

Sistema de recomendación de contenidos para libros electrónicos inteligentes*¹

[Contents recommender system for intelligent eBooks]

EDWARD ROLANDO NÚÑEZ VALDÉZ², VICENTE GARCÍA DÍAZ³,
JORDAN PASCUAL ESPADA⁴, CARLOS ENRIQUE MONTENEGRO MARÍN⁵,
JUAN MANUEL CUEVA LOVELLE⁶, ÓSCAR SANJUÁN MARTÍNEZ⁷

RECIBO: 01.02.2012 - APROBACIÓN: 20.05.2012

Resumen

Un sistema de recomendación de contenidos para libros electrónicos inteligentes permite construir conocimientos colectivos para un conjunto de usuarios de una red social. Basándose en el análisis del comportamiento, preferencias y antecedentes de

-
- * Modelo para citación de este artículo de investigación científica y tecnológica: NÚÑEZ VALDEZ, Edward Rolando; GARCÍA DÍAZ, Vicente; PASCUAL ESPADA, Jordan; MONTENEGRO MARÍN, Carlos Enrique; CUEVA LOVELLE, Juan Manuel y SANJUÁN MARTÍNEZ, Óscar (2012). Sistema de recomendación de contenidos para libros electrónicos inteligentes. No. 26 (ene. – jun., 2012). Manizales (Colombia): Facultad de Ciencias e Ingeniería, Universidad de Manizales. p. 111-127. ISSN: 0123-9678
- 1 Artículo proveniente del proyecto *eInkPlusPlus Plataforma hardware y software para el acceso a contenidos digitales mediante tinta electrónica (Referencia TSI-020110-2009-137)*, ejecutado en el periodo fecha 01/10/2009–31/12/2011, e inscrito en el grupo de investigación *MDE Research Group* del Departamento de Informática, Universidad de Oviedo.
 - 2 Licenciado en Informática; Máster en Ingeniería de Software; PhD. en Informática. Investigador en el Departamento de Informática. Universidad de Oviedo (España). Correo electrónico: edwardnu@gmail.com
 - 3 Ingeniero Técnico en Informática de Sistemas; Ingeniero en Informática; PhD. en Informática. Profesor en el Departamento de Informática. Universidad de Oviedo (España). Correo electrónico: garciavicente@uniovi.es
 - 4 Ingeniero Técnico en Informática de Gestión; Máster en ingeniería Web. Investigador en el Departamento de Informática. Universidad de Oviedo (España). Correo electrónico: jordansoy@gmail.com
 - 5 Ingeniero de sistemas; Magister en Ciencias de la información y las comunicaciones; PhD. Profesor en la Universidad Distrital Francisco José de Caldas, Bogotá (Colombia). Correo electrónico: cemonenegro@udistrital.edu.co
 - 6 Ingeniero superior; PhD. en Ingeniería. Director del Departamento de Informática, Universidad de Oviedo, Oviedo (España). Correo electrónico: cueva@uniovi.es
 - 7 Ingeniero Superior en Informática; PhD. en Ingeniería del Software. Profesor e Investigador, Universidad Carlos III, Departamento de informática, Madrid (España). Correo electrónico: oscar.sanjuan@uc3m.es

lectura, ayuda a los usuarios a descubrir contenidos interesantes relacionados a su perfil. En este trabajo, se propone un modelo para una plataforma de recomendación de contenidos basado en la retroalimentación implícita que ayude a los usuarios a descubrir contenidos de su interés de forma automática y dinámica.

Palabras Clave: ACRIE, GIUG, libros electrónicos, retroalimentación implícita, retroalimentación explícita, Sistemas de recomendación.

Abstract

A content recommendation system for intelligent electronic books can build collective knowledge to a set of social network users. Based on the analysis of the behavior, preferences and background reading, helps users discover interesting content related to their profile. In this paper, we propose a model for a content recommendation platform based on implicit feedback to help users to discover content on their interest, automatically and dynamically.

Keywords: ACRIE, eBooks, GIUG, implicit feedback, explicit feedback, recommendation systems.

Introducción

El uso de los sistemas de recomendación como técnica y estrategia de recuperación de información pretende solucionar el problema de sobrecarga de datos. Estos ayudan a filtrar la información disponible en la Web y encontrar la información de mayor interés y más valiosa para los usuarios, permitiendo descubrir nuevos contenidos de una forma más rápida y eficiente, según consideran O'Donovan & Smyth (2005), Taghipour & Kardan (2008) y Noor & Martinez (2009).

En el mundo de los libros, y concretamente en el de los libros electrónicos, que cada vez está cobrando más fuerza, se enfrenta al mismo problema: hay millones de libros que tratan de temas y aspectos muy diversos, que están al alcance de las manos de los usuarios, pero son difíciles de encontrar de una manera fácil. Así, un sistema que conozca a los usuarios, que actúe como un amigo que ha leído un libro o ha oído hablar de él e inmediatamente sabe que le va a gustar, sería un gran aliado para ahorrar tiempo y esfuerzo en la búsqueda de contenidos interesantes.

Para que los sistemas de recomendación sean más eficaces es necesario mejorar el proceso de retroalimentación. Para esto, es necesario reunir implícitamente mayor cantidad de información relacionada con

el perfil de usuario basándose en su comportamiento, de manera que permita medir su interés sobre un contenido o grupo de contenidos. Como lo muestran Claypool, Brown & Waseda (2001), las soluciones más comunes y frecuentes en los sistemas de recomendación son las basadas en las calificaciones explícitas. Estas técnicas pueden alterar la navegación normal del usuario y los patrones de lectura, porque tienen que detenerse a valorar los contenidos.

Núñez Valdez et al. (2010) definieron un conjunto de parámetros implícitos, sobre el cual se realizó un análisis comparativo y se encontraron las correlaciones entre las acciones que un usuario puede realizar durante la lectura de un libro electrónico y las valoraciones dadas por estos a cada contenido. Este proceso permite analizar el comportamiento de los usuarios en torno a los libros electrónicos y convertir estas acciones en calificaciones explícitas que ayudan al sistema para hacer recomendaciones más precisas relacionadas con el perfil del usuario.

1. Problemas

Para diseñar una plataforma de recomendación de contenidos basada en el comportamiento de los usuarios en los dispositivos de lecturas de libros electrónicos, hay que tener en cuenta una serie de problemas. En general, y a partir de Núñez Valdez et al. (2010), se puede decir que hay tres problemas principales relacionados con este tema:

1.1 Demasiado volumen de información

El acceso al gran volumen de datos disponibles en Internet requiere de mecanismos y algoritmos de clasificación que permitan optimizar las búsquedas y el acceso a estos contenidos eficientemente. Todos los días aumenta el volumen de información disponible en la Web, y esto se convierte en un problema de optimización para los sistemas de recomendación, según coinciden González Crespo et al. (2011), O'Donovan & Smyth (2005) y Resnick et al. (1994).

1.2 Implementación de un eficiente mecanismo de retroalimentación

En la mayoría de los casos, los mecanismos de retroalimentación están basados en la retroalimentación explícita, y esto puede causar inconvenientes a los usuarios, porque típicamente no les gusta valorar los contenidos. Las valoraciones explícitas son los más comunes y evidentes indicadores del interés del usuario, porque les permite decir al sistema que es lo que realmente piensan de los objetos a valorar. Por otro lado, pueden alterar la navegación normal y los patrones de lectura

de los usuarios, porque tienen que detenerse a valorar los contenidos. Además, expresan Claypool, Brown & Waseda (2001), estos pueden dejar de valorar los objetos, si no perciben algún beneficio.

Por lo tanto, es necesario capturar la mayor cantidad de información sin la intervención directa de los usuarios, con la finalidad de determinar sus intereses y necesidades, e intentar implementar un mecanismo de retroalimentación más eficaz.

1.3 Capacidad limitada de cómputo en los libros electrónicos

El consumo de memoria y CPU de cualquier sistema de recomendación es muy elevado al tratar con muchos datos. La optimización de los algoritmos para mejorar su rendimiento es uno de los principales campos de investigación dentro de esta área. Una característica constante es el procesamiento de los datos constantemente modificados (en tiempo real), lo cual requiere de algoritmos eficientes con un bajo costo de ejecución.

Un sistema de recomendación requiere de un aprendizaje continuo de los perfiles de los usuarios y una constante actualización de la información del sistema. Por eso, es necesario minimizar el consumo de memoria y de CPU durante la recuperación de la retroalimentación.

Como los libros electrónicos tienen ciertas limitaciones de cómputo y almacenamiento, es necesario evaluar y diseñar una metodología que permita a los dispositivos actualizar y almacenar los objetos valorados. Esto permitiría que los sistemas de recomendación puedan funcionar eficazmente y sin la necesidad de depender permanentemente de tecnologías externas. Por esto, se necesita un mecanismo de sincronización de los datos disponibles en servidores externos con el dispositivo. Este puede ser implementado a través de servicios Web o mediante unos procesos de sincronización con una aplicación de escritorio en un ordenador. Esta sincronización, aseguran Núñez Valdez et al. (2012), debe permitir almacenar en el dispositivo y usando un formato estándar, la información necesaria para el funcionamiento del sistema de recomendación.

2. Estado de arte de los sistemas de recomendación

Hoy en día los sistemas de recomendación son muy útiles en la Web y se utilizan ampliamente, ya que ayudan a los usuarios a descubrir

contenidos de una forma fácil, rápida y sin mucho esfuerzo. Tales contenidos son seleccionados y filtrados por los sistemas de recomendación de una gran cantidad de contenidos que están en plataforma.

Un sistema de recomendación es definido como «*un sistema que tiene como tarea principal, la elección de ciertos objetos que cumplen con los requisitos de los usuarios, donde cada uno de estos objetos se almacenan en un sistema informático y se caracteriza por un conjunto de atributos*» (Wang, 1998)

Los sistemas de recomendación, según Resnick & Varian (1997), se basan en el filtrado de información personalizada, que se utiliza para predecir si un usuario en particular le gusta un tema en particular (problema de la predicción), o identificar un conjunto de N elementos que pueden ser de interés para ciertos usuarios (problema recomendación top-N).

2.1 Clasificación de los sistemas de recomendación

Para Adomavicius et al. (2005) y Adomavicius & Tuzhilin (2005), los sistemas de recomendación pueden ser clasificados en diferentes tipos según el tipo de información que utilizan para hacer recomendaciones. Tradicionalmente, existen varios paradigmas de filtrado de información utilizados para generar las recomendaciones, estas se clasifican en:

- Basados en el contenido: se trata de intentar recomendar contenidos similares a otros que le gustaba a un determinado usuario en el pasado.
- Filtrado colaborativo: identifica a los usuarios cuyos gustos son similares a un usuario determinado y recomienda a este usuario los contenidos que le gusta a los demás usuarios.
- Un enfoque híbrido: es una combinación entre el filtrado colaborativo de y el basado en contenidos.

Otra variedad de técnicas han sido propuestas para la realización de recomendación por parte de otros autores (Burke, 2002), aunque están relacionados con las clasificaciones de los sistemas de recomendación mencionados anteriormente, como: recomendación demográfica, la recomendación basada en el conocimiento, y la recomendación de utilidad.

Por otro lado, hay una amplia gama de sistemas de recomendación que se utilizan en las diferentes áreas, ya sea con fines comerciales, científicos o experimentales, teniendo, a manera de ejemplo: PHOAKS (Terven et al., 1997), Referral Web (Kautz, Selman & Shah, 1997), Fab (Balabanovic & Shoham, 1997), sistema de recomendación de Amazon (Linden, Smith & York, 2003).

2.2 Técnica de retroalimentación de datos

Para que los sistemas de recomendación puedan recomendar contenidos a los usuarios es necesario recopilar una serie de información, relacionada al perfil de los usuarios y a los contenidos a recomendar. Las técnicas de retroalimentación se clasifican en dos tipos: Retroalimentación Implícita y Explícita, de acuerdo a lo estipulado por Adomavicius, et al. (2005), Resnick & Varian (1997) y Ziegler et al. (2005).

La combinación entre las técnicas de retroalimentación explícita y la implícita es otro paradigma para los sistemas de recomendación, afirma Jawaheer, Szomszor & Kostkova (2010), a pesar de que estos presentan características diferentes acerca de las preferencias de los usuarios.

2.2.1 Retroalimentación explícita. A través de un proceso de la encuesta, el usuario valora los contenidos mediante la asignación de una puntuación. Retroalimentación explícita proporciona a los usuarios un mecanismo para expresar de manera inequívoca su interés en los objetos (Jawaheer, et al., 2010). Por ejemplo, la tienda online *Amazon*, *Film affinity*, *Movilens* y otros, utilizan el sistema de puntuación de *cinco estrellas*, que permite a los usuarios valorar los productos de su interés. Por otro lado, las redes sociales como *Facebook*, *YouTube* y otros usan el sistema valoración *Like* para calificar los contenidos.

Finalmente, *Google +1* es una nueva funcionalidad que Google ha añadido a su motor de búsqueda para que los usuarios puedan evaluar, de forma explícita, los sitios web que les gustan y así recomendar estos sitios a los contactos del usuario que ha realizado la valoración.

2.2.2 Retroalimentación implícita. Este proceso consiste en evaluar los objetos, sin las intervenciones de los usuarios. Es decir, se realiza sin conocimiento del usuario, a través de la captura de la información obtenida de las acciones realizadas por ellos en la aplicación. Por ejemplo, cuando el usuario accede a una noticia o leer un artículo en línea, de acuerdo con el tiempo que toma para la lectura, el sistema puede deducir si el contenido es de su interés.

Las técnicas de retroalimentación implícita se han utilizado para recuperar, filtrar y recomendar una variedad de productos: películas, artículos de revistas, documentos de Web, artículos de noticias en línea, libros, programas de televisión, y otros. Estas técnicas, según Kelly & Teevan (2003), aprovechan del comportamiento del usuario para comprender los intereses y preferencias del usuario.

3. Caso de estudio

Hay muchos comportamientos que un usuario realiza en torno a los lectores de libros electrónicos y a la plataforma de contenidos digitales en las que se encuentran disponibles los contenidos, como por ejemplo: leer, compartir, recomendar, anotar, resaltar, navegar por los contenidos, etc. Analizando las acciones básicas de un usuario (o comportamientos básicos), relevantes para la recomendación de contenidos relacionados al perfil de los usuarios en una red social, se puede encontrar acciones que desempeñan roles claves en el interés de los usuarios. Las acciones que se muestran en la Tabla 1 son claves que permiten medir el comportamiento de los usuarios en un entorno de libros electrónicos y determinar su interés por los contenidos.

Tabla 1. Acciones que definen el comportamiento de los usuarios en una plataforma de libros electrónicos.

Identificador	Acción
A1	Valorar explícitamente un contenido.
A2	Recomendar un contenido a un contacto.
A3	Recomendar un contenido en redes sociales.
A4	Comentar un contenido.
A5	Tiempo de lectura de un contenido.
A6	Resaltar un contenido.
A7	Anotar en un contenido.
A8	Añadir un contenido a favoritos
A9	Añadir un contenido a la colección
A10	Rechazar una recomendación de contenido.
A11	Acceder a una categoría
A12	Eliminar el contenido de una colección.
A13	Eliminar el contenido de favoritos.

Con la finalidad de lograr una aproximación a la solución de la retroalimentación explícita en los sistemas de recomendación, en el entorno de libros electrónicos, se ha diseñado un modelo que permite analizar el comportamiento de los usuarios y convertir estos datos en un valor explícito, que se aproxime al valor que un usuario otorgaría a un contenidos de forma explícita. Para ello se desarrolló una plataforma web, una aplicación cliente para dispositivos *Android* que permiten capturar el comportamiento de los usuarios y un algoritmo que permite convertir estas acciones implícitas en un valor explícito.

3.1 Modelo

En la Figura 1 se muestra el modelo para la plataforma de recomendación de libros electrónicos basado en el comportamiento de los usuarios. Como se puede ver, se captura la información de los usuarios mediante un proceso de retroalimentación. Estos datos pueden ser obtenidos desde la aplicación Web y desde un dispositivo móvil que se comunica con la plataforma a través de servicios Web. Posteriormente, los datos son analizados por un proceso de conversión que permite convertir la información implícita en valores explícitos. Finalmente, con un motor de recomendación, se toman estos datos explícitos y se recomiendan a los usuarios contenidos relacionados a esta información. A continuación se describe cada uno de los procesos de este modelo.

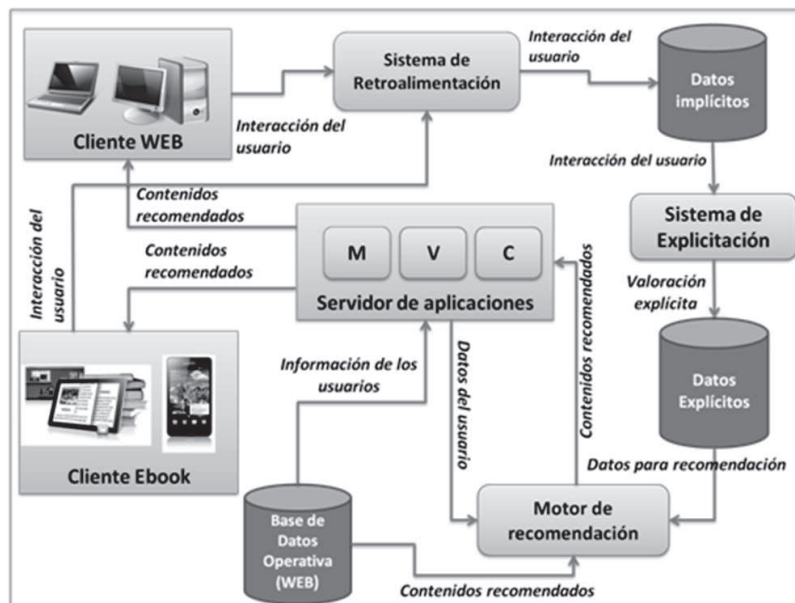


Figura 1. Modelo para la recomendación de contenidos para libros electrónicos inteligentes

3.1.1 Proceso de retroalimentación de la información. Para recopilar la mayor cantidad de información durante la interacción de los usuarios se desarrolló en *Ruby on Rails* la *Gema Grabador de Interacciones del Usuario*, GIUG, que permite almacenar la acciones del usuario de manera implícita, utilizando la plataforma web de libros electrónicos o desde un dispositivo móvil inteligente mediante servicios web. De forma general, esta gema brinda la facilidad de configurar cuáles acciones se desean almacenar en un aplicación web basada en el modelo MVC. En

la Tabla 1 se muestra el conjunto de acciones que se pueden capturan en la plataforma Web con la utilización de esta gema. En la aplicación se configuran las acciones específicas a incluir en el proceso, mediante un fichero de configuración.

La instalación de GIUG en el entorno se realiza de una forma fácil y rápida, una vez está instalada la gema en el equipo, puede ser utilizada por cualquier aplicación que se ejecute en este entorno. Esta se instala mediante la línea de comando: `gem install path/user_interactions_recorder.gem`

Para la utilización de esta gema en cualquier aplicación web desarrollada en *Ruby on Rails* solo hay que generar la configuración inicial de la aplicación utilizando la línea de comando: `script/generate user_interactions_recorder`

Este comando generará dos ficheros de configuración en la aplicación donde ejecute:

- Plantilla de configuración de controladores: la Figura 2 muestra una plantilla inicial de ejemplo de cómo pueden configurarse las acciones de los controladores que se desea almacenar.
- Fichero de migraciones a base de datos: Genera un fichero de migración para la creación de la tabla necesaria para el registro de las interacciones.

Una vez instalada y configurada GIUG, automáticamente la aplicación web comenzará a almacenar las interacciones de los usuarios.

```
dont_record_user_id
dont_record_session_id
dont_record_request_params

record :controller_name => 'contents',
:action_mappings => {'new' =>{:action_name => 'new_content'},
                    'create' => {:action_name => 'create_content'},
                    'edit' => {:action_name => 'edit_content'},
                    'show' => {:action_name => 'show_content'},
                    'update' => {:action_name => 'update_content'},
                    'index' => {:action_name => 'contents_list'}},
:options => {:object_name => 'Content',
            :object_id_request_name => 'id',
            :extra_request_params_names => :all}
```

Figura 2. Plantilla de configuración de controladores

Por otra parte, para almacenar las interacciones desde un dispositivo móvil se desarrolló un lector de libros electrónico basados en Android, que permite leer los libros de la plataforma, así como sincronizar sus contenidos disponibles en la aplicación Web (Figura 3).

3.1.2 Proceso de conversión de la información implícita en valores explícitos usando ACRIE. La finalidad del *Algoritmo de Conversión de la Retroalimentación Implícita a Explícita*, ACRIE, es evaluar los diferentes comportamientos del usuario relacionados a sus hábitos de lecturas y su interacción con una plataforma de libros electrónicos. Este algoritmo evalúa las acciones implícitas previamente configuradas en la plataforma y, mediante una serie de procesos, convierte estos valores en una valoración explícita establecida dentro de un rango que indicarían el interés de un usuario por un contenido.

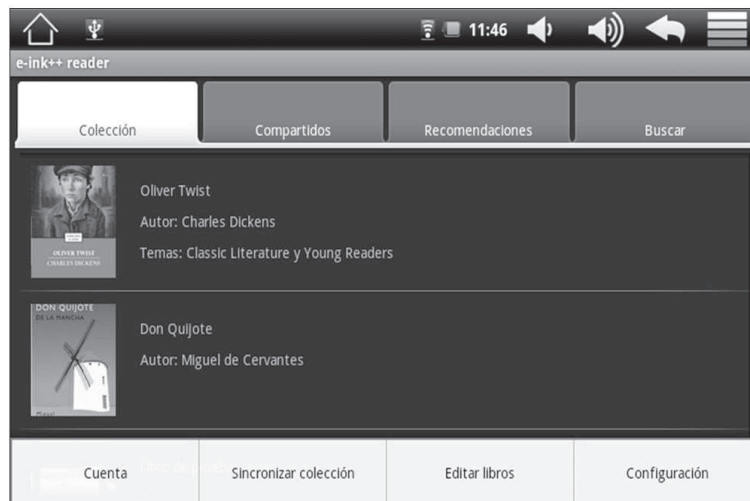


Figura 3. Pantalla principal de la aplicación Android

Comúnmente, cuando los usuarios valoran explícitamente un contenido otorgan un valor que indica si un producto le interesa o no, usando algunos de los sistemas de valoración explícita indicados en el estado de arte de este artículo, como por ejemplo: el de *Cinco estrellas*. ACRIE evalúa todas las acciones del usuario y los convierte en un valor explícito, es decir, como si el usuario diera un valor directamente al contenido.

Fundamentalmente, para que ACRIE pueda obtener una valoración que represente el interés de un usuario i por un contenido j basado en el análisis y la interpretación de las acciones que este realiza entorno al contenido, se definieron un conjunto de ecuaciones matemáticas que

con su implementación permiten medir el comportamiento del usuario en cada una de las acciones realizadas y convertirlas en un valor numérico definido dentro de un rango establecido.

La valoración final de un contenido j para un usuario i se determina midiendo cada acción de forma independiente y asignándole un peso P . El peso P tiene con finalidad la asignación del nivel de importancia de cada acción cuando se calcula el interés del usuario. La valoración final del interés del usuario i para el contenido j basado en el comportamiento del usuario, se calcula con la ecuación:

$$V(i, j) = \begin{cases} A_1 & \text{si } A_1 > 0 \\ S & \text{si } A_1 \leq 0 \end{cases}$$

Donde:

$V(i, j)$: es la valoración al j -ésimo contenido para el i -ésimo usuario.

i : es el i -ésimo usuario que realizó alguna acción entorno al j -ésimo contenido.

j : es el j -ésimo contenido en torno al cual i -ésimo usuario realizó alguna acción.

A_j : Es la valoración explícita del j -ésimo contenido asignado por el i -ésimo usuario.

S : es el valor obtenido del cálculo de las acciones implícitas. Este valor se calcula con la siguiente ecuación:

$$S = \frac{\sum_{k=2}^n (P_k + Pr)A_k + A_k}{N + 1}$$

Donde:

P_k : es el peso asignado a la acción A_k . Donde P_k debe cumplir con las siguientes restricciones:

- $0 \leq P_k \leq 1$
- $\sum_{k=2}^n P_k = 1$

k : es el sub-índice que identifica la acción.

$(P_k + Pr)A_k$: es el porcentaje del peso añadido a valor de la acción.

N : es la cantidad de acciones con el j -ésimo contenido realizadas por i -ésimo usuario. Este valor se obtiene mediante la ecuación:

$$N = \sum_{k=2}^n f(A_k)$$

$f(A_k)$: es la función que indica que el i -ésimo usuario realizó la acción A_k en el j -ésimo contenido. El valor de esta función se determina con:

$$f(A_k) = \begin{cases} 1, & \text{Si } A_k > 0. \\ 0, & \text{Si } A_k \leq 0 \end{cases}$$

Pr : es el peso restante de las acciones $A_2 \dots A_n$ NO realizadas por el i -ésimo usuario entorno j -ésimo contenido y que será redistribuido entre los pesos P_k de las acciones realizadas. El valor de Pr se calcula mediante:

$$Pr = \frac{\sum_{k=2}^n Q(A_k)}{N}$$

Donde:

N : es la cantidad de acciones realizadas por i -ésimo usuario entorno al j -ésimo contenido. Valor que se obtiene con mediante la fórmula definida en párrafos anteriores.

$Q(A_k)$: es la función que devuelve el valor del peso de la acción A_k que el i -ésimo usuario NO realizó entorno el j -ésimo contenido. El valor de esta función se determina con la forma siguiente:

$$Q(A_k) = \begin{cases} P, & \text{Si } A_k \leq 0. \\ 0, & \text{Si } A_k > 0 \end{cases}$$

Con la finalidad de mostrar cómo se calculan el valor de las acciones que se muestran en la Tabla 1 con *ACRIE*, a continuación se explica la formalización matemática para las dos primeras acciones presentadas en dicha tabla:

- A₁ Valorar explícitamente un contenido. Cuando un usuario valora explícitamente un contenido, las demás acciones que realizó sobre el contenido se descartan, porque el usuario está indicando, de forma explícita, el interés por dicho contenido. Esto indica que uno de los

puntos principales es saber si el usuario ha valorado explícitamente dicho contenido, por lo cual, cuando se realizan las mediciones de las interacciones implícitas del usuario se debe saber si ya se ha valorado anteriormente ese contenido, y si fue valorado explícitamente o implícitamente.

Si el contenido tiene valoración previa calculada automáticamente por el sistema, es decir, que si esta valoración se ha obtenido del análisis y cálculo de las acciones basadas en el comportamiento del usuario, y este valora nuevamente el contenido pero de manera explícita, el último valor reemplazará al valor anterior, ya que la valoración explícita indica de manera directa el interés del usuario por el contenido.

De forma general, dada la obtención del resultado de dos valoraciones de un usuario sobre un contenido (una explícita y otra implícita), el resultado final de la valoración del contenido será igual a la valoración dada por el usuario de forma explícita, independientemente de orden y del momento en que se obtengan dichos valores. La valoración explícita de un contenido se obtiene mediante la siguiente ecuación:

$$A1(i, j) = x$$

Donde:

i: es el *i*-ésimo usuario de la plataforma que valoró explícitamente el contenido.

j: es el *j*-ésimo contenido de la plataforma que fue valorado explícitamente por un usuario.

x: es la puntuación explícita que el *i*-ésimo usuario otorgó al *j*-ésimo contenido.

- **A₂ Recomendar un contenido a un contacto.** Según Núñez Valdez et al. (2012), los usuarios solo recomiendan a sus contactos los contenidos que les parecen interesantes. En esta plataforma es necesario conocer la cantidad de veces que el usuario recomendó un contenido a sus contactos, y la relación de estas recomendaciones con las hechas por todos los demás usuarios de la plataforma. A mayor número de recomendaciones, mayor es el interés.

De forma general, se puede decir que recomendar un contenido a un contacto es una acción que tendrá un peso importante a la hora de determinar el interés del usuario, debido a que la tendencia es que el usuario solo recomienda un contenido que le parece interesante o que cree que puede interesarle a quien lo recomienda. La relación con las recomendaciones realizadas por los demás usuarios de la plataforma se realiza con la finalidad de tomar en cuenta el interés general por el

contenido. El valor de recomendar un contenido a sus contactos se calcula mediante la siguiente ecuación:

$$A_2(i, j) = \begin{cases} \frac{Tr(i, j)}{MAX(TTr(i, j))} * (Ls - Li) + Li, & \text{si } Tr(i, j) > 0 \\ 0, & \text{si } Tr(i, j) \leq 0 \end{cases}$$

Donde:

i: es el *i*-ésimo usuario que recomendó un contenido a un contacto.

j: es el *j*-ésimo contenido de la plataforma que fue recomendado por un usuario.

Ls: es el límite superior de la normalización del valor de *Tr (i,j)*.

Li: es el límite inferior de la normalización del valor de *Tr (i,j)*.

Tr (i,j) : es el total de recomendaciones a sus contactos del *j*-ésimo contenido hecha por el *i*-ésimo usuario . Este total se calcula mediante la ecuación:

$$Tr(i, j) = \sum_{r=1}^n r(i, j)$$

Donde, *r*: es una recomendación a un contacto de un contenido hecha por un usuario.

TTr (i,j) : es el conjunto del total de las recomendaciones de los contenidos *j* de cada usuario *i* en la plataforma. Este conjunto se define como:

$$TTr(i, j) = Tr(1, 1), Tr(1, 2), \dots, Tr(2, 1), Tr(2, 2), \dots, Tr(i, j)$$

MAX (TTr(i, j)) : es el número máximo de recomendaciones de un contenido *j* que un usuario *i* a realizado a sus contactos en el conjunto *TTr(i, j)*

Con la implementación de estas formulaciones matemáticas, definidas para las acciones que se consideran en la plataforma, se puede determinar de forma eficaz el interés de usuario por un contenido, basándose en su comportamiento.

3.1.3 Motor de recomendación. Como se muestra en Tabla 2, después de definidas las acciones y analizado el comportamiento de los usuarios; ACRIE genera un conjunto de datos basados en una relación *Usuario -> Contenido-> Valor*. Con estos valores generados se puede implementar cualquier motor de recomendación existente en la actualidad, ya que las mayorías se basan en esta relación.

Tabla 2. Valoraciones de los usuarios a los contenidos

Usuario	Contenido	Valor
1	1	3
2	2	1
1	2	5

Con estos valores calculados y con la implementación de un motor de recomendación se puede recomendar, al usuario, contenidos relacionados con su perfil.

4. Conclusiones y trabajos futuros

En este trabajo se ha propuesto un modelo para definir una plataforma de recomendación de contenidos, basado en el comportamiento de los usuarios, que permita implementar un sistema de recomendación que ayude a los usuarios a descubrir contenidos de su interés.

Este modelo, basado principalmente en la retroalimentación implícita, permite recomendar contenidos sin la necesidad de que los usuarios tengan que valorar explícitamente los contenidos que le parecen interesantes.

Con el desarrollo del proceso de conversión de la información implícita, donde se evaluaron e implementaron las distintas acciones que fueron definidas con modelo de transformación matemático presentado en este artículo, se pueden construir sistemas de recomendación más eficaces, basado en el análisis del comportamiento de los usuarios en un entorno de libros electrónicos.

Como se muestran en el caso de estudio, la implementación de los procesos definidos en el modelo son pocos complejos de implementar, lo que permite que en una plataforma se pueda incluir fácilmente un sistema de recomendación.

Como trabajo futuro se piensa analizar la forma de implementar este modelo en otros entornos diferentes al de libros electrónicos que permita recomendar cualquier tipo de productos. Otro de los trabajos futuros es implementar un DSL (*Domain Specific Language* o Lenguaje de Dominio Específico) que permita independizar el diseño del sistema de recomendación de su implementación, haciendo que sea un proceso automático, para así reducir la complejidad.

Bibliografía

- ADOMAVICIUS, G. & TUZHILIN, A. (2005). Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. In: IEEE Transactions on Knowledge and Data Engineering, Vol. 17, No. 6, (Abr.), Washington (USA): IEEE Computer Society. p. 734-749, ISSN: 1041-4347.
- ADOMAVICIUS, G.; SANKARANARAYANAN, R.; SEN, S. & TUZHILIN, A. (2005). Incorporating contextual information in recommender systems using a multidimensional approach. In: ACM Transactions on Information Systems (TOIS), Vol. 23, No. 1, (Jan.), New York (NY, USA): ACM, p. 103-145. ISSN: 1046-8188.
- BALABANOVIC, M. & SHOHAM, Y. (1997). Fab: content-based, collaborative recommendation. In: Communications of the ACM, Vol. 40, No. 3, (Mar.). New York (NY, USA): ACM. p. 66-72. ISSN: 0001-0782.
- BURKE, R. (2002). Hybrid Recommender Systems: Survey and Experiments. In: User Modeling and User-Adapted Interaction, Vol. 12, No. 4 (Nov.), Hingham (MA, USA): Kluwer Academic Publishers. p. 331-370. ISSN: 0924-1868.
- CLAYPOOL, M.; BROWN, D., L. E. P. & WASEDA, M. (2001). Inferring User Interest. In: IEEE Internet Computing, Vol. 5, No. 6, (Nov/Dec.), Washington USA: IEEE Computer Society. p. 32-39. ISSN: 1089-7801.
- GONZÁLEZ CRESPO, R.; SANJUÁN MARTÍNEZ, O.; CUEVALOVELLE, J. M.; GARCÍA-BUSTELO PELAYO, B. C.; LABRA GAYO, J. E. & ORDÓÑEZ DE PABLOS, P. (2011). Recommendation System based on user interaction data applied to intelligent electronic books. In: Computers in Human Behavior, Vol. 27, No. 4, (Jul.), Elsevier. p. 1445-1449. ISSN: 0747-5632.
- JAWAHEER, G.; SZOMSZOR, M. & KOSTKOVA, P. (2010). Comparison of implicit and explicit feedback from an online music recommendation service. In: HetRec'10, (26-30/09/2010), Barcelona (Spain): ACM. Proceedings of the 1st International Workshop on Information Heterogeneity and Fusion in Recommender Systems. New York (NY, USA): ACM, p. 47-51. ISBN: 978-1-4503-0407-8.
- KAUTZ, H.; SELMAN, B. & SHAH, M. (1997). Referral Web: combining social networks and collaborative filtering. In: Communications of the ACM, Vol. 40, No. 3, (Mar.). New York (NY, USA): ACM, p. 63-65. ISSN: 0001-0782.
- KELLY, D. & TEEVAN, J. (2003). Implicit feedback for inferring user preference: a bibliography. In: ACM SIGIR Forum, Vol. 37, No. 2, (Fall), New York (NY, USA): ACM, p. 18-28. ISSN: 0163-5840.
- LINDEN, G.; SMITH, B. & YORK, J. (2003). Amazon.com recommendations: item-to-item collaborative filtering. In: Internet Computing, IEEE, Vol. 7, No. 1, (Jan/Feb.), Washington USA: IEEE Computer Society. p. 76-80. ISSN: 1089-7801.
- NOOR, S. & MARTINEZ, K. (2009). Using social data as context for making recommendations: an ontology based approach. In: Workshop on Context, Information and Ontologies, CIAO2009 (01/06/2009). Heraklion (Greece): ACM. Proceedings of the 1st Workshop on Context, Information and Ontologies, Article 7. New York (NY, USA): ACM. P. 7:1-7:8. ISBN: 978-1-60558-528-4.
- NÚÑEZ VALDEZ, E. R.; SANJUÁN MARTÍNEZ, O.; CUEVALOVELLE, J. M. & PELAYO GARCÍA-BUSTELO, B. C. (2010). First Steps towards Implicit Feedback for Recommender Systems in Electronic Books. In: CARVALHO A. de Leon F. de; RODRÍGUEZ-GONZÁLEZ, S.; DE PAZ SANTANA, J. F. & CORCHADO, J. M. (Eds.), Distributed Computing and Artificial Intelligence, Vol. 79, Berlin (Germany): Springer. p. 61-64. ISBN: 978-3-642-14882-8.
- NÚÑEZ VALDEZ, E. R.; SANJUÁN MARTÍNEZ, O.; CUEVALOVELLE, J. M.; ORDÓÑEZ DE PABLOS, P. & MONTENEGRO MARÍN, C. E. (2012). Implicit Feedback Techniques on Recommender Systems applied to Electronic Books. In: Computers in Human Behavior, Vol. 28, No. 4 (Jul.). Burlington (MA, USA): Elsevier Ltd. p. 1186-1193. ISSN: 0747-5632 <<http://www.sciencedirect.com/science/article/pii/S0747563211001956>> [consult: 13/03/2012]
- O'DONOVAN, J. & SMYTH, B. (2005). Trust in recommender systems. In: IUI'05. (09-12/01/2005), San Diego (CA, USA): ACM. Proceedings of the 10th international conference on intelligent user interfaces, New York (NY, USA): ACM. ISBN: 1-58113-894-6.

- RESNICK, P. & VARIAN, H. R. (1997). Recommender systems. In: Communications of. ACM, Vol. 40, No. 3, (Mar.), New York (NY, USA): ACM. p. 56-58. ISSN: 0001-0782.
- RESNICK, P.; IACOVOU, N.; SUCHAK, M.; BERGSTROM, P. & RIEDL, J. (1994). GroupLens: an open architecture for collaborative filtering of netnews. In: CSCW'94 (22-26/10/1994), Chapel Hill (NC, USA): ACM. Proceedings of the 1994 ACM conference on Computer supported co-operative work. New York (NY, USA): ACM, p. 175-186. ISBN: 0-89791-689-1.
- TAGHIPOUR, N. & KARDAN, A. (2008). A hybrid web recommender system based on Q-learning. In: 23rd Annual ACM Symposium on Applied Computing (16-20/03/2008). Fortaleza (Ceará, Brazil): The ACM Special Interest Group on Applied Computing. Proceedings of the 2008 ACM symposium on Applied computing. New York (NY, USA): ACM. p. 1164 - 1168. ISBN: 978-1-59593-753-7
- WANG, P. (1998). Why recommendation is special? In: AAAI-98, (26-30/07/1998). Madison (Wisconsin, USA): Association for the Advancement of Artificial Intelligence. Workshop on Recommender Systems, part of the 15th National Conference on Artificial Intelligence, p. 111-113. ISBN 978-1-57735-418-5.
- ZIEGLER, C. N.; MCNEE, S. M.; KONSTAN, J. A. & LAUSEN, G. (2005). Improving recommendation lists through topic diversification. In: WWW'05 (10-14/05/2005), Chiba (Japan): The International World Wide Web Conference Committee (IW3C2). Proceedings of the 14th international conference on World Wide Web, New York (NY, USA): ACM, p. 22-32. ISBN: 1-59593-046-9.

