

Modelo de recomendador de dedicación en Moodle con datos de Course Dedication Block

Álvaro Alexander Martínez-Navarro¹

Héctor Mauricio Sevillano-Ángulo²

Sebastián Camilo Estacio-Naranjo³

Giovanni Albeiro Hernández-Pantoja⁴

Franklin Eduardo Jiménez-Giraldo⁵

Robinson Andrés Jiménez-Toledo⁶

Resumen

En la educación los docentes mantienen un interés por mejorar el aprendizaje de los estudiantes, mediante diversas herramientas y técnicas que les ayudan a asimilar de mejor forma la información; esta situación se torna compleja, ya que todas las personas no se apropian con la misma rapidez de una asignatura. Desde la Inteligencia Artificial se vienen creando diferentes sistemas para dar solución a este panorama, los recomendadores construidos a partir de datos almacenados en sistemas gestores de aprendizaje son uno de ellos. En este trabajo se construyó un modelo para sistema de recomendación a partir de los datos del bloque de *Moodle Course Dedication*, para ello, se representó el perfil de usuario mediante la técnica basada en historia, se construyó un modelo de recomendación de dedicación de tiempo a una materia a través de filtrado colaborativo basado en ítem y se lo evaluó con un experimento *offline*. El 43 % de los estudiantes participantes

¹Docente, Universidad Mariana. Integrante del grupo de investigación GISMAR, Universidad Mariana, Pasto, Nariño, Colombia. Correo electrónico: amartinez@umariana.edu.co

²Correo electrónico: hesevillano@umariana.edu.co

³Correo electrónico: sestacio@umariana.edu.co

⁴Magíster en Docencia Universitaria, Especialista en Gerencia Informática, Ingeniero de Sistemas. Docente asociado tiempo completo e integrante del grupo de investigación GISMAR, Universidad Mariana, Pasto, Nariño, Colombia. Correo electrónico: gihernandez@umariana.edu.co

⁵Docente, Universidad Mariana. Integrante del grupo de investigación GISMAR, Universidad Mariana, Pasto, Nariño, Colombia. Correo electrónico: fjimenez@umariana.edu.co

⁶Docente, Universidad Mariana. Integrante del grupo de investigación GISMAR, Universidad Mariana, Pasto, Nariño, Colombia. Correo electrónico: rjimenez@umariana.edu.co

acogieron la recomendación generada por el modelo, de ellos el 33 % aprobó la asignatura, se alcanzó un 78 % aproximado de efectividad en la recomendación. El tiempo de dedicación a un curso en *Moodle* resultó ser un factor que incide en su superación.

Palabras clave: algoritmos de filtrado; Moodle Course Dedication Block; sistemas gestores de aprendizaje; sistemas recomendadores.

Dedication recommender model in Moodle with data from Course Dedication Block

Abstract

Although teachers maintain in their process interest in improving student learning through various tools and techniques that help them better assimilate information, this situation becomes complex, since not everyone appropriates a subject with the same speed. From Artificial Intelligence, different systems have been created to solve this panorama; recommenders built from data stored in learning management systems are one of them. In this work, a model for a recommendation system was built from the data of the Moodle Course Dedication block, representing the user profile through the history-based technique, building a recommendation model of time dedicated to a subject through collaborative item-based filtering, which was evaluated with an offline experiment. 43% of the participating students accepted the recommendation generated by the model; 33% of them passed the course, reaching an approximate 78% effectiveness in the recommendation. The time spent on a course in Moodle turned out to be a factor that affects its overcoming.

Keywords: filtering algorithms; Moodle Course Dedication Block; learning management systems; recommender systems.

Modelo de recomendação de dedicação em Moodle com dados do Bloco de Dedicção do Curso

Resumo

Embora os professores mantenham em seu processo o interesse em melhorar a aprendizagem dos alunos por meio de diversas ferramentas e técnicas que os ajudem a assimilar melhor as informações, essa situação torna-se complexa, pois nem todos se apropriam de uma matéria com a mesma velocidade. A partir da Inteligência Artificial, diversos sistemas foram criados para solucionar esse panorama; recomendadores construídos a partir de dados armazenados em sistemas de gerenciamento de aprendizagem são um deles. Um modelo para um sistema de recomendação foi construído neste trabalho, a partir dos dados do bloco *Moodle Course Dedication*, representando o perfil do usuário por meio da técnica baseada em histórico, construindo um modelo de recomendação de tempo dedicado a um assunto por meio de filtragem colaborativa baseada em itens, que foi avaliada com um experimento offline. 43% dos alunos participantes aceitaram a recomendação gerada pelo modelo; 33% deles foram aprovados no curso, atingindo uma efetividade de aproximadamente 78% na recomendação. O tempo despendido em um curso no Moodle acabou sendo um fator que interfere na sua superação.

Palavras-chave: algoritmos de filtragem; Bloco de Dedicção do Curso Moodle; sistemas de gestão de aprendizagem; sistemas de recomendação.

INTRODUCCIÓN

En la educación los docentes mantienen un interés por mejorar el aprendizaje de los estudiantes, esto se promueve entregándoles diversas herramientas y técnicas que les ayudan a asimilar de mejor forma la información; sin embargo, con esta idea y con base en la teoría de las inteligencias múltiples, se puede asumir que todos los estudiantes no asimilan con la misma rapidez la información o las temáticas de una asignatura (Gardner, 1983). Entonces, es imposible para el docente asumir que todos sus alumnos comprenderán la lección o quedarse y aplazar el avance de la clase por los estudiantes que aún no entienden el tema. Desde la Inteligencia Artificial se viene trabajando en estos aspectos; en específico los sistemas recomendadores han tomado fuerza en los últimos años en el campo educativo, debido a que son capaces de sugerir, de acuerdo con la información recolectada de las interacciones de los usuarios con aplicaciones, elementos relevantes y significativos según los intereses particulares (Anusha y Shilpa, 2016). En el ámbito escolar, los usuarios resultarían ser los estudiantes; las aplicaciones, por ejemplo, los sistemas gestores de aprendizaje, o por sus siglas en inglés llamados LMS, y los elementos, las experiencias de aprendizaje. Las plataformas mundiales como Amazon.com (<https://www.amazon.com/>) o Netflix.com (<https://www.netflix.com/>) entregan experiencias personalizadas en sus productos o servicios, a través de sus sistemas recomendadores con mucho éxito (Linden y Smith, 2017). En los ámbitos educativos se viene trabajando para aprovechar esos algoritmos y poder apoyar los procesos educativos, sobretodo en modalidades de E-learning, que, de acuerdo con el estudio de Zhong et al., (2019), mayoritariamente utilizan el filtrado híbrido como técnica de recomendación, combina diferentes métodos como el filtrado basado en contenido, ítem y colaborativo, con el propósito de optimizar los resultados y disminuir las limitaciones de un filtrado puro.

Este trabajo surge gracias a que los sistemas recomendadores aplicados a E-learning desde hace más de 5 años se han convertido en un campo de investigación, que atrae a muchos académicos (Zhong et al., 2019), por tanto, se transforma en una oportunidad y necesidad de indagación. Unido a lo anterior, la plataforma Moodle, como fuente de trabajo, también es blanco de diversos estudios, en especial porque no cuenta con un sistema recomendador que le permita al estudiante saber si su dedicación de tiempo a un curso, tema o unidad es suficiente. Estos dos insumos motivaron a la realización de esta investigación, más la oportunidad de investigación identificada en el estudio de literatura, hecho a continuación.

Muchos trabajos acerca de sistemas recomendadores en E-learning se orientan a la propuesta de modelos desde la teoría como algunos mencionados en Zhong et al. (2019); otros avanzan hacia consolidar investigaciones con resultados más concretos en el campo, donde los productos elaborados aplican técnicas de filtrado basado en contenido, ítem, colaborativo o híbrido, en un campo o contexto en específico de la educación, por ejemplo, CodERS (Ansari et al., 2017) es un recomendador híbrido para el aprendizaje de la programación, simula la presencia de un profesor inteligente en un aula virtual, proporciona a los estudiantes materiales de aprendizaje, ejercicios y

experiencias personalizadas y adaptadas. Para el área de las matemáticas (Adam et al., 2018), en este trabajo, comparan los sitios web Math MIT, Khan Academy, Youtube y Flipboard, que integran un recomendador para sugerir materiales en el área de cálculo.

Trabajos como el de Qomariyah y Fajar (2019) proponen una alternativa para ayudar a los estudiantes a seleccionar el mejor material educativo de acuerdo con sus preferencias. Está compuesta por dos módulos: el de aprendizaje, basado en marco de trabajo APARELL (Active Pairwise RELation Learner), y el recomendador, que genera las recomendaciones mediante un algoritmo basado en grafos; examina las preferencias de los usuarios como combinación de características que describen su estilo de aprendizaje.

En el trabajo de Rodríguez y Ramírez (2019) se realizó una revisión de literatura acerca del panorama sobre los sistemas recomendadores de recursos educativos digitales en educación superior. El estudio encontró que las características del perfil de usuario usadas para el sistema fueron preferencias de usuario, estilo de aprendizaje, calificación que otorgan los estudiantes y conocimiento previo; los entornos fueron en su mayoría web, en un solo trabajo se usó entornos móviles. Las técnicas de recomendación utilizadas fueron filtrado colaborativo, basado en contenido, basado en conocimiento y combinación de las anteriores. El estado de desarrollo de los sistemas analizados, en su mayoría, fue prototipo y muy pocos como sistema completo, *framework* o preliminar.

En la recomendación de cursos completos, el trabajo realizado por Guruge et al. (2021) presenta el estado del arte de las metodologías usadas con un resumen de conjuntos de datos utilizados para evaluar dichas técnicas. Este estudio evidenció la creciente popularidad del filtrado híbrido y minería de datos como estrategias mayormente incluidas en los recomendadores.

Como puede leerse, la mayoría de estudios generan las recomendaciones a partir de las interacciones de los usuarios con las plataformas software, proveen sugerencias de recursos educativos virtuales en contextos de áreas de conocimiento específico y utilizan las diversas técnicas de filtrado existentes. Sin embargo, no investigan cómo la información de tiempo dedicado en un sistema gestor de aprendizaje como Moodle puede ayudar a construir un recomendador para ayudar a los estudiantes a superar los cursos que toman, independiente del área de conocimiento en la que estén. Esta investigación quiere aportar en este sentido, construyendo un modelo de recomendador basado en datos de tiempo almacenados por el Course Dedication Block de Moodle (https://moodle.org/plugins/block_dedication). Para ello, se representó el perfil de usuario a partir de las características de tiempo de conexión en minutos y segundos, recuperado de los informes de la extensión del LMS mencionado, y rendimiento académico en una asignatura en particular, se consultó en las listas de calificaciones, en un periodo académico determinado; luego se construyó el sistema de recomendación, particularmente se trató de un recomendador con filtrado colaborativo basado en ítems, con el coseno como medida de similitud; finalmente se evaluó el modelo propuesto, mediante un experimento *offline* (Charnelli, 2019).

La forma como se llevó a cabo este trabajo esta descrita en el numeral 2; en el numeral 3 se presentan los resultados de cada uno de los objetivos propuestos y en el numeral 4 se describen las conclusiones y trabajos futuros.

Metodología

La construcción del modelo de recomendador de dedicación de tiempo en Moodle con datos de *Course Dedication Block* se realizó a partir de la representación del perfil de usuario, la elaboración del recomendador de tiempo de dedicación en Moodle en una asignatura específica, y se evaluó la propuesta mediante un experimento *offline*.

Para la representación del perfil se decidió trabajar con las características de cantidad de tiempo, en minutos y segundos, de dedicación en Moodle a una asignatura de la carrera Ingeniería de Sistemas de una universidad en Colombia, y cada una de las tres valoraciones obtenidas. Para ello, inicialmente, se instaló en el LMS Moodle la extensión *Course Dedication Block*, se la activó en un periodo académico y en la asignatura objeto de estudio, en la cual se matricularon 21 alumnos; se la analizó teniendo en cuenta los datos almacenados, esto generó varios informes en fechas diferentes, que corresponden al tiempo en que se publican las notas del rendimiento académico de los estudiantes. Para los datos de rendimiento académico se generaron listados del sistema de la institución colaboradora, para ser procesados se los anonimizó en archivos de hoja electrónica con tres hojas equivalentes a los momentos en que se publican oficialmente las valoraciones del rendimiento, en cada una de ellas se incluyó, por cada estudiante, el número consecutivo y la nota publicada.

La construcción del recomendador contó con tres etapas: 1) definición del tipo de recomendador y filtrado, además de las medidas de similitud y el algoritmo a usar, mediante una revisión de trabajos previos; 2) análisis detallado de la extensión *Course Dedication Block* de Moodle para determinar la forma como serán trabajados los datos que proporciona esta herramienta, y 3) elaboración del recomendador con filtrado basado en ítems, representados en intervalos de tiempo de 15 minutos, por recomendación de la técnica pomodoro (Cirillo, 2007), en total se trabajó con 9 ítems.

La evaluación del modelo de recomendador se realizó mediante un experimento *offline* (Charnelli, 2019). Los datos utilizados fueron las valoraciones del último corte de calificaciones de los estudiantes participantes. Se elaboró un instrumento de recolección de información, que consistió en una matriz con las siguientes columnas: número del estudiante, ítems recomendados por el sistema para aprobar la asignatura, ítem seleccionado por el estudiante en el último periodo de calificaciones, valor de la nota en el último corte, ¿aprobó el último corte?, ¿seleccionó algún ítem recomendado por el sistema propuesto?, efectividad de la recomendación hecha.

Resultados

Representación de perfil

Dentro de los recomendadores, el primer paso es representar el perfil del usuario, es decir, establecer qué información se va a tener en cuenta para las recomendaciones y, por tanto, hay que capturar. Además, estos datos se constituyen en un aspecto clave para que los sistemas recomendadores tengan éxito. Muchos enfoques existen para realizar esta tarea, por ejemplo, analizar los historiales de interacciones de las personas con las plataformas, los datos que se generan en la navegación web, en el proceso de enviar y recibir *email*, vectores de características, redes semánticas, redes asociativas, matrices de *ratings*, características demográficas, y otros más sofisticados como clasificadores que usan algoritmos de la inteligencia artificial: redes neuronales, árboles de decisión y redes Bayesianas (Montaner et al., 2003).

Para representar el perfil de usuario en el recomendador propuesto, se tuvo en cuenta la información de dedicación de tiempo a una asignatura, en particular que se genera mediante el *plugin Course Dedication Block* de Moodle, el cual se instaló y activó en el LMS institucional de la universidad colaboradora. Esta extensión permite ver el tiempo de dedicación en minutos estimado a un curso Moodle por parte de sus participantes, la valoración se basa en los conceptos de sesión y duración de sesión guardados en registros *log* del LMS. El almacenamiento de los datos puede darse en tres casos: *click*, es decir, cuando un usuario accede a una página; sesión, cuando existen dos o más *click* consecutivos, el tiempo transcurrido entre cada par de *clicks* no supera un tiempo establecido, y duración de sesión, equivalente al tiempo transcurrido entre el primer y último *click* de la sesión. La información generada en estos casos se graba en los *log* del sistema gestor de aprendizaje (CICEI y Talavera, s.f.). Cabe mencionar que el proceso de almacenamiento del tiempo de dedicación a un curso en la base de datos del LMS se realiza de manera automática y transparente para los estudiantes, por tanto, no se requiere de manera explícita invitar a que interactúen con la plataforma, sino que resulta ser una actividad natural para los usuarios. También fue necesario contar, por cada alumno, con las tres notas obtenidas en el curso objeto de estudio. El enfoque utilizado para la representación del perfil de usuario en el recomendador propuesto fue el modelo basado en historia (Montaner et al., 2003), gracias a las características de los datos utilizados. En la Tabla 1 se puede ver la representación del perfil utilizado en este estudio.

Tabla 1

Representación del perfil para el recomendador propuesto

Dato	Descripción
Tiempo de conexión	Duración en minutos y segundos que pasa un estudiante en la plataforma de la asignatura estudiada, este tiempo se obtendrá mediante el <i>plugin Course Dedication Block</i> del LMS Moodle.

Valoración 1	Valor de la nota obtenida en el primer corte por un estudiante en la asignatura objeto de estudio equivalente al 30 % de la nota final de la materia. El valor para aprobar debe ser mayor o igual a 3.5
Valoración 2	Valor de la nota obtenida en el primer corte por un estudiante en la asignatura objeto de estudio equivalente al 30 % de la nota final de la materia. El valor para aprobar debe ser mayor o igual a 3.5
Valoración 3	Valor de la nota obtenida en el corte final por un estudiante en la asignatura objeto de estudio equivalente al 40 % de la nota final de la materia. El valor para aprobar debe ser mayor o igual a 3.5

Construcción del recomendador

De acuerdo con Montaner et al. (2003), luego de representar el perfil de usuario, el recomendador que se quiera construir deberá pasar a recomendar productos o acciones a través de la técnica de filtrado que definirá la recomendación. En el caso particular de este estudio, se seleccionó la recomendación colaborativa, por tanto, el filtrado que se usó fue el colaborativo, en respuesta al modelo basado en historia, utilizado para representar el perfil de usuario, además, fue basado en ítems, representados por los intervalos de tiempo de dedicación al curso objeto de estudio.

El filtrado colaborativo busca perfiles de usuario similares en cuanto a comportamiento implícito, utilizado en este estudio, o explícito, y luego realiza las recomendaciones sobre esta base. La información de dedicación de tiempo en Moodle estableció de manera automática el actuar de los usuarios con el sistema, por ende, es una conducta implícita. En resumen, el propósito del recomendador propuesto es el de sugerir dedicaciones de intervalos de tiempo, que se convertirán en ítems, a los estudiantes para aprobar la materia objeto de este estudio.

Para construir el recomendador propuesto, inicialmente, se representan los ítems; luego se elabora la matriz de usuario-ítem, con el objeto de saber, por cada usuario, cuáles ítems utilizó para cumplir con el objetivo; a continuación, se obtiene la matriz de similitudes entre ítems, para ello se aplicó la medida coseno; finalmente, se crea la matriz con los ítems a recomendar para cada usuario.

Representación de ítems

En el filtrado colaborativo basado en ítems, estos últimos juegan un papel fundamental porque son ellos los que el sistema sugiere a otros usuarios, con base en los comportamientos similares que presenten en el sistema. En este estudio los ítems se representaron con intervalos de tiempo de 15 minutos, la cantidad obedeció a lo planteado en Cirillo (2007), de acuerdo con la efectividad de trabajo en el tiempo. Para el recomendador propuesto se establecieron nueve ítems, que pueden verse en la Tabla 2.

Tabla 2

Ítems para el recomendador propuesto

Ítems	Intervalos de tiempo (minutos)
Ítem 1	0-15
Ítem 2	16-30
Ítem 3	31-45
Ítem 4	46-60
Ítem 5	61-75
Ítem 6	76-90
Ítem 7	91-105
Ítem 8	106-120
Ítem 9	> 120

A partir de los ítems, el perfil de un usuario se representó como una tupla de la forma:

(número Consecutivo, ítem, valoración1, valoración2, valoración3)

Por ejemplo, si el estudiante 1 dedicó 120 minutos a la materia objeto de estudio y sus notas fueron 3.5, 4,2 y 5.0, entonces el perfil de usuario se representará así:

(1, ítem 8, 3.5, 4.2, 5.0)

Matriz usuario-ítem

Con los tiempos y las notas de los dos primeros cortes de los estudiantes se elaboró la matriz usuario-ítem, cuyas filas corresponden a cada uno de los estudiantes participantes y las columnas a los ítems. Los datos de la matriz se ingresan con números 1 y 0, el 1 representa los ítems (tiempo de dedicación) que un estudiante ocupó para aprobar el corte de nota y el 0 en caso contrario. Por ejemplo, la fila para el usuario 3 se interpreta de la siguiente manera: dicho usuario, para aprobar los dos primeros cortes de notas tuvo que invertir los ítems 4 y 8, que corresponden a los intervalos entre 46 a 60 minutos y 106 a 120 minutos, respectivamente; los usuarios 1, 5, 6, 14 y 20 no aprobaron la materia objeto de investigación en los dos primeros cortes. En la Tabla 3 se visualiza la matriz resultante.

Tabla 3*Matriz usuario-ítem con las notas de los dos primeros cortes*

Usuario	Ítems								
	Ítem 1	Ítem 2	Ítem 3	Ítem 4	Ítem 5	Ítem 6	Ítem 7	Ítem 8	Ítem 9
1	0	0	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0	0	1
3	0	0	0	1	0	0	0	1	0
4	0	0	0	0	0	0	0	0	1
5	0	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0	0
7	0	0	1	0	0	0	0	0	0
8	0	0	0	0	0	0	0	0	1
9	0	0	0	0	0	0	0	0	1
10	0	0	0	0	0	0	1	0	1
11	0	0	0	0	0	0	0	0	1
12	0	0	0	0	0	0	0	0	1
13	0	0	0	0	0	1	0	0	1
14	0	0	0	0	0	0	0	0	0
15	0	0	0	0	0	0	0	0	1
16	0	0	0	0	0	0	0	0	1
17	0	0	0	0	1	0	0	0	0
18	0	0	0	0	0	0	0	0	1
19	0	0	0	0	0	0	0	0	1
20	0	0	0	0	0	0	0	0	0
21	0	0	0	0	0	0	0	0	1

Matriz de similitud de ítems

El coseno es la medida utilizada para construir estas similitudes; consiste en calcular el coseno del ángulo entre los vectores que son formados por las columnas de ítems de la matriz usuario-ítem de la Tabla 3, la fórmula puede verse en (1). En la matriz resultante se tiene como máxima similitud entre vectores el 1 y el 0 como desigualdad plena. Por ejemplo, la similitud entre los ítems 9 y 6 es de aproximadamente 0.28. La Tabla 4 contiene los valores de similitudes entre los ítems.

$$\cos(\vec{A}, \vec{B}) = \frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| \|\vec{B}\|} = \frac{\sum_{i=1}^n A_i \cdot B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \cdot \sqrt{\sum_{i=1}^n (B_i)^2}} \quad (1)$$

Tabla 4

Matriz de similitudes coseno entre ítems

	Ítem 1	Ítem 2	Ítem 3	Ítem 4	Ítem 5	Ítem 6	Ítem 7	Ítem 8	Ítem 9
Ítem 1	1	0	0	0	0	0	0	0	0
Ítem 2	0	1	0	0	0	0	0	0	0
Ítem 3	0	0	1	0	0	0	0	0	0
Ítem 4	0	0	0	1	0	0	0	1	0
Ítem 5	0	0	0	0	1	0	0	0	0
Ítem 6	0	0	0	0	0	1	0	0	0,28
Ítem 7	0	0	0	0	0	0	1	0	0,28
Ítem 8	0	0	0	1	0	0	0	1	0
Ítem 9	0	0	0	0	0	0,28	0,28	0	1

Con los resultados obtenidos, los usuarios con tiempos dentro del ítem 4 recibirán recomendaciones de tiempo del ítem 8; de la misma manera, los usuarios que utilizaron el tiempo de los ítems 6 y 7 recibirán tiempos de recomendación del ítem 9. Los ítems cercanos también recibirán una recomendación en menor medida de los tiempos en los que se haya conseguido aprobar la asignatura, con esto se busca ampliar el espectro de recomendación para los estudiantes en todos los ítems.

Matriz de ítems a recomendar a cada usuario

Una vez analizada la información dada por la matriz de similitud y los tiempos de dedicación, donde los estudiantes lograron aprobar la asignatura en los cortes uno y dos del correspondiente periodo académico, se genera una tabla constituida por ítems con diferentes intervalos de tiempo, estos surgen al momento de extraer patrones de comportamiento en los tiempos de dedicación de los estudiantes.

En la asignación de los tiempos a los diferentes estudiantes se tienen en cuenta los datos de similitud, además, se exploran los resultados de otros estudiantes, aunque no tengan una curva de similitud, estos podrían ser aplicados en una recomendación de la misma forma y así nutrir las opciones para los usuarios finales. Los ítems de tiempo de dedicación recomendados pueden verse en la Tabla 5.

Los tiempos expuestos en la Tabla 5 no obedecen a los tiempos dados en la tabla de intervalos (ver Tabla 2), sino a una recopilación de tiempos en donde se agrupan los estudiantes que lograron aprobar la asignatura, estos tiempos recomendados son asignados cuando un usuario dedico cierto tiempo y no aprobó la asignatura, por

ejemplo, 300 minutos, dicho usuario, según los datos de la tabla de intervalos, estaría en el ítem 9, mas en la tabla de tiempos por recomendar estaría en el ítem 6, ya que esta tabla obedece a tiempo de aprobación dedicados.

Siguiendo el ejemplo con los datos de la tabla de similitud (ver Tabla 5), los usuarios del ítem 6 tienen similitud con los usuarios del ítem 9, entonces los estudiantes con tiempos correspondientes al ítem 6 recibirán tiempos del ítem 9. El ítem 7 también tiene similitud con el ítem 9, por tanto, los usuarios del ítem 6 recibirían tiempos del ítem 7.

Tabla 5

Tiempos a recomendar

Usuario	Tiempos por recomendar - minutos								
	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9
1							571-585	631-645	796-810
2				151-210	241-270	286-375	571-585	631-645	796-810
3	31-45	91-105	106-150	151-210	241-270		571-585	631-645	796-810
4				151-210	241-270	286-375	571-585	631-645	
5							571-585	631-645	796-810
6		91-105	106-150		241-270	286-375	571-585	631-645	796-810
7	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
8	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
9	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
10	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
11	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
12	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
13	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
14							571-585	631-645	796-810
15		91-105	106-150		241-270	286-375	571-585	631-645	796-810
16		91-105	106-150		241-270	286-375	571-585	631-645	796-810
17		91-105	106-150		241-270	286-375	571-585	631-645	796-810
18	31-45	91-105	106-150		241-270	286-375	571-585	631-645	796-810
19		91-105	106-150				571-585	631-645	796-810
20					241-270	286-375	571-585	631-645	796-810
21				151-210		286-375	571-585	631-645	796-810

Evaluación del recomendador

La idea de evaluar un sistema recomendador es poder medir la efectividad y satisfacción de las sugerencias hechas, para ello existen diversas formas de hacerlo. Charnelli (2019) describe tres: experimentos de usuarios, realizados con grupos seleccionados de participantes, quienes realizan tareas explícitas con el recomendador; experimentos *online*, donde someten al sistema a varias pruebas con usuarios reales para observar rendimiento y funcionalidad, en la mayoría, quienes usan el sistema no tienen conocimiento de la experiencia, y experimentos *offline*, que corresponden a simulaciones realizadas con un conjunto de datos recolectados con anterioridad para realizar las pruebas. El último fue utilizado para el recomendador propuesto.

Inicialmente, se elaboró un instrumento de recolección de información que consistió en una matriz, cuyas filas fueron los usuarios (estudiantes) y sus columnas correspondieron a los siguientes datos: números de ítems que el sistema recomienda, número ítem que el usuario seleccionó para el tercer corte, nota del tercer corte, indicador de sí aprobó o no el tercer corte, indicador de sí tomó o no un ítem recomendado por el sistema y el porcentaje de efectividad de la recomendación. En la Tabla 6 se puede ver los resultados de la evaluación.

Tabla 6

Resultados de la evaluación del recomendador

Usuario	Ítems recomendados	Ítem tomado en corte 3	Nota corte 3	¿Aprobó corte 3?	¿Se toma la recomendación?	Efectividad (%)
1	7, 8, 9	9	4.8	Sí	No	0
2	4, 5, 6, 7, 8, 9	9	4.1	Sí	Sí	100
3	1, 2, 3, 4, 5, 6, 7, 8, 9	1	5.0	Sí	No	0
4	4, 5, 6, 7, 8	9	3.2	No	Sí	50
5	7, 8, 9	9	4.6	Sí	No	0
6	2, 3, 4, 5, 6, 7, 8, 9	9	3.8	Sí	No	0
7	1, 2, 3, 4, 5, 6, 7, 8	1	3.3	No	No	0
8	1, 2, 3, 4, 5, 6, 7, 8	7	3.1	No	Sí	50
9	1, 2, 3, 4, 5, 6, 7, 8	9	3.9	Sí	Sí	100
10	1, 2, 3, 4, 5, 6, 7, 8	9	4.3	Sí	No	0
11	1, 2, 3, 4, 5, 6, 7, 8	1	4.6	Sí	No	0

12	1, 2, 3, 4, 5, 6, 7, 8	1	5.0	Sí	No	0
13	1, 2, 3, 4, 5, 6, 7, 8	1	5.0	Sí	No	0
14	7, 8, 9	9	3.3	No	No	0
15	2, 3, 4, 5, 6, 7, 8, 9	9	4.0	Sí	Sí	100
16	2, 3, 4, 5, 6, 7, 8, 9	9	5.0	Sí	Sí	100
17	2, 3, 4, 5, 6, 7, 8, 9	8	4.2	Sí	Sí	100
18	1, 2, 3, 4, 5, 6, 7, 8	9	2.6	No	No	0
19	7, 8, 9	9	4.4	Sí	Sí	100
20	5, 6, 7, 8, 9	9	2.7	No	No	0
21	4, 6, 7, 8, 9	9	4.4	Sí	Sí	100

Una vez entregadas las recomendaciones de tiempo a los estudiantes, se procedió a analizar los resultados de finales de corte para comprobar los datos y contrastar con los datos generados por la dedicación real de los usuarios en el último corte. Antes de realizar la recomendación se encontraban datos referentes a los estudiantes que reprobaron la asignatura en los primeros dos cortes o periodos; 10 perdieron la asignatura en los dos primeros cortes, es decir, su promedio fue menor a 3.5. De igual manera, se encontraron conexiones a altas horas de la noche, esto evidencia una dedicación inadecuada para dicha asignatura, que causa, en su mayoría, la pérdida parcial de la materia.

Al realizar la recomendación sugerida por el modelo de recomendador propuesto, se indica a los estudiantes el tiempo que podrían emplear en su asignatura para mejorar los tiempos de dedicación y las horas para un desempeño adecuado y mejor asimilación de las actividades que podrían funcionar si son puestas en prácticas por los educandos.

De acuerdo con la Tabla 6, nueve estudiantes, equivalente al 43 % aproximadamente, deciden tomar algún intervalo de tiempo que el sistema recomendador les sugirió para aprobar el corte tres en la materia objeto de estudio, de este porcentaje, siete, es decir, 78 % aproximadamente, aprueban el corte final, por tanto, la efectividad o satisfacción de las recomendaciones del modelo propuesto llega casi a la totalidad de los usuarios que decidieron tomarlas. En el grupo de usuarios que no decidieron aceptar la recomendación hecha, aprobaron el tercer corte ocho, que representa aproximadamente el 67 %, valor por debajo del grupo que tomó alguna sugerencia y efectivamente superó el corte final.

Conclusiones y trabajos futuros

La mayoría de sistemas recomendadores con filtrado colaborativo basado en ítems requieren que explícitamente de manera voluntaria los usuarios interactúen con las plataformas para poder capturar esa información y generar las recomendaciones. En este trabajo se pudo diseñar un recomendador con un perfil de usuario basado en historia que utiliza los datos almacenados por el *plugin Course Dedication Block* de Moodle para lanzar las sugerencias, esto permitió que las interacciones de los usuarios con la plataforma fuera automática, natural y transparente, que garantizó los datos para poder filtrar colaborativamente.

La efectividad de las recomendaciones hechas por el sistema propuesto llegó a un 78 % aproximadamente, es decir, que de diez usuarios que decidieron tomar alguna sugerencia hecha sobre el tiempo a dedicar en Moodle en la materia objeto de estudio para superarla, casi ocho lograron su propósito, por tanto, tuvieron una satisfacción plena de las recomendaciones que se les hizo.

Debido a los problemas que presentan los recomendadores con filtrado colaborativo basado en ítems en cuanto a los ítems nuevos, fue necesario trabajar con las notas del primer y segundo corte para realizar las sugerencias y poder calcular la matriz de similitudes entre ítems.

El experimento *offline* utilizado en este trabajo para evaluar el modelo de sistema recomendador con perfil de usuario basado en historia y filtrado colaborativo basado en ítem resultó ser el adecuado, ya que permitió calcular la satisfacción de las sugerencias hechas a partir de simulaciones realizadas con un conjunto de datos almacenados y recolectados con anterioridad, mediante el *plugin Course Dedication Block* de Moodle.

El presente trabajo deja abiertos los siguientes interrogantes: ¿cómo fabricar una extensión para Moodle que permita recomendar tiempos de dedicación a un curso en particular para superarlo académicamente?, ¿cómo personalizar y adaptar de mejor manera las recomendaciones hechas en este modelo propuesto, incluyendo aspectos psicológicos y tipos de estudio de los usuarios? y ¿de qué forma puede incluirse el recomendador propuesto en un sistema de tutor inteligente para Moodle? Las respuestas pueden ampliar el conocimiento y mejorar la propuesta que se realizó en este estudio.

Referencias

- Adam, N., Zulkafli, M., Soh, S. & Kamal, N. (2018). Preliminary study on educational recommender system. En IEEE (Ed.), *2017 IEEE Conference on E-Learning, e-Management and e-Services, IC3e 2017* (pp. 97–101). <https://doi.org/10.1109/IC3e.2017.8409245>
- Ansari, M., Moradi, M., NikRah, O. & Kambakhsh, K. (2017). CodERS: A hybrid recommender system for an E-learning system. En IEEE (Ed.), *Proceedings - 2016 2nd International Conference of Signal Processing and Intelligent Systems, ICSPIS 2016*. <https://doi.org/10.1109/ICSPIS.2016.7869884>
- Anusha, U. A. & Shilpa, B. (2016). Recommender Systems: A Survey. *International Journal of Latest Technology in Engineering, Management & Applied Science -IJLTEMAS*, 5(1), 42–45.
- Charnelli, M. (2019). *Sistemas Recomendadores aplicados en Educación* (trabajo de especialización, Universidad Nacional de La Plata). Sedici. <http://sedici.unlp.edu.ar/handle/10915/85850>
- CICEI y Talavera, A. (s.f.). Blocks: Course dedication. *Modle*. https://moodle.org/plugins/block_dedication
- Cirillo, F. (2007). *The pomodoro technique* (3.^a ed.). Currency.
- Gardner, H. (1983). *Frames of Mind: The Theory of Multiple Intelligences* (2.^a ed.). Basic Books.
- Guruge, D., Kadel, R. & Halder, S. (2021). The State of the Art in Methodologies of Course Recommender Systems—A Review of Recent Research. *Data*, 6(2), 18. <https://doi.org/10.3390/data6020018>
- Linden, G. & Smith, B. (2017). Two decades of recommender systems at Amazon.com. *IEEE Internet Computing*, 21(3), 12-18. <https://doi.org/10.1109/MIC.2017.72>
- Montaner, M., López, B. y De la Rosa, J. L. (2003). A taxonomy of recommender agents on the internet. *Artificial Intelligence Review*, 19, 285–330. <https://doi.org/10.1023/A:1022850703159>
- Qomariyah, N. & Fajar, A. (2019). Recommender System for e-Learning based on Personal Learning Style. En IEEE (Ed.), *2019 2nd International Seminar on Research of Information Technology and Intelligent Systems, ISRITI 2019* (pp. 563–567). <https://doi.org/10.1109/ISRITI48646.2019.9034568>

Rodríguez, A. y Ramírez, A. (2019). Sistema de recomendación en la educación superior: un estudio preliminar del estado del arte. En IEEE (Ed.), *Proceedings - 14th Latin American Conference on Learning Technologies, LACLO 2019* (pp. 231–236). <https://doi.org/10.1109/LACLO49268.2019.00047>

Zhong, J., Xie, H., & Wang, F. L. (2019). The research trends in recommender systems for e-learning: A systematic review of SSCI journal articles from 2014 to 2018. *Asian Association of Open Universities Journal*, 14(1), 12–27. <https://doi.org/10.1108/aaouj-03-2019-0015>