

Sistema de recomendación de objetos de aprendizaje a través de filtrado colaborativo

Recibido: 15 Ago 2016 – Revisado: 30 Sep 2016
Aceptado: 30 Oct 2016 – Publicado: 30 Dic 2016



Paula Andrea Rodríguez Marín

Candidata a Doctor, Departamento de Ciencias de la computación y de la decisión Facultad de Minas, Grupo de ambientes inteligentes adaptativos - GAIA, Universidad Nacional de Colombia Sede Medellín, Calle 80 No. 65-223 Campus Robledo, Medellín, Colombia.
parodriguezma@unal.edu.co

Ángela María Pérez Zapata

Estudiante de Administración de Sistemas Informáticos, Departamento de Informática y Computación, Grupo de ambientes inteligentes adaptativos - GAIA, Universidad Nacional de Colombia Sede Manizales, Kilómetro 7 vía al Magdalena La Nubia, Manizales, Colombia.
amperez@unal.edu.co

Luis Felipe Londoño Rojas

Estudiante de Administración de Sistemas Informáticos, Departamento de Informática y Computación, Grupo de ambientes inteligentes adaptativos - GAIA, Universidad Nacional de Colombia Sede Manizales, Kilómetro 7 vía al Magdalena La Nubia, Manizales, Colombia.
lfondonor@unal.edu.co

Néstor Darío Duque Mendez

Profesor asociado, Departamento de Informática y Computación, Grupo de ambientes inteligentes adaptativos - GAIA, Universidad Nacional de Colombia Sede Manizales, Kilómetro 7 vía al Magdalena La Nubia, Manizales, Colombia.
ndduqueme@unal.edu.co

Resumen: Los sistemas de recomendación de objetos de aprendizaje basados en filtrado colaborativo, apoyan a los estudiantes en su proceso de aprendizaje autónomo encontrando aquellos recursos que le gustó, interesó o sirvió a un estudiante con características similares; estos sistemas se basan en el concepto de que si dos personas se parecen y a una de ellas le gusta un ítem, hay una alta probabilidad de que a la otra también le guste ese ítem, entendiéndose ítem como cualquier material disponible (documentos, videos, imágenes, recursos, entre otros). Por este motivo en este artículo se presenta un modelo de recomendación por filtrado colaborativo, en donde para encontrar la similitud entre usuarios se utiliza una combinación de varias métricas que miden este valor, con el objetivo de encontrar una mayor cantidad de usuarios similares. Se realizaron pruebas a un caso de estudio y los resultados obtenidos demuestran que el uso de este sistema de recomendación colaborativo entrega objetos de aprendizaje relevantes para los estudiantes.

Palabras claves: métricas de similitud; objetos de aprendizaje; perfiles de usuario; sistemas de recomendación; filtrado colaborativo.

Abstract: Learning objects collaborative filtering recommender systems support students in their autonomous learning process, by finding resources that liked, interest or served a student with similar characteristics. These systems are based on the concept that if two people to be similar and one likes an item, there is a high probability that the other person also likes that item, meaning item as any material available (documents, videos, images, resources, among others). Therefore, in this paper a model is presented recommendation by collaborative filtering, where to find the similarity between users a combination of several metrics that measure this value, with the aim of finding a greater amount of similar users used. Tests were performed to a case study and the results show that the use of collaborative recommendation system delivers relevant and pertinent learning objects for students.

Key words: similarity metric; learning object; user profile; recommendation system; collaborative filtering.

1. INTRODUCCIÓN

Los sistemas de recomendación basados en el filtrado colaborativo cada vez más se abren paso en los diferentes ambientes virtuales con el objetivo de mejorar los resultados de las recomendaciones. Estos sistemas se basan en que si dos usuarios son semejantes en cuanto a sus características personales, preferencias y gustos, si a uno de ellos le gusta un ítem, a su semejante probablemente también le ha de gustar.

Actualmente, el filtrado colaborativo es la técnica comúnmente aplicada y estudiada, que se basa en el principio de encontrar usuarios similares para entregar las recomendaciones (Alonso, Gallego & Honey, 1997) (Betancur, Moreno, & Ovalle, 2009). La parte más importante de esta técnica de recomendación es la selección de los usuarios similares, para ello se deben utilizar medidas de similitud que calculen la cercanía entre un usuario y otro.

El reto principal de estos sistemas es modelar al usuario generando patrones de características y preferencias con el objetivo de mejorar el proceso de búsqueda de los usuarios similares. Las técnicas más utilizadas para ello son el análisis estadístico o la minería de datos, haciendo uso de la monitorización del comportamiento del usuario sobre el sistema, sus puntuaciones sobre los servicios, su historial, etc (Bobadilla, Ortega, Hernando & Alcalá, 2011).

En los sistemas de educación, también se pueden aplicar estas técnicas de recomendación basadas en filtrado colaborativo, donde se deben buscar estudiantes semejantes, pero esta vez teniendo en cuenta características relacionadas con su nivel educativo, preferencias de aprendizaje, entre otros (Bobadilla, Ortega, Hernando & Gutiérrez, 2013); esto se basa en la teoría de que si a un estudiante le sirve un objeto, ítem o documento para aprender, a otro estudiante similar también le ha de apoyar en su

proceso de aprendizaje y debe ser recomendado.

Por otro lado, los objetos de aprendizaje (OA) y su disponibilidad a través de repositorios y federaciones permiten que cada día más estudiantes tengan acceso a un gran volumen de información, que puede ayudar en su aprendizaje autónomo (Bobadilla, Serradilla & Hernando, 2009), es por ello que surgen los sistemas de recomendación en repositorios y federaciones para ayudar a la selección de materiales educativos acordes a las necesidades educativas de los estudiantes.

El filtrado colaborativo tiene algunos problemas como por ejemplo «la oveja gris», que se refiere a que cuando un estudiante se parece mucho a varios grupos de usuarios, el sistema debe tomar la decisión sobre la selección del estudiante más similar, para entregar materiales educativos que apoyen su proceso de aprendizaje autónomo.

Adicionalmente, está el problema del arranque en frío donde un usuario nuevo no tiene estudiantes similares, por lo tanto no se le puede entregar ningún OA; así mismo, si hay un nuevo OA que no tiene calificación, por esta técnica no sería recomendado a ningún estudiante.

El objetivo de este artículo es la propuesta de un modelo de recomendación colaborativa para entregar objetos de aprendizaje a estudiantes, utilizando una combinación de medidas de similitud para encontrar los vecinos cercanos de los estudiantes.

Este artículo está organizado como sigue: en la sección 2 se presenta el marco teórico, donde se encuentran los conceptos relacionados con la propuesta del presente artículo; la sección 3 cubre los trabajos relacionados con el modelo propuesto; en la sección 4 está el modelo de recomendación colaborativo que se propone. En la sección 5 se presenta la validación del modelo utilizando la medida de relevancia, entendida como la importancia que tiene un objeto de aprendizaje para un estudiante en particular.

Finalmente, en la sección 6 se presentan las conclusiones y el trabajo futuro.

2. MARCO TEÓRICO

A continuación se presentan los principales conceptos relacionados con la temática del artículo, entre los que se encuentran sistemas de recomendación, medidas de similitud, filtrado colaborativo y perfiles de usuario.

2.1 Sistemas De Recomendación

A mediados de los años 90 surgen los Sistemas de Recomendación (SR) con el objetivo de entregar a los usuarios resultados adaptados y cercanos a sus necesidades (Burke, 2002).

Los SR están demostrando ser una herramienta útil para hacer frente a una parte del fenómeno de la sobrecarga de información a través de Internet. Su evolución ha acompañado a la evolución de la web (Casali, Gerling, Deco & Bender, 2011). Chesani (2002) define un SR como aquel capaz de realizar predicciones a partir del hecho de que a un usuario le guste o no cierto ítem al que podría acceder, para esto es necesario almacenar la información de estos por medio de perfiles de usuario (Chesani, 2002).

En la actualidad se han desarrollado muchas técnicas de SR, cada una puede ser usada para diferentes enfoques y en diferentes contextos, de acuerdo a las necesidades y a la información disponible (Del Pino, Salazar, & Cedeño, 2011), debido a que estas técnicas necesitan gran cantidad de información sobre los usuarios y recursos a recomendar para entregar resultados de calidad. Esto se logra con la caracterización de los estudiantes y la retroalimentación que se realice de las recomendaciones.

2.2 Medidas de Similitud y Disimilitud

Una medida de similitud permite detectar si una cadena Q es parecida, similar o semejante a una P. Existen medidas que se basan en los caracteres de una palabra y otras en la cantidad de términos comunes entre las cadenas que se están comparando.

Existe una gran cantidad de índices de similitud o disimilitud, cada uno con propiedades y utilidades distintas, por lo cual la correcta selección es fundamental en los resultados.

Estas medidas de similitud son usadas comúnmente en recuperación de información, minería de texto, minería web, clasificación de texto, detección de copias de documentos, entre otros. Este trabajo está orientado a la recomendación colaborativa utilizando varias medidas de similitud para encontrar los vecinos más cercanos (Duque, Ovalle, & Moreno, 2015) (Bobadilla, Ortega, Hernando & Gutiérrez, 2013).

2.3 Sistemas de Recomendación Colaborativos

Entre la clasificación que presenta Burke (2002), se encuentran los sistemas de recomendación basados en filtrado colaborativo, los cuales construyen la recomendación como una agregación estadística/probabilística de las preferencias de otros usuarios [2]. Se fundamentan en el hecho de que los OA que le gustan a un usuario, les pueden interesar a otros usuarios con gustos similares. El gusto de un OA a un usuario se extrae de la votación que este dio al OA.

2.4 Perfiles de Usuario

El modelado de las características primordiales como datos personales, intereses y preferencias es llamado el perfil de usuario. El uso de perfiles pretende tener información de un estudiante como sus características, necesidades y preferencias con el fin de entregar un resultado de búsqueda acorde a los diferentes usuarios [6].

Un componente de un perfil de usuario, específicamente un perfil de estudiante, es el estilo de aprendizaje, que se refiere a las estrategias preferidas de recopilar, interpretar, organizar y pensar sobre la nueva información (Hernando, Bobadilla & Ortega, 2016).

Los estilos de aprendizaje sirven como indicadores relativamente estables, de cómo los alumnos perciben interacciones y responden a sus ambientes de aprendizaje.

3. TRABAJOS RELACIONADOS

En esta sección se presentan algunos trabajos relacionados enfocados a definiciones y propuestas desarrolladas hacia la recomendación de objetos de aprendizaje.

Sicilia et al. (2010) realizan una evaluación de los algoritmos de filtrado colaborativo con OA sobre Merlot, utilizando para ello recomendaciones basadas en el usuario aplicando la medida de correlación de Pearson y la similitud por distancia euclidiana.

Del Pino et al. (2011) presentan un trabajo donde su punto central es adaptar filtros colaborativos basados en el historial del usuario. Se realizaron pruebas para medir la efectividad de los dos algoritmos de similaridad (Tanimoto y LogLikelyhood). Esto para dar una recomendación de las materias que debería tomar un estudiante de sexto semestre de Ingeniería Electrónica y Telecomunicaciones ofertada por la FIEC –ESPOL.

Ortega et al. (2016) proponen recomendación de ítems por filtrado colaborativo aplicando factorización de matrices. Se realizaron pruebas con una base de datos de Netflix y de MovieLens para demostrar que el desempeño de un sistema de recomendación para grupos depende del tamaño de este.

Hernando et al (2016) presentan una nueva técnica para predecir los gustos de los usuarios. La realizan con un SR basado en filtrado colaborativo, para la cual proponen una técnica que consiste en factorizar la matriz de calificación en dos matrices no negativas, donde sus componentes se encuentran dentro del intervalo $[0, 1]$ con un significado probabilístico comprensible.

Bobadilla et al. (2009) proponen demostrar que los usuarios con mejores resultados en varias pruebas, tienen un mayor peso en el cálculo de las recomendaciones. Para llevarlo a cabo, diseñan algunas ecuaciones en el filtrado colaborativo basado en memoria.

El modelo propuesto en este artículo se diferencia de los trabajos relacionados, en la cantidad de medidas de similitud que se combinan para encontrar los vecinos más cercanos; además todas las medidas de similitud implementadas se utilizan tanto para datos cuantitativos como cualitativos, aspecto que en los trabajos relacionados se aplica por separado. Por ejemplo, aplican unas medidas de similitud a datos cuantitativos y otras a cualitativos, mas no implementan las mismas métricas para los datos cualitativos y cuantitativos; por lo cual se encuentran más vecinos cercanos y la cantidad de resultados entregados es mayor.

4. MODELO DE RECOMENDACIÓN PROPUESTO

Se propone un modelo de recomendación de OA utilizando filtrado colaborativo, donde se identifican vecinos cercanos del usuario activo basándose en el grado de similitud calculado entre estos.

Lo anterior es posible a través del algoritmo o el método basado en memoria del filtrado colaborativo. La propuesta plantea la implementación de múltiples métricas de similitud, las cuales permitan obtener mayor cantidad de usuarios similares. Esto ampliará

las opciones de recomendación y proporcionará una lista de posibles OA útiles para el usuario activo específico, incluso cuando se carece de grandes volúmenes de datos.

En la Figura 1, se presenta un modelo conceptual que permite identificar el sentido de las relaciones establecidas entre los componentes del SR colaborativo propuesto. Este sistema combina técnicas de similitud para la identificación de los usuarios similares.

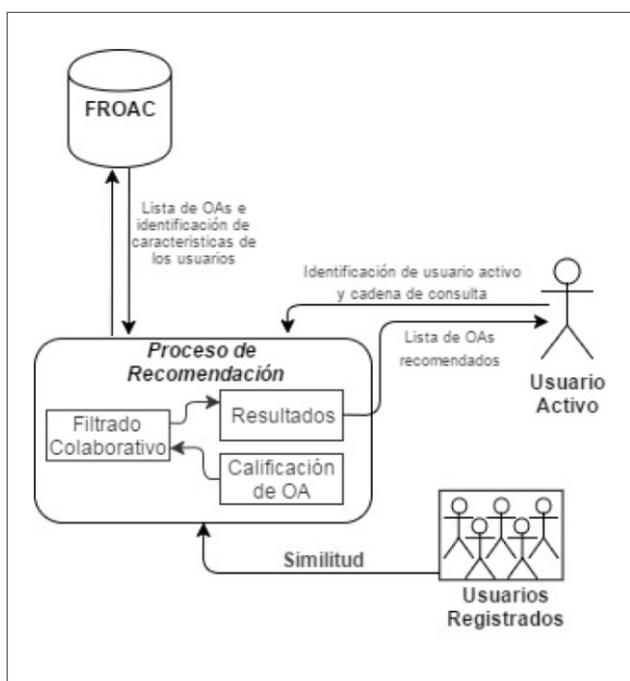


Figura 1. Modelo de recomendación aplicado.

En este modelo se establece la necesidad de identificar algunos datos importantes.

La identificación debe ser de forma previa a la ejecución del proceso del filtrado colaborativo por parte del sistema, esto para entregar los recursos educativos válidos al usuario activo.

Inicialmente se debe conocer la identificación del usuario que requiere la recomendación de los OA, lo

que se logra a través de la validación del usuario en el sistema de consulta.

La identificación del usuario permitirá establecer los valores de las características de su perfil, los cuales han sido catalogados en tres tipos para este modelo. Es necesario establecer los datos personales, para encontrar similitudes con la información demográfica, necesidad especial de educación que tenga, entendiéndose esta como algún tipo de discapacidad que presente el estudiante y finalmente el estilo de aprendizaje del usuario, ya que este es considerado el factor más relevante para entregar materiales educativos.

Para identificar algunos datos personales se establece, por ejemplo la fecha de nacimiento y el nivel educativo.

Las necesidades especiales de educación son establecidas como una discapacidad visual, auditiva o cognitiva y el grado o nivel de padecimiento de esta.

El estilo de aprendizaje se establece utilizando una combinación de los test de Felder Silverman y de VARK según trabajos previos realizados en el Grupo de Investigación de Ambientes Inteligentes Adaptativos (GAIA) de la Universidad Nacional de Colombia, donde se definen ocho dicotomías: lector global, lector secuencial, visual global, visual secuencial, auditivo global, auditivo secuencial, kinestésico global o kinestésico secuencial.

Se toman los estilos de aprendizaje del test de VARK y solo la característica secuencial-global de Felder Silverman.

Adicionalmente, el sistema debe continuar con la identificación de los OA necesarios para el usuario, según los parámetros que el usuario ha establecido en su búsqueda. Basados en los OA seleccionados previamente, el sistema debe identificar otros usuarios que han evaluado dichos OA pre-

seleccionados que cumplen con la necesidad de búsqueda del usuario activo, esto permite proceder con la recomendación.

Luego de que se establecen los datos principales para el algoritmo de filtrado colaborativo, se procede con la identificación de los vecinos cercanos. Estos se establecen al calcular las similitudes existentes entre el usuario activo y los demás usuarios. Solo se toman los usuarios que han calificado de forma previa los OA que satisfacen la cadena de consulta del usuario activo. Son utilizadas varias medidas de similitud, entre ellas, la distancia del coseno, overlap y distancia euclidiana, siempre buscando un mayor número de vecinos cercanos.

Luego de este proceso se seleccionan los OA a ser entregados según la calificación obtenida por los vecinos cercanos.

5. VALIDACIÓN (PRUEBAS)

Como caso de estudio, se realizó la implementación del sistema de recomendación propuesto en una versión de pruebas basada en el módulo de recomendación de la Federación de Repositorios de Objetos de Aprendizaje Colombiano FROAC, a través del enlace web <http://froac.manizales.unal.edu.co/froacPruebas/froacnPruebas>.

Se optó por utilizar esta plataforma para facilitar la recolección de los datos: a través del formulario de registro de usuarios es posible identificar tres tipos de datos necesarios para el funcionamiento de las recomendaciones. Esta información está compuesta por los datos personales, necesidades especiales de educación y estilos de aprendizaje. Además de esto, la plataforma FROAC permite un fácil acceso a consultas de OA y ofrece una cantidad considerable de los mismos en variados temas.

Se contó con la participación de 30 estudiantes de la Universidad Nacional Sede Manizales, los cuales permitieron poblar los datos base para la recomendación, al realizar su registro y una calificación valorada entre 1 y 5 (donde 1 indica menor satisfacción con el objeto) para un total de 10 recursos educativos por cada estudiante.

Estos OA fueron examinados al realizar una búsqueda en tres temas diferentes: «Sistemas», «Números» y «Bases». Se utilizó solo una palabra de consulta para obtener una mayor cantidad de OA con los cuales trabajar.

Para continuar con la validación final de la propuesta, se realizó la recomendación colaborativa de una muestra de 7 estudiantes. Estos usuarios, realizaron consultas de los OA basados en los temas predefinidos. Se solicitó a los usuarios realizar nuevamente la calificación de los objetos que les serían recomendados, con el fin de permitir la evaluación de la calidad de la recomendación a través de algunas métricas que serán identificadas más adelante.

En la Figura 2, se identifica la cantidad de los OA recomendados a cada usuario. Se encuentra que el estudiante 7 es el único usuario que no recibió resultados de recomendaciones, debido a que este no respondió al test de necesidades especiales de educación en la plataforma.

Por lo anterior, se disminuye la cantidad de características a evaluar en las métricas de similitud, lo que disminuye la cantidad de posibles vecinos cercanos. Pero el sistema no descarta estas características al comparar al estudiante con los demás usuarios del sistema, lo que implica una reducción de los pesos aplicados en las características utilizadas del perfil de usuario.

Los pesos son indispensables para identificar los vecinos cercanos, haciendo que los resultados obtenidos en el cálculo de las métricas de similitud aplicadas no permitan identificar recursos educativos aceptables.

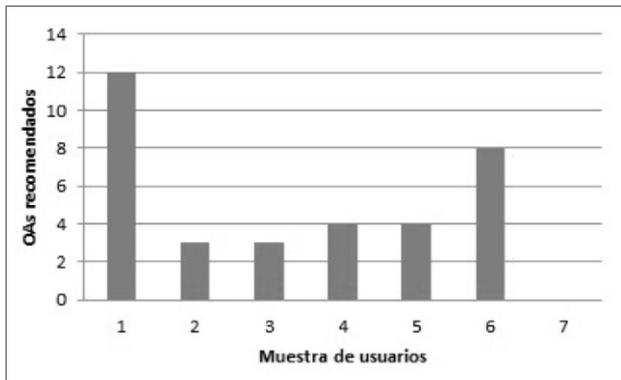


Figura 2. Cantidad de objetos de aprendizaje recomendado a cada usuario.

La evaluación de las recomendaciones entregadas a la muestra de estudiantes tomada, fue calculada aplicando la medida de precisión (ecuación 1) y se complementó con el método de evaluación estadística a través del parámetro de error medio absoluto, MAE (ecuación 2).

1)

$$\text{Precisión} = \frac{\text{Cantidad OA relevantes}}{\text{Cantidad OA recuperados}}$$

2)

$$\text{MAE} = \frac{1}{n} * \sum_{i=1}^n |p_i - r_i|$$

Donde n es la cantidad total de recursos recomendados y calificados por el usuario, pi es la predicción de la calificación que da el sistema de recomendación previamente calculada aplicando el promedio de las valoraciones entregadas por los vecinos cercanos para el objeto i; ri es la calificación real asignada por el usuario para el objeto i.

El MAE establece la diferencia entre el valor de la predicción y la evaluación real otorgada por el usuario activo que recibe la recomendación. Este indicador entrega valores entre 0 y 1. Cuando es más bajo este valor, se considera que la recomendación tiene mayor exactitud en sus resultados.

En la Figura 3, se presentan los resultados obtenidos para el MAE, donde fue necesario excluir los objetos recomendados que no fueron calificados por el usuario para la generación de la medida. Se identifica de forma general que la recomendación se acerca a lo que esperan los usuarios. El MAE calculado a cada usuario presentó un valor promediado de 1,2 con una desviación estándar de 0,3.

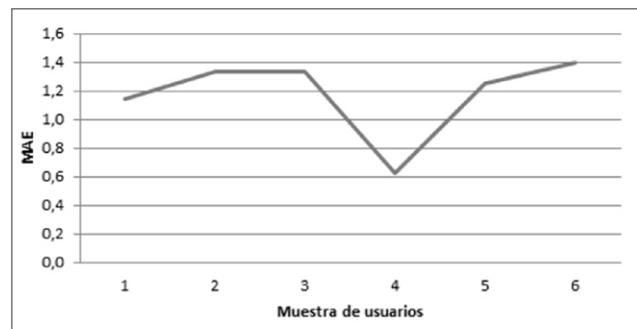


Figura 3. MAE por cada usuario.

En la Figura 4, se presenta la cantidad de los OA recuperados por la recomendación y la cantidad de OA para el usuario activo.

Los objetos relevantes serían aquellos cuya calificación tomó un valor igual o superior a 4 puntos por parte del usuario. El usuario 2, obtuvo 3 objetos recomendados, de los cuales ninguno identificó como relevante en sus calificaciones, esto es debido a que dicho usuario no finalizó de forma adecuada el test de estilos de aprendizaje, por lo cual reduce la cantidad de características para identificar sus vecinos cercanos, disminuyendo así la cantidad de OA que pueden ser útiles para este.

Se presentó un promedio de 5,7 OA recuperados para cada usuario con una desviación estándar de 3,6. Y se estableció un promedio de 3,3 recursos relevantes para cada usuario con una desviación estándar de 2,3.

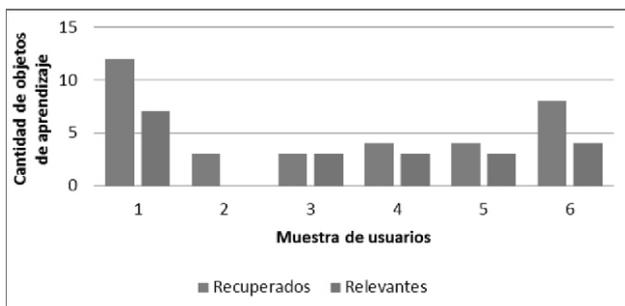


Fig. 4. Cantidad de objetos de aprendizaje recuperados y relevantes recomendados a cada usuario.

La medida de precisión permite establecer un índice de materiales acertados que hacen parte del total de ítems recuperados. Cuando su valor es cercano a 1 indica que la recomendación entrega de forma asertiva OA útiles para el usuario activo.

En la Figura 5, se presentan los resultados obtenidos al aplicar esta medida de evaluación, en donde se encuentra una valoración promedio de 0,6 para cada usuario con una desviación estándar de 0,3. Este cálculo promedio indica que la recomendación es apta.

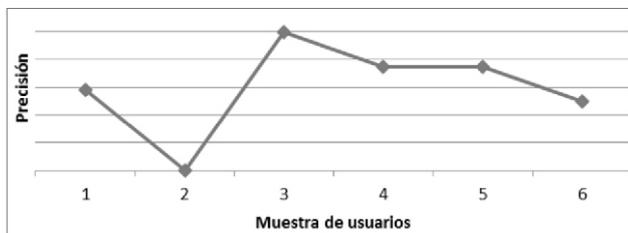


Figura 5. Precisión de la recomendación por cada usuario.

Adicionalmente se decidió ampliar esta validación aplicando una encuesta para identificar la percepción de la calidad de la recomendación por los usuarios muestreados, según los resultados recibidos.

En la Figura 6, se identifica la calificación que le otorgan los usuarios al sistema de recomendación en una escala de 1 a 5, donde 1 desmerita los resultados de la recomendación.

Se observa que el 57,2% de los usuarios dan una puntuación superior o igual a 4 en la recomendación. El 14,33% correspondiente a un usuario da una valoración en las demás escalas.

Es importante resaltar que el usuario que establece una valoración de 1 en el sistema, fue aquel usuario que no recibió recomendación alguna debido a la condición de no presentar necesidad especial de educación. Además el usuario que proporcionó una valoración de 2 puntos, fue aquel que no pudo establecer un recurso educativo relevante.

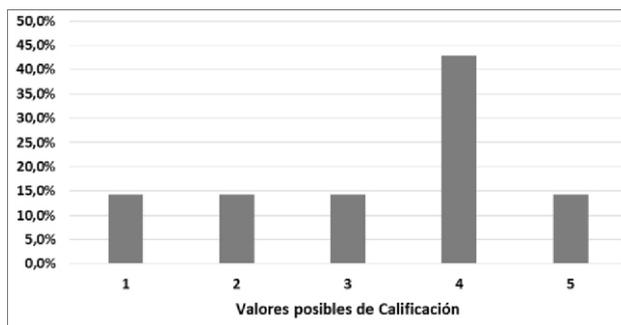


Figura 6. Calificación general de los usuarios hacia la recomendación entregada.

En la Figura 7, se identifica de forma general el nivel de aceptación de la recomendación, en donde los usuarios respondieron a la pregunta: ¿Utilizaría nuevamente este sistema de recomendación?

Se encontró que el 85,7% de los usuarios indicaron con una afirmación a esta respuesta, lo que indica una aceptación de la recomendación. Nuevamente solo una persona que indique que no utilizaría en otra ocasión esta recomendación, este individuo fue identificado como el usuario que no obtuvo ningún objeto de aprendizaje recomendado.

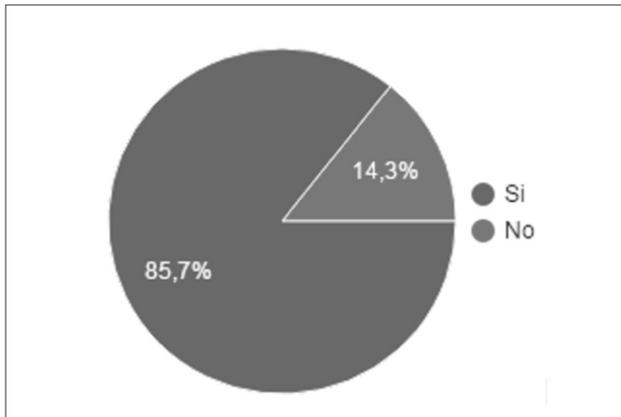


Figura 7. Aceptación de la recomendación por parte de los usuarios.

6. CONCLUSIONES

En este trabajo se presenta un sistema de recomendación de objetos de aprendizaje por filtrado colaborativo, utilizando una intersección de las métricas de similitud, donde los resultados obtenidos fueron relevantes para los estudiantes activos de la plataforma de prueba. El sistema de recomendación fue aplicado a la Federación de Repositorios de Objetos de Aprendizaje Colombia FROAC.

La técnica de filtrado colaborativo presentó fácil adecuación en su implementación al momento de realizar la recomendación de los objetos de aprendizaje aplicando una combinación de medidas de similitud.

Los sistemas de recomendación colaborativos pueden tener dificultades en los resultados de recomendación cuando se amplía la cantidad de características a evaluar en la identificación del perfil de los usuarios, sin embargo, la utilización de diversas características permite establecer con mayor precisión eficiencia en los resultados de las recomendaciones a entregar a los usuarios activos.

Trabajo futuro: se plantea la evaluación de estrategias que permitan identificar mayor cantidad de vecinos

cercanos cuando el usuario activo tiene datos faltantes en la identificación de su perfil de usuario dentro del sistema. Además, ampliar teóricamente el modelo y explicar el proceso de hacer híbridas las medidas de similitud.

AGRADECIMIENTOS

El trabajo de investigación presentado en este artículo fue financiado parcialmente por el proyecto del Departamento Administrativo de Ciencia, Tecnología e Innovación (Colciencias) y el Ministerio de Educación Nacional titulado: «RAIM: Implementación de un framework apoyado en tecnologías móviles y de realidad aumentada para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos», de la Universidad Nacional de Colombia, con código 1119-569-34172. También al programa nacional de formación de investigadores (COLCIENCIAS).

REFERENCIAS

- Alonso, C., Gallego, D. and Honey, P. (1997). Los Estilos de Aprendizaje. Procedimientos de diagnóstico y mejora. Bilbao: Mensajero.
- Betancur, D., Moreno, J. and Ovalle, D. (2009). Modelo para la recomendación y recuperación de objetos de aprendizaje en entornos virtuales de enseñanza/aprendizaje. Av. en Sist. e Informática, 6(1), 45–56.
- Bobadilla, J., Ortega, F., Hernando, A. & Alcalá, J. (2011). Improving collaborative filtering recommender system results and performance using genetic algorithms. Knowledge-Based Syst., 24(8), pp. 1310–1316.
- Bobadilla, J., Ortega, F., Hernando, A & Gutiérrez, A. (2013). Recommender systems survey. Knowledge-Based Syst., 46, 109–132.
- Bobadilla, J., Serradilla, F. and Hernando, A. (2009). Collaborative filtering adapted to recommender systems of e-learning. Knowledge-Based Syst., 22(4), 261–265.
- Burke, R. (2002). Hybrid Recommender Systems: Survey and Experiments. User Model. User-adapt. Interact., 12(4), pp. 331–370.
- Casali, A., Gerling, V., Deco, C. & Bender, C. (2011). Sistema inteligente para la recomendación de objetos de aprendizaje. Generación Digit. 9(1), 88–95.
- Chesani, F. (2002). Recommendation Systems. Corso di laurea Ing. Inform., (1–32).
- Del Pino, J., Salazar, G. and Cedeño, V. (2011). Adaptación de un Recomendador de Filtro Colaborativo Basado en el Usuario para la Creación de un Recomendador de Materias de Pregrado Basado en el Historial Académico de los Estudiantes. Rev. Tecnológica ESPOL–RTE, 24(2), 29–34.
- Duque, N. D., Ovalle, D. A. & Moreno, J. (2015) Objetos De Aprendizaje, Repositorios Y Federaciones... Conocimiento Para Todos.
- Hernando, A., Bobadilla, J. and Ortega, F. (2016). A non-negative matrix factorization for Collaborative Filtering Recommender Systems based on a Bayesian probabilistic model. Knowledge-Based Syst., 97, 188–202.
- Hdioud, F., Frikh, B. and Ouhbi, B. (2012). A comparison study of some algorithms in Recommender Systems. Inf. Sci. Technol., Colloquium, (130–135).
- Kim, M. and Choi, K. (1999). A comparison of collocation-based similarity measures in query expansion. Inf. Process. Manag., 35(1), 19–30.
- Ortega, F., Hernando, A., Bobadilla, J. & Kang, J. H. (2016). Recommending items to group of users using Matrix Factorization based Collaborative Filtering. Inf. Sci. (Ny), 345, 313–324.
- Rodríguez, P. A., Moreno, J., Duque, N. D., Ovalle, D. & Silveira, R. (2014). Un modelo para la composición semiautomática de contenido educativo desde repositorios abiertos de objetos de aprendizaje. A model for the semi-automatic composition of educational content from open repositories of learning objects. Electrónica Investig. Educ. (REDIE), 16(1).
- Sicilia, M. Á., García-Barriocanala, E., Sánchez-Alonso, S. and Cechinelb, C. (2010). Exploring user-based recommender results in large learning object repositories: the case of MERLOT. Procedia Comput. Sci., 1(2), 2,859–2,864.