

Análisis del riesgo de la titulación de grado considerando factores académicos y administrativos mediante dashboard interactivos

Risk analysis of undergraduate degrees considering academic and administrative factors using interactive dashboards

- 1 Johanna Mariuxi González Arias  <https://orcid.org/0009-0004-2938-7111>
Universidad Bolivariana del Ecuador (UBE), Duran, Ecuador. Maestría en Gestión y Análisis de Datos con mención en Inteligencia de Negocios.
jmgonzaleza@ube.edu.ec
- 2 Carlos Hernán Suárez Barragán  <https://orcid.org/0009-0000-7779-3297>
Universidad Bolivariana del Ecuador (UBE), Duran, Ecuador. Maestría en Gestión y Análisis de Datos con mención en Inteligencia de Negocios.
chsuareszb@ube.edu.ec
- 3 Jorge Luis Charco Aguirre  <https://orcid.org/0000-0002-0099-0345>
Universidad Bolivariana del Ecuador (UBE), Duran, Ecuador.
jlcharcoa@ube.edu.ec
- 4 Dayron Rumbaut Rangel  <https://orcid.org/0009-0001-9087-0979>
Universidad Bolivariana del Ecuador (UBE), Duran, Ecuador.
drumbautr@ube.edu.ec

Artículo de Investigación Científica y Tecnológica

Enviado: 08/12/2025

Revisado: 15/01/2026

Aceptado: 11/02/2026

Publicado: 07/04/2026

DOI: <https://doi.org/10.33262/cienciadigital.v10i2.3598>

Cítese:

Gonzalez Arias, J. M., Suárez Barragán, C. H., Charco Aguirre, J. L., & Rumbaut Rangel, D. (2026). Análisis del riesgo de la titulación de grado considerando factores académicos y administrativos mediante Dashboard interactivos. *Ciencia Digital*, 10(2), 157-170. <https://doi.org/10.33262/cienciadigital.v10i2.3598>



Ciencia Digital
Editorial



CIENCIA DIGITAL, es una revista multidisciplinaria, trimestral, que se publicará en soporte electrónico tiene como misión contribuir a la formación de profesionales competentes con visión humanística y crítica que sean capaces de exponer sus resultados investigativos y científicos en la misma medida que se promueva mediante su intervención cambios positivos en la sociedad. <https://cienciadigital.org>

La revista es editada por la Editorial Ciencia Digital (Editorial de prestigio registrada en la Cámara Ecuatoriana de Libro con No de Afiliación 663) www.celibro.org.ec.

Esta revista está protegida bajo una licencia *Creative Commons Atribución-NoComercial-CompartirIgual 4.0 International*. Copia de la licencia: <https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>.



Palabras claves: riesgo, dashboard educativos, titulación universitaria, analítica de datos, análisis predictivo.

Resumen: Resumen Introducción: la educación superior en el territorio ecuatoriano se enfrenta a escenarios de complejidad en cuanto a procesos académicos y administrativos previos a la titulación de grado, influenciado por el cumplimiento de requisitos, las modalidades de estudios y la creciente demanda estudiantes para ciertas carreras. Objetivo: analizar el riesgo de la titulación en el nivel de grado mediante la integración de factores académicos y administrativos, utilizando herramientas interactivas de análisis de datos, para identificar tempranamente los casos en riesgo y proponer estrategias institucionales que optimicen el proceso de titulación. Metodología: la metodología aplicada fue de enfoque mixto de carácter no experimental y retrospectivo centrado en la recolección de información de dataset anonimizado de datos estudiantiles cuya muestra de fue de 604 registros. Resultados: se identificó que los factores administrativos y los factores académicos que influyen significativamente en la aptitud del estudiante para acceder al proceso de titulación de grado. El análisis cualitativo y cuantitativo permitió establecer el nivel del riesgo potencialmente alto en estudiantes que presentan retrasos. A través del dashboard diseñado para este estudio, fue posible visualizar los riesgos y facilitar la toma de decisiones institucionales de manera oportuna y preventiva. Conclusión: se determina que aplicando un análisis de riesgo anticipado dentro de la gestión académica en carreras con alto número de estudiantes matriculados permite identificar aquellos con problemas previo a la titulación para aplicar una correcta decisión a nivel de dirección académica. Área de estudio general: Analítica de datos. Área de estudio específica: Análisis del Riesgo. Tipo de estudio: Artículo original.

Keywords: Risk analysis, educational dashboards, university degrees, data analytics, predictive analytics.

Introduction: higher education in Ecuador faces complex scenarios regarding academic and administrative processes prior to undergraduate graduation, influenced by the fulfillment of requirements, study modalities, and the growing student demand for certain programs. Objective: to analyze the risk of undergraduate graduation by integrating academic and administrative factors and using interactive data analysis tools to identify at-risk cases early and propose institutional strategies to optimize the graduation process. Methodology: the methodology applied was a mixed approach, non-experimental and retrospective, focused on the collection of information from an

anonymized dataset of student data, with a sample of 604 records. Results: the administrative and academic factors that significantly influence student suitability to access the undergraduate graduation process were identified. Qualitative and quantitative analysis made it possible to establish the level of potentially substantial risk in students who present delays. Using the dashboard designed for this study, it was possible to visualize risks and facilitate timely and initiative-taking institutional decision-making. Conclusion: it was determined that applying early risk analysis within academic management in programs with a high number of enrolled students allows students with problems prior to graduation to be identified, enabling appropriate decisions to be made at the academic management level. General Area of Study: Data Analytics. Specific Area of Study: Risk Analysis. Type of Study: Original article.

1. Introducción

La educación superior en el territorio ecuatoriano se enfrenta a escenarios de complejidad en procesos académicos y administrativos previos a la titulación de grado, con el cumplimiento de requisitos, las modalidades de estudios y la creciente demanda estudiantil para ciertas carreras constituye un elemento decisivo que marcan un precedente para anticipar el éxito o riesgo académico.

La gestión adecuada de los procesos garantiza que se cumplan con los requisitos favoreciendo desarrollo académico fluido dentro de los plazos establecidos, además que integra el fortalecimiento institucional al mantener la tasa de titulación elevada requerimiento importante dentro de los procesos de acreditación de las carreras ante el Consejo de Aseguramiento de la Calidad de la Educación Superior (CACES) en Ecuador

para garantizar la mejora continua de los procesos académicos.

La literatura reciente evidencia una brecha en el sistema educativo en la aplicación de herramientas tecnológicas integradas, capaces de combinar datos académicos y administrativos para predecir, mitigar o minimizar el riesgo de titulación (Acosta et al., 2024), sin embargo ante la existencia de sobre cómo predecir, hay una brecha en herramientas que logren mitigar mediante acciones automatizadas basadas en datos administrativos.

El proceso de titulación universitaria emerge como el hito culminante de la trayectoria académica, funcionando como un mecanismo de validación de los conocimientos, habilidades y competencias adquiridas por el estudiante a lo largo de su carrera (Mendoza et al., 2024).

La falta de mecanismos predictivos en etapas tempranas perpetúa un ciclo donde los problemas académicos o administrativos se identifican tardíamente dando como resultados estudiantes que abandonan los estudios al llegar a la titulación.

Según los autores Morales et al. (2025) uno de los factores entre los estudiantes que incrementan la brecha es la falta de manejo de plataformas educativas y de gestión académica la falta de dispositivos adecuados y la conectividad limitada dificultan la participación de los estudiantes en el proceso de aprendizaje.

Por otra parte, es válido mencionar que las universidades y otras instituciones de educación superior en Ecuador se expandieron rápidamente. Sin embargo, este crecimiento, provocado por el aumento de la población y la demanda, no estuvo acompañado de una supervisión efectiva ni de estándares de calidad (Macías et al., 2025).

Se puede señalar que la utilización de herramientas interactivas que apoyan la toma de decisiones estratégicas anticipando y prediciendo posibles riesgos que sirven como modelo de control preventivo (Zamora et al., 2019). A fin de que permita tratar la información de manera adecuada y acorde a las necesidades institucionales que este requiere.

Para el autor un dashboard es una herramienta de representación visual de la información más importante y necesaria para lograr los objetivos de forma consolidada y organizada en una sola pantalla cada vez

más utilizados en la inteligencia de negocios (Quiguanas & Arias, 2024).

El análisis de datos educativos con aprendizaje automático permite identificar estudiantes en riesgo desde etapas tempranas, facilitando intervenciones dirigidas que mejoran la retención y el éxito en la titulación de pregrado (Villalobos-Murillo et al., 2025).

El uso de Dashboard en el ámbito educativo permite integrar información académica y administrativa para interpretar de manera clara y oportuna los niveles de riesgo estudiantil. La visualización consolidada en una sola interfaz facilita la identificación de patrones, alertas tempranas y brechas de desempeño asociadas al proceso de titulación, lo que resulta clave para instituciones que enfrentan problemáticas de rezago académico y baja eficiencia terminal. Asimismo, estos entornos visuales posibilitan el seguimiento continuo de cohortes y carreras, orientando la priorización de intervenciones y la asignación de recursos institucionales con un enfoque preventivo y trazable.

El desarrollo de modelos matemáticos aplicados a la analítica educativa requiere una definición rigurosa del fenómeno de estudio, la selección de variables relevantes y un tratamiento de datos coherente con los supuestos estadísticos. La construcción del modelo debe complementarse con procesos de entrenamiento, validación cruzada y evaluación mediante métricas como precisión, sensibilidad, Área Bajo la Curva (AUC) y error, garantizando así su capacidad predic-

tiva.

En el marco de la educación basada en resultados o en sus siglas en inglés OBE (*Outcome-Based Education*), los resultados de aprendizaje pueden definirse y evaluarse tanto a nivel de curso como de programa. En esta perspectiva, los resultados de los cursos contribuyen al logro de los resultados del programa y su integración se realiza mediante una actividad clave denominada mapeo curricular. Para apoyar la implementación de OBE y documentar eficazmente las actividades de evaluación educativa, se desarrollaron diversas herramientas computarizadas (Namoun & Alshantqi, 2021).

La reproducibilidad del modelo se asegura a través de protocolos metodológicos, documentación adecuada y pruebas en distintos subconjuntos de datos y periodos temporales.

En este contexto, la toma de decisiones basada en información visual analizada mediante Dashboard constituye un soporte estratégico para la gestión académica institucional. Al integrar alertas, tendencias y comparativos por carrera, periodo y cohorte, se facilita la implementación de acciones oportunas como tutorías focalizadas, ajustes en la carga académica y optimización de trámites administrativos. De esta manera, la institución puede asignar recursos de forma eficiente, monitorear el impacto de las intervenciones y retroalimentar sus políticas académicas con el objetivo de mejorar los indicadores de titulación y retención estudiantil.

Respecto a esto el autor menciona que el

Sistema de Detección Temprana (EDS) desarrollado en este trabajo emplea diversas técnicas de aprendizaje automático, incluyendo redes neuronales, árboles de decisión y los algoritmos, para identificar características que distinguen a los estudiantes en riesgo de abandonar. La combinación de estos métodos permite mejorar significativamente la precisión de las predicciones y adaptarse a diferentes contextos universitarios (Berens et al., 2018).

En cuanto a la tasa de titulación y retención estudiantil en las Instituciones de Educación Superior (IES) (Mendoza et al., 2024), representa uno de los indicadores sustanciales que miden los procesos de acreditación de las instituciones, aunque actualmente ellas cuentan con su propio sistema de gestión académico carecen comúnmente de sistemas predictivos de información que son ideales para complementar y mejorar la tasa de éxito en la titulación de grado.

Finalmente comprender cómo los estudiantes perciben las políticas institucionales y los apoyos disponibles a lo largo de su trayectoria académica es un aspecto ampliamente reconocido por la literatura contemporánea en educación. Este tipo de percepciones influye de manera significativa en la equidad del aprendizaje, la permanencia estudiantil y el bienestar en los entornos formativos. Además, atender las particularidades de cada recorrido académico favorece entornos más inclusivos y fortalece la gestión del conocimiento.

2. Metodología

La presente investigación se ajustó con un enfoque mixto, combinando métodos cuantitativos y cualitativos para abordar de manera integral el problema estudiado. Desde la perspectiva cuantitativa, se realizó la recolección y análisis de datos numéricos y estructurados provenientes de expedientes estudiantiles, con el propósito de identificar patrones, probar relaciones y cuantificar la capacidad predictiva de los modelos aplicados. En el componente cualitativo, se exploraron datos de otro programa similar y de otras carreras sobre el estado del proceso de titulación.

El estudio fue de tipo descriptivo-explicativo y de carácter analítico, al buscar no solo caracterizar la población, las variables académicas y administrativas relevantes, sino también explicar su relación con el éxito en la titulación y desarrollar el análisis adecuado que permitan detectar tempranamente el riesgo académico. El diseño de investigación fue no experimental y retrospectivo, pues no se manipularon variables, sino que se analizaron datos históricos de estudiantes egresados.

La población estuvo constituida por los expedientes de estudiantes de grado del periodo octubre 2024 – abril 2025. Se incluyeron los casos con expedientes completos y registros académicos actualizados, y se excluyeron aquellos con información incompleta o en estado de abandono. Como técnicas de recolección de datos se utilizaron la revisión documental y la extracción de infor-

mación institucional bajo estrictos criterios de anonimización y confidencialidad correspondiente y el cumplimiento de las normas éticas para el tratamiento de datos personales y académicos de los estudiantes.

Para el análisis de datos de los dataset escogidos se llevó en tres fases:

- a. Extracción, limpieza y anonimización de datos sensibles de estudiantes, además de la eliminación de campos innecesarios para el estudio.
- b. Validación y declaración de variables para identificar los niveles de riesgos estudiantiles.
- c. Integración de todos los dataset a un solo conjunto de datos para utilizarlo en la herramienta interactiva que generará el dashboard que servirá para para visualizar la información.
- d. Creación de modelo de machine learning basado en regresión logística en Python.
- e. Comparación de valores obtenidos en el dashboard con el modelo de machine learning para sustento matemático de resultados.

Los dataset escogidos, que se visualizan en la Tabla 1, permitieron realizar el análisis de los datos para esta investigación. Durante el proceso de depuración, se determinó que la variable Total del monto adeudado no era relevante para los objetivos del estudio, debido a que se centró en la información

Tabla 1: Descripción de los campos del dataset

Variable	Descripción	Estado
Estado de la titulación	Esta es la variable principal, indica el estado final del proceso de titulación del estudiante.	Sustentado, no ingresa a titulación pendiente de sustentación
Estado de Pago	Variable administrativa que describe la situación financiera del estudiante en relación con sus obligaciones con la institución.	Al día y pendiente de cuotas
Total del monto adeudado	Variable numérica que representa el total de dinero adeudado por el estudiante.	Se elimina el campo al ser irrelevante para el análisis.
Materias vistas	Cantidad de asignaturas que el estudiante curso en el periodo académico.	Valores entre 1 y 21 depende del programa oscila entre 18 a 21 máximo.
Materias aprobadas	Número de asignaturas que el estudiante aprobó.	Valores entre 1 y 21 depende del programa.
Materias reprobadas	Número de asignaturas que el estudiante reprobó.	Valores entre 1 y 21 los factores por financieros, o descuido de estudios.

Nota: Dataset extraído del repositorio académico de la Instrucción de Educación Superior IES.

relacionada con las materias cursadas, aprobadas y reprobadas y estado de pago de los estudiantes.

Para definir las variables asociadas al riesgo de titulación, en este estudio se establecieron niveles específicos que permiten categorizar dicho riesgo en alto, medio y bajo. Estos umbrales fueron definidos cuidadosamente por los autores a partir del análisis de los factores académicos y administrativos relevantes, tal como se detalla en la Tabla 2.

Esta clasificación facilita una evaluación más precisa y contextualizada del riesgo para la toma de decisiones mediante paneles interactivos.

En este estudio se empleó medidas calculadas en la herramienta Power BI para optimizar el análisis de datos institucionales. Estas permitieron automatizar el análisis de riesgo frente a una posible no titulación, ga-

rantizar coherencia en los indicadores clave generados en los reportes administrativos y mejorar la trazabilidad de los estudiantes en riesgo.

Además, facilitaron la comparación dinámica entre periodos, con otras carreras o programas de similares características, para llegar a una conclusión sobre la mitigación o minimización el riesgo fortaleciendo la toma de decisiones basada en un apoyo visual de inteligencia de negocios y experiencia profesional de la dirección de carreras.

Se implementó un modelo de regresión logística para la clasificación binaria, utilizando un enfoque supervisado. El conjunto de datos fue dividido en 80 % para entrenamiento y 20 % para prueba, garantizando que la partición se realizara de manera aleatoria para evitar sesgos. Durante la fase de entrenamiento, se ajustaron los coeficientes del modelo mediante la maximización de

Tabla 2: Declaración de las variables de riesgos

Nivel del riesgo	Estado de finanzas	Materias aprobadas	Materias reprobadas	Requisitos adicionales
Bajo	Al día	Todas las cursadas	0	Nivel de Idiomas completo.
Medio	Desde 2 pagos pendientes en adelante	Depende si el factor es socioeconómico, bajo rendimiento académico.	Entre 1 a 3 materias	2 nivel de Idiomas completo.
Alto	Desde 3 pagos pendiente en adelante	Depende si el factor es socioeconómico, bajo rendimiento académico.	Entre 4 materias en adelante	2 o todos los niveles de idiomas incompletos.

la verosimilitud, con el objetivo de estimar la probabilidad de pertenencia a cada clase. Posteriormente, el modelo entrenado se evaluó sobre el conjunto de prueba utilizando métricas estándar como precisión (Accuracy) y ROC AUC, lo que permitió medir tanto la exactitud global como la capacidad discriminativa del modelo. Este procedimiento asegura una validación adecuada del rendimiento y la generalización del modelo.

3. Resultados

Los resultados de los indicadores permiten observar el riesgo basado de los dataset escogidos de 604 registros estudiantiles; el programa de estudio evaluado para esta investigación se dividió en dos como se muestra en la Tabla 3.

La clasificación para el análisis con la herramienta Power Bi visualiza los resultados para determinar los valores que arroja los indicadores que servirán para la toma de decisiones adecuadas e implementar medidas ante la necesidad de identificar que procesos causan los retrasos en la fluidez al cursar la malla académica normalmente.

El análisis de los datos revela que los programas de 15 meses de profundización presen-

tan un mayor número de asignaturas que deber cursar los estudiantes en periodos de corta duración de un año y una mayor matrícula estudiantil debido a la amplitud del campo de estudios que tienen como requisitos para ser admitidos en el programa causando que los procesos se ralenticen como la titulación incrementándose más en referente a los programas de 12 meses de profundización tomado de ejemplo para la comparación así como otros programas de profundización de similares características de duración en la formación de otras carreras dentro de la IES.

Tabla 3: Resultados de los indicadores del riesgo

	12 meses	15 meses
Factor académico	13.47	12.24
Factor Socio-económico	\$1207	\$1511
Valor de Riesgo	45.9 %	41.78 %

Junto con la recolección de la información se considera evaluar la situación a otras carreras, el tema socioeconómico en el programa de 15 meses el riesgo se elevó considerablemente emergió como el primer filtro crítico, señalando que la situación financiera del estudiante es un predictor temprano clave para el éxito en la titulación en las IES privadas, cabe señalar que establecen

sus procesos internos institucionales que influyen en el mismo. Un segundo filtro importante es el número de materias aprobadas por parte del estudiante el factor académico demuestra ser relevante incluso cuando las condiciones financieras son desfavorables puesto que implica que un alto rendimiento académico puede mitigar el riesgo de no titularse, incluso si el estudiante arrastra valores financieros, aunque también se considera un riesgo de titulación sobre aquellos que no logran puntajes requeridos por falta de desempeño en las asignaturas de la malla como se observa en la Tabla 4.

Tabla 4: Análisis comparativo de los indicadores del riesgo mediano a alto riesgo

	12 meses	15 meses
Factor académico	17.62	14.79
Factor Socio-económico	1660	1830
Valor de Riesgo	63.1 %	50.6 %


Con el fin de validar los resultados obtenidos mediante el Dashboard en Power BI, se implementó un modelo de regresión logística como herramienta de contraste. Este modelo permitió evaluar de forma cuantitativa la capacidad predictiva del sistema desarrollado, empleando las mismas variables académicas y socioeconómicas del dataset institucional. Las métricas de desempeño obtenidas confirman la solidez del enfoque metodológico adoptado, como se muestra en la Tabla 5.

Tabla 5: Análisis comparativo de modelos

Métrica	Valor	Descripción
Accuracy	0.967	Indica el porcentaje de predicciones correctas sobre el total de casos.
ROC AUC	0.954	Mide la capacidad del modelo para distinguir entre clases

Para complementar la evaluación del modelo, se analizó la distribución de las predicciones a través de una matriz de confusión, la cual permite identificar con precisión los aciertos y errores de clasificación en cada categoría de riesgo. Este análisis detallado evidencia que el modelo logra una alta tasa de verdaderos positivos y verdaderos negativos, con mínimos errores de clasificación entre las clases, lo que ratifica su idoneidad para su implementación en entornos institucionales, como se muestra en la Figura 1.

Figura 1: Matriz de Confusión



En la herramienta seleccionada, Power BI, se construyó un dashboard orientado a la

visualización integral de los resultados del análisis. Para su diseño se seleccionaron elementos gráficos adecuados, tales como gráficos de barras, tarjetas de indicadores y tablas dinámicas, priorizando aquellos que facilitan la comparación de variables y la identificación rápida de valores críticos. Al igual que, se incorporaron segmentadores para filtrar la información por período académico, carrera, paralelo y nivel de riesgo, permitiendo un análisis dinámico y adaptado a las necesidades como se muestra en la Figura 2.

Esta estructura favorece una interpretación de la información, desde una visión global hasta una revisión individual. El panel muestra el porcentaje de riesgo académico obtenido mediante la fórmula definida para el estudio, así como los valores asociados a cada variable.

El valor de riesgo se obtiene al multiplicar dos veces el valor de materias reprobadas por una unidad mayor a la cantidad de cuotas pendientes para evitar que un estudiante que no tenga materias reprobadas tenga un valor nulo de riesgo y tiene un rango de 0 a 672 puntos los cuales luego serán normalizados para obtener el porcentaje de riesgo que va en una escala de 0 a 1.

Esta configuración fue seleccionada con el objetivo de proporcionar a interesados académicos una herramienta intuitiva y funcional que permita identificar oportunamente a los estudiantes con mayor vulnerabilidad, facilitando la toma de decisiones informada y la planificación de intervenciones

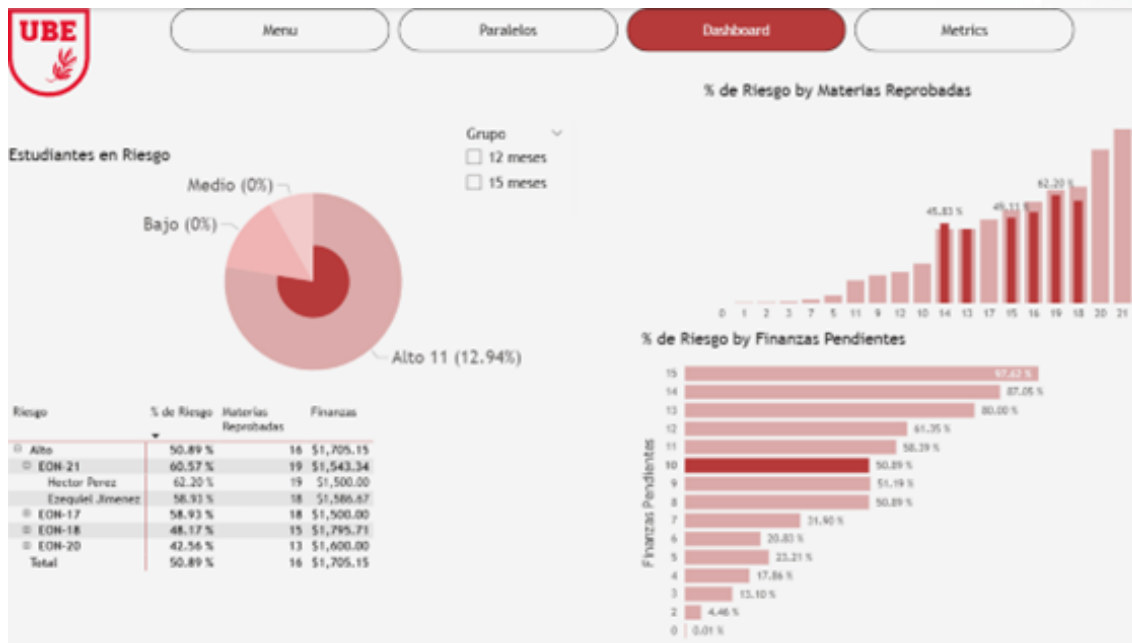
preventivas.

El estudio demostró que el peso de las materias reprobadas es aproximadamente doble el impacto al factor socioeconómico que mantiene el estudiante, para un correcto análisis en la herramienta se suma una unidad para evitar que la multiplicación no devuelva valores nulos (cero) justificando por no tener valores pendientes, permite representar correctamente los casos en los que el estudiante no tiene valores socioeconómicos críticos, pero sí registra materias reprobadas, sin embargo el nivel del riesgo se alto cae en la incidencia lo cual favorece una toma de decisiones más precisa por parte de los directivos académicos.

Se realizó la ejecución con el modelo Machine Learning para diferenciar cercanía de valores y si estos se apegan a la realidad del resultado obtenido como la regresión logística junto con Python para las comparativas numéricas del dataset obtenido de Power Bi a manera verificar la precisión de la probabilidad del riesgo de no titularse que muestra el Dashboard finalmente sea confiable. Como se evidencia en la Figura 1.

Los valores promedio del porcentaje de riesgo para el grupo alto para el modelo de regresión logística y el campo calculado en Power BI es de 62.43 % y 60.61 % respectivamente es decir una diferencia porcentual a 2 puntos, para el grupo medio con 18.56 % 19.05 % y grupo bajo con 0.92 % y 0.87 % es menor a un punto porcentual.

Figura 2: Presentación final del Dashboard



4. Discusión

Los procesos internos que conllevan las IES referente a la titulación son cruciales para garantizar el éxito académico (Machado & Castillo, 2017). En estos no solo se evalúa la metodología, sino también el cumplir con los lineamientos académicos de manera estricta (Mendoza et al., 2024).

La titulación representa una etapa crítica; sin embargo, el proceso suele verse obstaculizado por la carencia de herramientas predictivas que permitan anticipar el éxito del estudiante (Rabelo & Zárate, 2025). Esta deficiencia deriva en la identificación tardía de requisitos pendientes, problema que se acentúa por la gestión manual y los tiempos de revisión prolongados. Asimismo, la gestión ineficiente de los recursos genera cuellos de botella y una administración reactiva

que interrumpe la progresión fluida del egresado (Macías, 2025).

Ante la falta de análisis de datos, el uso de herramientas analíticas se convierte en un aliado estratégico (Ramaswami et al., 2022). Estas permiten asociar los niveles de riesgo de los estudiantes con los inconvenientes previos al ingreso a la unidad de titulación, mitigando los desafíos que enfrentan las instituciones (Quiguanas & Arias, 2024).

El incremento en la matrícula y la diversificación de programas ponen a prueba los estándares de los procesos actuales (Macías et al., 2025). El principal conflicto surge al finalizar la malla curricular: el incumplimiento de requisitos obliga al estudiante a una regularización forzada o, en casos más críticos, ocasiona la deserción estudiantil al no contar con acompañamiento sobre el pro-

ceso (Morales et al., 2025).

Los resultados del modelo de regresión logística demuestran un desempeño consistente con los reportados en el dashboard, lo cual valida el enfoque metodológico (Berens et al., 2018). La equivalencia entre las métricas alcanzadas y los indicadores visuales confirma que el proceso de entrenamiento es reproducible (Namoun & Alshantqi, 2021). Esta convergencia entre el análisis estadístico y la representación gráfica aporta robustez a los hallazgos y confirma la estabilidad del modelo como herramienta de toma de decisiones.

Las métricas obtenidas fueron consistentes con los indicadores visualizados en la herramienta, lo que evidencia que el proceso de entrenamiento y evaluación fue reproducible y confiable (Jimbo-Santana et al., 2023). Esta coherencia sugiere la ausencia de discrepancias significativas entre el análisis estadístico y la representación gráfica; por lo tanto, se aporta robustez a la interpretación de los hallazgos y se confirma la estabilidad del modelo frente a distintos métodos de presentación de resultados (Ngulube & Ncube, 2025).

5. Conclusiones

- El presente estudio examinó la efectividad de los procesos de titulación, demostrando que la optimización y prevención de nudos críticos dependen directamente de un seguimiento académico riguroso. En particular, se determinó que los programas de corta duración requieren un monitoreo per-

manente para asegurar su eficiencia operativa.

- A través de la aplicación del algoritmo de riesgo, se logró segmentar a la población estudiantil en niveles bajo, medio y alto. Esta categorización facilita que el departamento de titulación ejecute acciones prioritarias y personalizadas. Asimismo, la integración de herramientas de visualización interactiva, como Power BI, transformó datos complejos en información estratégica, permitiendo a los directivos una toma de decisiones basada en evidencia.
- En definitiva, es esencial que las instituciones superiores adopten la ciencia de datos y la analítica educativa como ejes transversales para fortalecer sus procesos administrativos y asegurar estándares de calidad internacional.

5.1 Recomendaciones para ser consideradas

Para garantizar la efectividad del dashboard desarrollado, se proponen las siguientes medidas de intervención:

- Riesgo Bajo: delegar el monitoreo a tutores personales mediante revisiones mensuales. El objetivo es actuar de forma preventiva para evitar el escalamiento hacia niveles de riesgo superiores.
- Riesgo Medio: implementar tutorías académicas focalizadas en casos de bajo rendimiento. Si el origen es finan-

ciero o personal, se debe coordinar el acompañamiento con Bienestar Estudiantil y las direcciones académicas con una frecuencia quincenal.

- **Riesgo Alto:** ejecutar intervenciones inmediatas con el apoyo del Vicerrectorado Académico y las facultades. Se recomienda un seguimiento semanal mediante un plan personalizado de casos especiales, el cual debe activarse al menos tres meses antes de finalizar el ciclo de formación académica.

6. Conflicto de intereses

Los autores declaran que no existe conflicto de intereses en relación con el artículo presentado.

7. Declaración de contribución de los autores

Todos autores contribuyeron significativamente en la elaboración del artículo.

8. Costos de financiamiento

La presente investigación fue financiada en su totalidad con fondos propios de los autores.

9. Referencias Bibliográficas

Acosta Guanoquiza, C. O., Mejía Alban, G. M., Ramírez Gutiérrez, C. V., & Reigo-

sa Lara, A. (2024). Herramientas digitales para fortalecer la metodología de enseñanza de los docentes. *Ciencia Digital*, 8(3), 161-178. <https://doi.org/10.33262/cienciadigital.v8i3.3144>

Berens, J., Schneider, K., Görtz, S., Oster, S., & Burghoff, J. (2018). Early detection of students at risk—predicting student dropouts using administrative student data and machine learning methods. *Journal of Educational Data Mining*, 11(3). <https://doi.org/10.2139/ssrn.3275433>

Álvarez Alpízar, O. C. (2025). Jimbo-Santana, P., Lanzarini, L. C., Jimbo-Santana, M., & Morales-Morales, M. (2023). Inteligencia artificial para analizar el rendimiento académico en instituciones de educación superior. Una revisión sistemática de la literatura. *Cátedra*, 6(2), 30–50. <https://doi.org/10.29166/catedra.v6i2.4408>

Machado Bello, X. A., & Castillo Orozco, Y. M. (2017). Gestión de riesgos en las IES. *Estrategia y Gestión Universitaria*, 5(1), 118–129. <https://revistas.unica.cu/index.php/regu/article/view/614>

Macías Galeas, I. P. (2025). Más allá de la tecnología: gestión académica y sistemas de alerta temprana en la retención estudiantil en la educación superior virtual. *ULEAM Bahía Magazine (UBM)*, 6(11), 127–137. <https://doi.org/10.56124/ubm.v6i11.014>

Macías Galeas, I., Bustamante Bermeo, M., González Arias, J., & Illescas Rendón, I.

- (2025). Transformaciones en la educación superior ecuatoriana: reflexiones de los últimos 30 años. *Investigación Tecnología E Innovación*, 17(23), 65-85. <https://doi.org/10.53591/iti.v17i23.2252>
- Mendoza González, C. J. (2024). Inteligencia de negocios para el análisis de los indicadores de titulación y permanencia en una institución de educación superior [Tesis de maestría, Universidad Estatal Península de Santa Elena - UPSE, La Libertad, Ecuador]. <https://repositorio.upse.edu.ec/handle/46000/11209>.
- Morales Suárez, T. P., González Puente, M. F., Toaquiza Catota, D. M., & Pinguil Caguas, N. J. (2025). Influencia de la brecha digital en la deserción estudiantil: un análisis en universidades ecuatorianas. *Ciencia y Educación*, 6(9.2 Edición Especial III), 259-367. <https://doi.org/10.5281/zenodo.17230836>
- Namoun, A., & Alshantqi, A. (2021). Predicting student performance using data mining and learning analytics techniques: a systematic literature review. *Applied Sciences*, 11(1), 237. <https://doi.org/10.3390/app11010237>
- Ngulube, P., & Ncube, M. M. (2025). Leveraging learning analytics to improve the user experience of learning management systems in higher education institutions. *Information*, 16(5), 419. <https://doi.org/10.3390/info16050419>
- Quiguanas Chila, B., & Arias Bocanegra, D. L. (2024). Herramienta de monitoreo y análisis: dashboard interactivo del desempeño académico de los estudiantes de Ciencia Política en la UNAD [Trabajo de especialización, Universidad Nacional Abierta y a Distancia UNAD, Bogotá, Colombia]. <https://repository.unad.edu.co/handle/10596/67207>
- Rabelo, A. M., & Zárate, L. E. (2025). A model for predicting dropout of higher education students. *Data Science and Management*, 8(1), 72-85. <https://doi.org/10.1016/j.dsm.2024.07.001>
- Ramaswami, G., Susnjak, T., Mathrani, A., & Umer, R. (2022). Use of predictive analytics within learning analytics dashboards: a review of case studies. *Technology Knowledge and Learning*, 28(3), 959-980. <https://doi.org/10.1007/s10758-022-09613-x>
- Villalobos-Murillo, J., Garita-González, G., & Alfaro Ramírez, B. J. (2025). Development of competencies: artificial intelligence and machine learning in supervised internships of computer science students. *Uniciencia*, 39(1), 1-19. <https://doi.org/10.15359/ru.39-1.3>
- Zamora Cabrera, E. P., Narváez Zurita, C. I., & Erazo Álvarez, J. C. (2019). Incidencia del control interno en la gestión administrativa de las IES. Caso: Departamento de Pastoral, Universidad Politécnica Salesiana. *Revista Arbitrada Interdisciplinaria Koinonía*, 4(2), 321-348. <https://doi.org/10.35381/r.k.v4i2.477>