.1.4241>
- Castrillón Mejía, G. (2018). *Factores que inciden en la deserción estudiantil en el Programa Académico Administración de Empresas en la Universidad del Valle Sede Pacífico*. [Tesis de Grado, Universidad del Valle].
<https://eds.p.ebscohost.com/eds/detail/detail?vid=2&sid=6fa50e3b-4e5a-496e-a3da-1cb3af17da42%40redis&bdata=Jmxhbmc9ZXMmc2l0ZT1lZHMtbGl2ZQ%3d%3d#AN=rbduv.10893.10760&db=ir00345a>
- Cawley, G. C., & Talbot, N. L. C. (2010). On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation. *Journal of Machine Learning Research*, 11(70), 2079-2107.
- Chaney, B., Lewis, L., & Farris, E. (1995). *Programs at Higher Education Institutions for Disadvantaged Precollege Students. Statistical Analysis Report. December 1995. Postsecondary Education Quick Information System (PEQUIS). Statistical Analysis Report*. U. <https://eric.ed.gov/?id=ED391437>
- Chaney, B., Muraskin, L. D., Cahalan, M. W., & Goodwin, D. (1998). Helping the Progress of Disadvantaged Students in Higher Education: The Federal Student Support Services Program. *Educational Evaluation and Policy Analysis*, 20(3), 197-215. <https://doi.org/10.3102/01623737020003197>
- Chitarroni, H. (2002). *La regresión logística*. Instituto de Investigación en Ciencias Sociales. <https://racimo.usal.edu.ar/83/1/Chitarroni17.pdf>

- Cortés Flores, A., & Palomar Lever, J. (2008). El proceso de admisión como predictor del rendimiento académico en la educación superior. *Universitas Psychologica*, 7(1), 199-215.
- Crouzevialle, M., & Butera, F. (2016). The Role of Test Anticipation in the Link Between Performance-Approach Goals and Academic Achievement. *Swiss Journal of Psychology*, 75(3), 123-132. <https://doi.org/10.1024/1421-0185/a000176>
- De Castella, K., Byrne, D., & Covington, M. (2013). Unmotivated or motivated to fail? A cross-cultural study of achievement motivation, fear of failure, and student disengagement. *Journal of Educational Psychology*, 105(3), 861-880. <https://doi.org/10.1037/a0032464>
- De La Fuente Fernández, S. (2011). *Regresión Logística*. Universidad Autónoma de Madrid.
- de Oliveira, C. F., Sobral, S. R., Ferreira, M. J., & Moreira, F. (2021). How Does Learning Analytics Contribute to Prevent Students' Dropout in Higher Education: A Systematic Literature Review. *Big Data and Cognitive Computing*, 5(4), Art. 4. <https://doi.org/10.3390/bdcc5040064>
- Del Bonifro, F., Gabbrielli, M., Lisanti, G., & Zingaro, S. P. (2020). Student Dropout Prediction. En I. I. Bittencourt, M. Cukurova, K. Muldner, R. Luckin, & E. Millán (Eds.), *Artificial Intelligence in Education* (pp. 129-140). Springer International Publishing. https://doi.org/10.1007/978-3-030-52237-7_11
- Diseth, Å., & Samdal, O. (2014). Autonomy support and achievement goals as predictors of perceived school performance and life satisfaction in the transition between lower and upper secondary school. *Social Psychology of Education*, 17(2), 269-291. <https://doi.org/10.1007/s11218-013-9244-4>
- Dompnier, B., Darnon, C., & Butera, F. (2013). When performance-approach goals predict academic achievement and when they do not: A social value approach. *British Journal of Social Psychology*, 52(3), 587-596. <https://doi.org/10.1111/bjso.12025>

- Eesley, C. E., & Lee, Y. S. (2021). Do university entrepreneurship programs promote entrepreneurship? *Strategic Management Journal*, 42(4), 833-861. <https://doi.org/10.1002/smj.3246>
- European Commission, Directorate-General for Education, Youth, Sport and Culture, Wollscheid, S., Stensaker, B., Jongbloed, B., Vossensteyn, H., Cremonini, L., Hovdhaugen, E., Kaiser, F., & Kottmann, A. (2015). *Dropout and completion in higher education in Europe: Main report*. Publications Office of the European Union. <https://data.europa.eu/doi/10.2766/826962>
- Fernández, A., Arnaiz, P., Mejía, R., & Barca, A. (2015). Atribuciones causales del alumnado universitario de República Dominicana con alto y bajo rendimiento académico || Causal attributions in low and high academic achievement university students in the Dominican Republic. *Revista de Estudios e Investigación en Psicología y Educación*, 2(1), Art. 1. <https://doi.org/10.17979/reipe.2015.2.1.1319>
- Fernandez-Berrocal, P., Extremera, N., & Ramos, N. (2004). Validity and Reliability of the Spanish Modified Version of the Trait Meta-Mood Scale. *Psychological Reports*, 94(3), 751-755. <https://doi.org/10.2466/pr0.94.3.751-755>
- Ferreira, M. M., Avitabile, C., Botero Álvarez, J., Haimovich Paz, F., & Urzúa, S. (2017). *Momento Decisivo: La Educación Superior en América Latina y el Caribe* [Report]. World Bank Group. <https://vtechworks.lib.vt.edu/handle/10919/83253>
- Frawley, J., Ober, R., Olcay, M., & Smith, J. (2017). *Indigenous Achievement in Higher Education and the Role of Self-Efficacy: Rippling Stories of Success* [Monograph]. National Centre for Student Equity in Higher Education (NCSEHE), Curtin University. https://www.ncsehe.edu.au/wp-content/uploads/2017/05/Frawley_Rippling-Stories.pdf
- García-Martín, S., & Cantón, I. (2016). *Factores que inciden en el rendimiento académico. El camino hacia el éxito escolar de todos*. Asociación Científica de Psicología y Educación (ACIPE). <http://rua.ua.es/dspace/handle/10045/64221>

- Gilar, R., Pozo-Rico, T., Sanchez, B., & Castejón, J. L. (2018). Promote Learning in Emotional Competence Across an E-Learning Context for Higher Education. *INTED2018 Proceedings*, 1374-1380. <https://doi.org/10.21125/inted.2018.0233>
- Gilar-Corbi, R., Pozo-Rico, T., & Castejón-Costa, J. L. (2019). Desarrollando la Inteligencia Emocional en Educación Superior: Evaluación de la efectividad de un programa en tres países. *Educación XX1*, 22(1), Art. 1. <https://doi.org/10.5944/educxx1.19880>
- Gilar-Corbi, R., Pozo-Rico, T., Pertegal-Felices, M. L., & Sanchez, B. (2018). Emotional intelligence training intervention among trainee teachers: A quasi-experimental study. *Psicología: Reflexão e Crítica*, 31(1), 33. <https://doi.org/10.1186/s41155-018-0112-1>
- Gilar-Corbí, R., Pozo-Rico, T., Sánchez, B., & Castejón, J. L. (2018). Can Emotional Competence Be Taught in Higher Education? A Randomized Experimental Study of an Emotional Intelligence Training Program Using a Multimethodological Approach. *Frontiers in Psychology*, 9. <https://www.frontiersin.org/articles/10.3389/fpsyg.2018.01039>
- Granados López, H., & Gallego López, F. A. (2016). Motivación, aprendizaje autorregulado y estrategias de aprendizaje en estudiantes de tres universidades de Caldas y Risaralda. *Revista Latinoamericana de Estudios Educativos*, 12(1), Art. 1.
- Halpern, D., Piña, M., & Ortega-Gunckel, C. (2020). *School performance: New multimedia resources versus traditional notes // El rendimiento escolar: Nuevos recursos multimedia frente a los apuntes tradicionales* (Journal Article (Paginated) N.º 64). Comunicar; Comunicar. <http://eprints.rclis.org/40062/>
- Haskins, R., & Rouse, C. E. (2013). Time for Change: A New Federal Strategy to Prepare Disadvantaged Students for College. *The Future of Children*, 23(1), 1-8.
- Helal, S., Li, J., Liu, L., Ebrahimie, E., Dawson, S., Murray, D. J., & Long, Q. (2018). Predicting academic performance by considering student heterogeneity.

- Knowledge-Based Systems*, 161, 134-146.
<https://doi.org/10.1016/j.knosys.2018.07.042>
- Hernandez, P. R., Schultz, P. W., Estrada, M., Woodcock, A., & Chance, R. C. (2013). Sustaining optimal motivation: A longitudinal analysis of interventions to broaden participation of underrepresented students in STEM. *Journal of Educational Psychology*, 105, 89-107. <https://doi.org/10.1037/a0029691>
- Instituto Nacional de Estadística y Censos. (2020). *Proyecciones Poblacionales*. Instituto Nacional de Estadística y Censos. <https://www.ecuadorencifras.gob.ec/proyecciones-poblacionales/>
- Jang, L. Y., & Liu, W. C. (2012). 2 × 2 Achievement goals and achievement emotions: A cluster analysis of students' motivation. *European Journal of Psychology of Education*, 27(1), 59-76. <https://doi.org/10.1007/s10212-011-0066-5>
- Jansen, E. P. W. A. (2004). The influence of the curriculum organization on study progress in higher education. *Higher Education*, 47(4), 411-435. <https://doi.org/10.1023/B:HIGH.0000020868.39084.21>
- Juba, B., & Le, H. S. (2019). Precision-Recall versus Accuracy and the Role of Large Data Sets. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01), Art. 01. <https://doi.org/10.1609/aaai.v33i01.33014039>
- Kastberg, E., Buchko, A., & Buchko, K. (2020). Developing Emotional Intelligence: The Role of Higher Education. *Journal of Organizational Psychology*, 20(3), 64-72.
- Kim, J.-B., Moon, K.-S., & Park, S. (2021). When is a performance-approach goal unhelpful? Performance goal structure, task difficulty as moderators. *Asia Pacific Education Review*, 22(2), 261-272. <https://doi.org/10.1007/s12564-020-09664-8>
- Kotsou, I., Mikolajczak, M., Heeren, A., Grégoire, J., & Leys, C. (2018). Improving Emotional Intelligence: A Systematic Review of Existing Work and Future Challenges. *Emotion Review*, 11(2). <https://journals.sagepub.com/doi/10.1177/1754073917735902>

- Lin, T.-C., Yu, W. W.-C., & Chen, Y.-C. (2012). Determinants and probability prediction of college student retention: New evidence from the Probit model. *International Journal of Education Economics and Development*, 3(3), 217-236. <https://doi.org/10.1504/IJEED.2012.049174>
- López-Roldán, P., & Fachelli, S. (2015). *Metodología de la investigación social cuantitativa*. <https://ddd.uab.cat/record/129382>
- Macfadyen, L. P., & Dawson, S. (2010). Mining LMS data to develop an “early warning system” for educators: A proof of concept. *Computers & Education*, 54(2), 588-599. <https://doi.org/10.1016/j.compedu.2009.09.008>
- Mayer, J. D., Faber, M. A., & Xu, X. (2007). Seventy-five years of motivation measures (1930–2005): A descriptive analysis. *Motivation and Emotion*, 31(2), 83-103. <https://doi.org/10.1007/s11031-007-9060-2>
- Midgley, C., Kaplan, A., & Middleton, M. (2001). Performance-approach goals: Good for what, for whom, under what circumstances, and at what cost? *Journal of Educational Psychology*, 93(1), 77-86. <https://doi.org/10.1037/0022-0663.93.1.77>
- Moreno, J. L. M., Mínguez, L. M., & Asparó, C. A. (2010). Factores del currículum condicionantes de los resultados escolares. *EDUCAR*, 46, 87-106.
- Mourão, M. F., & Braga, A. C. (2016). Strengths and Weaknesses of Three Software Programs for the Comparison of Systems Based on ROC Curves. En O. Gervasi, B. Murgante, S. Misra, A. M. A. C. Rocha, C. M. Torre, D. Taniar, B. O. Apduhan, E. Stankova, & S. Wang (Eds.), *Computational Science and Its Applications – ICCSA 2016* (pp. 359-372). Springer International Publishing. https://doi.org/10.1007/978-3-319-42085-1_28
- Mtshweni, B. V. (2022). Adjustment and socioeconomic status: How do these factors influence the intention to dropout of university? *South African Journal of Psychology*, 52(2), 262-274. <https://doi.org/10.1177/00812463211059141>

- Munizaga Mellado, F. R., Cifuentes Orellana, M. B., & Beltrán Gabrie, A. J. (2018). Retención y Abandono Estudiantil en la Educación Superior Universitaria en América Latina y el Caribe: Una Revisión Sistemática. *Education Policy Analysis Archives*, 26, 61-61. <https://doi.org/10.14507/epaa.26.3348>
- Nelis, D., Kotsou, I., Quidbach, J., Hansenne, M., Weytens, F., Dupuis, P., & Mikolajczak, M. (2011). Increasing emotional competence improves psychological and physical well-being, social relationships, and employability. *Emotion*, 11(2), 354-366. <https://doi.org/10.1037/a0021554>
- Niessen, A. S. M., & Neumann, M. (2022). Using personal statements in college admissions: An investigation of gender bias and the effects of increased structure. *International Journal of Testing*, 22(1), 5-20. <https://doi.org/10.1080/15305058.2021.2019749>
- Núñez, J., Ortiz, H., Díaz, T., & Rivas, A. (2020). Políticas de educación superior, ciencia, tecnología e innovación y desarrollo territorial: Nuevas experiencias, nuevos enfoques. *Revista Iberoamericana de Ciencia, Tecnología y Sociedad - CTS*, 15(43), 187-208.
- Oviedo, H. C., & Campo-Arias, A. (2005). Aproximación al uso del coeficiente alfa de Cronbach. *Revista Colombiana de Psiquiatría*, 34(4), 572-580.
- Paulick, I., Watermann, R., & Nückles, M. (2013). Achievement goals and school achievement: The transition to different school tracks in secondary school. *Contemporary Educational Psychology*, 38(1), 75-86. <https://doi.org/10.1016/j.cedpsych.2012.10.003>
- Pekrun, R., & Linnenbrink-Garcia, L. (2012). Academic Emotions and Student Engagement. En S. L. Christenson, A. L. Reschly, & C. Wylie (Eds.), *Handbook of Research on Student Engagement* (pp. 259-282). Springer US. https://doi.org/10.1007/978-1-4614-2018-7_12
- Pennington, C. R., Bates, E. A., Kaye, L. K., & Bolam, L. T. (2018). Transitioning in higher education: An exploration of psychological and contextual factors affecting

- student satisfaction. *Journal of Further and Higher Education*, 42(5), 596-607.
<https://doi.org/10.1080/0309877X.2017.1302563>
- Peralbo Uzquiano, M., Barca Lozano, A., & Brenlla Blanco, J. C. (2004). Atribuciones causales y enfoques de aprendizaje: La escala SIACEPA. *Psicothema*, 16(1), 94-103.
- Perdue, N. H., Manzeske, D. P., & Estell, D. B. (2009). Early predictors of school engagement: Exploring the role of peer relationships. *Psychology in the Schools*, 46(10), 1084-1097. <https://doi.org/10.1002/pits.20446>
- Phan, H. P., & Ngu, B. H. (2020). Schooling experience and academic performance of Taiwanese students: The importance of psychosocial effects, positive emotions, levels of best practice, and personal well-being. *Social Psychology of Education*, 23(4), 1073-1101. <https://doi.org/10.1007/s11218-020-09569-9>
- Pintrich, P. R., & De Groot, E. V. (1990). Motivational and self-regulated learning components of classroom academic performance. *Journal of Educational Psychology*, 82(1), 33-40. <https://doi.org/10.1037/0022-0663.82.1.33>
- Pozo-Rico, T., Gilar, R., & Castejón, J. L. (2017). Developing Emotional Competence Training for University Students in Argentina and Spain. *INTED2017 Proceedings*, 112-122. <https://doi.org/10.21125/inted.2017.0143>
- Puig Gimeno, B., Llamas Salguero, F., & Portolés Ariño, A. (2015). Relación entre las tecnologías de la información y la comunicación con el rendimiento académico y la práctica de la actividad física en educación primaria. *DIM: Didáctica, Innovación y Multimedia*, 32, Art. 32.
- Putwain, D., Sander, P., & 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>

- Rodarte-Luna, B., & Sherry, A. (2008). Sex differences in the relation between statistics anxiety and cognitive/learning strategies. *Contemporary Educational Psychology, 33*(2), 327-344. <https://doi.org/10.1016/j.cedpsych.2007.03.002>
- Rodrigo, M. F., Molina, J. G., Ros, R. G., & González, F. P. (2012). Efectos de interacción en la predicción del abandono en los estudios de Psicología. *Anales de Psicología / Annals of Psychology, 28*(1), Art. 1.
- Rodriguez, S., Cabanach, R. G., Piñeiro, I., Valle, A., Núñez, J. C., & González-Pienda, J. A. (2001). Metas de aproximación, metas de evitación y múltiples metas académicas | Psicothema. *Psicothema, 13*(4), 546-550.
- Rojas Torres, L. (2013). Validez predictiva de los componentes del promedio de admisión a la Universidad de Costa Rica utilizando el género y el tipo de colegio como variables control. *Revista Actualidades Investigativas en Educación, 13*(1), 1-24.
- Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *WIREs Data Mining and Knowledge Discovery, 10*(3), e1355. <https://doi.org/10.1002/widm.1355>
- Roos, A.-L., Goetz, T., Krannich, M., Jarrell, A., Donker, M., & Mainhard, T. (2021). Test anxiety components: An intra-individual approach testing their control antecedents and effects on performance. *Anxiety, Stress, & Coping, 34*(3), 279-298. <https://doi.org/10.1080/10615806.2020.1850700>
- Ruiz De Miguel, C. (2001). Factores familiares vinculados al bajo rendimiento. *Revista complutense de educación, 12*(1), 81.
- Sáez, F., López, Y., Cobo, R., & Mella, J. (2019). Revisión sistemática sobre intención de abandono en educación superior. *Congresos CLABES, 91-100*.
- Salovey, P., Mayer, J. D., Goldman, S. L., Turvey, C., & Palfai, T. P. (1995). Emotional attention, clarity, and repair: Exploring emotional intelligence using the Trait Meta-Mood Scale. En *Emotion, disclosure, & health* (pp. 125-154). American Psychological Association. <https://doi.org/10.1037/10182-006>

- Sánchez-Almeida, T., Naranjo, D., & Reina, J. (2021). *Análisis del desempeño académico de estudiantes de una institución de educación superior en Ecuador, antes y durante la pandemia* (COMPON-2021-CINAIC-0136). Art. COMPON-2021-CINAIC-0136. <https://doi.org/10.26754/CINAIC.2021.0136>
- Schickel, M., & Ringeisen, T. (2022). What predicts students' presentation performance? Self-efficacy, boredom and competence changes during presentation training. *Current Psychology*, 41(9), 5803-5816. <https://doi.org/10.1007/s12144-020-01090-8>
- Schunk, D. H. (2005). Self-Regulated Learning: The Educational Legacy of Paul R. Pintrich. *Educational Psychologist*, 40(2), 85-94. https://doi.org/10.1207/s15326985ep4002_3
- Scrimin, S., Mason, L., & Moscardino, U. (2014). School-related stress and cognitive performance: A mood-induction study. *Contemporary Educational Psychology*, 39(4), 359-368. <https://doi.org/10.1016/j.cedpsych.2014.09.002>
- Senko, C. (2019). When do mastery and performance goals facilitate academic achievement? *Contemporary Educational Psychology*, 59, 101795. <https://doi.org/10.1016/j.cedpsych.2019.101795>
- Sharif, I., Wills, T. A., & Sargent, J. D. (2010). Effect of Visual Media Use on School Performance: A Prospective Study. *Journal of Adolescent Health*, 46(1), 52-61. <https://doi.org/10.1016/j.jadohealth.2009.05.012>
- Siemens, G., & Baker, R. S. J. d. (2012). Learning analytics and educational data mining: Towards communication and collaboration. *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, 252-254. <https://doi.org/10.1145/2330601.2330661>
- Sierra Ramos, J. M. (2022). *Introducción a las redes neuronales artificiales* [Info:eu-repo/semantics/bachelorThesis, Universidad Complutense de Madrid]. <https://eprints.ucm.es/id/eprint/71132/>

- Sini, B., Muzzolini, B., Schmidt, S., & Tinti, C. (2018). School motivation: A comparison between Kenya and Italy. *The Journal of Educational Research*, 111(6), 746-755. <https://doi.org/10.1080/00220671.2018.1427035>
- Skaalvik, E. M. (1997). Self-enhancing and self-defeating ego orientation: Relations with task and avoidance orientation, achievement, self-perceptions, and anxiety. *Journal of Educational Psychology*, 89(1), 71-81. <https://doi.org/10.1037/0022-0663.89.1.71>
- Suárez Riveiro, J. M., Cabanach, R. G., & Arias, A. V. (2001). Multiple-goal pursuit and its relation to cognitive, self-regulatory, and motivational strategies. *British Journal of Educational Psychology*, 71(4), 561-572. <https://doi.org/10.1348/000709901158677>
- Tarabini, A. (2015). La meritocracia en la mente del profesorado: Un análisis de los discursos docentes en relación al éxito, fracaso y abandono escolar. *Revista de Sociología de la Educación-RASE*, 8(3), 349-360.
- Teoh, E. J., Tan, K. C., & Xiang, C. (2006). Estimating the Number of Hidden Neurons in a Feedforward Network Using the Singular Value Decomposition. *IEEE Transactions on Neural Networks*, 17(6), 1623-1629. <https://doi.org/10.1109/TNN.2006.880582>
- Tinajero, C., Martínez-López, Z., Rodríguez, M. S., & Páramo, M. F. (2020). Perceived social support as a predictor of academic success in Spanish university students. *Anales de Psicología / Annals of Psychology*, 36(1), Art. 1. <https://doi.org/10.6018/analesps.344141>
- Tinto, V., & Cullen, J. (1973). *Dropout in Higher Education: A Review and Theoretical Synthesis of Recent Research* (p. 99). Columbia University.
- Topham, P., & Moller, N. (2011). New students' psychological well-being and its relation to first year academic performance in a UK university. *Counselling and Psychotherapy Research*, 11(3), 196-203. <https://doi.org/10.1080/14733145.2010.519043>

- Turner, R., Morrison, D., Cotton, D., Child, S., Stevens, S., Nash, P., & Kneale, P. (2017). Easing the transition of first year undergraduates through an immersive induction module. *Teaching in Higher Education*, 22(7), 805-821. <https://doi.org/10.1080/13562517.2017.1301906>
- Urbina Nájera, A. B. (2019). Estrategia tecnológica para mejorar el rendimiento académico universitario. *Pixel-Bit*. <https://doi.org/10.12795/pixelbit.2019.i56.04>
- Valdivia-Salas, S., Ibáñez, J., López-Crespo, G., Martín-Albo, J., Sánchez-Martínez, R., & Castro, A. (2020). The Influence of Burnout and Psychological Inflexibility on Academic Achievement: Preliminary Evidence with Psychology Students. *INTED2020 Proceedings*, 2274-2280. <https://doi.org/10.21125/inted.2020.0694>
- Valle, A., Pérez, J. C. N., Rodríguez, S., Cabanach, R. G., Pienda, J. A. G., & Rosario, P. (2010). Perfiles motivacionales y diferencias en variables afectivas, motivacionales y de logro. *Universitas Psychologica*, 9(1), Art. 1. <https://doi.org/10.11144/Javeriana.upsy9-1.pmdv>
- Valle, A., Regueiro, B., Rodríguez, S., Piñeiro, I., Freire, C., Ferradás, M., & Suárez, N. (2015). Perfiles motivacionales como combinación de expectativas de autoeficacia y metas académicas en estudiantes universitarios. *European Journal of Education and Psychology*, 8(1), 1-8. <https://doi.org/10.1016/j.ejeps.2015.10.001>
- Valle Benavides, A. R. del. (2017). *Curvas ROC (Receiver-Operating-Characteristic) y sus aplicaciones*. <https://idus.us.es/handle/11441/63201>
- van Dinther, M., Dochy, F., & Segers, M. (2011). Factors affecting students' self-efficacy in higher education. *Educational Research Review*, 6(2), 95-108. <https://doi.org/10.1016/j.edurev.2010.10.003>
- van Rooij, E. C. M., Jansen, E. P. W. A., & van de Grift, W. J. C. M. (2017). Factors that contribute to secondary school students' self-efficacy in being a successful university student. *Research in Post-Compulsory Education*, 22(4), 535-555. <https://doi.org/10.1080/13596748.2017.1381301>

- van Rooij, E. C. M., Jansen, E. P. W. A., & van de Grift, W. J. C. M. (2018). First-year university students' academic success: The importance of academic adjustment. *European Journal of Psychology of Education, 33*(4), 749-767. <https://doi.org/10.1007/s10212-017-0347-8>
- Vandamme, J. -P., Meskens, N., & Superby, J. -F. (2007). Predicting Academic Performance by Data Mining Methods. *Education Economics, 15*(4), 405-419. <https://doi.org/10.1080/09645290701409939>
- Vergara Morales, J. R., Val, E. B. del, Barriga, O. A., & Larenas, C. D. (2017). Factores explicativos de la deserción de estudiantes de pedagogía. *Revista Complutense de Educación, 28*(2), Art. 2. https://doi.org/10.5209/rev_RCED.2017.v28.n2.50009
- Vooren, M., Haelermans, C., Groot, W., & van den Brink, H. M. (2022). Comparing success of female students to their male counterparts in the STEM fields: An empirical analysis from enrollment until graduation using longitudinal register data. *International Journal of STEM Education, 9*(1), 1. <https://doi.org/10.1186/s40594-021-00318-8>
- Wenglinsky, H. (2002). The Link Between Teacher Classroom Practices and Student Academic Performance. *Education Policy Analysis Archives, 10*, 12-12. <https://doi.org/10.14507/epaa.v10n12.2002>
- Wild, S. (2022). Trajectories of subject-interests development and influence factors in higher education. *Current Psychology*. <https://doi.org/10.1007/s12144-021-02691-7>
- Yen, S.-C., Lo, Y., Lee, A., & Enriquez, J. (2018). Learning online, offline, and in-between: Comparing student academic outcomes and course satisfaction in face-to-face, online, and blended teaching modalities. *Education and Information Technologies, 23*(5), 2141-2153. <https://doi.org/10.1007/s10639-018-9707-5>

Yu, R., Lee, H., & Kizilcec, R. F. (2021). Should College Dropout Prediction Models Include Protected Attributes? *Proceedings of the Eighth ACM Conference on Learning @ Scale*, 91-100. <https://doi.org/10.1145/3430895.3460139>



Universitat d'Alacant
Universidad de Alicante