REVISTA INVECOM
ISSN en línea: 2739-0063

Modelos estadísticos para la predicción del rendimiento académico en estudiantes de educación superior: una revisión sistemática

Statistical models for predicting academic performance in higher education students: A systematic review

Recibido: 20/08/2026 - **Aceptado:** 05/11/2026

Mario Orlando Suárez Ibujés
https://orcid.org/0000-0002-3962-5433
mosuarez@utn.edu.ec
Universidad Técnica del Norte. Ibarra, Ecuador

Olga Leyva Juárez Osorio
https://orcid.org/0000-0002-6255-7926
olga.jo@oaxaca.tecnm.mx
Instituto Tecnológico de Oaxaca. Oaxaca de Juárez, México

Luis Fabián Brito Mancero
https://orcid.org/0009-0008-2108-1715
luis.brito@ueb.edu.ec
Universidad Estatal de Bolívar. Guaranda, Ecuador

Víctor Daniel Álvarez Fajardo
https://orcid.org/0009-0002-4497-2138
danny.alvez@gmail.com
Investigador Independiente. Guayaquil, Ecuador

Cómo citar este artículo:
Suárez Ibujés, M. O., Juárez Osorio, O. L., Brito Mancero, L. F., & Álvarez Fajardo, V. D. (2026). Modelos estadísticos para la predicción del rendimiento académico en estudiantes de educación superior: una revisión sistemática. *Revista InveCom*, *6*(Núm. Especial 3), 1-10. https://doi.org/10.5281/zenodo.24292467

Resumen

Anticipar las dificultades académicas permite a las instituciones de educación superior orientar el acompañamiento estudiantil desde etapas tempranas de la trayectoria formativa. En este contexto, la presente investigación tuvo como objetivo analizar la evidencia científica disponible sobre los modelos estadísticos empleados para predecir el rendimiento académico en estudiantes universitarios. Para ello, se realizó una revisión sistemática de carácter descriptivo e integrador, cuyo reporte se basó en las directrices de la declaración PRISMA 2020, orientada a facilitar una comunicación clara, completa y reproducible de las revisiones sistemáticas. La síntesis de los 25 artículos incluidos examinó los métodos de estimación, las variables predictoras, los indicadores de rendimiento y los procedimientos de validación. Los estudios analizados emplearon, principalmente, antecedentes de ingreso, calificaciones previas y registros de participación en plataformas educativas para estimar resultados como las notas finales o la probabilidad de reprobación. En consecuencia, la elección del modelo dependió de la forma en que se definió y midió el desempeño académico. Así, la regresión logística binaria se utilizó cuando el resultado era dicotómico, por ejemplo, aprobación o reprobación; por su parte, la regresión logística ordinal resultó pertinente para conservar la jerarquía de los niveles de calificación. No obstante, las diferencias en la definición del resultado

y en los procedimientos de validación limitaron la comparación directa del desempeño predictivo entre las investigaciones. Por ello, se concluyó que la pertinencia de los modelos dependió de la correspondencia entre el indicador seleccionado, la información disponible al momento de la predicción y el contexto universitario en el que fueron evaluados.

Palabras clave: rendimiento académico, modelos estadísticos, análisis predictivo, educación superior.

Abstract

Anticipating academic difficulties allows higher education institutions to provide student support from the early stages of the educational journey. In this context, this research aimed to analyze the available scientific evidence regarding statistical models used to predict academic performance among university students. To this end, a descriptive and integrative systematic review was conducted, with the report following the PRISMA 2020 statement guidelines, which are designed to facilitate clear, complete, and reproducible reporting of systematic reviews. The synthesis of the 25 included articles examined estimation methods, predictor variables, performance indicators, and validation procedures. The studies analyzed primarily utilized entry-level background data, prior grades, and participation records from educational platforms to estimate outcomes such as final grades or the likelihood of course failure. Consequently, the choice of model depended on how academic performance was defined and measured. For instance, binary logistic regression was used when the outcome was dichotomous—such as passing or failing—while ordinal logistic regression was appropriate for preserving the hierarchical nature of grading levels. However, variations in how outcomes were defined and how validation procedures were carried out limited direct comparisons of predictive performance across the studies. Therefore, it was concluded that the suitability of the models depended on the alignment between the chosen indicator, the information available at the time of prediction, and the specific university context in which the models were evaluated.

Keywords: academic performance, statistical models, predictive analysis, higher education.

Introducción

La predicción del rendimiento académico en la educación superior permite anticipar posibles dificultades y orientar el acompañamiento estudiantil. Para ello, las instituciones pueden utilizar información como las calificaciones previas, los antecedentes de ingreso y los registros de participación en plataformas educativas. A partir de estos datos, es posible estimar resultados como la calificación final, el promedio académico o la probabilidad de reprobación.

La evidencia disponible muestra que el rendimiento universitario se relaciona con factores académicos, psicológicos, motivacionales y contextuales. Entre ellos se encuentran la trayectoria escolar previa, las calificaciones parciales, la autoeficacia, la procrastinación, la motivación, la autorregulación y la participación en actividades de aprendizaje. Asimismo, la disponibilidad de registros de plataformas de gestión del aprendizaje ha ampliado las posibilidades de realizar predicciones tempranas durante el curso.

En este ámbito, se han utilizado distintos modelos estadísticos para estimar el desempeño estudiantil. La regresión logística ha sido empleada para resultados categóricos, como la aprobación, la reprobación o la situación académica; la regresión ordinal, para calificaciones expresadas en categorías con un orden definido; y otros métodos, incluidos los bosques aleatorios, las máquinas de vectores de soporte y las redes neuronales, para abordar relaciones más complejas entre las variables. La elección del modelo depende de la naturaleza del resultado, de la información disponible y del propósito de la estimación.

No obstante, los estudios existentes presentan diferencias en la forma de medir el rendimiento, el momento de la predicción, las variables incorporadas y los procedimientos de validación. Estas diferencias dificultan la comparación directa de sus resultados y limitan la comprensión del desempeño real de los modelos en distintos contextos universitarios. Por ello, resulta necesario sintetizar de manera sistemática la evidencia sobre los modelos estadísticos utilizados para predecir el rendimiento académico en educación superior.

Tomando en cuenta lo planteado, el objetivo de la presente investigación fue analizar, mediante una revisión sistemática, la evidencia científica sobre los modelos estadísticos utilizados para predecir el rendimiento académico en estudiantes de educación superior. Para ello, se examinaron los tipos de modelos, las variables predictoras, los indicadores de rendimiento y los procedimientos de validación. A partir de lo anterior, se formularon las siguientes preguntas: ¿Qué modelos estadísticos se utilizaron para predecir el rendimiento académico en estudiantes de educación superior y qué variables se incorporaron en su construcción? ¿Qué desempeño predictivo y qué limitaciones metodológicas presentaron los modelos estadísticos según los procedimientos de validación y las métricas utilizadas en los estudios?

Metodología

Se realizó una revisión sistemática de carácter descriptivo e integrador sobre los modelos estadísticos utilizados para predecir el rendimiento académico en estudiantes de educación superior. La revisión siguió las directrices de la declaración PRISMA 2020 (Page et al., 2021) para documentar de manera transparente la identificación, la selección y la presentación de los estudios.

La búsqueda bibliográfica, sobre los modelos estadísticos para la predicción del rendimiento académico en estudiantes de educación superior, se efectuó entre abril y junio de 2026 en Scopus, Web of Science y SciELO. Estas bases de datos se seleccionaron por su cobertura de investigaciones sobre rendimiento académico, modelización predictiva y análisis de datos en contextos universitarios. Al cierre de la búsqueda, el 25 de junio de 2026, se recuperaron 110 registros antes de eliminar los duplicados, de los cuales 40 procedieron de Scopus, 30 de Web of Science y 40 de SciELO.

Tabla 1

Período de búsqueda y registros identificados por base de datos

Base de datos	Año de búsqueda	Meses de búsqueda	Fecha de cierre	Registros identificados
Scopus	2026	Abril, mayo y junio	25 de junio de 2026	40
Web of Science	2026	Abril, mayo y junio	25 de junio de 2026	30
SciELO	2026	Abril, mayo y junio	25 de junio de 2026	40
Total				**110**

Fuente. Elaboración propia

La estrategia de búsqueda se construyó mediante los operadores booleanos *AND* y *OR* y la combinación de términos en español e inglés vinculados con la predicción del rendimiento académico en educación superior. La ecuación general empleada fue (“*statistical model**” *OR* “*regression model**” *OR* “*linear regression*” *OR* “*logistic regression*” *OR* “*ordinal regression*” *OR* “*multilevel model**” *OR* “modelos estadísticos” *OR* “modelos de regresión” *OR* “regresión lineal” *OR* “regresión logística” *OR* “regresión ordinal” *OR* “modelos multinivel”) *AND* (*predict** *OR* predic* *OR pronostic** *OR* pronóstic*) *AND* (“*academic performance*” *OR* “*academic achievement*” *OR* “*grade point average*” *OR* “rendimiento académico” *OR* “desempeño académico” *OR* “logro académico” *OR* “promedio académico”) *AND* (“*higher education*” *OR* “*tertiary education*” *OR* “*postsecondary education*” *OR* “educación superior” *OR* “educación universitaria” *OR* universit*).

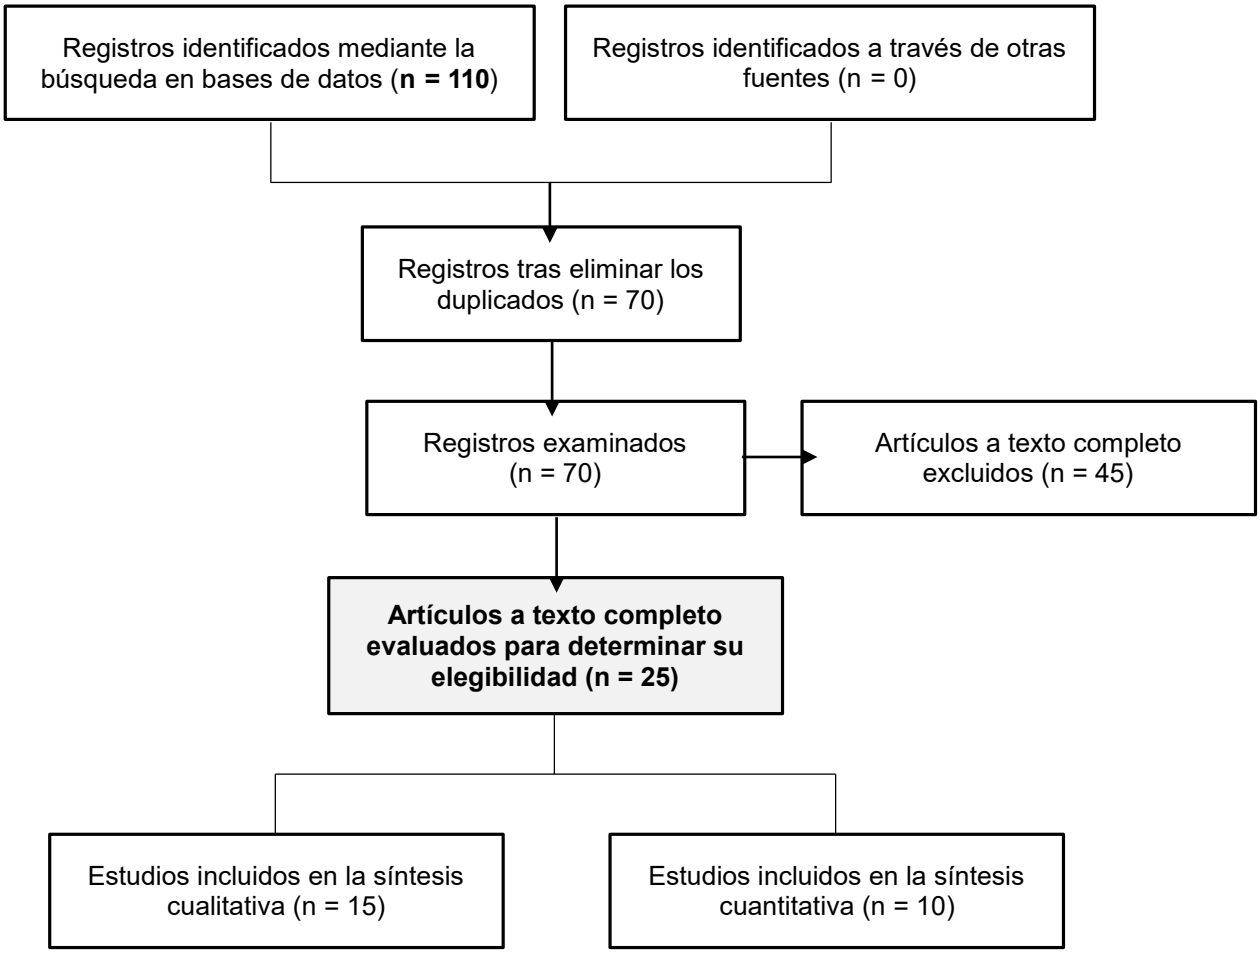
Se incluyeron artículos científicos publicados entre enero de 2016 y junio de 2026, escritos en español o inglés, sometidos a revisión por pares, disponibles en texto completo y recuperados de al menos una de las tres bases de datos seleccionadas: Scopus, Web of Science y SciELO. Se admitieron estudios empíricos cuantitativos y mixtos que desarrollaron, aplicaron, validaron o compararon modelos estadísticos para predecir el rendimiento académico en estudiantes de educación superior.

Se excluyeron los registros duplicados, las actas de congresos, las editoriales, las cartas al editor, los capítulos de libros, las tesis y los documentos que no fueron sometidos a revisión por pares. También se descartaron las publicaciones sin acceso al texto completo, las que quedaron fuera del período establecido o se publicaron en idiomas distintos del español y el inglés, y las investigaciones realizadas exclusivamente en niveles educativos distintos de la educación superior.

El proceso de selección comprendió la depuración de los registros y la evaluación de los artículos a texto completo. De los 110 registros identificados inicialmente, se eliminaron 40 duplicados y se evaluaron los 70 restantes conforme a los criterios de elegibilidad. Durante esta evaluación, se examinó la pertinencia de cada estudio para la predicción del rendimiento académico en estudiantes de educación superior, así como la coherencia entre el diseño de investigación, el modelo estadístico empleado y el indicador de rendimiento seleccionado.

Tras la evaluación de los 70 artículos a texto completo, se excluyeron 45 por incumplir los criterios de elegibilidad, corresponder a otros niveles educativos o no evaluar la capacidad de un modelo estadístico para predecir el rendimiento académico. El corpus final quedó conformado por 25 artículos científicos centrados en estudiantes de educación superior.

Figura 1
Método Prisma



Fuente. Elaboración propia

Resultados

Los resultados se derivaron del análisis de los 25 artículos científicos incluidos en la revisión sistemática sobre modelos estadísticos para predecir el rendimiento académico en estudiantes de educación superior. La síntesis permitió identificar los modelos empleados, las variables predictoras incorporadas y los indicadores utilizados para medir el rendimiento. También se examinaron los procedimientos de validación, las métricas de desempeño predictivo y las limitaciones metodológicas reportadas en los distintos contextos universitarios. Para facilitar la comparación entre los estudios, la Tabla 2 presenta una matriz organizada en cuatro campos: autor y año, diseño y contexto, modelo estadístico analizado y hallazgo principal.

Tabla 2
Matriz de síntesis de los estudios incluidos

Autor/año	Diseño y contexto	Estrategia analizada	Hallazgo principal
Abdel-Salam et al. (2023)	Estudio cuantitativo retrospectivo con registros de asignaturas consecutivas de la Universidad de Qatar.	Regresión logística ordinal para estimar las calificaciones de asignaturas posteriores a partir del desempeño previo y las características estudiantiles.	Las calificaciones en asignaturas previas aportaron información sobre la probabilidad de alcanzar distintos niveles de desempeño en cursos posteriores.

Arévalo-Cordovilla y Peña (2025)	Estudio predictivo con 2.225 estudiantes de ingeniería de una universidad pública ecuatoriana.	Comparación de modelos individuales y de ensamble con datos académicos y registros de interacción virtual. Se aplicó SHAP para interpretar las predicciones.	LightGBM alcanzó un AUC de 0,953 entre los modelos individuales. El primer examen y las primeras calificaciones parciales fueron los predictores más influyentes.
Cabı & Türkoğlu (2025)	Estudio cuasiexperimental con 127 futuros docentes en una asignatura universitaria de tecnologías de la información.	Retroalimentación basada en analítica del aprendizaje en un aula invertida.	No se observaron diferencias significativas en rendimiento ni autorregulación. Los participantes valoraron la retroalimentación para monitorear su aprendizaje.
Chang & Tsai (2022)	Estudio cuantitativo con 404 universitarios de Shanghái que cursaron inglés en línea.	Ecuaciones estructurales para examinar las relaciones entre inteligencia emocional, motivación, autoeficacia y logro académico.	La autoeficacia se relacionó positivamente con el logro académico y medió estadísticamente la relación entre motivación y desempeño.
Chen (2024)	Estudio cuasiexperimental en una asignatura universitaria de inglés impartida en modalidad híbrida.	Retroalimentación basada en analítica del aprendizaje y comparación de grupos mediante emparejamiento por puntaje de propensión.	El grupo que recibió retroalimentación completó una mayor proporción de actividades en línea y mostró mayor regularidad en el estudio.
Çırak et al. (2024)	Estudio predictivo retrospectivo con registros de 11.698 estudiantes de primer año universitario.	Comparación de Naïve Bayes, árboles de decisión y bosques aleatorios para clasificar el desempeño al final del primer año.	El bosque aleatorio alcanzó una exactitud del 90,2 %. La incorporación del promedio del primer semestre mejoró el desempeño predictivo.
Gamboa & Salinas (2022)	Estudio cuantitativo predictivo con registros de estudiantes de pregrado en Perú.	Selección de variables mediante Boruta y comparación de 12 clasificadores para estimar la situación académica después de seis semestres.	La regresión logística figuró entre los modelos de mejor desempeño. La calificación en Matemáticas fue uno de los predictores más relevantes.
Gámez-Granados et al. (2023)	Estudio comparativo con datos de siete cursos a distancia de la Open University.	Clasificación ordinal mediante reglas difusas para distinguir retiro, reprobación, aprobación y distinción.	El método propuesto obtuvo mejores resultados que los comparadores en el conjunto analizado y generó reglas más sencillas de interpretar.
Hardt et al. (2023)	Ensayo aleatorizado en asignaturas universitarias de microeconomía y macroeconomía en Alemania.	Tutorías remotas entre pares en grupos pequeños.	Las mejoras académicas fueron mayores entre los estudiantes con menor desempeño previo.
Herrmann & Weigert (2024)	Estudio predictivo con registros de programas de grado en economía y ciencias sociales de una universidad alemana.	Comparación de la exactitud de las predicciones de éxito académico entre el conjunto estudiantil y el subgrupo de estudiantes no tradicionales.	La exactitud fue significativamente menor en el subgrupo de estudiantes no tradicionales, lo que mostró diferencias de desempeño que la métrica global no reflejaba.
Ji et al. (2024)	Estudio cuantitativo predictivo con estudiantes universitarios de áreas científicas y de ingeniería.	Red neuronal que combinó habilidades visoespaciales y características individuales para clasificar el rendimiento en cinco niveles.	Las habilidades visoespaciales aportaron información a la clasificación de las calificaciones en el contexto analizado.
Lin et al. (2023)	Estudio cuantitativo con 374 estudiantes de primer año de una universidad italiana.	Análisis de las relaciones entre autoeficacia, estrategias de regulación y promedio académico autoinformado.	Los estudiantes con mayor autoeficacia y uso de estrategias de autorregulación presentaron mejor desempeño académico.

Liu et al. (2022)	Estudio predictivo con datos administrativos y de una plataforma de aprendizaje de una universidad de Shenyang, China.	Red neuronal de impulsos comparada con regresión logística, máquinas de vectores de soporte y otros clasificadores.	La red propuesta superó a los modelos de comparación en el conjunto de datos utilizado.
Navarro et al. (2023)	Estudio cuantitativo con 301 universitarios de Lima durante la educación remota.	Ecuaciones estructurales para analizar autoeficacia, autorregulación, aceptación tecnológica, rendimiento y aprendizaje percibido.	La autoeficacia y las estrategias metacognitivas se relacionaron con la aceptación tecnológica, vinculada a su vez con el desempeño y el aprendizaje percibido en el modelo estimado.
Pérez et al. (2026)	Estudio observacional con cohortes de 2022 y 2023 de dos asignaturas de matemáticas en universidades chilenas.	Regresión logística univariada basada en la primera calificación parcial para anticipar la reprobación.	El AUC osciló entre 0,85 y 0,93 en cohortes posteriores. Los valores predictivos variaron cuando cambió la proporción de estudiantes aprobados.
Pérez-González et al. (2022)	Estudio longitudinal con estudiantes de grado en España y mediciones del promedio académico a lo largo de tres años.	Regresión jerárquica y ecuaciones estructurales para examinar el aporte de factores cognitivos y no cognitivos.	El compromiso académico y la regulación del comportamiento y del contexto aportaron información adicional a la proporcionada por el rendimiento previo y otros predictores cognitivos.
Purkayastha & Huber (2024)	Estudio exploratorio con 990 estudiantes de una asignatura de administración de primer año en una universidad australiana.	Regresión logística ordinal con características estudiantiles, antecedentes de ingreso y variables de tutoría.	La relación de algunos factores con la probabilidad de alcanzar distintas categorías de calificación varió entre estudiantes nacionales e internacionales.
Rodríguez-Ortiz et al. (2026)	Estudio predictivo con datos de cursos de una universidad pública latinoamericana.	Modelización simultánea de indicadores formativos, validación temporal y estimación de incertidumbre mediante remuestreo.	El estudio presentó estimaciones de desempeño e intervalos de confianza bajo distintos protocolos de validación. Se excluyeron las calificaciones cuya disponibilidad al momento de predecir no pudo verificarse.
Santos & Henriques (2023)	Estudio predictivo con registros de actividad de distintas asignaturas universitarias en una plataforma de gestión del aprendizaje.	Comparación de modelos basados en registros de interacción disponibles en diferentes momentos del curso.	Con los datos de todo el curso, el bosque aleatorio alcanzó un AUC de 0,756 para identificar estudiantes en riesgo. El resultado ilustró la relación entre la cantidad de datos disponibles y el momento de emitir la alerta.
Subirats et al. (2023)	Estudio cuantitativo con 396 estudiantes de educación superior y datos anteriores, simultáneos y posteriores al confinamiento por COVID-19.	Agrupamiento de perfiles de trabajo autónomo y predicción de calificaciones con distintos períodos de observación.	El trabajo continuo se asoció con una mayor proporción de éxito. Las predicciones empeoraron al retirar los datos del mes anterior al examen final.
Wang & Luo (2024)	Estudio predictivo con registros de 87 estudiantes de una asignatura universitaria de japonés en Wuhan, China.	XGBoost para estimar calificaciones y SHAP para interpretar la contribución de las variables.	El modelo obtuvo un error absoluto medio cercano a 6 puntos y un coeficiente de determinación próximo a 0,82 en el conjunto analizado.

Yağcı (2022)	Estudio predictivo con registros de 1.854 estudiantes de una asignatura de lengua turca en una universidad estatal.	Comparación de regresión logística, bosques aleatorios y otros clasificadores mediante validación cruzada de diez particiones.	Las calificaciones del examen parcial permitieron estimar el desempeño en el examen final con varias semanas de anticipación.
Yermek et al. (2026)	Estudio retrospectivo con registros por semestre de 20.868 estudiantes de una institución universitaria de Asia Central.	Comparación de regresión ridge, regresión logística, ensambles y redes neuronales con separación temporal de entrenamiento, validación y prueba.	La regresión ridge alcanzó un R^2 de 0,552 y la regresión logística un AUC ROC de 0,904. Los modelos más complejos no superaron de forma clara a los modelos lineales regularizados.
Zumárraga-Espinosa & Cevallos-Pozo (2022)	Estudio cuantitativo con 788 estudiantes de universidades públicas y privadas de Quito, Ecuador.	Análisis de rutas para examinar la relación entre autoeficacia, procrastinación y rendimiento académico.	La procrastinación medió estadísticamente la relación entre autoeficacia y rendimiento. Las relaciones variaron según la etapa formativa y el tipo de institución.

Fuente. Elaboración propia

Los estudios sintetizados en la Tabla 2 emplearon modelos estadísticos y algoritmos de aprendizaje automático para predecir el rendimiento académico en educación superior. Los enfoques se diferenciaron según el indicador de desempeño. Por ejemplo, Abdel-Salam et al. (2023) aplicaron la regresión logística ordinal para estimar la probabilidad de alcanzar distintos niveles de calificación en asignaturas consecutivas. Por su parte, Gamboa Unsihuay y Salinas Flores (2022) situaron la regresión logística binaria entre los modelos con mejor desempeño para predecir la situación académica después de seis semestres.

Discusión

La revisión mostró que la elección del modelo estadístico dependió, principalmente, de cómo se definió y midió el rendimiento académico. Cuando el resultado se expresó como una situación categórica, la regresión logística binaria permitió estimar la probabilidad de ocurrencia de eventos como la aprobación, la reprobación o la permanencia académica. Gamboa y Salinas (2022), por ejemplo, la ubicaron entre los métodos con mejor desempeño para predecir la situación académica de estudiantes de pregrado después de seis semestres. Este hallazgo sugiere que la regresión logística continúa siendo una alternativa útil cuando se requiere interpretar probabilidades y comunicar resultados comprensibles para las instituciones.

En cambio, cuando el rendimiento se midió mediante categorías ordenadas, la regresión logística ordinal resultó más pertinente. Abdel-Salam et al. (2023) la emplearon para analizar las calificaciones obtenidas en secuencias de asignaturas de la Universidad de Qatar, mientras que Purkayastha y Huber (2024) la utilizaron para examinar el desempeño en una asignatura universitaria de administración. En ambos casos, el modelo permitió conservar la jerarquía de las categorías de calificación y analizar cómo las características del estudiante y de la enseñanza se relacionaron con distintos niveles de desempeño. Por tanto, la pertinencia del modelo no dependió únicamente de su capacidad predictiva, sino también de su correspondencia con la forma en que la institución define y registra el rendimiento.

Las calificaciones previas y las primeras evaluaciones parciales destacaron como predictores relevantes. Arévalo-Cordovilla y Peña (2025) identificaron el primer examen y las primeras calificaciones parciales entre los predictores más influyentes, mientras que Çırak et al. (2024) observaron que la incorporación del promedio del primer semestre mejoró considerablemente la predicción del resultado anual. Estos resultados coinciden con la idea de que la trayectoria académica reciente aporta información valiosa para anticipar el desempeño posterior. Asimismo, sugieren que las alertas tempranas pueden beneficiarse de la actualización periódica de los modelos conforme se disponen de nuevas calificaciones.

La utilidad de las predicciones estuvo condicionada, además, por la antelación con la que pudieron emitirse. Santos y Henriques (2023) analizaron la predicción temprana del desempeño mediante registros de plataformas de gestión del aprendizaje y reportaron un área bajo la curva ROC de 0,756. No obstante, este valor correspondió a un modelo que utilizó registros de todo el curso, por lo que describe la capacidad de discriminación del modelo dentro de una ventana temporal específica y no necesariamente su desempeño al inicio del período académico. Esta distinción es relevante para la práctica institucional, pues una predicción tardía puede ser precisa, pero ofrecer menos oportunidades para intervenir.

La comparación entre estudios también evidenció diferencias en las poblaciones evaluadas y en el alcance de la validación. Herrmann y Weigert (2024) observaron menor exactitud en la predicción del éxito académico entre estudiantes no tradicionales, lo que advierte que un desempeño agregado favorable puede ocultar diferencias entre grupos. De manera complementaria, Pérez et al. (2026) encontraron que la capacidad de discriminación de modelos logísticos de alerta temprana pudo mantenerse en cohortes posteriores, aun cuando variaron otros indicadores operativos. Estos hallazgos subrayan la necesidad de evaluar los modelos no solo mediante métricas globales, sino también según su estabilidad y desempeño en subgrupos específicos.

La interpretabilidad y la incertidumbre de las estimaciones constituyeron aspectos centrales para su aplicación educativa. Gámez-Granados et al. (2023) desarrollaron un método de clasificación ordinal basado en reglas difusas, cuya estructura facilita examinar cómo el modelo produce sus estimaciones. Rodríguez-Ortiz et al. (2026), por su parte, emplearon validación temporal e intervalos de confianza obtenidos por remuestreo para delimitar la incertidumbre de los resultados. Ambos enfoques contribuyen a que los responsables educativos comprendan mejor el alcance de las predicciones antes de utilizarlas para tomar decisiones.

Finalmente, la revisión mostró que la utilidad de las predicciones dependió de su articulación con acciones de apoyo cuya eficacia se evaluó de manera independiente. Hardt et al. (2023) documentaron mejoras académicas con la tutoría remota entre pares, especialmente entre estudiantes con menor desempeño previo. Sin embargo, Cabı y Türkoğlu (2025) no encontraron diferencias significativas en rendimiento ni autorregulación tras implementar un sistema de retroalimentación basado en analítica del aprendizaje, aunque los participantes valoraron su utilidad para monitorear el estudio. Estos resultados indican que la predicción, por sí sola, no garantiza mejoras en el desempeño; su efecto depende del diseño de la intervención, del contexto y de la población atendida.

En conjunto, los hallazgos de la revisión permiten concluir que los modelos estadísticos pueden contribuir a la identificación temprana de estudiantes en riesgo, siempre que se seleccionen de acuerdo con el indicador de rendimiento, la información disponible y el propósito del acompañamiento. Para futuras investigaciones, resulta pertinente fortalecer la validación externa, evaluar el desempeño diferencial entre grupos estudiantiles y examinar de manera más sistemática el efecto de las intervenciones derivadas de las alertas predictivas.

Conclusiones

La selección del modelo predictivo dependió de la forma en que se definió y midió el rendimiento académico. La regresión logística binaria resultó pertinente para estimar la probabilidad de aprobación o reprobación, mientras que la regresión logística ordinal permitió conservar la jerarquía de los niveles de calificación. No obstante, las diferencias entre los indicadores de rendimiento, las variables incorporadas y los procedimientos de validación limitaron la comparación directa del desempeño de los modelos entre los estudios revisados.

Las calificaciones previas y los resultados de las primeras evaluaciones parciales destacaron como variables para anticipar el desempeño universitario. En algunos estudios, el compromiso académico y la autorregulación aportaron información complementaria a estos predictores. Sin embargo, su contribución dependió de las características del contexto formativo y del momento en que los datos estuvieron disponibles para realizar la estimación.

La utilidad de los modelos como sistemas de alerta temprana dependió de la antelación con la que se emitieron las predicciones y de su desempeño en los distintos grupos estudiantiles. Los resultados obtenidos con datos de todo el curso ofrecieron evidencia limitada sobre la capacidad de anticipar dificultades en las etapas iniciales. Asimismo, las diferencias de exactitud entre grupos evidenciaron la necesidad de examinar el desempeño por subgrupos y de validar los modelos en cohortes posteriores antes de extender su aplicación a otros contextos universitarios.

Las predicciones de riesgo académico constituyeron un criterio útil para priorizar el contacto con estudiantes que pudieran requerir apoyo. No obstante, su aplicación institucional exigió evaluar por separado la capacidad del modelo para identificar casos de riesgo y los efectos de las tutorías o de la retroalimentación posterior. Esta distinción permitió valorar tanto la calidad de las alertas como los resultados educativos del acompañamiento implementado.

En conjunto, los hallazgos de la revisión indican que los modelos estadísticos pueden apoyar la identificación temprana de estudiantes en riesgo, siempre que su selección responda al indicador de rendimiento, a la información disponible y al propósito del acompañamiento. Para futuras investigaciones, resulta pertinente fortalecer la validación externa, examinar el desempeño diferencial entre grupos y evaluar de manera más sistemática el efecto de las intervenciones derivadas de las alertas predictivas.

Referencias

Abdel-Salam, A.-S. G., Ismail, R., Rhouma, M., Elatawneh, A., Al Hazaa, K., & Romanowski, M. H. (2023). Using grades in core curriculum chain courses as predictors of academic performance in subsequent courses: A study at Qatar University. *SAGE Open, 13*(4). https://doi.org/10.1177/21582440231206631

Arévalo-Cordovilla, F. E., & Peña, M. (2025). Evaluating ensemble models for fair and interpretable prediction in higher education using multimodal data. *Scientific Reports, 15*, 29420. https://doi.org/10.1038/s41598-025-15388-9

Cabı, E., & Türkoğlu, H. (2025). The impact of a learning analytics based feedback system on students' academic achievement and self-regulated learning in a flipped classroom. *The International Review of Research in Open and Distributed Learning, 26*(1), 175–196. https://doi.org/10.19173/irrodl.v26i1.7924

Chang, Y.-C., & Tsai, Y.-T. (2022). The effect of university students' emotional intelligence, learning motivation and self-efficacy on their academic achievement—Online English courses. *Frontiers in Psychology, 13*, 818929. https://doi.org/10.3389/fpsyg.2022.818929

Chen, J. (2024). Effects of learning analytics-based feedback on students' self-regulated learning and academic achievement in a blended EFL course. *System, 124*, 103388. https://doi.org/10.1016/j.system.2024.103388

Çırak, C. R., Akıllı, H., & Ekinci, Y. (2024). Development of an early warning system for higher education institutions by predicting first-year student academic performance. *Higher Education Quarterly, 78*(4), e12539. https://doi.org/10.1111/hequ.12539

Gamboa Unsihuay, J. E., & Salinas Flores, J. W. (2022). Predicción de la situación académica en alumnos de pregrado usando algoritmos de machine learning. *Perfiles, 1*(27), 4–10. https://dspace.espoch.edu.ec/items/a208a5c0-cd91-4129-8b17-3778312feba2

Gámez-Granados, J. C., Esteban, A., Rodriguez-Lozano, F. J., & Zafra, A. (2023). An algorithm based on fuzzy ordinal classification to predict students' academic performance. *Applied Intelligence, 53*, 27537–27559. https://doi.org/10.1007/s10489-023-04810-2

Hardt, D., Nagler, M., & Rincke, J. (2023). Tutoring in (online) higher education: Experimental evidence. *Economics of Education Review, 92*, 102350. https://doi.org/10.1016/j.econedurev.2022.102350

Hasa, E., & Grilli, L. (2020). Analysis of the prediction ability of a university self-evaluation test: Statistical learning methods for predicting student performance. *Statistica Applicata – Italian Journal of Applied Statistics, 31*(2), 201–213. https://www.sa-ijas.org/ojs/index.php/sa-ijas/article/view/31-11

Herrmann, L., & Weigert, J. (2024). AI-based prediction of academic success: Support for many, disadvantage for some? *Computers and Education: Artificial Intelligence, 7*, 100303. https://doi.org/10.1016/j.caeai.2024.100303

Ji, M., Le, J., Chen, B., & Li, Z. (2024). A predictive model for classifying college students' academic performance based on visual-spatial skills. *Frontiers in Psychology, 15*, 1434015. https://doi.org/10.3389/fpsyg.2024.1434015

Lin, S., Mastrokoukou, S., Longobardi, C., Bozzato, P., Gastaldi, F. G. M., & Berchiatti, M. (2023). Students' transition into higher education: The role of self-efficacy, regulation strategies, and academic achievements. *Higher Education Quarterly, 77*(1), 121–137. https://doi.org/10.1111/hequ.12374

Liu, C., Wang, H., & Yuan, Z. (2022). A method for predicting the academic performances of college students based on education system data. *Mathematics, 10*(20), 3737. https://doi.org/10.3390/math10203737

Navarro, R., Vega, V., Bayona, H., Bernal, V., & Garcia, A. (2023). Relationship between technology acceptance model, self-regulation strategies, and academic self-efficacy with academic performance and perceived learning among college students during remote education. *Frontiers in Psychology, 14*, 1227956. https://doi.org/10.3389/fpsyg.2023.1227956

Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., … Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ, 372*, n71. https://doi.org/10.1136/bmj.n71

Pérez, C., Nikulin, C., & Madariaga, B. (2026). Low-overhead learning analytics: A parsimonious early warning system for at-risk students in Chilean STEM courses. *Education Sciences, 16*(7), 1110. https://doi.org/10.3390/educsci16071110

Pérez-González, J.-C., Filella, G., Soldevila, A., Faiad, Y., & Sanchez-Ruiz, M.-J. (2022). Integrating self-regulated learning and individual differences in the prediction of university academic achievement across a three-year-long degree. *Metacognition and Learning, 17*(3), 1141–1165. https://doi.org/10.1007/s11409-022-09315-w

Purkayastha, A., & Huber, E. (2024). What factors contribute to higher grades in a first-year undergraduate management unit: An exploratory study at an Australian university. *Higher Education Research & Development, 43*(3), 735–752. https://doi.org/10.1080/07294360.2023.2258818

Rodríguez-Ortiz, M. Á., Santana-Mancilla, P. C., & Anido-Rifón, L. E. (2026). Beyond grades: Temporal validation of a multi-output model for formative academic indicators in a Latin American public university. *Applied Sciences, 16*(19), 9865. https://doi.org/10.3390/app16199865

Santos, R. M., & Henriques, R. (2023). Accurate, timely, and portable: Course-agnostic early prediction of student performance from LMS logs. *Computers and Education: Artificial Intelligence, 5*, 100175. https://doi.org/10.1016/j.caeai.2023.100175

Subirats, L., Palacios Corral, A., Pérez-Ruiz, S., Fort, S., & Sacha, G.-M. (2023). Temporal analysis of academic performance in higher education before, during and after COVID-19 confinement using artificial intelligence. *PLOS One, 18*(2), e0282306. https://doi.org/10.1371/journal.pone.0282306

Wang, S., & Luo, B. (2024). Academic achievement prediction in higher education through interpretable modeling. *PLOS One, 19*(9), e0309838. https://doi.org/10.1371/journal.pone.0309838

Yağcı, M. (2022). Educational data mining: Prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments, 9*, 11. https://doi.org/10.1186/s40561-022-00192-z

Yermek, T. B., Yergesh, B., Yelemessov, A., Yelemessova, M., Bekmanova, G., Omarbekova, A., Nazyrova, A., & Lamasheva, Z. (2026). A multi-model approach to academic performance prediction using student–semester educational data. *Artificial Intelligence and Applications*. https://doi.org/10.47852/bonviewAIA620210406

Zumárraga-Espinosa, M., & Cevallos-Pozo, G. (2022). Autoeficacia, procrastinación y rendimiento académico en estudiantes universitarios de Ecuador. *Alteridad, Revista de Educación, 17*(2), 277–290. https://doi.org/10.17163/alt.v17n2.2022.08

CONTRIBUCIÓN DE LA AUTORÍA:

1. Conceptualización: Mario Orlando Suárez Ibujés.
2. Curación de datos: Mario Orlando Suárez Ibujés.
3. Análisis formal – técnicas estadísticas, análisis de datos: Mario Orlando Suárez Ibujés.
4. Adquisición de fondos: N.A
5. Investigación – proceso de investigación: Mario Orlando Suárez Ibujés.
6. Metodología – diseño y desarrollo: Olga Leyva Juárez Osorio.
7. Administración del proyecto – gestión y coordinación: Olga Leyva Juárez Osorio.
8. Recursos – suministro de materiales de estudio: Olga Leyva Juárez Osorio.
9. Software – programación, diseño e implementación: Luis Fabián Brito Mancero.
10. Supervisión y liderazgo en la planificación: Luis Fabián Brito Mancero.
11. Validación – verificación: Luis Fabián Brito Mancero.
12. Visualización – presentación de datos: Víctor Daniel Álvarez Fajardo.
13. Redacción – documento original: Víctor Daniel Álvarez Fajardo.
14. Redacción – revisión y edición: Víctor Daniel Álvarez Fajardo.