

Recommender System Based on Student Competencies Assessment Results

Oscar Chavarriaga[&], Beatriz Florian-Gaviria^{*}, Oswaldo Solarte P.[#]

Resumen— Recommender systems in education are used to support the teaching-learning processes. These systems could make easier to take advantage of the social knowledge in competence-based and blended courses. In this paper we propose a system that merges collaborative-based and knowledge-based filtering techniques in order to recommend activities and resources, aiming to support the students to achieve the expected competence levels. The system takes into account the experiences stored and rated by students who have taken the course before (social knowledge), and the competence levels achieved by a student in the same current course. This information is analyzed against the competence levels achieved by former students, then the systems retrieve personalized recommendations to the current student, according to the available information of former students with similar performance. Our findings suggest that the technical approach is correct. They reflect that the social knowledge and the learning results are good sources of valuable recommendations.

Keywords— Collaborative filtering, Competence development, Educational recommender system, Knowledge-based filtering, Social Knowledge.

I. INTRODUCCIÓN

Los sistemas de recomendación son herramientas que buscan mejorar la experiencia de usuarios en distintos tipos de aplicaciones ayudándoles a tomar decisiones tales como qué música escuchar, cuáles productos comprar, qué textos leer, entre otras. Para hacer esto, usan diferentes técnicas con el fin de seleccionar qué ítems sugerir a los usuarios de un conjunto de datos [1].

En educación, los sistemas recomendadores se usan con varios propósitos tales como encontrar buenos ítems (ítems personalizados para un estudiante según algún criterio), encontrar nuevos recursos, predecir y apoyar el rendimiento del estudiante, entre otros [2][3]. Las técnicas más usadas, particularmente para encontrar buenos ítems (los mejores recursos, las mejores actividades, los mejores compañeros para un caso particular, etc.) y predecir el rendimiento de los estudiantes son el *filtrado colaborativo* y el *filtrado basado en conocimiento* [1].

Información valiosa relacionada con la experiencia de estudiantes antiguos (consejos, acciones que ellos hicieron,

material que usaron y que les ayudó a alcanzar los objetivos de un curso) y su desempeño académico histórico (calificaciones o cualificaciones) se almacena en repositorios de aprendizaje que se genera cuando los cursos se ofrecen apoyados en Sistemas de Gestión de Aprendizaje (LMS acrónimo en Inglés), Cursos en Línea Masivos y Abiertos (MOOC acrónimo en Inglés), Sistemas de Entrenamiento y Cursos en Línea Informales. Esta información se puede usar como *conocimiento social* [1][2][3][4] para dar apoyo a estudiantes nuevos, de manera que les ayude a mejorar su rendimiento aprendiendo de experiencias sociales almacenadas. Sin embargo, el *conocimiento social* puede crecer rápidamente a medida que más cursos históricos se tengan en cuenta. Un sistema recomendador es una buena opción para tratar este problema ya que puede tomar ventaja del *conocimiento social* y filtrar la información más relevante para brindar recomendaciones personalizadas.

En este artículo se describe un prototipo de sistema recomendador (CBRecSys) para asistir estudiantes en un curso con evaluación por competencias. El objetivo del sistema es encontrar buenos ítems (datos de la experiencia de estudiantes antiguos) y apoyar el proceso de aprendizaje de los estudiantes actuales. El sistema usa filtrado colaborativo y basado en conocimiento para aprovechar información de experiencias históricas documentadas y de resultados de evaluación. Además, filtra las mejores experiencias para un estudiante actual, personalizándolas a partir de información disponible sobre estudiantes antiguos con rendimiento similar que fueron exitosos alcanzando niveles esperados de competencias en el mismo curso.

Este artículo está organizado de la siguiente manera. En la sección 2 se presentan los trabajos relacionados sobre sistemas recomendadores en educación, haciendo una caracterización de estos sistemas. La sección 3 describe el proceso de recomendación. La sección 4 presenta el prototipo implementado y sus escenarios de pruebas funcionales. Finalmente, en la sección 5 se presentan, los hallazgos preliminares encontrados, las conclusiones y algunas propuestas de trabajo futuro.

II. TRABAJO RELACIONADO

La mayoría de sistemas recomendadores en educación se implementan usando técnicas de *filtrado colaborativo*, *basadas en contenido* o técnicas híbridas. Estos sistemas analizan la información de los estudiantes y los metadatos de los recursos, para encontrar patrones y proveer información

Escuela de Ingeniería de Sistemas y Computación
Universidad del Valle. Cali, Colombia

[&] oscar.chavarriaga@correounivalle.edu.co

^{*} beatriz.florian@correounivalle.edu.co

[#] oswaldo.solarte@correounivalle.edu.co

valiosa que está oculta en los datos. Generalmente se usan dos enfoques, el primero es buscar ítems calificados por usuarios similares y el segundo, es buscar ítems parecidos a los que han sido bien valorados por el usuario al que se le quiere recomendar.

En [5] se presenta un sistema recomendador que procesa información relacionada con perfiles psicológicos y fisiológicos de los estudiantes teniendo en cuenta aspectos que pueden tener un impacto significativo en la eficiencia del aprendizaje. Si dichos perfiles se pueden usar para encontrar patrones en los datos con el fin de hacer las recomendaciones, es válido analizar si las cualificaciones (niveles de competencia alcanzados) se pueden usar con el mismo objetivo.

En [6] los autores asocian el coeficiente intelectual (CI) con las habilidades de los estudiantes y sus resultados de aprendizaje. Usando la escala de inteligencia Stanford-Binet, se buscan asociaciones entre el nivel obtenido de CI por los estudiantes y su rendimiento. Los niveles de competencia representan también una escala y podrían ser usados de manera similar.

En algunos casos, los sistemas de recomendación en educación tienen como objetivo apoyar a los estudiantes en un momento específico, cuando el parámetro tiempo influye en la recomendación brindada. En este sentido, en [7] se describe un sistema para apoyar a los estudiantes en la selección de un

plan de estudios de pregrado. Las recomendaciones cambian en función del avance en el pregrado del estudiante y otro conjunto de preferencias. CBRecSys brinda recomendaciones para apoyar a los estudiantes en un momento específico de un curso.

En [8] se propone un sistema recomendador para apoyar la transferencia de conocimiento y habilidades entre el trabajador novato, el profesor (teoría) y el entrenador (área de trabajo). El sistema se basa en la idea de que la transferencia de información en ambientes educativos es diferente a la transferencia en ambientes de trabajo. Del manera similar, CBRecSys tiene en cuenta los conocimientos y las habilidades que un estudiante debe aprehender en un curso.

En [9] se propone un sistema recomendador híbrido. Los autores usan como ítems Objetos de Aprendizaje (OA) para la recomendación. Los atributos de los OA se usan para hacer recomendaciones basadas en contenido. También construyen un perfil de estudiante con sus atributos y preferencias con el fin de hacer recomendaciones usando el filtrado colaborativo. CBRecSys cuenta con cualificaciones de competencias las cuales pueden representar el perfil del estudiante y se pueden aprovechar usando filtrado colaborativo. La Tabla 1 resume los sistemas recomendadores analizados, con algunas de sus características importantes tales como el tipo de datos de entrada, si se usa el parámetro tiempo, si se tiene en cuenta el desarrollo de competencias.

Tabla 1 Comparación de los sistemas de recomendación analizados

Sistema recomendador	Datos de entrada			Objetivo		Técnica			
	Usa datos comunes (Demográficos, preferencias, comportamiento)	Usa otro tipo de datos	Usa el parámetro tiempo el cual puede cambiar las recomendaciones	Tiene en cuenta el desarrollo de competencias	Tiene en cuenta el conocimiento social	Busca buenos ítems	Ayuda a mejorar el rendimiento en el aprendizaje	Basado en conocimiento	Filtrado colaborativo
[5]		x					x	x	
[6]		x					x		x
[7]	x		x				x		x
[8]		x		x			x	x	x
[9]	x					x		x	x

III. PROCESO DE RECOMENDACIÓN

El sistema recomendador ha sido diseñado para extender la funcionalidad de la aplicación desarrollada en [10][11], que ayuda a diseñar, monitorear, evaluar y analizar cursos en ambientes universitarios diseñados bajo el EQF [12].

En cursos basados en competencias, un sistema recomendador que use los datos de las cualificaciones con el fin de ayudar a los estudiantes a mejorar su rendimiento resulta ser una buena forma de aprovechar datos subutilizados. El prototipo propuesto en este artículo usa la técnica de filtrado colaborativo para brindar las recomendaciones.

El objetivo de este sistema recomendador es asistir a los estudiantes a lo largo de cursos diseñados bajo un enfoque de evaluación por competencias. La idea principal del sistema recomendador es encontrar estudiantes antiguos similares de

acuerdo a su curva de aprendizaje (representada por el proceso que han llevado para alcanzar los niveles de cada competencia). Luego, el sistema busca los ítems que ellos calificaron y les da una puntuación de acuerdo a su importancia (dada por la similitud entre el estudiante antiguo que calificó el ítem y el estudiante actual que será recomendado). Al final del proceso, el sistema entrega las recomendaciones. El sistema recomienda experiencias, documentos de texto y recursos multimedia calificados anteriormente por profesores o estudiantes. El profesor debe ingresar un conjunto de recomendaciones iniciales en la creación de un curso. Esta información se almacena en una base de datos para hacer las recomendaciones a nuevos estudiantes. Los estudiantes pueden añadir nuevos ítems en cada Actividad Calificada (AC). La Figura 1 muestra cómo los ítems de recomendación son calificados y añadidos a la base

de datos. Algunos ejemplos de ítems de recomendación son:

- “Hacer ejercicios del tema X”
- “Ver <http://www.youtube.com/watch?v=8TMBjfs>”
- “Ejercicios 12-18 libro X, p. 23”
- “Leer paginas 15-18 en Dynamic programming v1.pdf”




Figura 1. Alimentando el sistema

El sistema necesita saber el momento específico del curso (última AC ejecutada) ya que las recomendaciones se presentan para apoyar a los estudiantes desde un momento A a un momento B en dicho curso. La Figura 2 muestra el proceso de calcular y entregar las recomendaciones. Este proceso describe cómo tener en cuenta las calificaciones de estudiantes antiguos para escoger los ítems de recomendación para un estudiante actual. El proceso está dividido en cuatro fases: Pre-procesamiento de datos, filtro de candidatos (estudiantes antiguos), cálculo de similitud, puntuación y entrega de ítems de recomendación.

A. Pre-procesamiento de datos

El sistema recomendador recibe dos tipos de datos de entrada; las calificaciones de los estudiantes vinculados al curso en el pasado y las calificaciones a la fecha del estudiante actual (al cual se va a recomendar). La primera, se representa con una matriz m,n , siendo m la cantidad de estudiantes antiguos y n la cantidad de AC en el curso. Asumiendo que un curso ha sido diseñado con ocho AC, la Tabla 2 muestra un ejemplo de cualificaciones de estudiantes antiguos en una competencia específica.

Tabla 2. Cualificaciones estudiantes antiguos
AC₁ AC₂ AC₃ AC₄ AC₅ AC₆ AC₇ AC₈

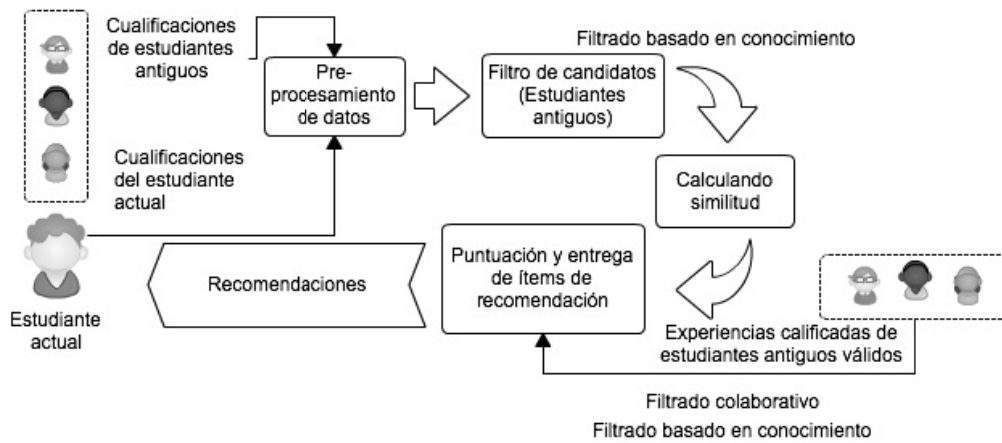


Figura 2. Proceso de recomendación

La Ecuación (1) se usa para calcular la similitud entre el estudiante actual y cada uno de los estudiantes antiguos. La

Andy	1	2	2	2	3	3	4	4
Bob	1	2	2	3	3	3	3	4
Dylan	1	2	2	2	2	4	4	4
Alice	1	2	3	3	3	3	3	4

B. Filtro de candidatos (estudiantes antiguos)

Esta fase filtra los estudiantes antiguos que alcanzaron el nivel de competencia esperado en la siguiente AC. La idea es remover los estudiantes que no alcanzaron el siguiente nivel de competencia esperado. Por ejemplo, basándose en la Tabla 2, con un nivel esperado de 3 en la AC₅, para filtrar los candidatos se comprueba cuáles estudiantes no alcanzaron el nivel de competencia esperado en la AC₅. De acuerdo con la Tabla 3, Dylan se remueve del conjunto de datos.

Tabla 3. Filtro de candidatos

	AC ₁	AC ₂	AC ₃	AC ₄	AC ₅	Resultado del filtro
Andy	1	2	2	2	3	Aprobado
Bob	1	2	2	3	3	Aprobado
Dylan	1	2	2	2	2	Removido
Alice	1	2	3	3	3	Aprobado

C. Calculando similitud

En esta fase se calcula la similitud entre el estudiante actual y los estudiantes antiguos filtrados anteriormente. Las coincidencias en su curva de aprendizaje dan la similitud. El coeficiente de Jaccard [13] se usa para calcular la similitud entre los estudiantes y está dado por la Ecuación (1).

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \tag{1}$$

Basándose en la Tabla 3 y un estudiante actual con calificaciones {1, 2, 2, 2} en las actividades 1, 2, 3 y 4 respectivamente, la Figura 3 muestra las coincidencias en las calificaciones.




Figura 2. Coincidencias en calificaciones

Tabla 4 muestra el coeficiente de Jaccard entre el estudiante actual y los estudiantes antiguos. El rendimiento de Andy

tiene la similitud más alta respecto al rendimiento del estudiante actual.

Tabla 4. Coeficiente de Jaccard

Estudiante	AC ₁	AC ₂	AC ₃	AC ₄	Similitud
Actual	1	2	2	2	
Andy	1	2	2	2	1
Bob	1	2	2	3	3/4
Alice	1	2	3	3	1/2

D. Puntuación y entrega de ítems de recomendación

Los ítems de recomendación están previamente calificados y almacenados para estudiantes antiguos. Cuando un estudiante califica algún ítem, esta acción se registra en la base de datos. La Tabla 5 muestra un ejemplo de posibles calificaciones para cuatro ítems (I_1, I_2, I_3, I_4). El objetivo de esta fase es puntuar automáticamente los ítems de recomendación. La puntuación se basa en el coeficiente de Jaccard previamente calculado y en las calificaciones de los ítems almacenadas en la base de datos.

Tabla 5. Calificaciones de ítems

Item	Andy		Bob		Alice	
	I_1	I_2	I_1	I_2	I_1	I_3
Calificación	4	3	4	4	5	2

La Ecuación (2) da la puntuación de un ítem I_n , donde k es la número de estudiantes que calificaron el ítem I_n , CJ_j es el coeficiente de Jaccard entre el estudiante j y el estudiante actual, y R_j es la calificación que el estudiante j le dio al ítem I_n .

$$I_n = \sum_{j=1}^k (CJ_j * R_j) \quad (2)$$

Usando la Ecuación (2) y con base en la Tabla 4 y Tabla 5, la puntuación para los ítems I_1, I_2, I_3, I_4 es:

$$I_1 = (1*4) + (3/4*4) + (1/2*5) = 7,5$$

$$I_2 = (1*3) + (3/4*4) = 4$$

$$I_3 = (1/2*2) = 1$$

$$I_4 = (1/2*3) = 1,5$$

Después de puntuar los ítems de recomendación, el sistema los ordena por relevancia. En éste ejemplo, el orden de relevancia es I_1, I_2, I_4 y I_3 . Finalmente, los ítems más relevantes se muestran al estudiante actual. En caso de que no se encuentren estudiantes similares (Fase C) el sistema provee las recomendaciones brindadas por el profesor.

IV. PROTOTIPO

El sistema recomendador fue implementado usando el lenguaje de programación Java y una base de datos PostgreSQL. Los ítems de recomendación y las calificaciones se generaron sintéticamente apuntando a unos resultados intencionales. Los resultados obtenidos corresponden a los resultados esperados y por tanto, las pruebas aplicadas al sistema recomendador fueron exitosas. En el conjunto de datos, se generaron calificaciones de 20 estudiantes antiguos y 5 ítems de recomendación. En los 3 escenarios, por simplicidad, la calificación que los estudiantes dan a los ítems fue la misma con el fin de observar los cambios en los resultados debido al filtrado colaborativo; los estudiantes 1-4 calificaron el primer ítem, los estudiantes 5-8 el segundo ítem, los estudiantes 9-12 el tercer ítem, los estudiantes 13-16 el cuarto ítem y los estudiantes 17-20 el quinto ítem.

Primer escenario: La Figura 4(A) muestra el primer escenario, donde el grupo de los primeros cuatro estudiantes antiguos tienen la similitud más alta en cuanto a su curva de aprendizaje con respecto al estudiante actual a quien se quiere recomendar. Para cada AC la Figura 4(B) muestra el número de coincidencias de calificaciones entre el estudiante actual y el primer grupo (1-4) de estudiantes antiguos.

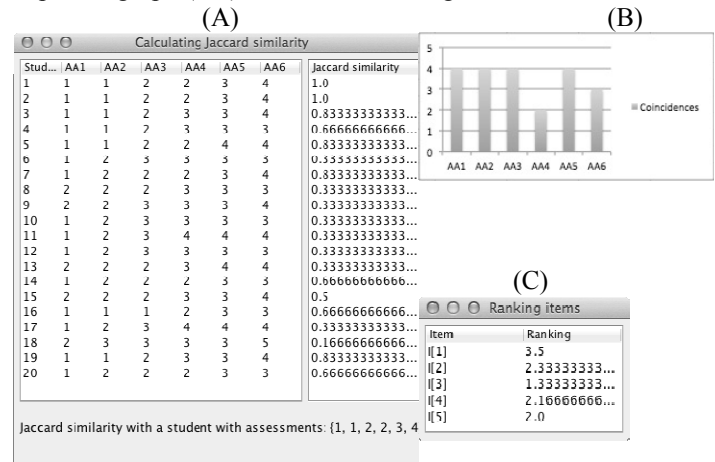


Figura 4. Escenario de prueba 1

El primer grupo de estudiantes antiguos (1-4) calificaron el ítem 1, como se esperaba, este ítem de recomendación tuvo la puntuación más alta ver Figura 4, entonces sería la primera opción para recomendar.

Segundo escenario: La Figura 5(A) muestra el segundo escenario en el cual la curva de aprendizaje del estudiante actual tiene poca similitud con respecto a la todos de los estudiantes antiguos en el conjunto de datos. Para cada AC, la Figura 5(B) muestra el número de coincidencias en niveles alcanzados entre el estudiante actual y el grupo total de estudiantes antiguos.

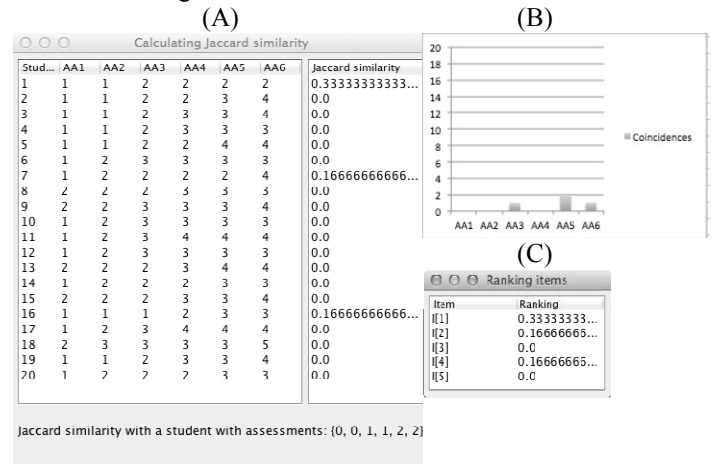


Figura 5. Escenario de prueba 2

Las puntuaciones calculadas para los ítems de recomendación son menores en relación con el escenario anterior. Entonces, se puede decidir que criterio usar, un criterio puede ser recomendar el ítem con la mayor puntuación o definir un umbral con el fin de seleccionar solo los ítems de recomendación que lo excedan.

Tercer escenario: La Figura 6(A) muestra el tercer escenario. Aquí, todas los datos de niveles alcanzados fueron

los mismos que en el primer escenario, pero los estudiantes (1-4) que calificaron el primer ítem no alcanzaron el nivel de competencia esperado en la siguiente AC. Entonces, no se tuvieron en cuenta para calcular la puntuación del ítem que calificaron, debido a esto el primer ítem obtuvo una menor puntuación. Así, comparado con el primer escenario, el sistema cambia su decisión, ahora la primer opción para recomendar sería el segundo ítem. Ver Figura 6(B).

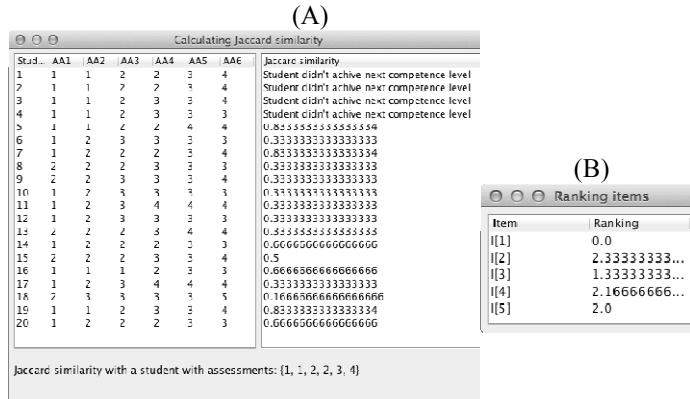


Figura 6. Escenario de prueba 3

La Figura 7 muestra cómo se presentan los ítems de recomendación al estudiante actual.

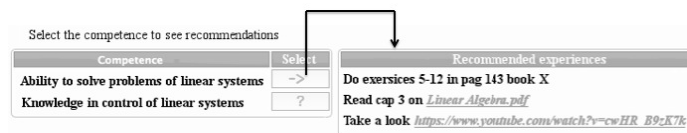


Figura 7. Presentación ítems de recomendación

V. CONCLUSIONES

En este artículo se presentó un prototipo de sistema recomendador para cursos en línea y mixtos con calificaciones basadas en competencias. El sistema podría ayudar a mejorar el rendimiento de los nuevos estudiantes después de haber reunido los datos de experiencias y niveles de competencia alcanzados de estudiantes antiguos. Este sistema usa la técnica de filtrado colaborativo y filtrado basado en conocimiento aprovechar los datos (las experiencias y calificaciones de estudiantes antiguos). De esta manera, las experiencias pueden ser sugeridas para ayudar a los estudiantes actuales a alcanzar los niveles deseados planeados en el diseño del curso.

Este sistema recomendador fomenta el conocimiento social ya que los participantes de un curso pueden contribuir con ideas que serán usadas por otros estudiantes en el futuro mientras mejoran su rendimiento. Por lo tanto, los nuevos estudiantes serán más capaces de alcanzar los niveles de competencia esperados en su propio proceso de aprendizaje.

Este sistema recomendador extiende la funcionalidad de la herramienta AEEA Suite [10][11]. La herramienta de calificaciones fue mejorada añadiendo métodos para recolectar las experiencias exitosas de los estudiantes antiguos. Cuando los estudiantes alcanzan o exceden los niveles de competencia esperados en una AC, son alentados a almacenar consejos para futuros estudiantes.

Esta propuesta puede ser usada por la comunidad TEL en cursos en línea o mixtos en diferentes contextos de aprendizaje (formal e informal). Muchos marcos de calificaciones por

competencias siguen el mismo patrón en su definición (descriptores en una matriz de tipo de competencias vs. niveles de competencia), la propuesta de este artículo puede ser usada para implementar nuevos recomendadores usando algunos de estos marcos de calificaciones.

Es posible usar cualquier tipo de calificaciones que representen una curva de aprendizaje para diseñar un algoritmo de un sistema recomendador usando la técnica de filtrado colaborativo.

VI. TRABAJO FUTURO

El sistema recomendador propuesto en este artículo hace parte de un trabajo de investigación de la Universidad del Valle. Como parte de la validación del mismo, se pondrá en marcha una variedad de cursos haciendo uso de la herramienta para realizar pruebas con el fin de analizar el impacto en el rendimiento de los estudiantes.

La herramienta AEEA junto con el sistema recomendador se adaptarán al marco de calificaciones [15] propuesto por el ministerio de educación y se usarán en cursos masivos para el diplomado TITA [14]. En TITA, alrededor de 500 profesores de escuelas públicas de educación primaria y secundaria han sido entrenados en competencias TIC.

Pensando en ampliar la funcionalidad del recomendador, los autores tienen algunas ideas tales como: Clasificar las experiencias de los estudiantes antiguos podría ayudar a los nuevos estudiantes a filtrar las recomendaciones escogiendo categorías, diseñar un recomendador para los profesores con el fin de ayudar a tomar decisiones en el diseño de los cursos y prevenir la deserción y pérdida de los estudiantes.

AGRADECIMIENTOS

Los autores quieren agradecer a la Universidad del Valle, Colombia por financiar el proyecto de investigación NUBE-UV (CI 2756). Este trabajo ha sido patrocinado como parte del proyecto NUBE-UV. También, los autores quieren agradecer especialmente a la profesora Martha Millán por su valiosa consultoría en el área de Descubrimiento del Conocimiento en Bases de Datos.

REFERENCIAS

- [1] Ricci, F., Rokach, L., Bracha, S., Kantor, P.B. eds: Recommender Systems Handbook. Springer US, Boston, MA (2011).
- [2] Adolphs, R.: The social brain: neural basis of social knowledge. *Annu. Rev. Psychol.* 60, 693–716 (2009).
- [3] Wan, X., Jamaliding, Q., Okamoto, T.: Analyzing Learners' Relationship to Improve the Quality of Recommender System for Group Learning Support. *J. Comput.* 6, 254–262 (2011).
- [4] Carrer-Neto, W., Hernández-Alcaraz, M.L., Valencia-García, R., García-Sánchez, F.: Social knowledge-based recommender system. Application to the movies domain. *Expert Syst. Appl.* 39, 10990–11000 (2012).
- [5] Kaklauskas, A., Seniut, M., Zavadskas, E., Dzemyda, G., Stankevicius, V., Simkevicius, C., Ivanikovas, S., Stankevicius, T., Matuliuskaite, A., Zemeckyte, L.: Recommender System to Analyse Students' Learning

- Productivity. In: Yang, D. (ed.) *Informatics in Control, Automation and Robotics SE - 23*. pp. 161–164. Springer Berlin Heidelberg (2012).
- [6] Arockiam, L., Charles, S., Arul Kumar, V., Cijo, P.: A Recommender System for Rural and Urban Learners. In: Nagamalai, D., Renault, E., and Dhanuskodi, M. (eds.) *Trends in Computer Science, Engineering and Information Technology SE - 63*. pp. 619–627. Springer Berlin Heidelberg (2011).
- [7] Cho, J., Kang, E.: Personalized Curriculum Recommender System Based on Hybrid Filtering. *Adv. Web-Based Learn. – ICWL 2010 SE - 7*. 6483, 62–71 (2010).
- [8] Kong, X., Boll, S., Heuten, W.: A Hybrid Multi-recommender System for a Teaching and Learning Community for the Dual System of Vocational Education and Training. In: Hernández-Leo, D., Ley, T., Klamma, R., and Harrer, A. (eds.) *Scaling up Learning for Sustained Impact SE - 77*. pp. 613–614. Springer Berlin Heidelberg (2013).
- [9] Andrea, P., Marín, R., Morales, V.T.: Modelo multi-agente para recomendación híbrida de objetos de aprendizaje Multi-agent Model for Hybrid Recommendation of Learning Objects Modèle multi-agent pour recommandation hybride d ' objets d ' apprentissage Mots-clés. *Rev. Virtual Univ. Católica Del Norte*. 40, 96–111 (2013).
- [10] Florian-Gaviria, B., Glahn, C., Gesa, R.F.: A Software Suite for Efficient Use of the European Qualifications Framework in Online and Blended Courses. *IEEE Trans. Learn. Technol.* 6, 283–296 (2013).
- [11] Florian-Gaviria, B.: Technology-Enhanced Support For Lifelong Competence Development In Higher Education, <http://www.tdx.cat/handle/10803/101517>, (2013).
- [12] European Commission: *The European Qualifications Framework for Lifelong Learning (EQF)*. (2008).
- [13] Maimon, O., Rokach, L.: *Data Mining and Knowledge Discovery Handbook*. (2010).
- [14] TIT@ Educación Digital para Todos, <https://www.facebook.com/educaciondigitaltita>
- [15] Calderón, G.G., Buitrago, B., Alcira Acevedo, M., Tobón, M.I.: *Competencias TIC Para el Desarrollo Profesional Docente*.