

**MODELO DE GESTIÓN DEL CONOCIMIENTO EN LA EDUCACIÓN SUPERIOR
TÉCNICA: ESTUDIO DE CASO EN LA CARRERA DE ELECTROMECAÁNICA DE UN
INSTITUTO DE EDUCACIÓN SUPERIOR DE RIOBAMBA
KNOWLEDGE MANAGEMENT MODEL IN TECHNICAL HIGHER EDUCATION: CASE
STUDY IN THE ELECTROMECHANICAL ENGINEERING PROGRAM AT A HIGHER
EDUCATION INSTITUTE IN RIOBAMBA**

Autores: ¹Kelvin Howard Pizarro Romero y ²Michael Andrés Zamora Campoverde.

¹ORCID ID: <https://orcid.org/0000-0002-3650-5372>

²ORCID ID: <https://orcid.org/0000-0002-1145-4476>

¹E-mail de contacto: kelvin.pizarro@unach.edu.ec

²E-mail de contacto: mazamora@utmachala.edu.ec

Afiliación: ¹*Universidad Nacional del Chimborazo, (Ecuador). ²*Universidad Técnica de Machala, (Ecuador).

Artículo recibido: 30 de noviembre del 2024

Artículo revisado: 15 de diciembre del 2024

Artículo aprobado: 31 de enero del 2025

¹Ingeniería en Finanzas, graduado en la Universidad Técnica de Machala, (Ecuador) con 15 años de experiencia laboral. Magíster en Administración de Empresas con mención en Negocios Internacionales, graduado en la Universidad de Guayaquil, (Ecuador). Doctor en Estadística Matemática Aplicada, graduado en la Universidad Nacional de Tumbes, (Perú) Candidato a Magister en Matemática Aplicada con mención en Matemática Computacional, Universidad Nacional del Chimborazo, (Ecuador).

²Ingeniero en Comercio Internacional, graduado en la Universidad Técnica de Machala (Ecuador) con 20 años de experiencia laboral. Magíster en Negocios Internacionales y Gestión de Comercio Exterior, graduado en la Universidad de Guayaquil, (Ecuador). Diploma Superior en Comercio Exterior, graduado en la Universidad de Guayaquil, (Ecuador). Candidato a Doctor dentro del Programa en Administración de Empresas en la Universidad de Investigación e Innovación de México, (México).

Resumen

El presente estudio abordó la necesidad de comprender los factores que influyen en el rendimiento académico de estudiantes de la carrera de Electromecánica en un instituto de educación superior técnico en Riobamba. Se planteó como objetivo construir un modelo matemático basado en regresión logística binaria para identificar patrones predictivos asociados a la probabilidad de aprobación estudiantil. La metodología fue cuantitativa, de alcance explicativo y enfoque correlacional, aplicada sobre una muestra intencionada. El modelo de gestión del conocimiento desarrollado mostró un buen ajuste general, evidenciado por un AIC favorable y un área bajo la curva ROC (AUC) de 0.8232. Se identificó que la variable "ha repetido al menos una materia" tuvo un efecto negativo significativo sobre la probabilidad de aprobar. Estos hallazgos subrayan la importancia de la trayectoria académica como factor determinante del desempeño estudiantil. Se concluye que el modelo es una herramienta predictiva válida y útil para apoyar la toma de decisiones institucionales orientadas a mejorar

el acompañamiento académico y reducir la deserción.

Palabras clave: Rendimiento académico, Regresión logística, Modelos estadísticos.

Abstract

This study addressed the need to understand the factors influencing the academic performance of students in the Electromechanical Engineering program at a technical higher education institute in Riobamba. The main objective was to build a mathematical model based on binary logistic regression to identify predictive patterns associated with students' probability of passing. A quantitative methodology with an explanatory scope and correlational approach was applied to a purposive sample. The developed knowledge management model showed a good overall fit, evidenced by a favorable AIC and an area under the ROC curve (AUC) of 0.8232. It was found that the variable "has repeated at least one subject" had a significant negative effect on the probability of passing. These findings highlight the importance of academic trajectory as a key determinant of student performance. It is concluded that the model is a valid and useful predictive tool to support institutional decision-

making aimed at improving academic support and reducing dropout rates.

Keywords: Academic performance, Logistic regression, Statistical models.

Sumário

Este estudo abordou a necessidade de compreender os fatores que influenciam o desempenho acadêmico dos estudantes do curso de eletromecânica em um instituto de ensino técnico superior em Riobamba. O objetivo principal foi construir um modelo matemático baseado em regressão logística binária para identificar padrões preditivos associados à probabilidade de aprovação dos estudantes. Foi aplicada uma metodologia quantitativa, com escopo explicativo e abordagem correlacional, sobre uma amostra intencional. O modelo de gestão do conhecimento desenvolvido apresentou um bom ajuste geral, evidenciado por um AIC favorável e uma área sob a curva ROC (AUC) de 0,8232. Identificou-se que a variável “ter repetido pelo menos uma disciplina” teve um efeito negativo significativo na probabilidade de aprovação. Esses achados ressaltam a importância da trajetória acadêmica como um fator determinante do desempenho estudantil. Conclui-se que o modelo é uma ferramenta preditiva válida e útil para apoiar a tomada de decisões institucionais voltadas para a melhoria do acompanhamento acadêmico e a redução da evasão escolar.

Palavras-chave: Desempenho acadêmico, Regressão logística, Modelos estatísticos.

Introducción

Bautista et al. (2024) sostienen que, en la actualidad, las instituciones de educación superior se enfrentan al reto ineludible de optimizar sus procesos de enseñanza-aprendizaje mediante el aprovechamiento estratégico de los datos académicos que generan de manera continua. Esta exigencia impulsa el diseño, desarrollo e implementación de herramientas matemáticas y analíticas que permitan comprender con mayor precisión el comportamiento estudiantil, respaldar la toma

de decisiones pedagógicas con evidencia y consolidar una gestión del conocimiento más efectiva y sostenible. Para que ese caudal de información cumpla realmente su propósito, no basta con recolectarlo: resulta imprescindible que sea comprendido, interpretado y aplicado adecuadamente dentro de un sistema educativo comprometido con la mejora continua. En tal sentido, la incorporación de modelos matemáticos orientados al análisis del aprendizaje y a la evaluación del entorno académico adquiere un papel central, por cuanto ofrece bases sólidas para rediseñar estrategias de enseñanza, personalizar la atención al estudiantado y fortalecer la gestión del conocimiento a partir de indicadores verificables y trazables.

En consonancia con lo anterior, Domínguez et al. (2020) destacan que la analítica del aprendizaje emerge como un campo en franca consolidación, capaz de recolectar, procesar e interpretar grandes volúmenes de información educativa con fines de mejora institucional. Este enfoque parte de la premisa de que cada interacción del estudiante—especialmente en entornos digitales—deja una huella que, adecuadamente tratada, puede transformarse en conocimiento útil para reconfigurar prácticas pedagógicas y optimizar procesos de enseñanza. No obstante, los autores subrayan la necesidad de incorporar dimensiones éticas, pedagógicas y culturales al análisis de datos, pues el uso intensivo de algoritmos y macrodatos en educación implica riesgos asociados al sesgo, la privacidad y la equidad. Por ello, recomiendan que las instituciones de educación superior adopten una perspectiva crítica y multidisciplinaria, orientando la gestión de la información no solo a la eficiencia operativa, sino también al bienestar del estudiantado, a la transparencia de los procesos

y a la mejora estructural del sistema educativo en su conjunto.

En esa misma dirección, Suazo (2023) y Aymerich y Albarracín (2022) señalan que los modelos matemáticos aplicados a los análisis estadísticos en educación superior permiten identificar patrones de comportamiento, predecir resultados académicos y clasificar perfiles estudiantiles cuando existe una gestión del conocimiento institucional sólida y bien articulada. Esta aproximación es particularmente pertinente en contextos donde convergen modalidades de estudio diversas y demandas de información oportunas, como sucede en el Instituto Superior Universitario Carlos Cisneros, que requiere una sistematización eficaz de sus repositorios académicos para sustentar decisiones pedagógicas basadas en evidencia. Además, la modelización matemática facilita establecer vínculos claros entre las estrategias docentes implementadas y los resultados efectivamente alcanzados, habilitando ajustes curriculares oportunos, mejoras en los recursos didácticos y un seguimiento más fino del desempeño estudiantil a lo largo de su trayectoria formativa.

Desde un enfoque científico y educativo, Legusov et al. (2022), Tavares (2021) y Van der Velden et al. (2023) enfatizan la importancia de comprender cómo los estudiantes perciben las políticas institucionales relacionadas con su trayectoria académica y el acompañamiento que reciben en cada etapa. Tales percepciones inciden directamente en la equidad del aprendizaje, en la retención estudiantil y en el bienestar dentro del entorno educativo. Diversas investigaciones han mostrado que considerar las particularidades del recorrido de cada estudiante, reconociendo fortalezas, necesidades y ritmos, no solo favorece entornos

más inclusivos y humanos, sino que también ayuda a cerrar brechas de rendimiento y a fortalecer los procesos de gestión del conocimiento. Sin embargo, como advierte Devine (2022) aunque muchas instituciones cuentan con normativas orientadas a fortalecer el aprendizaje y la permanencia, su implementación suele verse limitada por la falta de recursos o por la insuficiente capacitación del personal. Esta situación debilita los mecanismos de seguimiento académico y de apoyo temprano a estudiantes en riesgo. En ese contexto, el modelo predictivo propuesto en esta investigación se plantea como una alternativa técnica de alto valor, capaz de compensar parcialmente dichas restricciones y de facilitar decisiones académicas más oportunas, objetivas y personalizadas.

Bajo una visión humanista y transdisciplinaria, Díaz (2024) y Mendoza y Bullón (2022) recuerdan que la gestión del conocimiento universitario no se reduce a procedimientos técnicos o a flujos documentales estandarizados: entraña una dimensión profundamente vinculada con el talento humano, la cultura organizacional y la transformación social. El conocimiento, en esta perspectiva, no se recibe pasivamente; es una construcción activa, situada y contextual, en la que la mediación docente y las condiciones del entorno institucional resultan determinantes para su circulación y apropiación. Esta concepción se alinea con los hallazgos del presente estudio, que ponen de manifiesto la necesidad de diseñar e implementar modelos predictivos que reconozcan, junto a los indicadores académicos tradicionales, las realidades humanas y organizativas que condicionan el aprendizaje. De forma complementaria, Cuadrado (2020) y Ocaña et al. (2023) sostienen que la evaluación de la gestión del conocimiento en las universidades

permite valorar de manera integral el desempeño organizacional mediante instrumentos que articulan procesos internos y resultados tangibles, proporcionando insumos clave para la toma de decisiones informada.

En el plano metodológico, Ruipérez (2020) y Devia (2021) argumentan a favor de la relevancia de los modelos matemáticos predictivos como parte del abanico de estrategias de analítica del aprendizaje orientadas a la evaluación educativa. En la misma línea, Campos et al. (2022) enfatizan que los enfoques analíticos, cuando se implementan con criterios de calidad, permiten no solo recolectar e interpretar datos de forma sistemática, sino también orientar intervenciones pedagógicas más eficaces, pertinentes y contextualizadas. Por su parte, Mora (2015) advierte que el rendimiento académico es el resultado de una combinación compleja de factores personales, pedagógicos e institucionales que exceden el ámbito de las calificaciones; por ello, su interpretación requiere marcos analíticos integrales. Coherentemente, Mora et al. (2020) y Andrade et al. (2022) sostienen que los estudiantes que desarrollan habilidades de autorregulación y reciben un apoyo institucional oportuno tienden a lograr aprendizajes más profundos y sostenibles, especialmente en entornos de educación virtual, en los que la calidad del acompañamiento puede marcar diferencias decisivas.

De igual modo, Acuña et al. (2021), Escorcía y Guzmán (2020) y Huaranga y Méndez (2022) subrayan que la gestión del conocimiento se convierte en un componente estratégico cuando las instituciones integran sus datos académicos en procesos de mejora pedagógica y de toma de decisiones, fortaleciendo la colaboración docente y optimizando la producción científica.

En sintonía, Sánchez y Martínez (2020) y Martínez (2021) proponen ampliar los instrumentos de evaluación para que no se limiten a medir el rendimiento, sino que también valoren la retroalimentación, la motivación y la participación activa del estudiantado, con miras a un entendimiento más completo de las condiciones reales de aprendizaje.

En este contexto, la presente investigación propone la aplicación de un modelo matemático que, además de recolectar y transformar datos, los analice rigurosamente con el fin de evaluar cómo variables del entorno educativo como la aprobación, ciertos factores sociales y el tiempo de estudio inciden en el rendimiento del estudiantado. A la par, se busca determinar de qué manera la institución puede utilizar esta evidencia para retroalimentar sus procesos de enseñanza-aprendizaje y robustecer una gestión del conocimiento ética, precisa y sostenida en el Instituto Superior Universitario Carlos Cisneros, situado en la ciudad de Riobamba, Ecuador. El propósito es ofrecer información accionable que oriente prácticas docentes, decisiones curriculares y estrategias de acompañamiento, favoreciendo así una cultura institucional basada en datos y centrada en el estudiante.

Materiales y Métodos

Basándose en Hernández et al. (2014) la investigación se enmarca en un enfoque aplicado, con un nivel de profundidad descriptivo y explicativo respecto al objeto de estudio, de carácter cuantitativo, apoyado en el análisis de datos académicos registrados de manera oficial en el Instituto Superior Universitario Carlos Cisneros. La población de referencia estuvo conformada por 255 estudiantes de todos los niveles y secciones de la carrera de Electromecánica, quienes cursan

sus estudios bajo la modalidad presencial. Dado que se contó con registros académicos completos, organizados y verificados por la unidad académica correspondiente, se optó por un muestreo no probabilístico por conveniencia que, en la práctica, coincidió con la totalidad de la población disponible. Esta decisión metodológica se sustenta en lo señalado por Hernández y Mendoza (2018), para quienes este tipo de muestreo selecciona casos en función de la accesibilidad a los datos, la pertinencia para los objetivos del estudio y las particularidades del contexto institucional, resultando apropiado en etapas iniciales de investigación aplicada. El estudio se centra en tres variables académica y cuatro socioeducativas registradas institucionalmente, entre ellas: estado (aprobado o reprobado), género, edad, estado civil, haber perdido la gratuidad, historial de haber repetido al menos una materia, ocupación del estudiante. La recolección de la información se realizó a partir de las bases documentales internas del sistema académico, garantizando su calidad mediante procedimientos de depuración, consistencia y verificación estructural. Estos controles previos resultan esenciales para asegurar la validez de los análisis y reducir el impacto de posibles errores de captura, omisiones o valores atípicos derivados de procesos administrativos. Conforme a la tipología propuesta por Bastidas (2009), el diseño de investigación adoptado es transversal, dado que examina la información en un corte temporal específico, sin manipular variables ni intervenir en los procesos formativos.

Asimismo, Arias (2021) señala que la investigación utiliza un método deductivo, permitiendo derivar conclusiones fundamentadas en el marco teórico y normativo vigente. Finalmente, el estudio se desarrolla bajo un diseño transversal, dado que analiza

casos y sentencias correspondientes a un período determinado, en este caso 2024, sin seguimiento longitudinal. En cuanto al tratamiento estadístico, no fue necesario aplicar técnicas orientadas a la normalización en la variable edad. Posteriormente, se empleó la regresión lineal múltiple como técnica principal, con la finalidad de identificar patrones asociados a la evaluación del aprendizaje y explorar relaciones significativas entre los indicadores académicos y los factores sociales y contextuales incluidos en el estudio.

Desde la perspectiva del análisis multivariante entendido como “la parte de la estadística y del análisis de datos que estudia, analiza, representa e interpreta los datos que resultan de observar más de una variable estadística sobre una muestra de individuos” (Cuadras, 2019, p. 31), el uso de la regresión lineal múltiple permite estimar la contribución relativa de cada predictor bajo supuestos formales conocidos, facilitando la interpretación sustantiva de los coeficientes y el contraste de hipótesis. En este trabajo, las variables consideradas edad, género, estado civil, haber repetido al menos una materia, haber perdido la gratuidad y ocupación del estudiante fueron medidas de forma directa y codificadas según su naturaleza, principalmente como variables categóricas binarias (Sí = 1, No = 2), lo que facilitó su incorporación y análisis en el modelo estadístico utilizado. La validación del modelo incluyó pruebas de significancia para los parámetros estimados, evaluación del coeficiente de determinación (R^2) como indicador de ajuste global, análisis de residuos para verificar supuestos y detectar posibles problemas de especificación, así como la consideración de p-valores para el contraste individual de efectos. Además, se empleó una matriz de confusión con fines complementarios de evaluación siguiendo criterios internos de

control para valorar el grado de acierto en tareas de clasificación derivadas, cuando correspondía.

En su conjunto, el modelo matemático desarrollado buscó establecer relaciones empíricamente fundadas entre variables que inciden en el rendimiento académico, generando evidencia útil para retroalimentar la práctica docente, optimizar la planificación educativa y fortalecer la gestión del conocimiento institucional en el Instituto Superior Universitario Carlos Cisneros. Este enfoque no solo aporta una radiografía descriptiva del desempeño estudiantil en el periodo de análisis, sino que también habilita la formulación de estrategias de intervención pedagógica focalizadas, alineadas con necesidades detectadas y sostenidas en información verificable. El propósito último es contribuir a la toma de decisiones informadas, a la mejora continua de los procesos de enseñanza-aprendizaje y a la consolidación de una cultura de evaluación centrada en el estudiantado. La evaluación del aprendizaje se abordó a partir de un conjunto de variables que permitieron analizar el rendimiento académico, las cuales se clasifican en cuatro categorías según su naturaleza estadística. Esta organización facilita interpretar de manera ordenada los indicadores disponibles, distinguir sus funciones analíticas y articular, con mayor claridad, los insumos que alimentan el proceso de modelización y las decisiones pedagógicas derivadas. La evaluación del aprendizaje, se trabajó a través de un conjunto de variables que permitieron analizar el rendimiento académico, las mismas se clasifican en categorías según su naturaleza estadística:

En el estudio se incluyó una variable cuantitativa discreta correspondiente a la edad, medida en número entero de años, así como

variables categóricas dicotómicas que comprenden: la repetición de al menos una materia (1 = sí ha repetido, 0 = no ha repetido), la pérdida de la gratuidad (1 = sí ha perdido, 0 = no ha perdido), el género (1 = hombre, 2 = mujer), el estado civil (1 = soltero, 2 = casado) y la ocupación del estudiante (1 = solo estudia, 2 = trabaja y estudia); estas variables fueron seleccionadas por su relevancia en la caracterización sociodemográfica y académica de la población analizada. Las categóricas como “ha repetido al menos una materia”, ya codificadas como binarias (0 y 1), no fueron sometidas a transformación, pues la normalización en este caso distorsionaría su significado lógico. La variable categórica dicotómica (ha repetido al menos una materia) fue codificada como binaria (0 = No ha repetido, 1 = Ha repetido), manteniéndose en su escala natural sin ser normalizadas para no perder su significado interpretativo.

Según Rencher y Christensen (2002), la estandarización de variables cuantitativas es una etapa clave en análisis multivariado, especialmente cuando se pretende aplicar técnicas como regresión múltiple, donde se requiere homogeneidad en la escala de medición. Para analizar los factores que inciden en la gestión del conocimiento del aprendizaje de los estudiantes, se estimó un modelo de regresión lineal múltiple en el que la variable dependiente fue ESTADO, calculado a partir (aprobado o reprobado) por cada estudiante. Las variables independientes incluidas en el modelo fueron: la variable dicotómica denominada “ha repetido al menos una materia”, que indica si el estudiante ha repetido alguna asignatura (1 = sí, 0 = no); género (1 = hombre, 2 = mujer); estado civil (1 = soltero, 2 = casado); ocupación del estudiante (1 = solo estudia, 2 = trabaja y estudia); y la variable cuantitativa edad. Estas variables fueron seleccionadas por su respaldo

teórico en investigaciones similares y por la disponibilidad de información confiable en la base de datos utilizada.

Resultados y Discusión

En base a lo anteriormente mencionado, la estructura del modelo quedó representada de la siguiente forma: Estado ~ Edad + genero + estado civil + ha Repetido al menos una materia + ha perdido la gratuidad + estudiante ocupación.

Modelo para gestión del conocimiento

El modelo propuesto incorpora diversas tipologías de variables, clasificadas según su naturaleza estadística, siguiendo los lineamientos metodológicos aceptados en el análisis de regresiones logísticas. En primer lugar, se incluyó una variable cuantitativa continua: edad, expresada en años completos al momento de la recolección de datos. Esta variable, de carácter numérico, puede asumir cualquier valor dentro del rango observado y permite el uso de operaciones aritméticas, facilitando su inclusión directa en el modelo de regresión. En segundo lugar, se incorporaron variables categóricas dicotómicas, codificadas de forma binaria para su análisis. Entre ellas, se encuentran:

- Ha repetido al menos una materia (1 = ha repetido, 2 = no ha repetido), que identifica antecedentes de repetición académica.
- Ha perdido la gratuidad (1 = sí ha perdido, 2 = no ha perdido), asociada a la pérdida del derecho a gratuidad educativa según el artículo 80 de la LOES.
- Género (1 = masculino, 2 = femenino), que distingue el sexo del estudiante.
- Ocupación del estudiante (1 = solo estudia, 2 = estudia y trabaja), que diferencia la dedicación exclusiva al estudio de la combinación con actividades laborales.

Aunque algunas variables fueron originalmente cualitativas, su conversión a factores binarios permitió integrarlas de manera eficiente en la estimación del modelo logístico binario, asegurando la interpretabilidad de los coeficientes y la coherencia de los resultados estadísticos.

Análisis descriptivo de las variables del modelo gestión del conocimiento

Tabla 1. Resultados del modelo logístico de Gestión del conocimiento

	Estimate	Std. Error	z value	Pr(> z)
(Intercepto)	-0.716	1.177	-0.608	0.543
Edad	-0.0301	0.055	-0.544	0.586
Género 2	0.8273	0.9198	0.900	0.368
estadocivilId2	-0.772	11.923	-0.648	0.517
Ha repetido al menos una materia (2)	-3.169	0.7681	-4.127	6.38e-05 ***
Ha perdido la gratuidad (2)	0.7133	0.5337	1.336	0.181
Ocupación del estudiante (2)	0.1914	0.4538	0.422	0.673
(Dispersion parameter for binomial family taken to be 1)				
Null deviance: 180.66 on 254 degrees of freedom				
Residual deviance: 140.86 on 248 degrees of freedom				
AIC: 150.86				
Number of Fisher Scoring iterations: 7				

Fuente: elaboración propia

El análisis descriptivo de la variable cuantitativa edad en el modelo de gestión del conocimiento revela patrones relevantes dentro de la población estudiantil. La edad media es de 23,62 años, con una desviación estándar de 7,18, lo que refleja una dispersión moderada en los valores observados. La asimetría positiva (1,07) indica una ligera concentración de estudiantes en edades más jóvenes, mientras que la curtosis (0,72) sugiere una distribución sin colas extremas, relativamente próxima a la normalidad.

Análisis del modelo matemático logístico binario para gestión del conocimiento

El modelo logístico binario planteado para estimar la probabilidad de que un estudiante se encuentre en estado aprobado (estado = 1) o

reprobado (estado = 0) fue construido a partir de variables sociodemográficas y académicas seleccionadas por su relevancia contextual y estabilidad estadística. Las variables incluidas fueron: edad, género, estado civil, repetición de materias, pérdida de gratuidad y ocupación del estudiante. En la tabla 1 de resultados se observa que la mayoría de las variables no presentan significancia estadística individual ($p > 0.05$), a excepción de la variable ha repetido al menos una materia, la cual muestra un coeficiente negativo significativo ($\beta = -3.169$; $p < 0.001$), evidenciando que haber repetido materias reduce considerablemente la probabilidad de aprobación. La variable edad, tratada como continua, presentó un coeficiente negativo ($\beta = -0.0301$; $p = 0.586$), lo que sugiere que, en esta cohorte, los estudiantes de mayor edad tienden a tener una probabilidad ligeramente menor de aprobar, aunque este efecto no es estadísticamente concluyente. En cuanto al género (1 = masculino, 2 = femenino), se obtuvo un coeficiente positivo ($\beta = 0.8273$; $p = 0.368$), indicando que las mujeres podrían tener una mayor probabilidad de aprobar en comparación con los hombres, si bien la falta de significancia estadística impide afirmaciones sólidas. Respecto al estado civil, codificado como 1 = soltero(a) y 2 = casado(a)/unión libre, se observó un coeficiente negativo ($\beta = -0.772$; $p = 0.517$), lo que apunta a una ligera reducción en la probabilidad de aprobación entre quienes se encuentran en una relación formal, sin evidencia estadística robusta.

La variable ha perdido la gratuidad (1 = sí, 2 = no) mostró un coeficiente positivo ($\beta = 0.7133$; $p = 0.181$), sugiriendo que quienes no han perdido este beneficio podrían tener una ventaja en el rendimiento, aunque la relación no es estadísticamente significativa. Por último, la variable ocupación del estudiante (1 = solo estudia, 2 = estudia y trabaja) presentó un

coeficiente positivo cercano a cero ($\beta = 0.1914$; $p = 0.673$), lo que indica que compatibilizar trabajo y estudio no se asocia de forma significativa con cambios en la probabilidad de aprobación. En términos de ajuste, el modelo registró una deviance residual de 140.86 frente a una deviance nula de 180.66, así como un AIC de 150.86, lo que sugiere un ajuste aceptable para fines explicativos, aunque con un margen de mejora en capacidad predictiva. Este modelo, pese a que la mayoría de los predictores no son significativos individualmente, ofrece una estructura interpretable y coherente con la realidad académica analizada, siendo útil para identificar tendencias y orientar futuras investigaciones.

Tabla 2. Odds Ratios Modelo Logístico Binario

Variable	Odds Ratio	IC 95% Inferior	IC 95% Superior
(Intercepto)	0.48859847	0.0546588	6.13390
Edad	0.97027065	0.8586347	1.07310
Género 2	2.28734858	0.2941086	13.1014
estadocivilId2	0.46186205	0.0215286	3.55322
Ha repetido al menos una materia (2)	0.04201605	0.0064506	0.15188
Ha perdido la gratuidad (2)	2.04088077	0.6872470	5.73006
Ocupación del estudiante (2)	1.21104349	0.4989431	2.99563

Fuente: elaboración propia

A partir del modelo logístico binario, se calcularon las razones de probabilidades (odds ratios) junto con sus intervalos de confianza al 95%, tal como se presenta en la Tabla 2. Esta información permite interpretar la magnitud y dirección del efecto de cada predictor sobre la probabilidad de aprobar (estado = 1). El intercepto presentó un odds ratio de 0.49 (IC 95%: 0.05 – 6.13), lo que sugiere que, en las condiciones base, la probabilidad de aprobación es menor que la de no aprobación, aunque el amplio intervalo refleja escasa precisión y obliga a interpretar con cautela. La variable edad registró un odds ratio de 0.97 (IC 95%: 0.86 – 1.07), indicando que cada año adicional

de edad disminuye levemente la probabilidad de aprobar. Al incluir el valor 1 dentro del intervalo, este efecto carece de significancia estadística. Para género (1 = masculino, 2 = femenino), el odds ratio fue de 2.29 (IC 95%: 0.29 – 13.10), sugiriendo que las mujeres podrían tener una mayor probabilidad de aprobar en comparación con los hombres; sin embargo, el rango tan amplio del intervalo refleja alta incertidumbre.

En estado civil (1 = soltero(a), 2 = casado(a)/unión libre), el *odds ratio* fue de 0.46 (IC 95%: 0.02 – 3.55), lo que apunta a una probabilidad menor de aprobar para quienes tienen pareja formal, aunque la relación no es estadísticamente concluyente. La variable ha repetido al menos una materia (1 = sí, 2 = no) arrojó un *odds ratio* de 0.04 (IC 95%: 0.006 – 0.15), siendo estadísticamente significativa y evidenciando que quienes han repetido materias tienen una probabilidad sustancialmente menor de aprobar. En ha perdido la gratuidad (1 = sí, 2 = no), el *odds ratio* fue de 2.04 (IC 95%: 0.68 – 5.73), lo que sugiere que no perder este beneficio podría asociarse a mayor probabilidad de aprobar, aunque sin significancia estadística. En ocupación del estudiante (1 = solo estudia, 2 = estudia y trabaja), se obtuvo un *odds ratio* de 1.21 (IC 95%: 0.49 – 2.99), indicando escasa diferencia en la probabilidad de aprobación entre ambos grupos, con alta variabilidad y sin efecto estadísticamente significativo.

Tabla 3. Diagnóstico de Colinealidad

Variable	VIF
Edad	1.319641
Género	1.076779
estadocivilId2	1.215824
Ha repetido al menos una materia	1.053613
Ha perdido la gratuidad	1.057357
Ocupación del estudiante	1.097163

Fuente: elaboración propia

Para evaluar la posible presencia de colinealidad entre los predictores del modelo logístico binario, la Tabla 3 presenta los resultados del Factor de Inflación de la Varianza (VIF). Este estadístico mide cuánto aumenta la varianza de un coeficiente debido a la correlación con otras variables independientes del modelo. Valores altos de VIF indican una posible multicolinealidad, lo que puede generar estimaciones inestables y dificultar la interpretación de los coeficientes. En este caso, los valores obtenidos fueron bajos para todas las variables: edad (VIF = 1.32), género (1.08), estado civil (1.21), ha repetido al menos una materia (1.05), ha perdido la gratuidad (1.06) y ocupación del estudiante (1.10). Estos resultados se encuentran muy por debajo del umbral comúnmente aceptado de 5, e incluso por debajo de 2, lo que indica un nivel de correlación prácticamente irrelevante entre predictores. La ausencia de colinealidad significativa implica que cada variable aporta información independiente al modelo, lo que favorece la estabilidad de las estimaciones y la confiabilidad de la interpretación de los coeficientes. Esto respalda la validez estadística de los resultados obtenidos y sugiere que el modelo es robusto desde el punto de vista de la especificación, permitiendo que las conclusiones derivadas sean consistentes y no estén distorsionadas por redundancias lineales entre las variables incluidas.

Tabla 4. Evaluación del ajuste del modelo mediante coeficientes de Pseudo R^2

Fitting null model for pseudo-r2	
llh	-70.4307527
llhNull	-90.3297151
G2	39.7979248
McFadden	0.2202925
r2ML	0.1445009
r2CU	0.2846736

Fuente: elaboración propia

El análisis de ajuste global del modelo logístico binario, basado en los indicadores de Pseudo R^2 de la Tabla 4, evidenció valores consistentes con un buen desempeño: McFadden = 0.2203, Cox & Snell (R^2 ML) = 0.1445 y Nagelkerke (R^2 CU) = 0.2847. Estos resultados reflejan que el modelo captura una proporción significativa de la variabilidad en la probabilidad de aprobación, destacando que el valor de McFadden supera el umbral de 0.2, considerado indicativo de un ajuste satisfactorio en términos predictivos. En cuanto a la capacidad de clasificación, la matriz de confusión mostró un alto nivel de acierto: 226 estudiantes aprobados y 29 reprobados fueron correctamente identificados de acuerdo con la predicción binaria generada por el modelo. Este desempeño sugiere un equilibrio adecuado entre sensibilidad y especificidad, lo que respalda la confiabilidad del modelo en la población evaluada. Asimismo, el análisis del poder discriminativo mediante el área bajo la curva ROC (AUC) registró un valor de 0.8232, calificado como muy bueno según estándares estadísticos ($AUC > 0.8$). Este resultado implica que el modelo distingue de manera consistente entre estudiantes que aprueban y aquellos que reprueban, incrementando su valor como herramienta de pronóstico académico. En conjunto, las métricas presentadas confirman que el modelo no solo presenta un ajuste global apropiado, sino que también ofrece una capacidad de discriminación elevada, lo que lo convierte en un recurso estadístico robusto para anticipar el rendimiento estudiantil y apoyar la toma de decisiones en contextos educativos similares.

Efectos marginales promedio del modelo logístico binario

El análisis de los efectos marginales promedio del modelo logístico binario permitió cuantificar el impacto directo de cada predictor

sobre la probabilidad de aprobación, manteniendo constantes las demás variables del modelo. Se consideraron seis variables independientes: edad, estado civil, ocupación estudiantil, género, haber perdido la gratuidad y haber repetido al menos una materia. De estas, solo la variable “haRepetidoAlMenosUnaMateria2” resultó estadísticamente significativa, con un efecto marginal negativo estimado en -0.2250 ($p < 0.001$). Esto indica que los estudiantes que han repetido al menos una materia disminuyen su probabilidad de aprobar en aproximadamente un 22.5% en comparación con quienes no han repetido ninguna asignatura, evidenciando una fuerte relación inversa entre la repetición de materias y la aprobación académica. Las demás variables no mostraron efectos estadísticamente significativos sobre la probabilidad de aprobación ($p > 0.05$). En particular, “haPerdidoLaGratuidad2” presentó un efecto marginal positivo de 0.0688, aunque con un valor p de 0.2196, lo que no permite confirmar un efecto real, pero podría indicar una ligera tendencia favorable a aprobar para quienes no han perdido la gratuidad. Variables como edad (-0.0026, $p = 0.5857$), estado civil (-0.0546, $p = 0.4147$), ocupación estudiantil (0.0163, $p = 0.6706$) y género (0.0842, $p = 0.4262$) evidenciaron efectos marginales pequeños y no significativos, lo que sugiere que estas características demográficas y contextuales no afectan de forma determinante la probabilidad de aprobación en el presente modelo.

La Figura 1 presenta la curva ROC correspondiente al modelo logístico binario aplicado para analizar el rendimiento académico. La curva muestra una buena capacidad discriminativa, manteniéndose cercana al vértice superior izquierdo del gráfico, lo que indica un balance adecuado entre sensibilidad (verdaderos positivos) y

especificidad (verdaderos negativos). Este comportamiento se refleja en el valor del área bajo la curva (AUC = 0.8232), que confirma que el modelo posee una capacidad sólida para distinguir entre estudiantes que aprueban y quienes reprueban, aunque no perfecta. En términos prácticos, un AUC superior a 0.8 se considera una buena medida de desempeño del modelo.




Figura 1. Curva ROC - Modelo de Gestión del Conocimiento

Fuente: elaboración propia

La Figura 2 presenta los efectos de las variables independientes sobre la probabilidad de aprobación, expresados como razones de probabilidad (*odds ratios*) con sus respectivos intervalos de confianza al 95%. Se observa que la variable ha repetido al menos una materia se ubica considerablemente por debajo del valor de referencia 1, lo que evidencia un efecto negativo marcado sobre la probabilidad de aprobar en quienes han repetido asignaturas. En contraste, la variable ha perdido la gratuidad presenta un *odds ratio* superior a 1, aunque con un intervalo de confianza amplio, lo que refleja mayor incertidumbre en su estimación. La edad se sitúa prácticamente en el valor de referencia ($OR \approx 1$), lo que indica un efecto cercano a neutral. De igual forma, la variable género se aproxima al valor de neutralidad, sugiriendo que, en esta muestra, no se aprecian diferencias

sustanciales en el rendimiento académico entre hombres y mujeres. En conjunto, el gráfico permite identificar tanto la dirección como la magnitud de los efectos, ofreciendo una representación clara de la influencia relativa de cada predictor incluido en el modelo.




Figura 2. Efectos del Modelo Logístico Binario

Fuente: elaboración propia

Los resultados obtenidos en el modelo de Gestión del Conocimiento confirman que variables relacionadas con la trayectoria académica y aspectos personales influyen significativamente en la probabilidad de aprobación de los estudiantes. En particular, la variable “ha repetido al menos una materia” mostró un efecto negativo considerable y estadísticamente significativo, indicando que quienes no han repetido asignaturas presentan una mayor probabilidad de éxito académico. Este hallazgo coincide con estudios previos que destacan la importancia de la trayectoria educativa como predictor clave del rendimiento (Suárez, 2023). Por otro lado, variables como edad, género, estado civil, haber perdido la gratuidad y ocupación del estudiante no alcanzaron significancia estadística en el modelo, lo que sugiere que, en el contexto específico del programa de Electromecánica en el Instituto de Educación Superior de Riobamba, estos factores tienen un impacto

menos determinante sobre el desempeño académico. Esta particularidad puede estar relacionada con las características sociodemográficas y académicas de la población estudiantil, y destaca la necesidad de focalizar intervenciones en aquellos aspectos que realmente inciden en el éxito educativo.

El modelo logístico binario empleado mostró un buen ajuste general, evidenciado por un valor de AIC favorable y una curva ROC con un área bajo la curva (AUC) de 0.8232, lo que indica una capacidad adecuada para discriminar entre estudiantes con probabilidad de aprobar y reprobar. Aunque la discriminación no es perfecta, el rendimiento del modelo es consistente con estándares aceptados en estudios educativos y permite su aplicación práctica para la gestión del conocimiento dentro de la institución. Estos resultados refuerzan la relevancia de implementar estrategias de gestión del conocimiento que permitan identificar a tiempo las trayectorias educativas irregulares, facilitando el diseño de acciones pedagógicas focalizadas y oportunas. El seguimiento y acompañamiento de los estudiantes con historial de repetición podría favorecer la resiliencia académica y mejorar sus resultados, alineándose con enfoques actuales que promueven la intervención basada en evidencia para la mejora continua. El modelo de Gestión del Conocimiento aquí analizado aporta una herramienta útil para la toma de decisiones en la gestión educativa, orientada a potenciar el rendimiento académico mediante la identificación y apoyo a estudiantes en situación de riesgo, enfatizando la importancia de una gestión basada en datos confiables y sistematizados.

Conclusiones

La investigación permitió desarrollar y validar un modelo matemático basado en regresión logística binaria aplicado al análisis del

rendimiento académico desde la perspectiva de la gestión del conocimiento. Este modelo mostró una estructura sólida y un buen ajuste global, evidenciado por un valor de AIC favorable y una curva ROC con un área bajo la curva (AUC) de 0.8232, lo que indica una capacidad adecuada para discriminar entre estudiantes con probabilidad de aprobar o reprobar. Aunque la mayoría de las variables independientes incluidas no alcanzaron significancia estadística individual, el análisis de efectos marginales resaltó que haber repetido al menos una materia tiene un impacto negativo significativo en la probabilidad de aprobación, reforzando la importancia de la trayectoria académica como predictor clave del desempeño estudiantil.

El modelo demostró ser estable y parsimonioso, lo que facilita su aplicación práctica para identificar estudiantes en riesgo y diseñar intervenciones focalizadas basadas en evidencia. Se concluye que este enfoque de gestión del conocimiento aporta una herramienta útil para la toma de decisiones en contextos educativos técnicos, contribuyendo a optimizar el acompañamiento académico y la mejora continua. Se recomienda que futuras investigaciones amplíen el espectro de variables a incluir, especialmente en dimensiones psicológicas, motivacionales y familiares, para incrementar la capacidad explicativa del modelo. Además, sería pertinente validar y adaptar el modelo a otras carreras y modalidades académicas del instituto, a fin de fortalecer su generalización y utilidad institucional.

Referencias Bibliográficas

Acuña, M. (2021). Manejo de emociones en estudiantes universitarios en tiempos de confinamiento: Una Propuesta de intervención desde un proyecto de aula. *Boletín de Innovación, Logística y*

- Operaciones*, 3(1).
<https://doi.org/10.17981/bilo.3.1.2021.08>
- Aymerich, À., & Albarracín, L. (2022). Mathematical Modeling in Statistical Activities: Key Episodes for Model Generation. *Uniciencia*, 36(1), 1-16.
<http://dx.doi.org/10.15359/ru.36-1.16>
- Andrade, M. (2020). Beyond quality metrics: Defying journal rankings as the philosopher's stone of mathematics education research. *Educational Studies in Mathematics*, 103, 359-374.
<https://doi.org/10.1007/s10649-020-09932-9>
- Bastidas, R. (2009). Metodología de la Investigación Educativa (2 ed.). Madrid: La Muralla S.A.
- Bautista, T. (2024). Perspectivas y oportunidades para la integración de analíticas de aprendizaje: un estudio cualitativo en universidades mexicanas. *Revista de Análisis de Aprendizaje*, 11(1), 49-66.
<https://doi.org/10.18608/jla.2024.8125>
- Campos, R. (2022). Analítica del aprendizaje: un desafío al desempeño del personal docente. *Revista Universidad y Sociedad*, 14(6), 40-48.
http://scielo.sld.cu/scielo.php?pid=S2218-36202022000600040&script=sci_arttext
- Cuadrado, G. (2020). Gestión del conocimiento en la universidad: cuestionario para la evaluación institucional. *Revista Iberoamericana de Educación Superior*, 11(30), 201-218.
<https://doi.org/10.22201/iissue.20072872e.2020.30.596>
- Cuadras, C. (2019). Nuevos Métodos de Análisis Multivariante. Barcelona-España: CMC.
<https://es.scribd.com/document/420846198/Cuadras-Nuevos-me-todos-de-estadistica-multivariante>
- Devia, C. (2021). Sistema de gestión del conocimiento basado en estándares de alta calidad para un programa educación superior. *Revista Ingeniería, Matemáticas y Ciencias de la Información*, 8(16), 55-64.
<http://dx.doi.org/10.21017/rimci.2021.v8.n1.6.a102>
- Devine, P. (2022). Diversity training goals, limitations, and promise: A review of the multidisciplinary literature. *Annual Review of Psychology*, 73(1), 403-429.
<https://doi.org/10.1146/annurev-psych-060221-122215>
- Díaz, J. (2024). Gestión del conocimiento dirigido a docentes de educación universitaria, desde la perspectiva humanista y transdisciplinaria. *Aula Virtual*, 5(11), 13-28.
https://ve.scielo.org/scielo.php?script=sci_arttext&pid=S2665-03982024000100013
- Domínguez, D., Reich, J., & Ruipérez, J. (2020). Analítica del aprendizaje y educación basada en datos: Un campo en expansión. *RIED. Revista Iberoamericana de Educación a Distancia*, 23, 33-43.
<https://doi.org/10.5944/ried.23.2.27105>
- Escorcia, J. (2020). Gestión del conocimiento en Instituciones de Educación Superior: Caracterización desde una reflexión teórica/ Knowledge management in Higher Education Institutions: Characterization from a theoretical reflection. *Revista de Ciencias Sociales*, 26(3), 83-91.
<https://doi.org/10.31876/rcs.v26i3.33235>
- Figaredo, D. (2020). Analítica del aprendizaje y educación basada en datos: Un campo en expansión. *RIED-Revista Iberoamericana de Educación a Distancia*, 23(2), 33-43.
<https://doi.org/10.5944/ried.23.2.27105>
- Hair, J., Black, W., Babin, B., & Anderson, R. (2019). Multivariate Data Analysis. Upper Saddle River: Pearson.
<https://www.drnishikantjha.com/papersCollection/Multivariate%20Data%20Analysis.pdf>
- Hernández, R., & Mendoza, C. (2018). Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta. México: McGraw Hill Education.
<http://www.biblioteca.cij.gob.mx/Archivos/Materiales%20de%20consulta/Drogas%20de%20Abuso/Articulos/SampieriLasRutas.pdf>
- Huaringa, H., & Méndez, J. (2022). Gestión del conocimiento, herramientas tecnológicas en

- la comunicación efectiva en directivos de las instituciones educativas, Lima-2022. Universidad César Vallejo. <https://hdl.handle.net/20.500.12692/94517>
- Legusov, O. (2022). Equity, diversity, and inclusion from the perspective of international community college students. *Canadian Journal of Higher Education*, 52(4), 121-134. <https://doi.org/10.47678/cjhe.v52i4.189821>
- Martínez, M. (2021). Análisis factorial confirmatorio: un modelo de gestión del conocimiento en la universidad pública. *RIDE. Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 12(23), 1-23. <https://doi.org/10.23913/ride.v12i23.1103>
- Mendoza, C., & Bullón, C. (2022). Gestión del conocimiento en instituciones de educación superior: una revisión sistemática. *Revista de Investigación en Ciencias de la Educación, Horizontes*, 6(26), 1992-2003. <https://repositorio.cidecuador.org/handle/123456789/2476>
- Mora, R. (2015). Factores que intervienen en el rendimiento académico universitario: Un estudio de caso. *Universidad del Zulia*, 31, 1041-1063. <https://www.redalyc.org/pdf/310/31045571059.pdf>
- Mora, C. (2020). En sintonía con esta postura, lo indicado por Mora Yate, Mahecha Escobar y Conejo Carrasco (2020) sostiene que los estudiantes que desarrollan habilidades de autorregulación y cuentan con apoyo institucional tienden a lograr aprendizajes más profundos. *Cultura, Educación y Sociedad*, 11(2), 191-206. <http://dx.doi.org/10.17981/cultedusoc.11.2.2020.12>
- Ocaña, J., Álvarez, I., & Paredes, A. (2023). La gestión del conocimiento e innovación en los procesos educativos en la disciplina del diseño. *Cuadernos del Centro de Estudios de Diseño y Comunicación*, 180, 173-182. <https://doi.org/10.18682/cdc.vi181.8904>
- Rencher, A., & Christensen, W. (2002). *Methods of multivariate analysis* (3rd ed.). United States of America: John Wiley & Sons, Inc. https://eprints.uad.ac.id/135/1/Handbook_of_analysis_multivariat.pdf
- Ruipérez, J. (2020). El Proceso de Implementación de Analíticas de Aprendizaje. *RIED. Revista Iberoamericana de Educación a Distancia*, 23(2), 85-101. <http://dx.doi.org/10.5944/ried.23.2.26283>
- Sánchez, M., & Martínez, A. (2020). Evaluación del y para el aprendizaje: instrumentos y estrategias. Imagia Comunicación. Ciudad de México: Universidad Nacional Autónoma de México. https://www.puees.unam.mx/sapa/dwnf/114/3.Sanchez-Mendiola_2020_EvaluacionDelAprendizaje.pdf
- Suazo, I. (2023). Knowledge management models in higher education. *European Journal of Education and Psychology*, 6(2), 1-23. <https://orcid.org/0000-0002-1689-1632>
- Suazo, I. (2023). Modelo de Gestión del Conocimiento. *Universidad Autónoma de Chile*, 3(1), 3-14. <https://repositorio.uaautonoma.cl/handle/20.500.12728/10275>
- Tavares, V. (2021). Feeling excluded: international students experience equity, diversity and inclusion. *International Journal of Inclusive Education*, 28(8), 1551-1568. <https://doi.org/10.1080/13603116.2021.2008536>
- Van, G. (2023). Peer-mentorship and first-year inclusion: Building belonging in higher education. *BMC Medical Education*, 23, 833. <https://doi.org/10.1186/s12909-023-04805-0>



Esta obra está bajo una licencia de Creative Commons Reconocimiento-No Comercial 4.0 Internacional. Copyright © Kelvin Howard Pizarro Romero y Michael Andrés Zamora Campoverde.

