

Personalización de recursos para la enseñanza de matemáticas universitarias usando inteligencia artificial*

Juan Sebastián Parra Sánchez**

Ingrid Durley Torres Pardo***

Carmen Ysabel Martínez de Meriño****

Recibido: 14-04-2022

Aceptado: 27-07-2022

Citar como: Parra Sánchez, J. S., Torres Pardo, I. D. y Martínez de Meriño, C. Y. (2023). Personalización de recursos para la enseñanza de matemáticas universitarias usando inteligencia artificial. *Revista Interamericana de Investigación, Educación y Pedagogía*, 16(1), 319-340. <https://doi.org/10.15332/25005421.7904>

Resumen

Objetivo: presentar un modelo de personalización de recursos de aprendizaje usando técnicas de inteligencia artificial (IA) para la enseñanza de matemáticas universitarias. **Metodología:** El modelo se construyó basado en los estilos de aprendizaje de Felder y Silverman y en un cuestionario de saberes previos aplicado a los estudiantes en álgebra, geometría y trigonometría una vez ingresan a carreras

*Artículo de investigación científica y tecnológica. El artículo se deriva del proyecto de investigación doctoral: "Modelo de personalización de estrategias de aprendizaje basado en inteligencia artificial para estudiantes en riesgo de deserción universitaria por desempeño académico", ejecutado en el marco del doctorado en Educación de la Universidad Católica Luis Amigó y con el apoyo del grupo de investigación Grupo Sistemas De Información y Sociedad del Conocimiento SISCO.

**Candidato a doctor en Educación. Magíster en Ingeniería. Docente de la Universidad Católica Luis Amigó. Medellín, Colombia.
Correo electrónico: juan.parraan@amigo.edu.co
CVLAC: https://scienti.minciencias.gov.co/cvlac/visualizador/generarCurriculoCv.do?cod_rh=0000072898
Google Scholar: <https://scholar.google.es/citations?hl=es&user=-.84PbicAAAAJ>
ORCID: <https://orcid.org/0000-0002-5873-3894>

***Doctora en Ingeniería. Ingeniera de sistemas. Docente de la Universidad Católica Luis Amigó, Medellín, Colombia.
Correo electrónico: ingrid.torrespa@amigo.edu.co
CVLAC: https://scienti.minciencias.gov.co/cvlac/visualizador/generarCurriculoCv.do?cod_rh=00011404075
Google Scholar: <https://scholar.google.es/citations?hl=es&user=nchHazIAAAAAJ>
ORCID: <https://orcid.org/0000-0003-4503-7512>

****Doctora en Educación. Magíster en Educación. Docente de la Universidad Católica Luis Amigó, Medellín, Colombia.
Correo electrónico: carmen.martinezde@amigo.edu.co
CVLAC: https://scienti.minciencias.gov.co/cvlac/visualizador/generarCurriculoCv.do?cod_rh=0000031091
Google Scholar: <https://scholar.google.es/citations?hl=es&user=a5eJhxMAAAAAJ>
ORCID: <https://orcid.org/0000-0002-8134-2306>

profesionales de ingeniería. *Resultados:* Se analizaron las recomendaciones de recursos de aprendizaje por estilos de aprendizaje y se aplicaron técnicas de IA, para encontrar patrones en siete grupos diferentes de estudiantes. *Conclusión:* Con este modelo se evaluó la posibilidad de realizar una adecuada recomendación de recursos de aprendizaje, teniendo en cuenta el tipo y el orden de presentación de estos y, además, sobre las áreas que se deben priorizar en el ingreso a la universidad.

Palabras clave: enseñanza de las matemáticas, inteligencia artificial, educación universitaria, aprendizaje, recursos educativos abiertos, álgebra, geometría.

Personalization of resources for the teaching of university mathematics using artificial intelligence

Abstract

Objective: to present a model for the personalization of learning resources using artificial intelligence (AI) techniques for the teaching of university mathematics. *Methodology:* The model was built based on the learning styles of Felder and Silverman and on a prior knowledge questionnaire applied to students in algebra, geometry and trigonometry once they enter professional engineering careers. *Results:* The recommendations of learning resources by learning styles were analyzed and AI techniques were applied, to find patterns in seven different groups of students. *Conclusion:* With this model, the possibility of making an adequate recommendation of learning resources was evaluated, considering the type and order of presentation of these and, in addition, on the areas that should be prioritized when entering the university.

Keywords: mathematics education, artificial intelligence, higher education, learning, open educational resources, algebra, geometry.

Personalização de recursos para o ensino de matemática universitária usando inteligência artificial

Resumo

Objetivo: apresentar um modelo de personalização de recursos de aprendizagem utilizando técnicas de inteligência artificial (IA) para o ensino de matemática universitária. *Metodologia:* O modelo foi construído com base nos estilos de aprendizagem de Felder e Silverman e em um questionário de conhecimentos prévios aplicado a alunos de álgebra, geometria e trigonometria ao ingressarem nas carreiras profissionais de engenharia. *Resultados:* Foram analisadas as recomendações de recursos de aprendizagem por estilos de aprendizagem e aplicadas técnicas de IA, para encontrar padrões em sete grupos diferentes de alunos. *Conclusão:* Com este modelo, avaliou-se a possibilidade de fazer uma recomendação adequada de recursos de aprendizagem, levando em consideração o tipo e ordem de apresentação destes e, além disso, sobre as áreas que devem ser priorizadas ao ingressar na universidade.

Palavras-chave: ensino de matemática, inteligência artificial, formação universitária, aprendendo, recursos educacionais abertos, álgebra, geometria.

Introducción

La personalización de recursos de aprendizaje está relacionada con la adaptación del currículo y los entornos de aprendizaje para

satisfacer las necesidades de los estudiantes en su proceso educativo (Rivero *et al.*, 2019). Con este fin, los enfoques relacionados con la personalización no se orientan a que todo el alumnado alcance los objetivos de la misma forma, sino que toma en consideración las características, condiciones y estilos de aprendizaje de cada sujeto. Un enfoque en el cual el docente pueda conocer de antemano esta información de sus estudiantes facilitaría la toma de decisiones frente a la planeación y el trayecto de actividades, permitiendo así mejorar el rendimiento académico de los estudiantes y la motivación (Castro *et al.*, 2020).

Por su parte, a diferencia de la individualización y diferenciación que están centradas en el papel del docente respecto al proceso de enseñanza, la personalización está centrada en el estudiante. A este respecto, uno de los grandes retos que presenta la personalización es cómo obtener la información sobre el proceso de aprendizaje de los diferentes alumnos presentes en la clase y cómo procesarla para ajustar la acción educativa más adecuada para cada uno de ellos. Este ha sido tradicionalmente el gran obstáculo para llevar a la práctica este tipo de enseñanza y el origen de las críticas que se le han hecho con cierta frecuencia (Coll, 2016).

Sin embargo, la personalización del aprendizaje, aunque ha demostrado ser un desafío difícil para las universidades (Lerís *et al.*, 2017), también ha comenzado a ser una actividad más frecuente tanto para las instituciones educativas como para las empresas de software (Simanca *et al.*, 2018) aunque implica importantes costos en recurso humano, tecnológico y un elevado esfuerzo académico para adaptar los contenidos, particularmente en cursos presenciales (Rincón *et al.*, 2019).

Ahora bien, ¿cuál es el recurso o herramienta por utilizar, para la construcción de un modelo de personalización que integre las variables descritas? La aplicación de la IA permite explorar desde una

atractiva perspectiva el dinamismo del aprendizaje en relación con el proceso de la educación personalizada. El fin último de la IA en la educación es definido por Pearson y el *University College* de Londres como: “la consecución de un entendimiento más profundo y exacto de cómo ocurre el proceso de aprendizaje en los estudiantes” (León y Viña, 2017).

Dentro de la IA, entre muchas técnicas, se encuentra el aprendizaje automático (*machine learning*), el cual es un subconjunto que utiliza algoritmos informáticos para analizar datos y tomar decisiones inteligentes basadas en lo que ha aprendido. En un modelo tradicional, se ingresan los datos de las variables y las reglas para obtener una respuesta, mientras que en un modelo de *machine learning* basado en IA, se ingresan los datos y las respuestas y el algoritmo crea las reglas que permiten relacionar las entradas (datos) con las respuestas (salidas).

Los enfoques como el de la inteligencia artificial (IA), vienen siendo utilizados para enriquecer los procesos de enseñanza aprendizaje, y se crean en una de sus líneas, espacios de trabajos personalizados, que tienen como base los estilos de aprendizaje de cada estudiante (Rivero *et al.*, 2019). Algunos trabajos sobre el tema mencionados por Donoso *et al.* (2018) muestran que los estudiantes que toman cursos personalizados autoguiados presentan mayor grado de persistencia y permanencia en los estudios que los que siguen cursos tradicionales. Sin embargo, la mayoría de estos trabajos no tienen en cuenta un diagnóstico inicial de las competencias genéricas con las que ingresan los estudiantes a la educación superior.

En el contexto de las matemáticas universitarias, dichas competencias genéricas o saberes previos pueden referirse a tres áreas fundamentales: el álgebra, la geometría y la trigonometría. Al respecto, se coincide con Vargas y Montero (2016) al afirmar que es ineludible determinar objetivamente el nivel de conocimientos

que poseen los estudiantes y conocer ciertas actitudes que tienen los mismos hacia el aprendizaje, dado que esto puede constituirse en una información muy valiosa para los procesos de enseñanza.

Otros estudios (Valbuena *et al.*, 2021; Pérez *et al.*, 2019; Soria y Zúñiga, 2014; Bravo y Mejía, 2010) presentan planteamientos que indican que las dificultades pedagógicas y de formación de profesores en la enseñanza de ciencias básicas, como las matemáticas en la educación media, serían factores que estarían repercutiendo no solo en la deserción de las ingenierías, sino también en otras áreas del conocimiento que tienen como base, las matemáticas universitarias. Ante esto, se evidencia que hay una dificultad bidireccional para el docente y para los estudiantes en la enseñanza de dicha área del conocimiento (Chiliquinga y Balladares, 2020).

Vale la pena destacar, que una de las variables más importantes que se encuentra en los enfoques de personalización está asociada a los estilos de aprendizaje, como la manera que tiene el estudiante para entender y aprehender el mundo y, sobre todo, la forma en la que adquiere conocimiento. Por otra parte, desde el punto de vista de los estudiantes se ha encontrado que estos pueden mejorar sus resultados al comprender su propia manera de aprender.

Respecto a este concepto se encuentran aproximadamente 71 modelos diferentes de estilos de aprendizaje en la literatura para comparar la forma en la que un estudiante en particular entiende, procesa y percibe información sobre una temática (Ciloglugil & Inceoglu, 2016). Si bien fueron propuestos hace aproximadamente tres décadas, retoman importancia gracias al auge de las TIC utilizadas en los procesos educativos y que han llevado a impulsar el aprendizaje autónomo en los individuos (Rodríguez, 2018).

Es importante tener en cuenta que, aunque los estudiantes muestran gran motivación por estas estrategias que involucran la innovación y el

manejo de las Tecnologías de la Comunicación y la Información (TIC), también se enfatiza en lo indispensable del componente pedagógico de cara a las diferencias que se presentan de acuerdo con los estilos de aprendizaje (Camacho *et al.*, 2012).

El modelo que se presenta en este estudio es de personalización, dado que está centrado en el estudiante y se adapta a las características de este; además, toma en consideración el estilo de aprendizaje y los saberes previos y otras variables propias en las que se puedan revisar sus intereses y adaptar las estrategias de aprendizaje acorde con sus necesidades y ritmos, que potencian y contextualizan su desarrollo.

Metodología

En este estudio, se tuvo como objetivo presentar un modelo de personalización de recursos de aprendizaje usando técnicas de inteligencia artificial para la enseñanza de matemáticas universitarias en los niveles iniciales de educación superior, donde se presenta la mayor tasa de reprobación en las áreas de ciencias básicas. La muestra del estudio estuvo conformada por los estudiantes de pregrado que ingresaron a los programas de ingeniería de una universidad privada colombiana en el primer semestre del año 2021. Los estudiantes participaron en el estudio como parte de una estrategia frente a la mitigación de la deserción en la escuela de ingenierías.

Los datos fueron obtenidos a través de dos instrumentos, que se aplicaron por medio de un sistema gestor del aprendizaje (SGA). La recolección de datos fue realizada durante los primeros meses del año 2021 de forma remota. El primer instrumento consistió en un cuestionario para evaluar los estilos de aprendizaje de los estudiantes. El enfoque que se seleccionó fue el de Felder y

Silverman, debido a que es el más apropiado para ambientes de aprendizaje virtual y ha sido ampliamente aplicado en contextos de personalización (Nafea *et al.*, 2019).

El enfoque de Felder y Silverman concibe el estilo de aprendizaje basado en algún rasgo bipolar en cuatro dimensiones o categorías dicotómicas. Felder (1993) para realizar una primera clasificación de los estilos de aprendizaje, formuló preguntas que originan dimensiones de las diferentes preferencias para recibir y procesar información tal y como se expone en la Tabla 1, en la que se encuentra el cuestionamiento y las dimensiones de rasgo bipolar que dan respuesta a él.

Tabla 1. Cuestionamiento y dimensiones para el enfoque de estilos de aprendizaje de Felder y Silverman.

Cuestionamiento	Dimensiones
¿Qué tipo de información preferentemente perciben los estudiantes?	Sensorial/Intuitivo
¿A través de qué sentidos los estudiantes preferentemente perciben la información?	Visual/Verbal
¿De qué manera los estudiantes prefieren procesar la información?	Activo/Reflexivo
¿De qué manera los estudiantes entienden y procesan los contenidos que se les presentan?	Secuencial/Global

Fuente: elaboración propia

El instrumento para evaluar los estilos de aprendizaje según el enfoque de Felder y Silverman se conoce como el cuestionario ILS (*Index of Learning Style*). En este cuestionario, a cada categoría bipolar que se expone en la Tabla 1, le corresponden once (11) preguntas. Es decir, hay 11 preguntas para la categoría activo/reflexivo, 11 para secuencial/global y así sucesivamente, por lo que es posible evidenciar una predominancia por un estilo de aprendizaje u otro y a cada estudiante se le asignan cuatro estilos predominantes de acuerdo con cada dimensión.

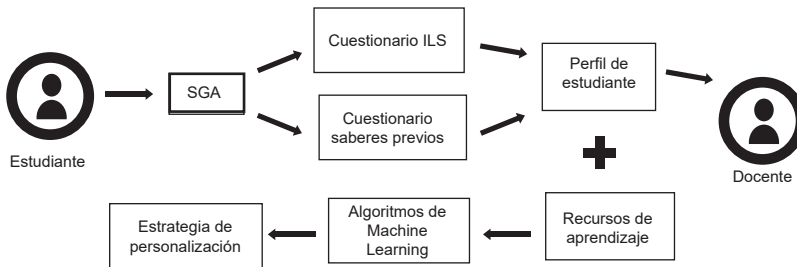
El segundo instrumento consistió en un cuestionario de saberes previos de 30 preguntas, basado en tres módulos relacionados con las áreas de álgebra, geometría y trigonometría. En este cuestionario, se presentaron 10 preguntas de cada una de estas áreas, en un formato de selección múltiple con única respuesta. Este cuestionario fue validado con anterioridad con el fin de evaluar su consistencia interna y su viabilidad para ser aplicado.

Para la administración y aplicación de los diferentes instrumentos, se contó con el aval de los directivos de la universidad, así mismo con el consentimiento informado de los estudiantes que accedieron a un sistema gestor del aprendizaje. Los datos fueron analizados por medio de R y Weka. Se protegió la identidad de los estudiantes de acuerdo con la ley de protección de datos y cada uno de los pasos del plan de investigación estuvo resumido en un formato de consentimiento. Por otra parte, los resultados de la investigación fueron guardados con un código numérico o identificador para cada estudiante, con el fin de lograr trazabilidad con los datos y preservar que el estudio fuera de carácter anónimo.

Resultados y discusión

La Figura 1 consolida cada uno de los elementos del modelo de personalización propuesto. El proceso inicia cuando el estudiante ingresa al Sistema de gestión del aprendizaje (SGA) y diligencia los dos instrumentos: el primero, orientado a conocer su estilo de aprendizaje y el segundo, un cuestionario de saberes previos. El proceso paso a paso se describe en esta sección.

Figura 1. Propuesta de modelo de personalización.



Fuente: elaboración propia

SGA. Un sistema de gestión del aprendizaje (SGA) se puede definir como un software que permite la creación y gestión de entornos virtuales de aprendizaje de forma automatizada. En el caso del principio de personalización se tiene como objetivo evitar el inadecuado uso de recursos en diversos formatos, que pueden llevar a la distracción y falta de motivación del estudiante en el uso de un SGA, lo que puede causar fracaso en su proceso (Carvalho *et al.*, 2017). Para este estudio, se utilizó la plataforma Moodle.

Perfil del estudiante. Una vez aplicados los instrumentos anteriores, se construyó una base de datos de estudiantes con los resultados de ambos cuestionarios, con el fin de crear un perfil del estudiante que integrara tanto los estilos de aprendizaje como los saberes previos. Este perfil de estudiante es entregado al docente con el fin de que pueda conocer con anterioridad las características del grupo. El docente a su vez es quien selecciona y diseña los recursos de aprendizaje de acuerdo con sus conocimientos y los objetivos de aprendizaje. La manera en que se consolidó la información de ambos cuestionarios para los estudiantes se muestra en la Tabla 2 a modo de ejemplo de los tres primeros estudiantes que participaron en el estudio. Para las categorías de álgebra (Alg), geometría (Geo) y trigonometría (Trig), los datos están dados en porcentaje de respuestas correctas.

De esta forma, el estudiante de ID 1, respondió de forma correcta al 90 % de preguntas de álgebra, al 50 % de preguntas de geometría y al 60 % de preguntas de trigonometría. Los demás atributos (columnas), indican los resultados del cuestionario de estilos de aprendizaje para cada una de las dimensiones descritas anteriormente en la Tabla 1. En este caso, por ejemplo, el estudiante de ID 1, tiene un porcentaje 64 % activo (Act) respecto a un 36 % reflexivo (Ref), 55 % sensorial (Sen) y 45 % intuitivo (Int), 73 % visual (Vis) y 27 % verbal (Ver) y finalmente, 55 % Secuencial (Sec) y 45 % Global (Glo).

Tabla 2. Perfil del estudiante de acuerdo con su estilo de aprendizaje y cuestionario de saberes previos.

ID	Saberes previos			Estilo de aprendizaje							
	Alg	Geo	Trig	Act	Ref	Sen	Int	Vis	Ver	Sec	Glo
1	0.9	0.5	0.6	0.64	0.36	0.55	0.45	0.73	0.27	0.55	0.45
2	0.8	0.7	0.7	0.36	0.64	0.45	0.55	0.73	0.27	0.64	0.36
3	0.4	0.3	0.5	0.73	0.27	0.45	0.55	0.91	0.09	0.73	0.27


Fuente: elaboración propia

Algoritmos de Machine Learning. La IA, en su rama de Machine Learning, presenta, entre otras técnicas, el agrupamiento (*clustering*), una de las herramientas de minería de datos más comúnmente utilizada en los sistemas de recomendación, con el fin de desarrollar reglas o construir modelos a partir de grandes conjuntos de datos (Gironés *et al.*, 2017).

Esta técnica (también llamada segmentación) consiste en agrupar la información por clústeres cuyo objetivo es encontrar grupos similares en los juegos de datos que tengan dos características: separabilidad y cohesión. La separabilidad se refiere a la existencia de diferencias significativas entre los grupos hallados (heterogeneidad intergrupo) y la cohesión, a la cercanía de los elementos de un grupo a su centroide (homogeneidad intragrupo) (Gironés *et al.*, 2017), teniendo en cuenta que el valor de cada centroide es calculado como la media de todos los puntos que pertenecen a ese grupo.

Uno de los principales cuestionamientos que se dan al aplicar esta técnica, es cual es la cantidad de clústeres que debe seleccionarse. Para subsanar este interrogante, se usa el método del codo (Mandale *et al.*, 2021), en el que se calcula y grafica la suma de errores cuadráticos respecto al número de clústeres y se busca un cambio de pendiente de empinada a poca profundidad, con el fin de determinar el número óptimo de clústeres. En la Figura 2, se muestra dicha gráfica para el caso de este estudio. De acuerdo con lo anterior, se seleccionan 7 clústeres como número óptimo.

Figura 2. Comparación del número de clústeres respecto a la suma de errores cuadráticos.



Fuente: elaboración propia

Estrategia de personalización. Basado en Nafea *et al.* (2019), hay varias formas en las que un SGA puede ser utilizado para la gestión del aprendizaje personalizado: el primero, consiste en filtrado colaborativo, la cual es una técnica para generar recomendaciones en las que hay similitud de opiniones sobre algunos recursos de aprendizaje, y que son utilizadas para predecir opiniones para otros similares.

El segundo, basado en contenido, consiste en una técnica para crear recomendaciones basadas en el contenido de los recursos de aprendizaje y los perfiles de las preferencias de los estudiantes. El tercero, basado en el conocimiento, es una técnica para proporcionar recomendaciones utilizando modelos de conocimiento sobre los estudiantes y los recursos de aprendizaje. Para este estudio se tomó un enfoque híbrido basado tanto en el contenido de los recursos de aprendizaje como en el conocimiento.

Un primer hallazgo está relacionado con los estudios de personalización basados en el enfoque de Felder y Silverman, en los que se encontraron diferencias respecto a las recomendaciones del recurso de aprendizaje más apropiado para cada estilo de aprendizaje (Arnao *et al.*, 2017; Borges y Stiubiener, 2014; Carvalho *et al.*, 2017; Cilogluligil & Inceoglu, 2016; Dorca *et al.*, 2016; Duque *et al.*, 2016; Ramirez *et al.*, 2016). La Tabla 3 muestra un resumen del porcentaje de estudios que recomiendan cada tipo de recurso para cada uno de los estilos de aprendizaje.

Por ejemplo, al revisar la primera fila, respecto al recurso de aprendizaje "Ejercicio", se encuentra que el 100 % de los estudios encontrados recomienda este recurso de aprendizaje para estudiantes de estilo de aprendizaje activo (Act) mientras que el 0 % de estudios recomienda el ejercicio para estudiantes predominantemente reflexivos (Ref). Continuando con este ejemplo, el 57 % de estudios recomiendan el ejercicio para estudiantes sensoriales (Sen) y el 0 % para estudiantes intuitivos (Int), el 14 % para estudiantes visuales (Vis), 0 % para estudiantes verbales, 28 % para estudiantes secuenciales (Sec) y 0 % para estudiantes globales (Glo).

Respecto al orden en el que se presentan los recursos al estudiante, estos pueden mostrarse de lo específico a lo general o comenzar desde lo general y proceder a la parte específica para comprensión del todo.

En la Tabla 3 se presentan las coincidencias de estudios en cuanto a la recomendación de recursos de aprendizaje para cada estilo en particular. Para el caso de los estudiantes activos, la mayoría coincide en que los ejercicios, simulaciones y experimentos son los tipos de recursos más adecuados, seguidos por los cuestionarios, exámenes y autoevaluación.

Para los estudiantes reflexivos, los textos son los recursos más predominantes, seguidos por las tablas, imágenes, diagramas y presentaciones. Respecto a los estudiantes sensoriales, se encuentran las simulaciones y tablas, seguidos por los ejercicios y experimentos, mientras que los estudiantes intuitivos prefieren diagramas y textos. Para los estudiantes visuales, se encuentran con mayor porcentaje las imágenes, diagramas y videos, mientras que para los verbales, los cuestionarios, textos y la clase/conferencia.

Por otra parte, en las dos últimas columnas de la Tabla 3 se puede observar que la dimensión secuencial/global no genera recomendaciones de tipo de recurso importantes según los autores de los estudios encontrados, pero sí puede referir el orden en el que se muestran dichos recursos, en este caso, a los estudiantes secuenciales se muestran los recursos en forma lineal (de lo específico a lo general) mientras que los estudiantes globales (de lo general a lo específico).

Tabla 3. Porcentaje de documentos que referencian tipo de recurso y estilo de aprendizaje de acuerdo con el enfoque de Felder y Silverman

Tipo de recurso	Act	Ref	Sen	Int	Vis	Ver	Sec	Glo
Ejercicio	100 %	0 %	57 %	0 %	14 %	0 %	28 %	0 %
Simulación	100 %	14 %	86 %	14 %	43 %	0 %	28 %	0 %
Cuestionario	71 %	28 %	14 %	43 %	14 %	57 %	14 %	0 %
Examen	71 %	28 %	43 %	43 %	28 %	14 %	28 %	14 %

Tipo de recurso	Act	Ref	Sen	Int	Vis	Ver	Sec	Glo
Diagrama	0%	71%	14%	86%	86%	0%	28%	14%
Imagen	0%	86%	28%	43%	71%	0%	14%	14%
Presentación	14%	57%	28%	43%	43%	14%	14%	0%
Tabla	14%	86%	86%	0%	43%	28%	14%	14%
Texto	0%	100%	14%	57%	0%	71%	28%	0%
Experimento	86%	14%	57%	0%	28%	14%	28%	0%
Clase	0%	71%	14%	14%	0%	71%	14%	0%
Vídeo	14%	14%	14%	0%	57%	0%	0%	0%
Resumen	0%	14%	0%	14%	0%	0%	0%	14%
Autoevaluación	71%	28%	28%	28%	28%	43%	28%	14%
Estructura	0%	57%	43%	14%	43%	14%	0%	14%

Fuente: elaboración propia

Una vez revisado el tipo de recurso apropiado para cada estilo de aprendizaje y realizado el perfil del estudiante, se procedió a la aplicación de la técnica de agrupamiento o segmentación. En la Tabla 4, se muestran los resultados con los centroides para cada uno de los siete clústeres creados en el modelo.

A cada grupo se le ha asignado la letra C, seguida de un número para identificarlo. El número que se encuentra en la segunda fila corresponde a la cantidad de estudiantes que quedaron agrupados en cada clúster, lo que permitirá asignar a cada grupo los recursos de aprendizaje apropiados, en un orden determinado y con una cantidad y nivel de énfasis, de acuerdo con los resultados del cuestionario de saberes previos.

En cuanto a la columna sombreada, esta corresponde al total de los datos de los estudiantes. Para el caso de los estudiantes de primer semestre de ingeniería, se encontró, en general, una predominancia por los estilos de aprendizaje activo, sensorial, visual y secuencial. Sin embargo, es posible establecer diferencias entre cada uno de los clústeres hallados.

Tabla 4. Resultados del proceso de agrupamiento (clustering)

	Total Datos	C0	C1	C2	C3	C4	C5	C6
Atributo/ Registros	100	16	15	20	4	22	16	7
Activo	0.61	0.58	0.40	0.70	0.80	0.71	0.53	0.68
Reflexivo	0.39	0.42	0.60	0.30	0.20	0.29	0.47	0.32
Sensorial	0.59	0.65	0.42	0.44	0.73	0.70	0.68	0.59
Intuitivo	0.41	0.35	0.58	0.55	0.27	0.30	0.32	0.41
Visual	0.60	0.68	0.50	0.55	0.87	0.50	0.61	0.89
Verbal	0.40	0.32	0.50	0.45	0.13	0.50	0.39	0.11
Secuencial	0.63	0.60	0.55	0.62	0.45	0.71	0.60	0.76
Global	0.37	0.40	0.45	0.38	0.55	0.29	0.40	0.24
Álgebra	0.51	0.21	0.41	0.73	0.43	0.47	0.70	0.53
Geometría	0.48	0.29	0.31	0.68	0.25	0.51	0.63	0.46
Trigonometría	0.48	0.18	0.37	0.76	0.52	0.40	0.59	0.53

Fuente: elaboración propia

Al observar los centroides hallados, se encontraron diferentes hallazgos. Por ejemplo, en el clúster cero (C0) en el que quedaron 16 estudiantes segmentados, se tiene un valor de 0.21 para álgebra, 0.29 para geometría y 0.18 para trigonometría, esto refiere dificultades en cuanto a los saberes previos dado que, en promedio, contestaron correctamente a 2 de las 10 preguntas de álgebra y trigonometría y a 3 de las 10 preguntas para el caso de geometría. Al revisar los estilos de aprendizaje predominantes en dicho grupo, se encuentra predominio en cuanto al estilo de aprendizaje activo, sensorial, visual y secuencial.

A partir de los resultados de la tabla 4, se puede evidenciar, además, que solo en el clúster 3 (C3) en el que quedaron 4 estudiantes segmentados, se encuentra una predominancia respecto a un estilo Global (0.55) sobre el secuencial (0.45), pero solamente cuatro estudiantes quedaron agrupados allí. Es decir, en general, los estudiantes se orientan hacia una comprensión de tipo analítica siguiendo procesos lineales y predeterminados, sobre el entendimiento holístico de los contenidos. Esto conduce a una relación importante respecto al orden en el que se le presentará los contenidos a este grupo en particular.

Respecto a los estudiantes activos y reflexivos, únicamente en un clúster (C1) se encuentra una predominancia por el estilo reflexivo, que además es el que presenta mayor predominancia por el estilo intuitivo.

En general, todos los grupos corresponden a estudiantes que son más visuales o que no tienen un predominio marcado respecto a la dimensión visual/verbal y no se encontraron grupos con predominio verbal.

En relación con los resultados de saberes previos, los valores encontrados en cada clúster se relacionan entre sí. Por ejemplo, en el clúster 0 (C0), los valores relacionados con las competencias en matemáticas están por debajo de 0.30, lo que indica unos resultados bajos, mientras que en el clúster 2, todos los valores son superiores a 0.70, lo que denota un mejor desempeño, con lo que se puede ver un comportamiento similar entre todas las áreas; es decir, los resultados de saberes previos mostraron ser muy similares para las tres áreas evaluadas en relación con las matemáticas universitarias. Así, el resultado de un estudiante en álgebra, se relaciona con el resultado en geometría y trigonometría, siendo los resultados más bajos los que se presentan en geometría, seguido por trigonometría.

Otro hallazgo importante se refiere a que, en general, los resultados de la prueba de saberes previos indican que, en promedio, un estudiante que ingresa a la universidad a cursar una carrera de ingeniería, responde correctamente a 1 de cada 2 preguntas relacionadas con las áreas de álgebra, geometría y trigonometría, que son revisadas a lo largo de la educación básica y media y que se consolidan como el punto de partida de carreras profesionales, principalmente en ingenierías, ciencias exactas y ciencias administrativas.

Conclusiones

En comparación con la revisión de la literatura, este modelo contribuye a los enfoques de personalización tradicionales, dado que no se tiene en cuenta el nivel de saberes previos con los que los estudiantes ingresan a las carreras profesionales, como en el caso de las ingenierías. Se logró en este estudio establecer mediante agrupamiento un perfil de estudiante con base a los saberes previos y el estilo de aprendizaje para personalizar recursos de aprendizaje para la enseñanza de matemáticas universitarias a estudiantes de primer semestre de ingeniería, basado en las áreas de álgebra, geometría y trigonométrica.

En cuanto a las técnicas de aprendizaje automático, en relación con la IA, el agrupamiento como estrategia permitiría crear una alerta temprana sobre aquellos estudiantes que ingresan con un bajo nivel de saberes previos necesarios para afrontar las matemáticas universitarias, al mismo tiempo, que permite revisar cuál debe ser el enfoque apropiado para presentar la información de acuerdo a su tipo, orden y énfasis.

Respecto a las recomendaciones de recursos de aprendizaje, basados en las dimensiones propuestas por Felder y Silverman, se encuentra que no hay igualdad de criterio entre los autores, por lo que se propuso una nueva tabla que resume dichos enfoques.

Principalmente, para la dimensión global/secuencial, no se encuentra claridad respecto al tipo de recurso más adecuado, pero se puede utilizar esta información para seleccionar el orden en el cual se presentan los recursos.

Por otro lado, de acuerdo con los resultados obtenidos, los estudiantes que ingresan a carreras profesionales de ingeniería tienen una predominancia en cuanto al procesamiento de la información activa, esto indica preferencias hacia el procesamiento a través de la aplicación de los conocimientos y el trabajo en grupo, ejercicios, simulaciones y experimentos. Respecto a los saberes previos, los estudiantes, en promedio, responden a una de dos preguntas acertadamente dentro de las áreas de álgebra, geometría y trigonometría, lo que evidencia la importancia de fortalecer estas competencias, una vez los estudiantes ingresan a la educación superior.

Finalmente, como trabajo futuro, se pretende seguir monitoreando el modelo para que los estudiantes participen activamente y realicen comentarios para validar que efectivamente las recomendaciones realizadas sean adecuadas en función de los estilos de aprendizaje encontrados y la revisión teórica. Además, que el hecho de conocer los perfiles de estudiantes permita no solo generar recomendaciones, sino también tomar acciones pedagógicas más focalizadas, basada en el análisis previo de los datos.

Referencias

- Borges, G., y Stiubiener, I. (2014). Recommending Learning Objects Based on Utility and Learning Style. *IEEE Frontiers in Education Conference (FIE) Proceedings*, 1–9. <https://10.1109/FIE.2014.7044245>
- Bravo, M., y Mejía, A. (2010). Los retos de la educación superior en Colombia: Una reflexión sobre el fenómeno de la deserción universitaria. *Revista Educación En Ingeniería*, 5(10), 85–98. <https://bit.ly/3mYogo8>

- Camacho, J., Laverde, I., y Clara, I. (2012). Blended Learning y estilos de aprendizaje en estudiantes universitarios del área de la salud Blended learning and learning styles in university students of the health areas. *Revista de Educación Médica Superior*, 26(1), 27–44. <https://bit.ly/3o9lvzp>
- Carvalho, Z., Ferreira, L., y Pimentel, A. (2017). Adaptation of Learning Object Interface based on Learning Style. *ICIES*, 3, 119–126. <https://doi.org/10.5220/0006319001190126>
- Castro, B., Manrique, R., González, D., y Segura, A. (2020). Academic trajectory and factors associated with graduation, dropout and graduation delay in undergraduate students at a private university of Medellín (Colombia). *Formación Universitaria*, 13(1), 43–54. <https://doi.org/10.4067/S0718-50062020000100043>
- Ciloglugil, B., & Inceoglu, M. (2016). A felder and silverman learning styles model based personalization approach to recommend learning objects. *Lecture Notes in Computer Science*, 9790, 386–397. https://doi.org/10.1007/978-3-319-42092-9_30
- Chiliquinga-Campos, F, y Balladares-Burgos, J. (2020). Rutinas de pensamiento: Un proceso innovador en la enseñanza de la Matemática. *Revista Andina De Educación*, 3(1), 53-63. <https://doi.org/10.32719/26312816.2020.3.1.9>
- Coll, C. (2016). La personalización del aprendizaje escolar El qué, el por qué y el cómo de un reto insoslayable. *Universidad de Barcelona. Reptes de l'educació a Catalunya. Anuari d'Educació*.
- Donoso, S., Iturrieta, T., y Traverso, G. (2018). Sistemas de Alerta Temprana para estudiantes en riesgo de abandono de la Educación Superior. *Ensaio: Avaliação e Políticas Públicas Em Educação*, 26(100), 944–967. <https://doi.org/10.1590/s0104-40362018002601494>
- Dorca, F., Araújo, R., de Carvalho, V., Resende, D., y Cattelan, R. (2016). An Automatic and Dynamic Approach for Personalized Recommendation of Learning Objects Considering Students Learning Styles: An Experimental An Automatic and Dynamic Approach for Personalized Recommendation of Learning Objects Considering Students. *Learning Informatics in Education*, 15(1), 45–62. <https://doi.org/10.15388/infedu.2016.03>
- Duque, N., Tabares, V., y Vicari, R. (2016). Learning Object Metadata Mapping with Learning Styles as a Strategy for Improving Usability of Educational Resource Repositories. *Revista Iberoamericana de Tecnologías Del Aprendizaje*, 11(2), 101–106. <https://doi.org/10.1109/RITA.2016.2554038>

- Gironés-Roig, J., Casas-Roma, J., Minguillón-Alfonso, J., y Caihuelas-Quiles, R. (2017). *Minería de datos: Modelos y Algoritmos*. Editorial UOC. <https://doi.org/10.1017/CBO9781139058452.002>
- León, G. de la C., y Viña, S. M. (2017). La inteligencia artificial en la educación superior. Oportunidades y amenazas. *INNOVA Research Journal*, 2(8.1), 412–422. <https://doi.org/10.33890/innova.v2.n8.1.2017.399>
- Lerís, D., Sein M. L., Hernández, M., y Bueno, C. (2017). Validation of indicators for implementing an adaptive platform for MOOCs. *Computers in Human Behavior*, 72, 783–795. <https://doi.org/10.1016/j.chb.2016.07.054>
- Mandale, R., Patil, A., y Adamuthe, A. (2021). Improved Undergraduate Software Capstone Project Development with Adoption of Industry Practices. *Journal of Engineering Education Transformations* ,34(4), 74-89. <https://doi.org/10.16920/jeet/2021/v34i4/153757>
- Maza, L., Raymundo, C., y Domínguez, F. (2017). Modelo de asociación entre objetos y estilos de aprendizajes para una Plataforma de aprendizaje adaptativo. *CICIC 2017*, 148–153. <https://bit.ly/3bHLB6S>
- Nafea, S., Siewe, F., y He, Y. (2019). A Novel Algorithm for Course Learning Object Recommendation Based on Student Learning Styles. 2019 *International Conference on Innovative Trends in Computer Engineering*, 192-201. <https://doi.org/10.1109/ITCE.2019.8646355>
- Pérez, C., Cerón, E., Suárez, R., Mera, M., Briones, N., Zambrano, L., y Barreto, M. (2019). Deserción y repitencia en estudiantes de la carrera de Enfermería matriculados en el período 2010-2015. Universidad Técnica de Manabí. Ecuador. 2017. *Educación Médica*, 20(2), 84–90. <https://doi.org/10.1016/j.edumed.2017.12.013>
- Ramirez, A., Bory, J., y Hernández, L. M. (2016). Learning Object Assembly Based on Learning Styles. *Smart Innovation, Systems and Technologies*, 59, 447–462. <https://doi.org/10.1007/978-3-319-39690-3>
- Rincón, E., Mena, J., López, E., y Olmos, O. (2019). Adaptive learning based on AI with predictive algorithms. *ACM International Conference Proceeding Series*, 607–612. <https://doi.org/10.1145/3362789.3362869>
- Rivero, D., Ulloa, N., Guerra, L., Arellano, B., y Arciniegas, S. (2019). Agente adaptativo para la enseñanza en ambientes inteligentes. *RISTI*, 694–707.

- Rodríguez, R. (2018). Los modelos de aprendizaje de Kolb, Honey y Mumford: implicaciones para la educación en ciencias. *Sophia*, 14(1), 51–64. <https://doi.org/10.18634/sophiaj.14v.1i.698>
- Rusell, S., y Norvig, P. (2004). *Inteligencia Artificial. Un Enfoque Moderno*. Pearson Education. Madrid.
- Simanca, H., Burgos, D., Crespo, R., y Baena, L. (2018). Automation of the tutoring process in online environments through the analytics of learning, *Iberian Conference on Information Systems and Technologies*, CISTI, 1–5. <https://doi.org/10.23919/CISTI.2018.8399403>
- Soria, K., y Zúñiga, S. (2014). Aspectos determinantes del éxito académico de estudiantes universitarios. *Formación Universitaria*, 7(5), 41–50. <https://doi.org/10.4067/S0718-50062014000500006>
- Valbuena, S., Jiménez, M. A., y Jiménez, W. (2021). Aportes de los actores de la práctica pedagógica al desarrollo de las competencias específicas en la licenciatura en matemática en formación virtual y presencial. *Revista Interamericana De Investigación Educación Y Pedagogía RIIEP*, 14(2), 247-275. <https://doi.org/10.15332/25005421.6114>
- Vargas, M., y Montero, E. (2016). Factores que determinan el rendimiento académico en Matemáticas en el contexto de una universidad tecnológica: aplicación de un modelo de ecuaciones estructurales. *Universitas Psychologica*, 15(4). <https://doi.org/10.11144/Javeriana.upsy15-5.eetc>

