

CAPÍTULO 27

RENDIMIENTO ACADÉMICO Y VARIABLES SOCIOECONÓMICAS ASOCIADAS: MODELO DE PREDICCIÓN EN LA UNIVERSIDAD NACIONAL DE EDUCACIÓN (ECUADOR)

JACK VIDAL*, RAQUEL GILAR CORBÍ**, Y EFSTATHIOS STEFOS***
**Instituto Superior Tecnológico Sucre; **Universidad de Alicante;*
****Universidad Nacional de Educación UNAE*

INTRODUCCIÓN

Algunos de los objetivos principales de la Educación Superior son el fomento de la investigación, el desarrollo y la innovación. Para lograr estos objetivos las universidades se esfuerzan por formar a profesionales cualificados, capaces de responder a las demandas de la sociedad y el mundo laboral actual. Desde esta perspectiva se hace indispensable un sistema educativo de calidad, que potencie las habilidades innatas de los estudiantes, convirtiéndose así en una herramienta efectiva para disminuir las brechas en sociedades con profundas desigualdades como las de Latinoamérica.

Las instituciones de Educación Superior latinoamericanas han hecho grandes esfuerzos para que sean consideradas como actores relevantes del desarrollo social (Arocena y Sutz, 2005). Durante el siglo XX, importantes movimientos estudiantiles desencadenaron el llamado Movimiento de Reforma Universitaria (Ribeiro, 1971; Tünnermann, 2001), que permitió la inclusión de políticas sociales basadas en el aumento de la matrícula en la educación superior a pesar de las controversias políticas o militares de pasadas décadas. Esta expansión de la democracia en el sistema de educación superior ha cumplido los objetivos de estándares de enseñanza e investigación más sólidos (De Moura y Levy, 2001).

Para conseguir eliminar estas diferencias o desigualdades es necesario abordar tres aspectos: la diversidad, la equidad y la calidad en la Educación Superior. La diversidad en la oferta académica facilita que los estudiantes seleccionen la carrera más adecuada a sus habilidades, sin embargo, este proceso va ligado a la equidad en el acceso y este proceso presenta diferentes propuestas dependiendo del país o el tipo de universidad. Según datos del Banco Mundial la tasa bruta de matrícula en educación superior ha crecido del 21 al 43 por ciento entre los años 2000 y 2013, derivando este crecimiento en un nuevo y complejo panorama relacionado directamente con la calidad de los programas que ofrecen las universidades (Ferreira, Avitabile, Botero, Haimovich, y Humano, 2017). Asimismo, la calidad de una universidad está íntimamente relacionada con el nivel académico de los estudiantes

que ingresan a la misma, es decir se relaciona con la eficiencia en los procesos de admisión y con el perfil de egreso de la educación media; en este proceso aparece el rendimiento académico como una medida, difícil de definir, referente al esfuerzo realizado por el estudiante en el proceso de aprendizaje. El rendimiento académico del estudiante es una de las variables principales en el análisis de la deserción y tasas de graduación en la educación superior, por lo tanto, generar un modelo para poder predecirlo y tomar acciones preventivas es muy valioso en los procesos de mejora continua de las universidades.

Existen numerosos trabajos en los que se trata de analizar, explicar y predecir el rendimiento académico y el abandono en Educación Superior. Muñoz (2016) realiza un análisis clúster muy detallado basado en 11 factores que influyen en el rendimiento académico en la educación secundaria, obteniendo un acierto superior al 90%, pero este método tiene una alta capacidad predictiva en la misma cohorte en la que se realiza el análisis, pero puede ir disminuyendo con el pasar de los años debido a la dinámica de los sistemas educativos. En el estudio realizado por Salgado et al. (2019), aplicado a 300 estudiantes de la carrera de Ingeniería de Sistemas de la Universidad Central del Ecuador, se obtiene una predicción correcta del 75,28%, utilizando análisis basado en redes neuronales y learning analytics en la plataforma Moodle de la institución. En lo que se refiere a los análisis correlacionales y los métodos de regresión logística, existen varios estudios de predicción; en este sentido, García, Alvarado, y Jiménez (2000), realizan una comparación entre la regresión lineal y la regresión logística y proponen el uso de la regresión logística para la predicción del rendimiento académico, así en su estudio se obtiene un 70% de casos bien clasificados. García (2015) realizó un estudio en la Universidad Técnica Particular de Loja de Ecuador (universidad pionera en educación virtual en el Ecuador) utilizando learning analytics y dos modelos: logístico bivalente (410 estudiantes en un periodo de 5 años) y regresión multinivel (23583 estudiantes, en 468 grupos durante un periodo), en este trabajo la predicción logística aumenta del 71% (con dos variables de respuesta) al 81% (añadiendo covariables).

En la literatura previa existente se puede observar que la predicción del rendimiento académico puede ser analizada utilizando diferentes técnicas y pueden variar dependiendo de la carrera y área en la que se realice el estudio, por lo que si se pretende realizar un modelo de predicción del rendimiento académico en una universidad es necesario analizar y seleccionar el modelo más idóneo al contexto de dicha institución (Guzman, 2012).

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 a la hora de atender y dar una respuesta educativa adecuada a un grupo masivo y heterogéneo de estudiantes (Braxton, Sullivan, y Johnson, 1977; Himmel, 2002).

En Ecuador, se han realizado varios estudios para determinar qué variables en 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 intervienen en el fenómeno del fracaso estudiantil (Sandoval, Sánchez, Velasteguí, y Naranjo, 2018). 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 a realizar para identificar tempranamente a los estudiantes en riesgo y, en consecuencia, implementar acciones correctivas en el proceso educativo (Di Caudo, 2015; Sandoval-Palis, Naranjo, Gilar-Corbi, y Pozo-Rico, 2020; Sandoval, Sánchez, Naranjo, y Jiménez, 2019).

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 del ámbito de la educación 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.

MÉTODO

Descripción del contexto y de los participantes

Los participantes de este estudio fueron el total de egresados de la promoción 2015-2019 de la Universidad Nacional de Educación de Ecuador. Los participantes fueron 285 estudiantes de dicha universidad. 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.

En la primera cohorte de alumnos ingresados durante abril del 2015, se matricularon en la UNAE 285 estudiantes; De ellos el 53.68% fueron mujeres y el 46.32% hombres; El 95.09% mestizos, 1.75% indígenas, 1.40% montubios, 1.40% afrodescendientes, y 0.35% blancos. El 2.11% de los alumnos tuvo discapacidad; El 85.26% fueron solteros, 12.28% casados, 1.40% en unión libre, y 1.05% divorciados; El 11.93% tuvo un hijo, 1.75% dos hijos, y 0.35% tres hijos; El 59.30% pertenecía en el quintil bajo, 20.35% medio bajo, 5.61% medio, 5.26% medio alto, y 9.47% alto. Los

estudios de las carreras de la UNAE son de 9 periodos académicos. En este marco, los ingresados de abril del 2015 finalizaron sus estudios el agosto del 2019. Durante el año 2019, se egresaron 251 alumnos que constituyen el 88.07% de los alumnos que ingresaron durante el año 2015.

Instrumentos

Las variables analizadas fueron las siguientes: Género (hombre o mujer), Etnia (Indígena, Mestizo, Montubio, Afro descendiente 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 (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 (indica si el estudiante egresa o no de la titulación).

Procedimiento

Los datos se obtuvieron, una vez autorizado por la autoridad responsable de la universidad, de los registros informáticos existentes en la administración de Universidad Nacional de Educación. Todos los datos se trataron de forma anónima.

RESULTADOS

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, se analizaron las características de los perfiles de egreso de los estudiantes en comparación con los que no consiguen egresar, y se realizaron análisis de regresión logística y redes neuronales para analizar qué variables son las que hacen una mayor contribución a la predicción del egreso. Los análisis se realizaron con el programa SPSS V.24.0 (IBM, Armonk, EE. UU.) con licencia para la Universidad de Alicante. Los resultados se presentan agrupados según el tipo de análisis.

Análisis de contingencia y comparación de perfiles

De los análisis de contingencia se desprenden los siguientes resultados.

El mayor porcentaje de egresados 56.97% corresponde a las mujeres. Mientras que los estudiantes que no consiguen egresar son mayoritariamente hombres (70.59%), (Tabla 1).

Tabla 1. Egresado – Género

	Género		Total	
	Femenino	Masculino		
Egresado	Si	143	108	251
		56.97%	43.03%	100.00%
	No	10	24	34
		29.41%	70.59%	100.00%
Total		153	132	285
		53.68%	46.32%	100.00%

En relación a la etnia se comprueba que todos los alumnos indígenas, montubios, y afrodescendientes finalizaron sus estudios (Tabla 2), siendo los mestizos, que pertenecen a la etnia mayoritaria, los que presentan la mayor tasa de abandono.

Tabla 2. Egresado – Etnia

	Etnia					Total	
	Indígena	Mestizo	Montubio	Afro descendiente	Blanco		
Egresado	Si	5	238	4	4	0	251
		1.99%	94.82%	1.59%	1.59%	0.00%	100.00%
	No	0	33	0	0	1	34
		0.00%	97.06%	0.00%	0.00%	2.94%	100.00%
Total		5	271	4	4	1	285
		1.75%	95.09%	1.40%	1.40%	0.35%	100.00%

En relación a la variable discapacidad, el 83.33% de los alumnos con discapacidad (5 de 6) egresaron durante el año 2019 (Tabla 3).

Tabla 3. Egresado – Discapacidad

	Discapacidad		Total	
	Si	No		
Egresado	Si	5	246	251
		1.99%	98.01%	100.00%
	No	1	33	34
		2.94%	97.06%	100.00%
Total		6	279	285
		2.11%	97.89%	100.00%

En relación a la variable Estado Civil el 82.85% de los casados (29 de 35), y el 75% de los alumnos en unión libre (3 de 4) finalizaron sus estudios (Tabla 4).

Tabla 4. Egresado - Estado civil

		Estado civil				Total
		Soltero	Casado	Unión libre	Divorciado	
Egresado	Si	217 86.45%	29 11.55%	3 1.20%	2 0.80%	251 100.00%
	No	26 76.47%	6 17.65%	1 2.94%	1 2.94%	34 100.00%
Total		243 85.26%	35 12.28%	4 1.40%	3 1.05%	285 100.00%

En relación a la variable Número de hijos, los resultados muestran que el 79.41% de los alumnos con un hijo (27 de 34), el 80% de los alumnos con dos hijos (4 de 5), y el 100% de las personas con tres hijos (un alumno) finalizaron sus estudios (Tabla 5).

Tabla 5. Egresado - Número de hijos

		Número de hijos				Total
		0	1	2	3	
Egresado	Si	219 87.25%	27 10.76%	4 1.59%	1 0.40%	251 100.00%
	No	26 76.47%	7 20.59%	1 2.94%	0 0.00%	34 100.00%
Total		245 85.96%	34 11.93%	5 1.75%	1 0.35%	285 100.00%

En relación a la variable Quintil, los resultados muestran que el 85.80% de los alumnos de quintil bajo (145 de 169), y el 87.93% de los alumnos de quintil medio bajo (51 de 58) finalizaron sus estudios durante el año 2019 (Tabla 6).

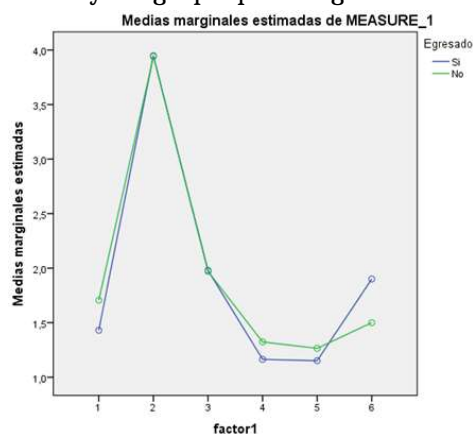
Tabla 6. Egresado – Quintil

		Quintil				Total	
		Bajo	Medio bajo	Medio alto	Alto		
Egresado	Si	145 57.77%	51 20.32%	16 6.37%	13 5.18%	26 10.36%	251 100.00%
	No	24 70.59%	7 20.59%	0 0.00%	2 5.88%	1 2.94%	34 100.00%
Total		169 59.30%	58 20.35%	16 5.61%	15 5.26%	27 9.47%	285 100.00%

A continuación, representamos gráficamente los perfiles de los estudiantes que consiguen egresar con éxito de la titulación y los que egresan, para poder así comprobar las características de los perfiles de ambos grupos.

Tal como se puede comprobar en la Figura 1, en el grupo de estudiantes que egresan hay un mayor porcentaje de mujeres que en el grupo que no egresa (en el que hay un mayor porcentaje de hombres), también en el grupo que egresa están la mayoría de los estudiantes que señalaron ser solteros, también presentan un menor número de hijos que los estudiantes del grupo que no egresa, y pertenecen mayoritariamente a quintiles más bajos. Respecto a la variable Etnia y Discapacidad no mostraron porcentajes diferentes al grupo de estudiantes que no egresa.

Figura 1. Representación gráfica del grupo de estudiantes que egresa y del grupo que no egresa



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

Los resultados indican que las mujeres consiguen una mejor tasa de egreso, que todos los estudiantes de etnias minoritarias consiguieron finalizar los estudios, todos los estudiantes con discapacidad salvo uno consiguieron su egreso, y que más del 80% de los estudiantes de los quintiles más bajos también consiguen egresar. El género aparece como la variable con mayor poder predictivo en el egreso. Analizando las variables relacionadas con los perfiles de egreso de los estudiantes de educación superior se podrán identificar aquellos aspectos en los que centrar las posibles intervenciones de cara a la mejora de la tasa de egresados, lo que sin duda repercutiría en el aumento de la calidad de la educación superior.

Análisis de regresión logística

Se utilizó un modelo predictivo y se realizó un análisis de regresión logística por pasos (estadístico de *Wald*). Este modelo estimó estimar la probabilidad de ocurrencia de un evento (en nuestro caso, egreso), 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.

Las variables independientes (covariables) consideradas fueron género, etnia, discapacidad, estado civil, número de hijos y quintil. Y como variable dependiente se consideró la variable dicotómica egresa / no egresa.

La Tabla 7 muestra las variables que han sido significativas en el modelo para predecir el egreso/no egreso académico. Siendo la variable género la única que ha resultado significativo, deteniéndose el procedimiento por pasos ya que al eliminar la variable menos significativa se obtuvo un modelo previamente ajustado (con la variable género).

Tabla 7. Variables significativas en el modelo de regresión logística.

		<i>B</i>	<i>E.T.</i>	<i>Wald</i>	<i>gl</i>	<i>Sig.</i>	<i>O.R.</i>	<i>I.C. 95% para O.R.</i>	
								Inferior	Superior
Paso 1 ^a	GENERO	-1,156	,397	8,465	1	,004	,315	,144	,686
	Constante	-1,504	,226	44,422	1	,000	,222		
	GENERO	-1,269	,412	9,469	1	,002	,281	,125	,631
	ETNIA			,000	4	1,000			
	ETNIA(1)	,266	27855,143	,000	1	1,000	1,305	,000	.
Paso 2 ^b	ETNIA(2)	43,445	44800,559	,000	1	,999	7,381E18	,000	.
	ETNIA(3)	,670	26479,696	,000	1	1,000	1,953	,000	.
	ETNIA(4)	19,527	19789,270	,000	1	,999	3,023E8	,000	.
	Constante	-20,974	19789,270	,000	1	,999	,000		

Nota. *B*= coeficiente; *E.T.*= error típico; *Wald*= estadístico de *Wald*; *gl*= grados de libertad; *Sig.*= significación; *O.R.* = odd ratio.

El estadístico R2 de Nagelkerke estimó un valor de ajuste del modelo de ,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.

Redes Neuronales Artificiales

Las redes neuronales artificiales permiten establecer un modelo de predicción, para analizar las relaciones entre variables y basado en el aprendizaje automático (Bouwman, Javed, Sultana, y Jung, 2019). Las redes neuronales son útiles para predecir y clasificar en varias áreas incluida la educación, sobre todo en relación con el rendimiento del alumno y otras variables implicadas en el proceso de aprendizaje (Baars, Stijnen, y Splinter, 2017; Marbouti, Diefes-Dux, y Madhavan, 2016; Mason, Twomey, Wright, y Whitman, 2018).

Se empleó las redes neuronales artificiales para predecir las tasas de abandono de los estudiantes de la Universidad Nacional de Educación, teniendo en cuenta las

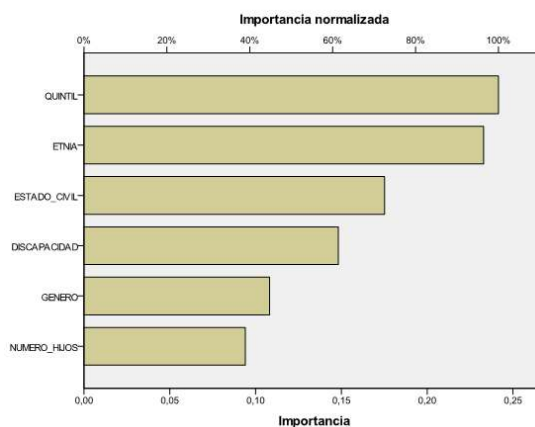
variables de tipo sociodemográfico. La variable dependiente fue "egresa-no egresa" y los factores fueron género, etnia, discapacidad, estado civil, número de hijos y quintil.

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, Tan, y Xiang., 2006; Vandamme, Meskens, y Superby, 2007).

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


En el modelo de redes neuronales artificiales (RNA), todas las variables resultaron significativas, siendo clasificadas de mayor a menor importancia en el siguiente orden: quintil, etnia, estado civil, discapacidad, género y número de hijos (Figura 2). Obteniéndose una exactitud de clasificación del 90,9%.

Figura 2. Importancia relativa de cada una de las variables independientes en el modelo



Al analizar el área bajo la curva COR se encuentra un valor de AUC= ,803, lo que indica que el modelo tiene una buena capacidad discriminativa (Figura 3).

Figura 3. Representación gráfica del área bajo la curva
COR (AUC) del modelo de RNA



DISCUSIÓN/CONCLUSIONES

La reducción de las desigualdades en el acceso y finalización de la educación superior ha sido un objetivo estratégico en diferentes países (EACEA P9 Eurydice, 2012). Esta prioridad viene dada por el hecho de que la probabilidad de matriculación y retención universitaria difiere sustancialmente de un entorno social a otro.

En el presente estudio, 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 podemos 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.

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. Las variables consideradas en el modelo de predicción del egreso/abandono académico no solo describen factores socioeconómicos y académicos, sino que también confirman su influencia histórica en el fracaso de los estudiantes.

Nuestros resultados son similares a los encontrados en otros estudios con población universitaria, aunque de otras ramas de conocimiento. Sandoval et al. (2020) realizó la identificación de los factores que influyen en el fracaso de los estudiantes en el primer curso de la Escuela Politécnica Nacional de Ecuador. Se modeló una dimensión de red neuronal artificial reducida a partir de cinco variables que contienen información académica y socioeconómica de los estudiantes.

Las variables que formaron parte en el este modelo predictivo fueron la nota de acceso a la titulación, el índice de vulnerabilidad, el régimen de solicitud, el género y el segmento poblacional. Estos autores proponen que su modelo se podría utilizar como guía para liderar políticas de intervención, como ayudas económicas o apoyos académicos, por lo que las altas tasas de fracaso en el curso de acceso a la universidad disminuirían.

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, que pueden ser claves a la hora de determinar el rendimiento de los estudiantes, y quizá se podría proponer la extensión de este modelo a otras universidades para tratar de aumentar sus tasas de egreso.

El estado ecuatoriano busca generar un modelo de desarrollo cuyo eje es la educación como instrumento de construcción de conocimiento, que apoya en la socialización de los beneficios de la evolución de la ciencia y tecnología, siendo el docente un factor clave puesto, según últimas investigaciones (Instituto Nacional de Evaluación Educativa, 2014), la calidad del sistema educativo no puede ser superior a la calidad de sus docentes, por lo que se vuelve imprescindible contribuir a su desarrollo profesional, generando en ellos aprendizajes de orden superior que les permitan organizar ideas a favor de un pensamiento informado, independiente y creativo (Fields, 2011).

La UNAE se alinea al desafío de búsqueda de calidad en la Educación Superior, en todos los ámbitos, especialmente en la formación de profesionales de la educación con excelencia que puedan interpretar la complejidad del mundo actual y su cambio permanente en cuanto a recursos educativos, nuevas competencias requeridas en el ámbito laboral, nuevas profesiones, etc.; para esto se requiere de un modelo curricular cuyo componente práctico comprenda aproximadamente un 40%, dejando el restante 60% a la teoría, teniendo como un eje transversal las plataformas virtuales de aprendizaje que se sugiere sean usadas un 30% del tiempo (UNAE, 2019).

La organización de las instituciones de educación superior tiene un impacto en el individuo y su socialización y satisfacción. Por esta razón, 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 social y el apoyo social (Bernardo et al., 2016; Vossensteyn et al., 2015).

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 del curso de nivelación académica, así como programas de tutoría entre pares durante

el semestre para que las tasas de reprobación e incluso deserción de los estudiantes disminuyan.

REFERENCIAS

- Arocena, R. y Sutz, J. (2005). Latin American Universities: From an original revolution to an uncertain transition. *Higher Education*, 50(4), 573–592. doi:10.1007/s10734-004-6367-8
- Baars, G.J.A., Stijnen, T., y Splinter, T.A.W. (2017). A Model to Predict Student Failure in the First Year of the Undergraduate Medical Curriculum. *Health Professions Education*, 3(1), 5–14. doi: 10.1016/j.hpe.2017.01.001
- Bernardo, A., Esteban, M., Fernández, E., Cervero, A., Tuero, E., y Solano, P. (2016). Comparison of Personal, Social and Academic Variables Related to University Drop-out and Persistence. *Frontiers in Psychology*, 7(OCT), 1610. doi: 10.3389/fpsyg.2016.01610
- Bouwman, T., Javed, S., Sultana, M., y Jung, S.K. (2019). Deep neural network concepts for background subtraction: A systematic review and comparative evaluation. *Neural Networks*, 117, 8–66. Elsevier Ltd. doi: 10.1016/j.neunet.2019.04.024
- Braxton, J., Sullivan, A., y Johnson, R. (1977). Appraising Tinto's theory of college student departure. In *Higher education: Handbook of theory and research* (pp. 107–164). Springer.
- Cawley, G.C. y Talbot, N.L.C. (2010). On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation. In *Journal of Machine Learning Research* (Vol. 11).
- De Moura, C. y Levy, D. (2001). Putting Reality Ahead of Myths: Latin American Reform. *International Higher Education*, 22. doi: 10.6017/ihe.2001.22.6909
- Di Caudo, M.V. (2015). Política de cuotas en Ecuador: me gané una beca para estudiar en la Universidad. Ponto-e-Vírgula. *Revista de Ciências Sociais*, 1(17), 196–218.
- EACEA P9 Eurydice. (2012). *Cifras clave de la educación en Europa 2012*. Recuperado de: <https://op.europa.eu/en/publication-detail/-/publication/9e2d1009-d3bd-4d00-9feb-74cce4d5e990/language-es>
- Ferreira, M.M., Avitabile, C., Botero, J., Haimovich, F., y Humano, D. (2017). *Momento decisivo*. La educación superior en América Latina y el Caribe. Recuperado de: <https://openknowledge.worldbank.org/bitstream/handle/10986/26489/211014ovSP.pdf?sequence=5&isAllowed=y>
- Fields, J. (2011). *Uncertainty: Turning Fear and Doubt into Fuel to Brilliance*. Portfolio Penguin.
- García, D.K. (2015). *Construcción de un modelo para determinar el rendimiento académico de los estudiantes basado en learning analytics (análisis del aprendizaje), mediante el uso de técnicas multivariantes*. Universidad de Sevilla. Recuperado de: <https://idus.us.es/handle/11441/40436>
- García, M.V., Alvarado, J.M., y Jiménez, A. (2000). La predicción del rendimiento académico: regresión lineal versus regresión logística. *Psicothema*, 12(2), 248–252.
- Guzman, M.P. (2012). Modelos predictivos y explicativos del rendimiento académico universitario: caso de una institución privada en México. *Kas.Unibe.Ch*, 90–92. Recuperado de: http://www.kas.unibe.ch/logo2013/Abstracts/PrimoCano_Carlos.pdf

Helal, S., Li, J., Liu, L., Ebrahimie, E., Dawson, S., Murray, D.J., y Long, Q. (2018). Predicting academic performance by considering student heterogeneity. *Knowledge-Based Systems*, 161, 134–146. doi: 10.1016/j.knosys.2018.07.042

Himmel, E. (2002). Modelo de análisis de la deserción estudiantil en la educación superior. *Calidad En La Educación*, 17, 108. doi: 10.31619/caledu.n17.409

Instituto Nacional de Evaluación Educativa. (2014). *Presentación de los resultados de España y la OCDE del Informe PISA Resolución de Problemas*. Recuperado de: <http://blog.intef.es/inee/2014/04/03/presentacion-de-los-resultados-de-espana-y-la-ocde-del-informe-pisa-resolucion-de-problemas/>

Juba, B. y Le, H.S. (2019). Precision-Recall versus accuracy and the role of large data sets. *33rd AAAI Conference on Artificial Intelligence, AAAI 2019, 31st Innovative Applications of Artificial Intelligence Conference, IAAI 2019 and the 9th AAAI Symposium on Educational Advances in Artificial Intelligence, EAAI 2019*, 33(01), 4039–4048. doi: 10.1609/aaai.v33i01.33014039

Marbouti, F., Diefes-Dux, H.A., y Madhavan, K. (2016). Models for early prediction of at-risk students in a course using standards-based grading. *Computers and Education*, 103, 1–15. doi: 10.1016/j.compedu.2016.09.005

Mason, C., Twomey, J., Wright, D., y Whitman, L. (2018). Predicting Engineering Student Attrition Risk Using a Probabilistic Neural Network and Comparing Results with a Backpropagation Neural Network and Logistic Regression. *Research in Higher Education*, 59(3), 382–400. doi: 10.1007/s11162-017-9473-z

Muñoz, A. (2016). *Modelos para la mejora del rendimiento académico de alumnos de la E.S.O. mediante técnicas de minería de datos*. Universidad de Murcia. Recuperado de: <https://dialnet.unirioja.es/servlet/tesis?codigo=127044&info=resumen&idioma=ENG>

Ribeiro, D. (1971). La Universidad Latinoamericana. Ediciones de la Biblioteca de la Universidad Central de Venezuela.

Salgado, N., Beltrán, J., Guaña, J., Escobar, C., Nicolalde, D., y Chafla, G. (2019). Modelo para predecir el rendimiento académico basado en redes neuronales y analítica de aprendizaje. *Revista Ibérica de Sistemas y Tecnologías de Información*, 1, 258–266. Recuperado de: <https://uvirtual.uce.edu.ec/>

Sandoval, I., Sánchez, T., Naranjo, D., y Jiménez, A. (2019). *Programa piloto de Matemática para estudiantes de Ingeniería pertenecientes a grupos vulnerables de la Escuela Politécnica Nacional*. 17th LACCEI International Multi-Conference for Engineering, Education, and Technology.

Sandoval, I., Sánchez, T., Velasteguí, V., y Naranjo, D. (2018, November 30). *Factores asociados al abandono en estudiantes de grupos vulnerables. Caso escuela politécnica nacional Línea Temática 1: Factores asociados al abandono*. Tipos y perfiles de abandono. Congresos CLABES. Recuperado de: <https://revistas.utp.ac.pa/index.php/clabes/article/view/1907>

Sandoval-Palis, I., Naranjo, D., Gilar-Corbi, R., y Pozo-Rico, T. (2020). Neural Network Model for Predicting Student Failure in the Academic Leveling Course of Escuela Politécnica Nacional. *Frontiers in Psychology*, 11, 3383. doi: 10.3389/fpsyg.2020.515531

Teoh, E.J., Tan, K.C., y 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. doi: 10.1109/TNN.2006.880582

Tünnermann, C. (2001). *Universidad y sociedad Balance histórico y perspectivas desde América Latina*. HISPAMER.

UNAE. (2019). *Modelo Pedagógico de la Universidad Nacional del Educación UNAE*. Recuperado de: <https://unae.edu.ec/wp-content/uploads/2019/11/modelo-pedagogico-unae.pdf>

Vandamme, J.P., Meskens, N., y Superby, J.F. (2007). Predicting Academic Performance by Data Mining Methods. *Education Economics*, 15(4), 405–419. doi: 10.1080/09645290701409939

Vossensteyn, H., Kottmann, A., Jongbloed, B., Kaiser, F., Cremonini, L., Stensaker, B., ... Wollscheid, S. (2015). *Dropout and Completion in Higher Education in Europe Main Report*. European Union.