

# Modelado estadístico de la deserción escolar en estudiantes de ingeniería basado en minería de procesos

## Statistical modeling of school dropout in engineering students based on process mining

Héctor Fernando Gómez García<sup>1</sup>: Universidad del Caribe, México.

[fgomez@ucaribe.edu.mx](mailto:fgomez@ucaribe.edu.mx)

Jessica Mendiola Fuentes: Universidad del Caribe, México.

[jmendiola@ucaribe.edu.mx](mailto:jmendiola@ucaribe.edu.mx)

Víctor Manuel Romero Medina: Universidad del Caribe, México.

[vromero@ucaribe.edu.mx](mailto:vromero@ucaribe.edu.mx)

Fecha de Recepción: 13/06/2024

Fecha de Aceptación: 25/10/2024

Fecha de Publicación: 24/12/2024

### Cómo citar el artículo

Gómez García, H. F., Mendiola Fuentes, J., Romero Medina, V. M. (2025). Modelado estadístico de la deserción escolar en estudiantes de ingeniería basado en minería de procesos. [Statistical modeling of school dropout in engineering students based on process mining]. *European Public & Social Innovation Review*, 10, 01-22. <https://doi.org/10.31637/epsir-2025-974>

### Resumen

**Introducción:** El presente trabajo describe el desarrollo de un modelo estadístico para estimar la probabilidad de deserción en estudiantes de programas de ingeniería de la Universidad del Caribe, mediante la aplicación de técnicas de minería de procesos. **Metodología:** Se definió un proceso de formación matemática que se utilizó como referencia para evaluar la idoneidad de las trayectorias académicas de estudiantes de cuatro cohortes. Las evaluaciones de la conformidad con el proceso de formación matemática, durante los primeros tres semestres de cada estudiante, se utilizaron como predictores de la probabilidad de deserción en un modelo estadístico. **Resultados:** El modelo se ajustó utilizando los datos de las primeras tres cohortes y se validó aplicándolo a la cohorte más reciente, comparando los pronósticos con los resultados observados de deserción. **Discusión:** El estudio demuestra

<sup>1</sup> Autor Correspondiente: Héctor Fernando Gómez García. Universidad del Caribe (México).

la efectividad de las técnicas de minería de procesos para generar información académica relevante, útil en la toma de decisiones que mitiguen el riesgo de deserción escolar a partir del análisis de las trayectorias académicas de los estudiantes. **Conclusiones:** Se sugieren direcciones futuras, como la implementación de sistemas de monitoreo y la inclusión de otros procesos críticos en el análisis, para aumentar significativamente la efectividad de las intervenciones educativas.

**Palabras clave:** Deserción escolar; formación matemática; minería de procesos; análisis de conformidad; redes de Petri; analítica curricular; modelado estadístico; modelos predictivos.

### Abstract

**Introduction:** The present work describes the development of a statistical model to estimate the probability of dropout among engineering students at the University of the Caribbean through the application of process mining techniques. **Methodology:** A mathematical training process was defined as a reference to evaluate the suitability of the academic trajectories of students from four cohorts. The evaluations of conformance with the mathematical training process, during the first three semesters of each student, were used as predictors of dropout probability in a statistical model. **Results:** The statistical model was adjusted using data from the first three cohorts and validated by applying it to the most recent cohort, comparing the predictions with the observed dropout results. **Discussions:** The study demonstrates the effectiveness of process mining techniques in generating relevant academic information, useful for decision-making to mitigate the risk of school dropout based on the analysis of students' academic trajectories. **Conclusions:** Future directions are suggested, such as the implementation of monitoring systems and the inclusion of other critical processes in the analysis to significantly increase the effectiveness of educational interventions.

**Keywords:** School dropout; mathematical training; process mining; conformance checking; Petri nets; curriculum analytics; statistical modeling; predictive models.

## 1. Introducción

La deserción escolar, particularmente definida como la no reinscripción en el siguiente período semestral tras la culminación de uno anterior (Tinto, 1989), es un fenómeno complejo influenciado por factores intrínsecos del individuo, variables familiares, económicas, contextuales y educativas (De Witte y Rogge, 2013) (Paramo y Correa, 1999).

El índice de deserción en instituciones de educación superior de América Latina muestra una notable variabilidad, oscilando entre el 40% y el 70% (Amaya *et al.*, 2020). En México, según datos de la Organización para la Cooperación y el Desarrollo Económicos (OCDE), apenas el 38% de los jóvenes que ingresan a la universidad logran graduarse. Por otro lado, la Asociación Nacional de Universidades e Instituciones de Educación Superior (ANUIES) reporta un promedio nacional de eficiencia terminal del 39%, considerando la titulación (López *et al.*, 2008). A nivel estatal, de acuerdo con datos del Instituto Nacional de Estadística, Geografía e Informática (s.f.), Nuevo León, Querétaro y Jalisco presentaron las menores tasas de deserción entre 2001 y 2021, mientras que las mayores tasas se registraron en Baja California Sur y Quintana Roo, entidades con una gran vocación turística.

Uno de los principales factores que incide en la deserción estudiantil en educación superior es el bajo rendimiento académico, particularmente evidenciado en altos índices de reprobación en asignaturas del área de matemáticas (Pérez, 2010). Un estudio realizado en el Centro Universitario de Ciencias Exactas e Ingenierías (CUCEI) muestra que ciertos

programas de ingeniería presentan tasas de reprobación significativas en disciplinas matemáticas (Valdivia *et al.*, 2019). Además, investigaciones sobre índices de reprobación y deserción en ingeniería civil indican que asignaturas como probabilidad y estadística, cálculo diferencial e integral, y ecuaciones diferenciales son particularmente críticas en este contexto (Aguilar *et al.*, 2020). Otro estudio señala que programas en áreas de ingeniería y ciencias exactas y naturales destacan por sus altos índices de rezago estudiantil (Murillo y Luna, 2020), mismo que se atribuye, en parte, a las dificultades en la comprensión y aplicación de conceptos matemáticos (Ocampo *et al.*, 2010).

En la última década, han emergido diversas técnicas de análisis de datos destinadas a respaldar la toma de decisiones informadas, generando grandes expectativas en las instituciones de educación superior respecto a su papel crucial en el apoyo a procesos institucionales. El análisis de datos académicos promete mejorar significativamente la enseñanza, los resultados del aprendizaje y reducir la deserción estudiantil (Banihashem *et al.*, 2018), así como optimizar los planes de estudio (Gottipati y Shankararaman, 2017). En un estudio reciente (Salazar *et al.*, 2021), se introdujo un algoritmo basado en minería de procesos para detectar la deserción escolar, utilizando la metáfora de una mochila que representa las asignaturas en rezago de los estudiantes. Este algoritmo clasifica y analiza las trayectorias curriculares de estudiantes con comportamientos y contextos similares, mejorando la comprensión sobre cómo los estudiantes manejan los cursos reprobados en el programa de estudio y qué secuencias de cursos están asociadas con una mayor tasa de deserción del programa. En (Loder, 2024) se propone, mediante el uso de la minería de procesos, una mejora en la visualización de las trayectorias de los estudiantes según sea su condición de abandono o graduado, brindando el beneficio de comparar y monitorear el desempeño de los estudiantes en tiempo real.

### ***1.1. Desafíos y estrategias para mejorar la eficiencia terminal en programas de ingeniería: El caso de la Universidad del Caribe***

Según las estadísticas de la Universidad del Caribe, el porcentaje de egreso entre los estudiantes de programas de ingeniería es del 42,32%, en contraste con el 61,22% para los estudiantes de otros programas educativos. En la Universidad, las tasas de reprobación varían significativamente: el 72,41% de los estudiantes en todos los programas han reprobado alguna asignatura, mientras que en los diferentes programas de ingeniería este porcentaje oscila entre el 80,70% y el 93,10%. La alta tasa de deserción se atribuye principalmente al rezago en las asignaturas de matemáticas, que presentan una elevada tasa de reprobación. Entre el 78,95% y el 79,31% de los estudiantes de ingeniería que han reprobado, lo han hecho en asignaturas relacionadas con matemáticas o estadística.

Para abordar esta situación, la Universidad ha implementado un servicio de tutorías que asigna a cada estudiante en riesgo un tutor dedicado. Este tutor proporciona orientación al estudiante en el diseño de su carga académica y apoyo en la mejora de su desempeño escolar. Sin embargo, a pesar de ser una iniciativa funcional, muchos estudiantes no aprovechan las tutorías disponibles. Además, frecuentemente la asignación de tutorías ocurre después de que los estudiantes han seleccionado sus asignaturas semestrales, lo cual dificulta el seguimiento oportuno de su progreso académico.

Una complicación adicional es que, debido al modelo flexible de la Universidad del Caribe, los estudiantes pueden cursar asignaturas sin seguir las secuencias recomendadas en el mapa curricular. Esto les permite inscribirse en cursos sin haber adquirido los conocimientos previos necesarios, lo que resulta particularmente problemático en las asignaturas relacionadas con las matemáticas. Aunque las tutorías representan un recurso valioso para

los estudiantes en riesgo, la falta de anticipación en la elección de asignaturas y la flexibilidad del modelo académico son desafíos importantes que deben abordarse para mejorar la retención y el éxito estudiantil en las ingenierías de la Universidad del Caribe.

El objetivo del presente trabajo es desarrollar una herramienta predictiva para la identificación oportuna de estudiantes en riesgo de deserción escolar en los programas de ingeniería de la Universidad del Caribe. La herramienta se basa en la definición de un proceso ideal de formación matemática, estructurado a partir de una secuencia de cursos básicos, y en la aplicación de técnicas de minería de procesos para evaluar la conformidad de las trayectorias académicas observadas en los estudiantes con dicho proceso ideal. Utilizando datos de varias cohortes consecutivas, se construye y valida un modelo estadístico basado en métodos de ensamble con alto poder predictivo. La metodología propuesta tiene el potencial de convertirse en una herramienta efectiva para la toma de decisiones oportunas, contribuyendo a reducir las tasas de deserción y reprobación en los programas de ingeniería de la Universidad del Caribe.

## 2. Metodología

La formación integral de un estudiante de ingeniería puede considerarse como un conjunto de procesos complementarios que buscan desarrollar un profesional competente. Cada uno de estos procesos tiene el objetivo de fomentar en el estudiante habilidades específicas en diferentes áreas del conocimiento, tales como matemáticas, mecánica, electricidad, electrónica, programación, gestión de proyectos y comunicación, entre otras (Prince y Felder, 2006).

Estos procesos académicos se implementan a través de una serie de cursos y actividades curriculares y extracurriculares que se integran entre sí. Por ejemplo, en el área de electrónica, los cursos de circuitos eléctricos, electrónica digital y microcontroladores equipan a los estudiantes con el conocimiento necesario para diseñar sistemas electrónicos. En el ámbito de la mecánica, los cursos de mecánica de materiales, dinámica y termo fluidos permiten a los estudiantes aplicar principios físicos a sistemas reales.

Entre todos los procesos que contribuyen a la formación de un estudiante de ingeniería, destaca el desarrollo y fortalecimiento de habilidades matemáticas, ya que proporciona herramientas fundamentales para el éxito en todas las demás áreas de la ingeniería. Este proceso inicia con las asignaturas matemáticas más básicas, como precálculo o cálculo diferencial, y concluye con alguna de las más avanzadas, como ecuaciones diferenciales. Un desarrollo deficiente en este proceso compromete la formación integral del estudiante, aumentando el riesgo de deserción escolar. Por ello, resulta esencial contar con instrumentos que permitan evaluar el cumplimiento de este proceso y responder oportunamente cuando se presenten deficiencias o desviaciones. En este sentido, la minería de procesos puede ofrecer las herramientas necesarias para lograr este objetivo.

### 2.1. Minería de procesos

Un proceso es una secuencia estructurada de actividades orientadas a alcanzar un objetivo específico dentro de una organización. Estas secuencias de actividades forman las unidades operativas básicas de cualquier entidad, proporcionando una base para la producción de bienes y la prestación de servicios. Las múltiples ejecuciones de las actividades que componen un proceso, denominadas *eventos*, generan datos que se registran en sistemas de información, proporcionando un rastro detallado de cómo se desarrollan las actividades en

la práctica. Estos registros son fundamentales para el análisis y la mejora continua de los procesos de cualquier organización (Dumas *et al.*, 2018; van der Aalst, 2016).

En este contexto, la minería de procesos emerge como una disciplina clave dentro de la ciencia de datos y la administración. Su enfoque principal es analizar los datos de eventos registrados en sistemas de información para descubrir, monitorear y mejorar los procesos organizacionales. Según van der Aalst (2016), esta práctica permite extraer conocimiento valioso de los registros de eventos, proporcionando una visión detallada de cómo se llevan a cabo los procesos en la práctica.

La minería de procesos incluye tres técnicas principales: descubrimiento, mejora y conformidad (van der Aalst, 2011). El descubrimiento de procesos implica generar un modelo de proceso basado únicamente en los registros de eventos sin información previa. La mejora se centra en optimizar los procesos existentes, utilizando datos históricos para encontrar y corregir cuellos de botella; mientras que la conformidad verifica si la ejecución real de las actividades de un proceso se ajusta a un modelo predeterminado, identificando desviaciones, siendo estas técnicas las de mayor relevancia para el objetivo de este proyecto.

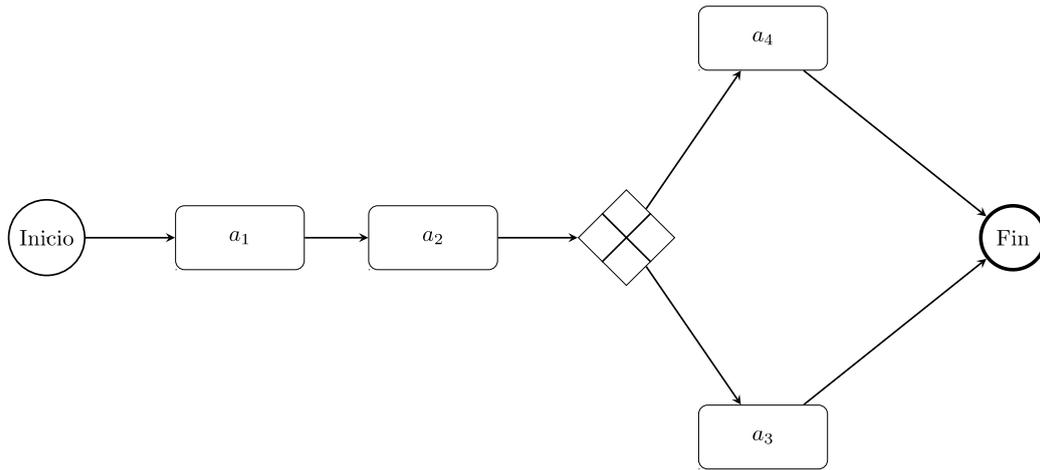
### 2.1.1. Modelo y notación de procesos de negocio

Un modelo de un proceso es una representación gráfica de las actividades que lo componen y de las decisiones involucradas en su gestión. Esto facilita la comprensión y la comunicación entre los diferentes actores responsables de su operación. Existen diversas técnicas para modelar un proceso, siendo una de las más utilizadas la de Modelo y Notación de Procesos de Negocio (BPMN, por sus siglas en inglés). Con esta técnica, las actividades de un proceso se representan gráficamente con rectángulos, el inicio y el final del proceso con círculos, y el flujo de las actividades con flechas. Además, se emplean compuertas para dirigir el flujo de las actividades del proceso (International Business Machines [IBM], 2022).

La Figura 1 muestra el diagrama de un proceso en el que se deben realizar las actividades  $a_1$  y  $a_2$ , en ese orden. Antes de finalizar, es necesario llevar a cabo una de las actividades  $a_3$  o  $a_4$ . Ambas están precedidas por una compuerta XOR (disyunción exclusiva) representada por un rombo cruzado, la cual restringe la ejecución a una sola de las actividades, impidiendo que ambas se realicen, por lo que las únicas secuencias de actividades válidas en el proceso modelado son:  $\sigma_1 = \langle a_1, a_2, a_3 \rangle$  y  $\sigma_2 = \langle a_1, a_2, a_4 \rangle$ .

#### Figura 1.

*Ejemplo de un modelo de proceso empleando la notación BPMN*



**Fuente:** Elaboración propia (2024).

### 2.1.2. Redes de Petri

Una red de Petri es una herramienta ampliamente utilizada para modelar la ejecución de las actividades de un proceso. Una red de Petri se define como la tripleta  $N = (P, T, F)$  en donde  $P$  es un conjunto de sitios,  $T$  un conjunto de transiciones, que en la práctica representan a las actividades del proceso, y  $F \subseteq (P \times T) \cup (T \times P)$  un conjunto de arcos dirigidos entre los sitios y las transiciones o viceversa. Para modelar los estados de un proceso se emplean *fichas*. La siguiente lista describe las características de dichos componentes (Murata, 1989):

- **Sitios.** Representados gráficamente como círculos, los sitios pueden almacenar fichas. Cada sitio puede contener un número variable de fichas.
- **Transiciones.** Representadas como rectángulos, las transiciones son eventos asociados a las actividades del proceso que al ocurrir cambian su estado. Las transiciones están conectadas a los sitios mediante arcos.
- **Fichas.** Representadas como puntos dentro de los sitios, las fichas son elementos dinámicos que se mueven a través de la red de Petri indicando el estado actual del proceso.

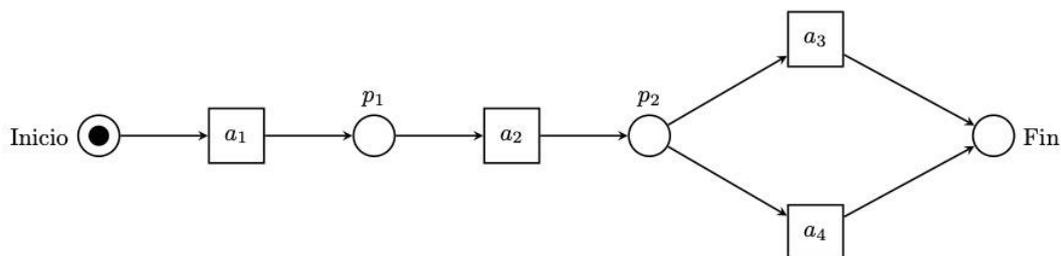
La dinámica de una red de Petri se basa en la interacción entre sitios, transiciones y fichas. Los sitios almacenan fichas, mientras que las transiciones consumen fichas de los sitios de entrada y las trasladan a los sitios de salida a los que están conectadas. Este proceso se denomina *disparo* de una transición.

Para que una transición pueda dispararse, debe estar habilitada, es decir, debe tener una ficha, por lo menos, en cada uno de sus sitios de entrada. Cuando una transición se dispara, consume una ficha de cada sitio de entrada al que esté conectada y produce una ficha en cada sitio de salida. Este movimiento de fichas a través de la red representa la evolución del proceso a lo largo del tiempo.

La Figura 2 muestra la red de Petri asociada al mismo proceso cuyo modelo se presenta en la Figura 1. Las actividades del proceso se corresponden con las transiciones de la red,  $T = \{a_1, a_2, a_3, a_4\}$ , y están directamente conectadas con diferentes sitios,  $P = \{Inicio, p_1, p_2, Fin\}$ . En la red, una ficha ubicada al inicio del proceso define un estado que habilita la ejecución de la actividad  $a_1$ , representando una marcación de la red determinada por la dupla  $(N, M_0)$ , siendo  $M_0 = [Inicio]$  un multiconjunto (un sitio puede contener varias fichas por lo que debe considerarse la posibilidad de que un elemento del conjunto se repita) y siendo  $N = (P, T, F)$ .

**Figura 2.**

*Red de Petri asociada al proceso de la Figura 1. La red contiene una ficha al inicio, lo que habilita la actividad  $a_1$  y define la red marcada  $(N, [Inicio])$*



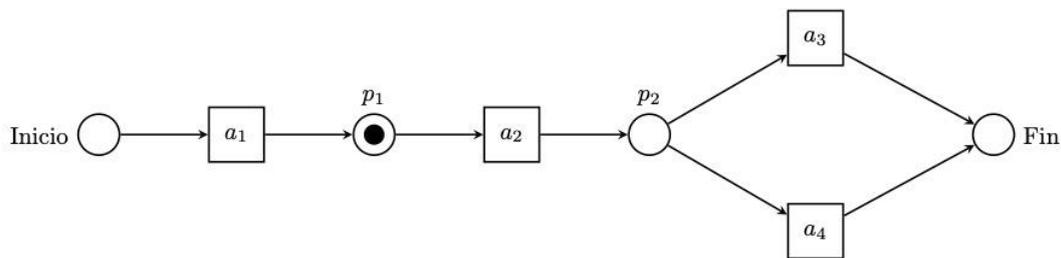
**Fuente:** Elaboración propia (2024).

Al ejecutarse la actividad  $a_1$ , se consume la ficha del inicio y se genera una nueva en el sitio  $p_1$ , como se observa en la Figura 3.

Se emplea la simbología  $(N, M_i) \xrightarrow{t} (N, M_j)$  para indicar que la red de Petri marcada,  $(N, M_i)$ , habilita la transición  $t$  y produce la red de Petri marcada  $(N, M_j)$ ; por lo que en la transición descrita en las Figuras 2 y 3 se indica que  $(N, [Inicio]) \xrightarrow{a_1} (N, [p_1])$ .

**Figura 3.**

*Red de Petri marcada:  $(N, [p_1])$ . La realización de la actividad  $a_1$  consume la ficha de inicio y genera una nueva en el sitio  $p_1$*



**Fuente:** Elaboración propia (2024).

Obsérvese que la red del ejemplo define únicamente dos secuencias de eventos válidas:  $\sigma_1 = \langle a_1, a_2, a_3 \rangle$  y  $\sigma_2 = \langle a_1, a_2, a_4 \rangle$ . También, a partir de la red de Petri marcada inicial, se obtendrá siempre la siguiente sucesión de estados del proceso definidos por las redes de Petri marcadas

$$(N, [Inicio]), (N, [p_1]), (N, [p_2]), (N, [Fin]) ,$$

dado que al ejecutarse cualquiera de las transiciones  $a_3$  o  $a_4$  siempre se consumirá una ficha del sitio  $p_2$  y se generará una nueva en el sitio final del proceso.

### 2.1.3. Análisis de conformidad

El análisis de conformidad en la minería de procesos consiste en un conjunto de técnicas destinadas a cuantificar el grado en que una secuencia de eventos se ajusta a un modelo de proceso, predefinido, tomado como referencia (van der Aalst, 2016). Cuantificar el grado de cumplimiento es especialmente importante en sectores altamente regulados, como el financiero, donde las normativas son estrictas y el incumplimiento puede resultar en sanciones legales o pérdidas financieras. Una idea fundamental para este proyecto es que la cuantificación del grado de cumplimiento de un estudiante con los procesos académicos formativos en diferentes áreas, y particularmente en matemáticas, tiene el potencial de ser una herramienta efectiva para la estimación del riesgo de deserción escolar, lo que hace que la siguiente discusión sea central.

Si se considera un proceso definido por una red de Petri,  $N = (P, T, F)$ , una secuencia de eventos,  $\sigma$ , que represente una ejecución del proceso (conocida también como *traza*), será válida si es posible generar una sucesión de estados del proceso mediante transiciones válidas en la red, es decir, transiciones siempre habilitadas. El proceso se inicia colocando una ficha en el sitio de inicio del proceso, lo cual debe disparar las transiciones (eventos) de la traza y debe finalizar con una única ficha en el sitio final. Esto implica que cada transición

en la traza debe estar habilitada por las fichas presentes en los sitios de entrada correspondientes y, al dispararse, debe consumir y producir las fichas adecuadas para permitir que la siguiente transición en la traza también se dispare. En otras palabras, la secuencia de eventos,  $\sigma$ , debe respetar las reglas de disparo y flujo definidas por la red de Petri, asegurando que cada evento en la traza esté habilitado por el estado actual del proceso y conduzca a un nuevo estado válido, culminando en el estado final con una ficha en el sitio de término (Van der Aalst, 2016).

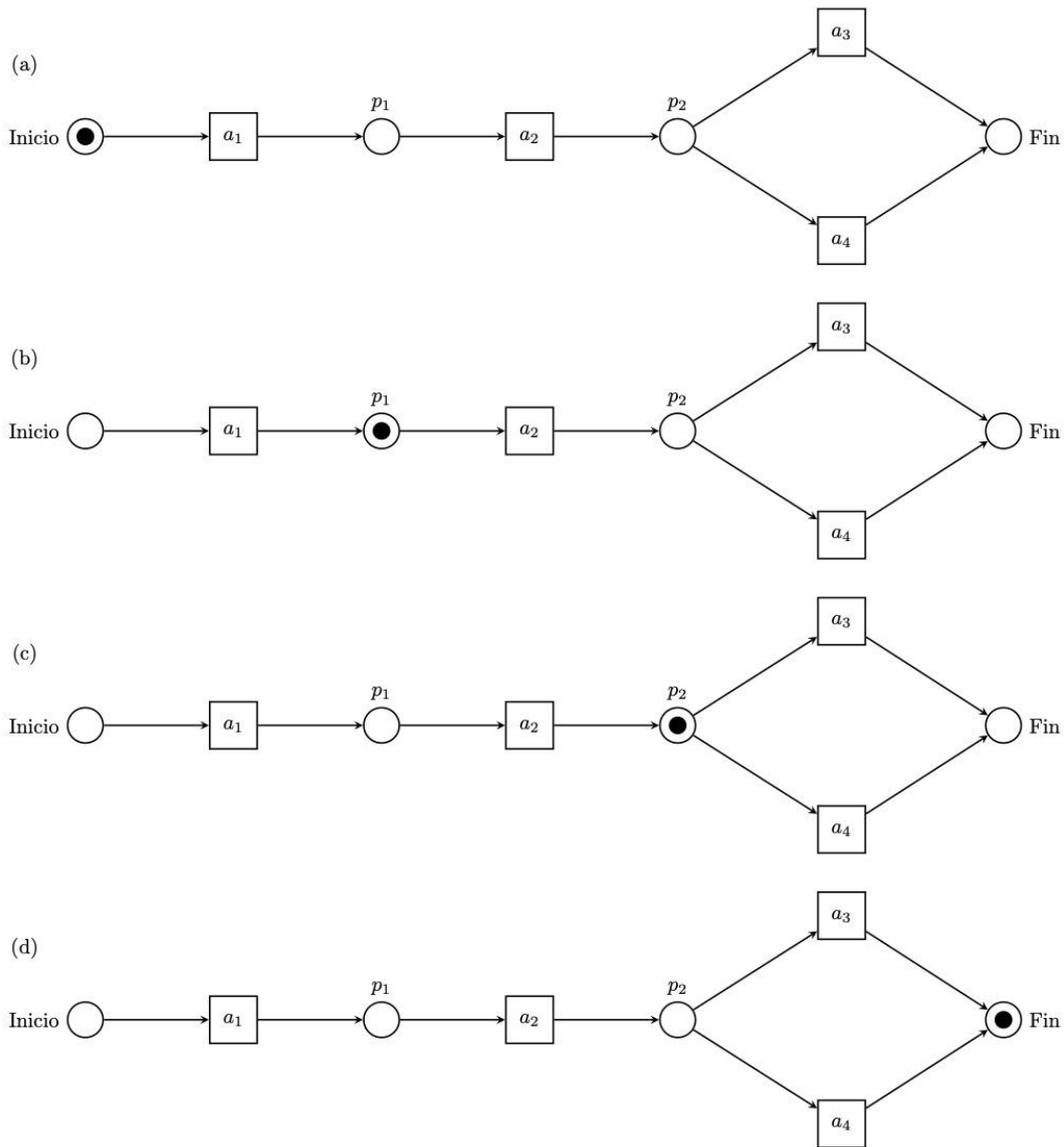
Tómese como ejemplo el proceso cuyo modelo se muestra en la Figura 1, la traza  $\alpha = \langle a_1, a_2, a_4 \rangle$  se ajusta al modelo pues se asocia con la siguiente sucesión de transiciones habilitadas:

$$(N, [Inicio]) \xrightarrow{a_1} (N, [p_1]) \xrightarrow{a_2} (N, [p_2]) \xrightarrow{a_4} (N, [Fin]) .$$

En la Figura 4 se puede observar la secuencia de estados del proceso asociada con la traza.

#### **Figura 4.**

*Secuencia de estados del proceso que valida a la secuencia de eventos  $\alpha = \langle a_1, a_2, a_4 \rangle$*



**Fuente:** Elaboración propia (2024).

En la reproducción de los eventos de la traza, se puede notar que:

- Se generó una ficha para construir la red de Petri marcada inicial:  $(N, [Inicio])$ .
- La transición  $(N, [Inicio]) \xrightarrow{a_1} (N, [p_1])$  consumió la ficha inicial y generó la ficha que se ubicó en el sitio  $p_1$ .
- En total, en la reproducción de la secuencia de eventos se generan 4 fichas.
- Al consumir la ficha ubicada en el sitio final y vaciar la red de Petri, se consumen en total 4 fichas (el consumo de la ficha final no se muestra en la Figura 4).

De manera que el total de fichas generadas es 4,  $g = 4$ , y las consumidas también son 4,  $c = 4$ .

Por otro lado, la traza  $\beta = \langle a_1, a_2, a_2, a_3 \rangle$ , no se ajusta al modelo pues se repite injustificadamente la actividad  $a_2$ . Obsérvese que la ficha inicial habilita la ejecución sucesiva de los eventos  $a_1$  y  $a_2$ :

$$(N, [Inicio]) \xrightarrow{a_1} (N, [p_1]) \xrightarrow{a_2} (N, [p_2]),$$

y para ello, se deben generar 3 fichas y consumir 2:  $g = 3, c = 2$ . Dado que el estado actual del proceso no habilita la ejecución de  $a_2$ , para justificar una nueva ejecución hace falta incluir una ficha en el sitio  $p_1$ , por lo que se incluye considerándola una ficha *faltante*; en paralelo se inicia el conteo de fichas faltantes,  $m = 1$  (el símbolo  $m$  es por *missing*). La nueva red de Petri marcada es:  $(N, [p_1, p_2])$ . Este nuevo estado permite validar al resto de las actividades de la secuencia:

$$(N, [p_1, p_2]) \xrightarrow{a_2} (N, [p_2^2]) \xrightarrow{a_3} (N, [p_2, Fin]).$$

La marca final,  $[p_2, Fin]$  contiene una ficha *remanente* en el sitio  $p_2$ , por lo que el conteo de fichas remanentes es uno:  $r = 1$ . Una vez que se consuma la ficha ubicada al final del proceso, el conteo final es el siguiente:  $g = 5, c = 5, m = 1, r = 1$ .

Generalizando los ejemplos descritos, se puede afirmar que una secuencia de eventos que no se ajusta al proceso de referencia se identifica por un conteo de fichas faltantes o remanentes diferente de cero. Se puede establecer entonces una medida del grado de conformidad de una secuencia de eventos,  $\sigma$ , con respecto a un proceso definido en una red de Petri,  $N$ , a partir de la siguiente función:

(1)

$$f(\sigma, N) = \frac{1}{2} \left(1 - \frac{m}{c}\right) + \frac{1}{2} \left(1 - \frac{r}{g}\right)$$

siendo  $m$ ,  $r$ ,  $c$  y  $g$  el total de fichas faltantes, remanentes, consumidas y generadas, respectivamente, en la reproducción de los eventos de la secuencia. Identificamos a la función  $f$  como *función de ajuste* o *función de conformidad*. Esta función está acotada,  $f \in [0,1]$ , y obtiene su máximo valor cuando se evalúa en secuencias de eventos que son conformes con el modelo definido en la red de Petri (van der Aalst, 2016).

Al evaluar la función de ajuste sobre las dos trazas ejemplificadas anteriormente se verifica que:

- $f(\alpha, N) = 1$
- $f(\beta, N) = 4/5 < 1$

Esto muestra que la traza  $\alpha$  es perfectamente conforme con el proceso modelo, mientras que la traza  $\beta$  tiene un grado de conformidad menor, debido a la repetición injustificada de la actividad  $a_2$ .

## 2.2. Proceso de desarrollo de habilidades matemáticas

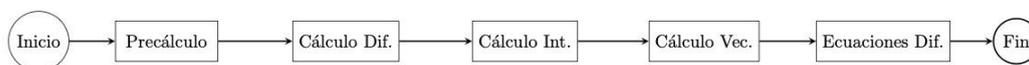
El desarrollo de las habilidades matemáticas necesarias en los estudiantes de programas educativos de ingeniería es un proceso complejo que implica no solo la adquisición de conocimientos teóricos, sino también la aplicación práctica de estos conocimientos en situaciones diversas. Esta formación es fundamental, ya que la comprensión profunda de conceptos matemáticos permite a los estudiantes abordar problemas técnicos con un enfoque analítico y desarrollar soluciones innovadoras y eficientes.

Con la finalidad de obtener un panorama simplificado que pueda aprovecharse en el análisis de trayectorias académicas personalizadas, este proceso de formación matemática puede considerarse como la secuencia de los cursos matemáticos definida en el mapa curricular del programa educativo. Cada curso en esta secuencia está diseñado para construir sobre el conocimiento adquirido en cursos anteriores, creando una progresión lógica en el aprendizaje del estudiante.

Aun restringiéndose a la formación matemática, esta puede componerse de varios procesos específicos. Por ejemplo, la formación en matemáticas continuas puede iniciar con cursos de precálculo, continuar con cálculo diferencial, integral y vectorial, y concluir con ecuaciones diferenciales u otro curso más avanzado. Esta secuencia proporciona una base sólida en el análisis de funciones reales y sus aplicaciones, preparando a los estudiantes para abordar problemas en diversas áreas de la ingeniería. Como ejemplo, en la Figura 5 se muestra un modelo de dicho proceso.

**Figura 5.**

*Ejemplo de un modelo de proceso de formación en matemáticas continuas*



**Fuente:** Elaboración propia (2024).

Por otro lado, la formación en estadística podría seguir una secuencia diferente. Los estudiantes podrían comenzar con los cursos de cálculo, luego, avanzarían a cursos de probabilidad y estadística, que les proporcionan las herramientas necesarias para analizar datos y evaluar probabilidades. Finalmente, concluirían con cursos de estadística inferencial, donde aprenderían a hacer pronósticos de variables de interés y tomar decisiones basadas en datos. Esta secuencia es crucial para áreas como la ingeniería industrial, donde la toma de decisiones informada es esencial.

En la práctica, la trayectoria académica de un estudiante puede desviarse de los procesos de formación matemática ideales definidos en el mapa curricular. Por ejemplo, si no aprueban un curso en la primera oportunidad, deben recursarlo un número (frecuentemente limitado) de veces hasta aprobarlo. También se presentan desviaciones de los procesos ideales cuando se cambia el orden de la secuencia de cursos, como al cursar ecuaciones diferenciales antes de cálculo integral. Casos como estos son representativos de programas educativos con modelos flexibles, donde los estudiantes pueden elegir los cursos de cada periodo lectivo con pocas restricciones, como es el caso de la institución en la que se desarrolló el presente proyecto.

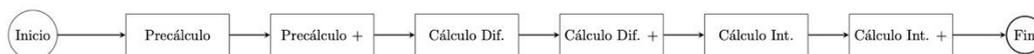
En tales condiciones, la cantidad de trayectorias académicas que se desvían de un proceso de formación matemática ideal puede ser elevada, complicando su estudio. Sin embargo, esto representa una oportunidad propicia para la aplicación de técnicas de análisis de conformidad de la minería de procesos.

Considerando que el análisis de las trayectorias académicas y su apego a procesos de formación matemática ideales puede brindar información relevante para identificar el riesgo de deserción escolar, la selección de uno o varios procesos de referencia es fundamental. Esta información debe obtenerse de forma oportuna para permitir la aplicación de medidas

preventivas que mitiguen el impacto de una trayectoria no ideal. En el presente proyecto, se considera el proceso ideal de formación matemática cuyo modelo se muestra en la Figura 6.

**Figura 6.**

*Modelo ideal del proceso de formación matemática empleado como referencia en este proyecto*



**Fuente:** Elaboración propia (2024).

El proceso modelo considera únicamente los cursos de precálculo, cálculo diferencial y cálculo integral, que forman parte del mapa curricular de los programas de ingeniería analizados. Al finalizar cada curso, idealmente, el estudiante debe aprobarlo, lo cual se indica en las actividades etiquetadas con el nombre del curso seguido del símbolo “+”. El proceso implica que el estudiante curse y apruebe en la primera oportunidad las tres asignaturas. Dado que el curso de precálculo se asigna al inicio de cada programa educativo, y que el resto de los cursos se ubican en semestres consecutivos en los mapas curriculares correspondientes, el proceso ideal debe completarse en tres semestres. Elegir un proceso con una corta duración permite estimar el riesgo de deserción escolar en los tres primeros semestres, facilitando la adopción de medidas oportunas.

Las trayectorias académicas que se desvían del proceso modelo se presentan cuando un estudiante no aprueba algún curso, cambia el orden de la secuencia o evita inscribirse a los cursos del proceso ideal. La siguiente lista muestra algunos ejemplos de secuencias que representan variaciones del proceso ideal, considerando solamente los tres primeros semestres del historial académico de los estudiantes:

1.  $\sigma_1 = \langle \text{Precálculo}, \text{Precálculo } +, \text{Cálculo Dif}, \text{Cálculo Dif-}, \text{Cálculo Dif}, \text{Cálculo Dif } + \rangle$ . En esta traza, el estudiante aprobó precálculo en el primer semestre, no aprobó cálculo diferencial en el segundo semestre, aunque lo hizo en el tercero.
2.  $\sigma_2 = \langle \text{Precálculo}, \text{Precálculo } +, \text{Cálculo Int}, \text{Cálculo Int-}, \text{Cálculo Dif}, \text{Cálculo Dif } + \rangle$ . Esta traza corresponde a un estudiante que aprobó precálculo en primer semestre, cursó y no aprobó cálculo integral en segundo semestre, incluso sin cubrir el requisito de cálculo diferencial, cursando y aprobando finalmente cálculo diferencial en el tercer semestre.
3.  $\sigma_3 = \langle \text{Precálculo}, \text{Precálculo } - \rangle$ . La traza corresponde a un estudiante que no aprobó precálculo y tampoco se registró a algún otro curso del proceso durante los primeros tres semestres.

### 2.3. Obtención y procesamiento de datos

Los datos empleados en el presente proyecto se basan en el historial académico de estudiantes de tres programas educativos, del área de ingeniería, de la Universidad del Caribe:

1. Ingeniería Ambiental.
2. Ingeniería Industrial.
3. Ingeniería en Logística y Cadena de Suministro.

Los estudiantes considerados en este estudio pertenecen a cuatro cohortes consecutivas: 2014-2017. Se incluyeron únicamente aquellos que hubieran egresado de su programa educativo o causado baja definitiva (por deserción o por no haber aprobado alguna asignatura en un máximo de tres oportunidades). Además, se consideraron únicamente los estudiantes que permanecieron por lo menos tres semestres en la universidad, el tiempo necesario para concluir el proceso de formación matemática ideal. Las cohortes de 2014 y 2015 no tienen estudiantes activos, ya que todos egresaron o causaron baja definitiva. Mientras que, al momento de desarrollar el presente trabajo, las cohortes de 2016 y 2017 presentaban el 6% y 12% de estudiantes activos, respectivamente. El conjunto de datos final representa a un total de 506 estudiantes.

El historial académico de cada estudiante incluido en el estudio se obtuvo del Sistema de Administración Escolar mediante consultas directas, filtrando únicamente las calificaciones correspondientes a los cursos incluidos en el proceso de formación matemática, que se muestra en la Figura 6. Para cada calificación registrada, se añadió un nuevo registro que indicaba si el estudiante aprobó o no la asignatura, agregando el símbolo “+” o “-” respectivamente al nombre de la asignatura, como se describió previamente.

El procesamiento de los datos se realizó empleando el lenguaje Python, a través de la librería *pandas* (McKinney, 2010). A partir de los datos de los historiales académicos, fue necesario construir una tabla de datos de eventos, la cual se estructuró considerando tres columnas:

1. **Matrícula.** Identifica de forma única a cada estudiante.
2. **Evento.** Se consideraron dos tipos de eventos: el registro de un estudiante a un curso y el resultado final obtenido (aprobado o no).
3. **Fecha.** La estampa temporal en la que se verificó el evento (la fecha de inicio del semestre para el registro al curso y la fecha del final del semestre para el resultado).

La tabla de datos de eventos con esta estructura, conocida como *log de eventos*, es necesaria para la aplicación de las técnicas de análisis de conformidad de la minería de procesos. Para el análisis de conformidad se empleó la librería *pm4py* (Berti *et al.*, 2019).

A partir de la tabla de datos de eventos, se evaluó, para cada estudiante, la conformidad con el proceso de formación matemática (ver Ecuación 1). Previamente, se excluyeron de la tabla de eventos todos los registros cuya fecha fuera superior a tres semestres desde la fecha de ingreso del estudiante correspondiente, dado que el proceso modelo debe completarse en un plazo de tres semestres.

Además, se consideraron subprocesos del modelo ideal para uno y dos semestres. Para el subproceso de dos semestres, se incluyeron únicamente los cursos de precálculo y cálculo diferencial, mientras que, para el subproceso de un semestre, solo se tomó en cuenta el curso de precálculo. Para cada estudiante, se evaluó la conformidad del historial académico (traza) con respecto a los subprocesos modelo, obteniendo así tres valores numéricos por estudiante.

El conjunto de datos final contiene un registro por cada estudiante, en el que cada valor numérico representa la conformidad del historial académico del estudiante con respecto al proceso ideal de formación matemática al finalizar el primer, segundo y tercer semestre. Además, se agregó una columna con valores binarios indicando si el estudiante causó baja o egresó de su programa educativo.

#### 2.4. Modelado estadístico

El modelado estadístico se realizó empleando la librería *sklearn* (Pedregosa *et al.*, 2011). Se ajustó un modelo estadístico basado en la técnica de clasificación XGBoost (Chen y Guestrin, 2016) para modelar la probabilidad de deserción escolar a partir del conjunto de datos. El modelo utilizó como predictores de la deserción la evaluación de la conformidad con el proceso de formación matemática de cada estudiante al finalizar el primer, segundo y tercer semestre.

Los datos de entrenamiento correspondieron a las cohortes de 2014 a 2016, mientras que la cohorte de 2017 se utilizó para la validación del modelo. El modelo ajustado, utilizando exclusivamente los datos de entrenamiento, consistió en 5 árboles de clasificación binaria ensamblados mediante la técnica XGBoost. Para validar el modelo, se aplicó a los datos de la cohorte de 2017, y los resultados relacionados con su calidad predictiva se reportan en la siguiente sección.

Para la visualización de los resultados, se utilizó la librería *plotly* (Plotly Technologies Inc., 2015), lo que permitió crear gráficos interactivos y detallados para facilitar la interpretación de los datos.

### 3. Resultados

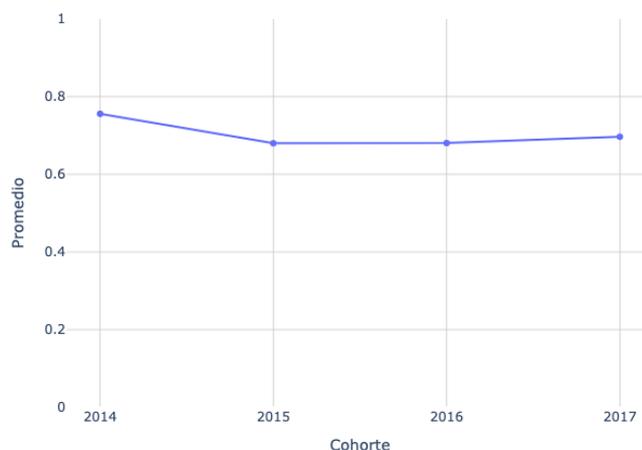
#### 3.1. Exploración de datos

El análisis de los datos indicó que aproximadamente el 48% de los estudiantes de las cohortes consideradas en el análisis egresaron de sus programas educativos mientras que el 47,5% causaron baja definitiva. El 4,5% restante representa a estudiantes activos de las cohortes 2016 y 2017 al momento de escribir este reporte.

El porcentaje de estudiantes de las cuatro cohortes que completaron el proceso ideal de formación matemática, en un máximo de tres semestres, fue del 14,7%, mientras que el promedio del valor de la función de ajuste al proceso ideal fue de 0,70. El valor promedio de esta función por cohorte puede apreciarse en la Figura 7.

**Figura 7.**

*Promedio de la función de ajuste al proceso de formación matemática ideal por cohorte*

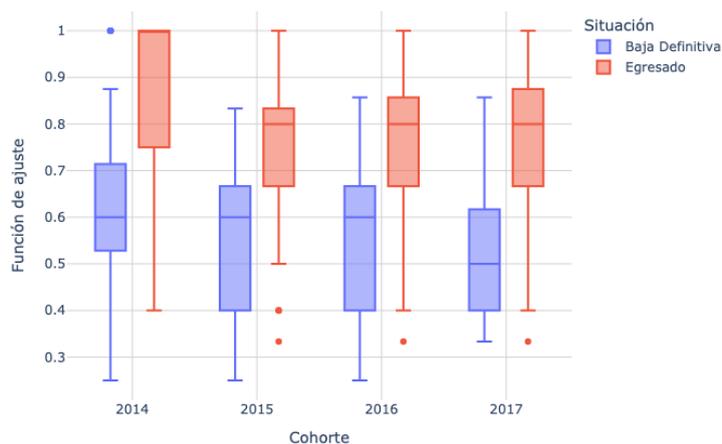


**Fuente:** Elaboración propia (2024).

La Figura 8 muestra la distribución de los valores de la función de ajuste al proceso ideal de formación matemática, desglosada por cohorte y situación académica. Se observa una diferencia significativa en la distribución de estos valores entre los estudiantes egresados y aquellos que causaron baja definitiva, lo cual refuerza la idea de que esta función es un predictor significativo de la deserción escolar.

### Figura 8.

*Distribución de la función de ajuste al proceso de formación matemática ideal por cohorte y por situación académica*



**Fuente:** Elaboración propia (2024).

### 3.2. Modelado estadístico

En esta sección se mostrarán los resultados del modelo estadístico ajustado. El modelo se construyó empleando la técnica de XGBoost, conocida por su eficacia en tareas de clasificación. Para este análisis, se utilizaron 5 árboles de clasificación para el ensamblaje del modelo.

Como predictores, se emplearon tres variables: los valores de la función de ajuste al proceso de formación matemática en el primer, segundo y tercer semestre. Los datos se dividieron en conjuntos de entrenamiento (cohortes 2014-2016) y de prueba (cohorte 2017). Una vez ajustado el modelo utilizando los datos de entrenamiento, se aplicó a los datos de prueba para evaluar la probabilidad de que un estudiante no egresara. Para pronosticar que un estudiante no egresará, se empleó un umbral de probabilidad de 0,5. Los resultados pronosticados por el modelo se compararon con los resultados reales registrados en la cohorte 2017.

Las métricas de calidad predictiva obtenidas en la prueba del modelo se presentan en la Tabla 1. El modelo realiza un pronóstico correcto en el 82% de los casos de prueba (exactitud de 0,82), identifica correctamente al 76% de los estudiantes que no egresaron (exhaustividad de 0,76) y acertó en el 69% de las ocasiones en que pronosticó el no egreso de un estudiante (precisión de 0,69). El área bajo la curva (AUC) de precisión contra exhaustividad fue de 0,83. Para valorar la capacidad del modelo, también se incluyen los resultados de un modelo de referencia que clasifica cada caso (egreso o baja) generando un pronóstico aleatorio basado

en la misma proporción de las dos clases en los datos originales. Los resultados también pueden apreciarse en la matriz de confusión que se muestra en la Figura 9.

**Tabla 1.**

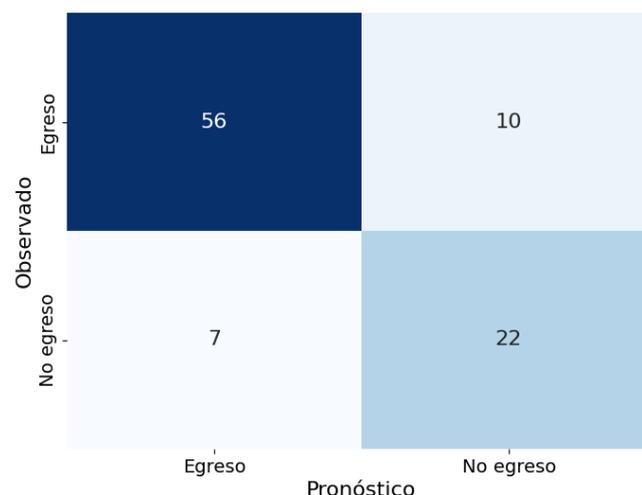
*Métricas de calidad obtenidas con la aplicación del modelo sobre los datos de la cohorte 2017. Como referencia, se reportan las mismas métricas obtenidas con la aplicación de un modelo aleatorio*

Modelo	AUC	Precisión	Exhaustividad	Exactitud
XGBoost	0,83	0,69	0,76	0,82
Referencia (aleatorio)	0,42	0,23	0,34	0,45

**Fuente:** Elaboración propia (2024).

**Figura 9.**

*Matriz de confusión obtenida al aplicar el modelo a los datos de la cohorte 2017 y comparar los pronósticos contra los valores observados*



**Fuente:** Elaboración propia (2024).

Las métricas que se obtuvieron reflejan un buen desempeño del modelo en la predicción de la deserción escolar de la cohorte 2017. Sin embargo, dado que el conjunto de datos es reducido, la estimación de la calidad de generalización del modelo puede conllevar una alta varianza. Para obtener una estimación más confiable, el conjunto de datos completo se separó aleatoriamente en conjuntos de entrenamiento (75%) y prueba (25%), el modelo se ajustó con los datos de entrenamiento y se aplicó sobre el conjunto de prueba, evaluando después las métricas de calidad. El proceso se repitió en 20 ocasiones. La mediana de las métricas de calidad obtenidas mediante las repeticiones se muestra en la Tabla 2.

**Tabla 2.**

*Métricas de calidad obtenidas con la aplicación repetida del modelo. Los conjuntos de entrenamiento y de prueba se separaron aleatoriamente en cada ocasión*

Modelo	AUC	Precisión	Exhaustividad	Exactitud
XGBoost	0,81	0,57	0,88	0,70

Referencia (aleatorio)	0,50	0,37	0,43	0,53
---------------------------	------	------	------	------

---

**Fuente:** Elaboración propia (2024)

## 4. Discusión

El uso de la minería de procesos para analizar las trayectorias académicas de los estudiantes proporciona una metodología robusta para identificar patrones de deserción, tal como lo sugieren (Banihashem *et al.*, 2018) y (Salazar *et al.*, 2021). Estos estudios han resaltado la capacidad del análisis de datos para mejorar la retención estudiantil y optimizar planes de estudio, y los hallazgos descritos en el presente proyecto confirman la aplicabilidad de estas técnicas en un contexto específico como el de la Universidad del Caribe.

Los resultados obtenidos muestran que la evaluación de la conformidad de las trayectorias académicas de los estudiantes con respecto al proceso de formación matemática ideal, establecido en el mapa curricular, es un predictor significativo de la deserción escolar en estudiantes de ingeniería. Esto concuerda con las observaciones de (Loder, 2024), quien destacó la importancia de visualizar las trayectorias estudiantiles para monitorear su desempeño en tiempo real. El empleo del modelo para estimar la probabilidad de deserción puede convertirse en una herramienta efectiva para identificar oportunamente a los estudiantes en riesgo escolar, brindando la oportunidad de aplicar intervenciones tempranas y mitigar los riesgos de deserción.

La metodología de modelado descrita en el presente proyecto puede adaptarse fácilmente para su aplicación en otras universidades o contextos educativos, aunque, dado el modelo educativo flexible de la universidad en la que se realizó el estudio y a que el conjunto de datos es relativamente pequeño, la generalización de los hallazgos puede ser limitada.

La identificación de estudiantes en riesgo de deserción puede enriquecerse mediante el análisis de otros procesos de formación críticos, tal es el caso de los que involucran cursos con altas tasas de reprobación (por ejemplo, los relacionados con la física, la programación, la química o la estadística). Evaluar la conformidad de las trayectorias académicas de los estudiantes con esos procesos puede proporcionar una visión más completa de los factores que contribuyen a la deserción escolar. Al identificar y monitorear procesos de formación adicionales, las intervenciones educativas pueden ser más específicas y efectivas, abordando las áreas donde los estudiantes tienen más dificultades y, por ende, mejorando las tasas de retención y éxito académico.

Otra limitación es la naturaleza retrospectiva de nuestro análisis. Aunque la minería de procesos proporciona una herramienta poderosa para entender y predecir la deserción escolar, su capacidad para influir en decisiones prospectivas depende de la calidad y actualidad de los datos disponibles. La utilización efectiva de los modelos basados en la evaluación de la conformidad con el proceso de formación matemática debe considerar su actualización continua con datos recientes y relevantes. Esto implica la necesidad de implementar sistemas de monitoreo en tiempo real que permitan la captura y análisis de datos de manera continua y que estén disponibles para todos los agentes involucrados en el acompañamiento estudiantil. De esta manera, se garantiza que las intervenciones educativas se basen en información actualizada y precisa.

## 5. Conclusiones

Este estudio ha demostrado que la minería de procesos es una herramienta efectiva para predecir y abordar la deserción escolar en programas de ingeniería, evaluando la conformidad de las trayectorias académicas de los estudiantes con un proceso ideal de formación matemática. Los hallazgos indican que esta evaluación es un predictor significativo de la deserción escolar en estudiantes de ingeniería de la Universidad del Caribe, permitiendo la identificación temprana de estudiantes en riesgo y la aplicación de intervenciones personalizadas, con lo que se responde de manera precisa al objetivo de este proyecto.

Desde el punto de vista descriptivo, la función de ajuste al proceso de formación matemática, evaluada en diferentes niveles de agregación, como grupos, programas educativos o cohortes, puede representar un indicador confiable del desempeño de los agentes académicos responsables de la formación matemática. Al tomarla como referencia, se facilitará el planteamiento de metas académicas, el diseño de estrategias y la evaluación de acciones.

Este estudio confirma la utilidad de la minería de procesos en la predicción de la deserción escolar y sugiere direcciones futuras para la investigación. Implementar sistemas de monitoreo en tiempo real y expandir el análisis a otros procesos críticos puede mejorar significativamente la capacidad predictiva y la efectividad de las intervenciones educativas, contribuyendo a aumentar las tasas de retención y éxito académico en las carreras de ingeniería.

## 6. Referencias

- Amaya Amaya, A., Huerta Castro, F. y Flores Rodríguez, C. O. (2020). Big Data, una estrategia para evitar la deserción escolar en las IES. *Revista Iberoamericana de Educación Superior*, 11(31), 166-178. <https://doi.org/10.22201/iisue.20072872e.2020.31.712>
- Banihashem, S. K., Aliabadi, K., Ardakani, S. P., Delaver, A., y Ahmadabadi, M. N. (2018). Learning analytics: A systematic literature review. *Interdisciplinary Journal of Virtual Learning in Medical Sciences*, 9(1), 41-60.
- Berti, A., van Zelst, S. J. y Schuster, D. (2023). PM4Py: A process mining library for Python. *Software Impacts*, 17, 100556. <https://doi.org/10.1016/j.simpa.2023.100556>
- Chen, T. y Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
- De Witte, K. y Rogge, N. (2013). Dropout from secondary education: All's well that begins well. *European Journal of Education*, 48(1), 131-149. <https://doi.org/10.1111/ejed.12001>
- Dumas, M., La Rosa, M., Mendling, J. y Reijers, H. A. (2019). *Fundamentals of Business Process Management*. Springer.
- Felder, R. M. y Brent, R. (2004). The Intellectual Development of Science and Engineering Students. Part 2: Teaching to Promote Growth. *Journal of Engineering Education*, 93(4), 279-291. <http://doi.org/10.1002/j.2168-9830.2004.tb00817.x>

- Gottipati, S. y Shankararaman, V. (2018). Competency analytics tool: Analyzing curriculum using course competencies. *Education and Information Technologies*, 23(1), 41-60. <https://doi.org/10.5812/IJVLMS.63024>
- Instituto Nacional de Estadística Geografía e Informática. (s.f.). Tasa de abandono escolar por entidad federativa según nivel educativo. <https://bit.ly/3VSicNW>
- International Business Machines [IBM]. (6 de enero de 2022). BPMN basics: Understanding and using BPMN. IBM. <https://www.ibm.com/blog/bpmn/>
- Loder, A. K. F. (2024). The use of educational process mining on dropout and graduation data in the curricula (Re-)Design of universities. *Trends in Higher Education*, 3(1), 50-66. <https://doi.org/10.3390/higheredu3010004>
- López Suárez, A., Albíter Rodríguez, Á. y Ramírez Revueltas, L. (2008). Eficiencia terminal en la educación superior, la necesidad de un nuevo paradigma. *Revista de la Educación Superior*, XXXVII(2), 135-151.
- McKinney, W. (2010). Data Structures for Statistical Computing in Python. *Proceedings of the 9th Python in Science Conference*, 51-56.
- Murata, T. (1989). Petri nets: Properties, analysis and applications. *Proceedings of the IEEE*, 77(4), 541-580. <https://doi.org/10.1109/5.24143>
- Murillo-García, O. L. y Luna-Serrano, E. (2021). El contexto académico de estudiantes universitarios en condición de rezago por reprobación. *Revista Iberoamericana de Educación Superior*, 12(33), 58-75. <https://doi.org/10.22201/iisue.20072872e.2021.33.858>
- Ocampo Díaz, J., Martínez Romero, M., de las Fuentes Lara, M. y Zatarain Jorge, J. (2010). Reprobación y deserción en la facultad de ingeniería Mexicali de la Universidad Autónoma de Baja California. <https://bit.ly/4671Us1>
- Paramo, G. J. y Correa Maya, C. A. (2012). Deserción estudiantil universitaria. Conceptualización. *Revista Universidad EAFIT*, 35(114), 65-78.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... y Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Pérez, S. L. G. (2010). El papel de la tutoría en la formación integral del universitario. *Tiempo de Educar*, 11(21), 31-56.
- Plotly Technologies Inc. (2015). Collaborative data science. Montréal, QC: Plotly Technologies Inc. <https://plot.ly>
- Salazar-Fernández, J. P., Muñoz-Gama, J., Maldonado-Mahauad, J., Bustamante, D. y Sepúlveda, M. (2021). Backpack Process Model (BPPM): A process mining approach for curricular analytics. *Applied Sciences*, 11(9), 4265. <https://doi.org/10.3390/app11094265>

- Tinto, V. (1989). Definir la deserción: una cuestión de perspectiva. *Revista de Educación Superior*, 71(18), 1-9.
- Valdivia, E. M., Ruíz, B. V., Cárdenas, C. M. y Ortiz, C. P. (2019). *Diseño de un programa de tutoría integral para alumnos de ingeniería*. ANFEI Digital, 11.
- Van der Aalst, W. (2011). *Process Mining: Discovery, Conformance and Enhancement of Business Processes*. Springer.
- Van der Aalst, W. (2016). *Process Mining: Data Science in Action*. Springer.

## CONTRIBUCIONES DE AUTORES/AS, FINANCIACIÓN Y AGRADECIMIENTOS

### Contribuciones de los/as autores/as:

**Conceptualización:** Gómez García, Héctor Fernando; **Software:** Gómez García, Héctor Fernando; Mendiola Fuentes Jessica; **Validación:** Gómez García, Héctor Fernando; Mendiola Fuentes Jessica; Romero Medina, Víctor Manuel; **Análisis formal:** Gómez García, Héctor Fernando; Mendiola Fuentes Jessica; **Curación de datos:** Gómez García, Héctor Fernando; Mendiola Fuentes Jessica; Romero Medina, Víctor Manuel; **Redacción-Preparación del borrador original:** Gómez García, Héctor Fernando; Mendiola Fuentes Jessica; **Redacción-Re-visión y Edición:** Mendiola Fuentes Jessica; Romero Medina, Víctor Manuel; **Visualización:** Mendiola Fuentes Jessica; Romero Medina, Víctor Manuel **Supervisión:** Gómez García, Héctor Fernando; **Administración de proyectos:** Mendiola Fuentes Jessica; **Todos los/as autores/as han leído y aceptado la versión publicada del manuscrito:** Gómez García, Héctor Fernando; Mendiola Fuentes Jessica; Romero Medina, Víctor Manuel.

**Financiación:** Esta investigación no recibió financiamiento externo.

### AUTOR:

**Héctor Fernando Gómez García**  
Universidad del Caribe, México.

Profesor Investigador de Tiempo Completo adscrito al programa de Ingeniería en Datos e Inteligencia Organizacional. Doctor en Ciencias con orientación en Computación por el Centro de Investigación en Matemáticas. Ha desarrollado diversos proyectos de investigación en procesamiento digital de imágenes, visión computacional y ciencia de datos, con especial interés en las aplicaciones de la inteligencia artificial en la educación y en el modelado estadístico de sistemas ambientales para el desarrollo de energías renovables.

[fgomez@ucaribe.edu.mx](mailto:fgomez@ucaribe.edu.mx)

Orcid ID: <https://orcid.org/0000-0002-6563-5539>

**Jessica Mendiola Fuentes**  
Universidad del Caribe, México.

Licenciatura en matemáticas aplicadas por la Universidad Juárez del Estado de Durango. Maestría y Doctorado en Control y Sistemas Dinámicos ambos por el Instituto de Investigación Científica y Tecnológica A. C. (IPICYT). Estancia posdoctoral en el Instituto de Física de la Universidad Autónoma de San Luis Potosí (UASLP). Ganadora del premio Sofia Kovalévskaya en 2017. Líder del departamento de HPC en el Centro Nacional de Supercómputo (CNS) durante el 2020 y hasta el 2022. Principales áreas de interés se enfocan en teoría de control, sistemas dinámicos y sus aplicaciones. Miembro del Sistema Nacional de Investigadores (SNI). Actualmente es profesora investigadora de tiempo completo del Departamento de Ciencias Básicas e Ingenierías de la Universidad del Caribe.

[jmendiola@ucaribe.edu.mx](mailto:jmendiola@ucaribe.edu.mx)

**Índice H:** 2

**Orcid ID:** <https://orcid.org/0000-0001-5686-7189>

**Scopus ID:** <https://www.scopus.com/authid/detail.uri?authorId=56646610700>

**Google Scholar:** <https://scholar.google.com/citations?user=JFo9jiIAAAJ&hl=es>

**ResearchGate:** <https://www.researchgate.net/profile/Jessica-Mendiola>

**Víctor Manuel Romero Medina**  
Universidad del Caribe, México.

Profesor Investigador Titular de Tiempo Completo adscrito al programa educativo de Ingeniería Ambiental. Ingeniero Aeronáutico con Maestría en Ingeniería Mecánica enfocado a la dinámica de fluidos computacional y Doctorado en Ciencia e Ingeniería de Materiales con orientación al desarrollo de modelos matemáticos para el análisis de crecimiento de grietas y deformación plástica de materiales compuestos. Ha participado en proyectos de investigación básica y aplicada, principalmente en Dinámica de Fluidos Computacional, enfocados al aprovechamiento de las energías renovables desarrollando prototipos. Ha participado en diversos congresos y publicado varios artículos. Es miembro activo de la Asociación Nacional de Energía Solar, International Solar Energy Society, Ocean Thermal Energy Association y Centro Mexicano de Investigación en Energía del Océano.

[vromero@ucaribe.edu.mx](mailto:vromero@ucaribe.edu.mx)