

Control del usuario en sistemas de recomendación

[User control in recommendation systems]

Gary Reyes and Jimmy Sornoza

Facultad de Ciencias Matemáticas y Físicas,
Universidad de Guayaquil,
Guayaquil, Ecuador

Copyright © 2018 ISSR Journals. This is an open access article distributed under the *Creative Commons Attribution License*, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT: At present where there are large volumes of information, recommendation systems are needed to help users find and evaluate articles of preference or interest. A number of investigations in this domain suggest that “best” recommendations, according to objective metrics, are sometimes not the ones that are most satisfying or useful to users. However, if the system assumes that user preferences are not in line with the recommendation made, mechanisms should be provided to put the user in control of the recommendations. The article investigates how to give control to the users in the systems of recommendation and the quality of these from a perspective centered on the user. We discuss a study that involved 4 scientific investigations related to the subject and consider parameters such as the type of recommendation system, the method used, the application area and the results obtained in those investigations. Which focuses on the accuracy and novelty of the recommended articles, and on the general satisfaction of the users. We have classified the recommendations considered with respect to these attributes and compared these results with measures of statistical quality of the algorithms considered. It is intended to generate new recommendations based on new preferences that could lead to greater user satisfaction and confidence in the system.

KEYWORDS: User control, user experience and recommendation system.

RESUMEN: En la actualidad, donde hay grandes volúmenes de información, se necesitan sistemas de recomendación para ayudar a los usuarios a encontrar y evaluar artículos de preferencia o interés. Varias investigaciones en este campo sugieren que las "mejores" recomendaciones, de acuerdo con las métricas objetivas, a veces no son las más satisfactorias o útiles para los usuarios. Sin embargo, si el sistema asume que las preferencias del usuario no están en línea con la recomendación formulada, se deben proporcionar mecanismos para poner al usuario en control de las recomendaciones. El artículo investiga cómo dar control a los usuarios en los sistemas de recomendación y la calidad de estos desde una perspectiva centrada en el usuario. Discutimos un estudio que involucró 4 investigaciones científicas relacionadas con el tema y consideramos parámetros tales como el tipo de sistema de recomendación, el método utilizado, el área de aplicación y los resultados obtenidos en esas investigaciones. Que se centra en la precisión y novedad de los artículos recomendados, y en la satisfacción general de los usuarios. Hemos clasificado las recomendaciones consideradas con respecto a estos atributos y comparamos estos resultados con medidas de calidad estadística de los algoritmos considerados. Tiene la intención de generar nuevas recomendaciones basadas en nuevas preferencias que podrían conducir a una mayor satisfacción del usuario y confianza en el sistema.

PALABRAS-CLAVE: control del usuario, experiencia del usuario y sistema de recomendación.

1 INTRODUCCIÓN

Los sistemas de recomendación son herramientas de software desarrolladas para ayudar a los usuarios en el proceso de toma de decisiones con respecto a un tema específico. Estos sistemas comienzan a emerger a mediados de los años 90, como solución ante el desbordamiento de información que desde aquel entonces ya estaban ocasionando a nivel global las nuevas tecnologías de la información y las comunicaciones (TICs) y en particular la World Wide Web (WWW), haciendo difícil para una persona obtener la mejor información dentro de este cúmulo, al no tener esta, en muchos casos, detalles de cada una de las alternativas a seleccionar.

Los **sistemas de recomendación** forman parte de un sistema de filtrado de información, los cuales presentan distintos tipos de temas o ítems de información (películas, música, libros, noticias, imágenes, páginas web, etc.) que son del interés de un usuario en particular. Generalmente, un sistema recomendador compara el perfil del usuario con algunas características de referencia de los temas, y busca predecir el "ranking" o ponderación que el usuario le daría a un ítem que aún el sistema no ha considerado. Estas características pueden basarse en la relación o acercamiento del usuario con el tema o en el ambiente social del mismo usuario.

Actualmente, el uso de estos sistemas se ha extendido a una gran variedad de aplicaciones, destacándose las de E-commerce y las de E-learning. De manera general, se puede decir que los datos que utilizan los sistemas recomendadores pueden separarse en tres grupos:

- **Ítems:** Son los elementos que son recomendados. El valor de un ítem puede ser positivo si resulta útil para el usuario, así como puede ser negativo si el usuario considera que fue una mala decisión seleccionarlo. Los ítems tienen, además, características que pueden indicar cuan necesario resultan para un usuario determinado.
- **Usuarios:** Un usuario puede tener diversidad de metas o preferencias cuando accede a un software. Para poder ofrecer las recomendaciones adecuadas el sistema debe explorar toda la información disponible acerca de dicho usuario, ya sea la que inicialmente se haya solicitado o la que se va recopilando a lo largo de la interacción de la persona con el sistema.
- **Transacciones:** Genéricamente se le denomina transacciones a la interacción de los usuarios con el sistema de recomendación. De esta manera se puede almacenar información acerca de las preferencias de los usuarios sobre los ítems. Una de las formas más frecuentes y populares de ver las transacciones es a través de los "ratings". Este término se refiere a la evaluación que realiza un individuo sobre un ítem que es sometido a su consideración, de esta forma se puede almacenar el criterio que tiene el usuario sobre un ítem determinado.

Existen diversos tipos de sistemas recomendadores, agrupándose en tres clasificaciones generalmente: basados en el contenido, filtrado colaborativo y recomendadores híbridos.

Los recomendadores basados en el contenido son aquellos sistemas que recomiendan los ítems a los usuarios basándose exclusivamente en la descripción del ítem y de un perfil que contenga los intereses del propio usuario.

El filtrado colaborativo (FC) tiene como base identificar personas con similitudes en sus preferencias para así crear las recomendaciones. Con el FC los usuarios expresan sus intereses a partir de algunos ítems que se les presentan, ayudando al sistema, de esta manera, a crear un perfil [9].

Los híbridos combinan dos o más técnicas de la recomendación para ganar un funcionamiento mejor con menos desventajas, aprovechando los puntos fuertes de estas técnicas.

En la actualidad estos sistemas de recomendaciones al seguir algoritmos específicos según el tipo de sistema recomendado tiene como deficiencia que solamente muestra al usuario información basada en las preferencias del usuario o coincidencias que pueda tener con un vecino, sin ser capaz de ampliar la gama de contenido o proponerle otros temas que podrían ser de interés. Esto trae consigo que muchas veces el usuario no encuentre exactamente lo deseado o se quede con lo mostrado sin profundizar que otro contenido le podría interesar, limitándolo de información. Por tanto, la calidad de la recomendación, su precisión y exhaustividad puede no ser certera y si el usuario no posee control del mismo entonces puede implicar que no abarque otras posibles soluciones que podrían ser de interés al usuario.

El presente trabajo tiene como **objetivo general:** realizar un análisis del control del usuario en sistemas de recomendación teniendo en cuenta los ítems recomendados, la calidad de la recomendación y su precisión.

El artículo consta de las siguientes secciones:

- **Antecedentes y trabajos relacionados:** Se explica en qué consisten los sistemas de recomendaciones y de qué forma se le puede dar el control al usuario a partir del estudio de investigaciones referentes al tema.

- **Materiales y métodos:** Se realiza una revisión de algunas investigaciones que estudian cómo dar control al usuario en Sistemas de Recomendación y se exponen los principales métodos que usan. Se comparan además cada una de las investigaciones revisadas teniendo en cuenta el tipo de sistema de recomendación, el método usado, el área de aplicación y los resultados obtenidos.
- **Conclusión y trabajos futuros:** Se analizan los resultados obtenidos y se muestra cómo el usuario puede tomar el control de las recomendaciones. Además se expone campos abiertos en el tema en los que se puede profundizar.

2 ANTECEDENTES Y TRABAJOS RELACIONADOS

Actualmente los núcleos consolidados en lo referente a temas de dirección económica, política y cultural están integrados en Internet, lo cual lo convierte en el medio de comunicación y de relación esencial sobre el que se basa la nueva forma de sociedad que ya vivimos. La actividad en Internet crece por minutos lo que deriva la rapidez con la que lo hace también la información. Nos encontramos en una era donde existen más de mil millones de sitios web, donde el trabajo adquiere cada vez mayor importancia en una economía que depende de la capacidad para obtener, procesar y aplicar información on-line.

En efecto, nos encontramos en plena eclosión informativa, donde podemos encontrar información en diferentes formatos, ya sea texto, imágenes, videos y audios. Debido a esto, se vuelve cada vez más complejo tomar una buena decisión acerca de algo de nuestro interés. Los Sistemas de Recomendación son herramientas de software y técnicas que ayudan a dar una sugerencia al usuario en la selección de un producto y apoya a la toma de decisión. Los datos de entrada a estos sistemas se procesan mediante algoritmos de filtrado para posteriormente realizar una predicción de recomendaciones. **[Erreur ! Source du renvoi introuvable.]**

El artículo “Sistemas de recomendación” por Adriana Almaraz Pérez y John Goddard Close plantea como se vuelve cada vez más complejo tomar una buena decisión acerca de algo de nuestro interés, que responde la interrogante de: ¿cuántas veces nos hemos encontrado con tanta información en la red que no sabemos que elegir? Los autores muestran la manera en que estos sistemas nos ayudan a tomar beneficio de la gran cantidad de información que es procesada antes de darnos una recomendación acorde a nuestras necesidades o intereses. **[Erreur ! Source du renvoi introuvable.]**

Algunos ejemplos actuales del uso de sistemas de recomendación son **[Erreur ! Source du renvoi introuvable.]**:

- **Recomendaciones en tiendas on-line:** Partiendo de un producto se recomiendan otros productos que han interesado a los usuarios que compraron el mismo. La web pionera en este tipo de recomendaciones fue Amazon.com Filtrado de noticias, en el que se construye un perfil que almacena las noticias que un usuario consulta.
- **Recomendaciones musicales, de libros o películas:** En los últimos años han surgido decenas de webs de este tipo entre las que destacan “last.fm” y “MyStrands”. En estos servicios, cada vez que un usuario escucha una canción se envía su información a la base de datos del sistema, el cual las utiliza para generar nuevas recomendaciones, pero las funcionalidades que ofrecen crecen constantemente. Por ejemplo last.fm ofrece radios personalizadas para cada usuario en función de las recomendaciones que reciba y MyStrands organiza fiestas en las que la música se elige automáticamente de forma colaborativa en función de los gustos de los asistentes. El modelo de negocio de estas empresas, es además de la publicidad, el de acuerdos con tiendas on-line para enlazar directamente las recomendaciones con su servicio de venta.
- **Búsqueda de personas afines en comunidades o redes sociales:** En webs como meneame.net se tienen en cuenta las noticias que cada usuario ha votado para generar una lista de vecinos con similares intereses y Facebook por su parte usa un sistema de recomendación para sugerir nuevas amistades a partir de la colaboración entre grupos sociales.

Existe una gran variedad de sitios web donde podemos encontrar Sistemas de Recomendación, dentro de los más comunes se encuentran:

- **Amazon.com:** Se utilizan los algoritmos de recomendación para personalizar la tienda en línea para cada cliente y puede tener un cambio radical para cada uno, es decir, no es lo mismo que se le muestra a un ingeniero que a una mamá primeriza, usa recomendaciones como una herramienta de marketing dirigido en muchas campañas de correo electrónico y en muchos sitios de páginas web, incluyendo la demanda de su propia página.
- **Netflix:** Sistema de recomendación de películas que le proporciona al suscriptor una cantidad ilimitada de rentas de las películas y series de su catálogo. Realiza recomendaciones personalizadas por lo cual el suscriptor verá en su cuenta los programas y películas que más le interesan, según sus gustos. Dichas preferencias se recolectan durante la suscripción, tras la visualización que cada miembro haga del contenido y también tiene en cuenta la calificación que el

usuario otorga a cada película o serie. Con toda esta información se determinan las preferencias y el sistema personalizará las recomendaciones de contenido que serán más interesantes para ese usuario concreto.

- Facebook: Es una de las redes sociales más grandes a nivel mundial que maneja sistemas de recomendación. Los SR se utilizan para recomendar al usuario personas que quizá conozca, películas, libros, páginas, productos, grupos, juegos, basándose en la información brindada por la comunidad o por el mismo usuario.
- MovieLens: es un Sistema de Recomendación de películas gratuito que utiliza el filtrado colaborativo para generar recomendación de películas. En este sistema el usuario puede calificar las películas que ha visto indicando que tanto es de su agrado, esta permite generar una recomendación personalizada de otras películas que pueden ser de interés para el usuario.

Entre los objetivos que persiguen los sistemas de recomendación está incrementar la satisfacción del usuario, de manera que se brinden recomendaciones afines al mismo, para que esté complacido con la recomendación y la decisión que ha tomado con su ayuda, ya sea al comprar un producto, escuchar una canción o ver una película. Si el Sistema de Recomendación da una recomendación del interés del usuario y éste queda satisfecho seguramente regresará a utilizar ese sistema para futuras consultas.

A pesar de la eficacia de este tipo de sistemas también se pueden encontrar con retos que provocan fallas, como la falta de datos, el cambio de gustos de cada usuario con el tiempo y la forma en que el usuario pueda o no controlar las recomendaciones del sistema. Para combatir los retos que se presentan es importante que se investigue el campo que se desea estudiar, se conozcan los datos con los que se cuentan y en base a ello elegir el tipo de agrupamiento más adecuado a implementar para un Sistema de Recomendación. Se debe tener presente que cada persona es diferente y por lo tanto las recomendaciones deben contemplar diferentes afinidades para no terminar en fracaso. **[Erreur ! Source du renvoi introuvable.]**

El principio de funcionamiento de los sistemas de recomendación está resumido en el problema de la recomendación, el cual puede ser formulado de la siguiente forma: Sea C un conjunto de usuarios, y S el conjunto de todos los ítems posibles a ser recomendados, tales como libros, películas o restaurantes, pudiendo ser bien grande la cardinalidad de ambos conjuntos. Sea además u una función que mide la utilidad del ítem s al usuario c , o sea $u: C \times S \rightarrow R$, donde R es un orden total (enteros no negativos o números reales en un determinado rango). Con estos elementos, se desea, para cada usuario $c \in C$, aquel ítem $s' \in S$ que maximice la utilidad del usuario. Más formalmente: $\forall c \in C, S'c = \operatorname{argmax}_{s \in S} u(c, s)$

Estos sistemas suelen predecir la relevancia de cada elemento para el usuario individual sobre la base de sus preferencias pasadas y su comportamiento observado. Sin embargo, si el sistema asume que las preferencias de los usuarios son incorrectas u obsoletas, deberían proporcionarse mecanismos que pongan el usuario al control de las recomendaciones, por ejemplo, permitiéndoles especificar sus preferencias explícitamente o dar su opinión sobre las mismas.

La explicación de las recomendaciones para proporcionar transparencia y aumentar la confianza se ha investigado ampliamente durante la última década. En la mayoría de los casos, estas explicaciones se presentan en texto sin formato e indican por qué se sugiere un elemento específico a un usuario, como ¿por qué ha seleccionado o ha sido altamente clasificado: Película A? Además de apoyar la transparencia, se busca permitir la interacción con los sistemas de recomendación como base para apoyar la exploración y el control del usuario. En los últimos años, se han hecho algunas investigaciones para visualizar recomendaciones que permitan estas nuevas capacidades [3].

Estudios anteriores han examinado el impacto de diferentes técnicas de recomendación sobre las percepciones subjetivas de los usuarios de las recomendaciones y es práctica común en aplicaciones industriales para medir el impacto de las recomendaciones sobre el comportamiento del usuario.

Los investigadores han implementado varios aspectos del control en los sistemas de recomendación, que van desde la simple elicitación de preferencias en el tiempo de recomendación [5, 17] hasta procesos complejos iterativos como la crítica dinámica que permite a los usuarios modificar atributos numéricos ordenados durante la fase de recomendación. Un trabajo reciente analiza las representaciones gráficas interactivas del proceso de recomendación, para permitir el control de las preferencias tanto de los artículos como de los usuarios en los sistemas de recomendación colaborativos.

3 MATERIALES Y MÉTODOS

3.1 PONER A LOS USUARIOS EN CONTROL DE SUS RECOMENDACIONES

En el artículo los autores plantean la hipótesis de que cualquier algoritmo recomendador se ajusta mejor a las expectativas de algunos usuarios que otros, dejando oportunidades de mejora. Para abordar este desafío, estudian un recomendador que

pone el control en manos de los usuarios. Además construyen y evalúan un sistema que incorpora modificadores de popularidad y de usuarios actualizados por el mismo. Plantean que los usuarios que reciben estos controles evalúan las recomendaciones resultantes de manera más positiva. El hecho de que los usuarios divergen en sus configuraciones preferidas confirma la importancia de darles el control. [Erreur ! Source du renvoi introuvable.]

Los autores estudian y plantean un método que les permite analizar el control al usuario a partir de la creación de una lista de recomendaciones de cada uno, luego la construcción de una puntuación de mezcla personalizada ($s_{u,i}$) para cada elemento, y por último la clasificación por cada puntuación. El mecanismo para calcular las puntuaciones se mantienen simples para aprender de los resultados, y flexibles para que se pueda experimentar con diferentes estrategias de mezcla. [Erreur ! Source du renvoi introuvable.]

La ecuación 1 muestra la forma general del método, una combinación lineal ponderada de variables de entrada. Donde $r_{u,i}$ es la puntuación del recomendador del ítem i para el usuario u ; f_1^1, \dots, f_1^n son representaciones numéricas de las características de los ítems, y w_u^0, \dots, w_u^n son pesos que determinan la importancia relativa de las características.

$$S_{u,i} = w_u^0 \cdot r_{u,i} + w_u^1 \cdot f_1^1 + \dots + w_u^n \cdot f_1^n \quad (1)$$

Se opera este método general como se muestra en la Ecuación 2.

$$S_{u,i} = w_u^0 \cdot \text{pred}_{u,i} + w_u^1 \cdot \text{pop}_i + w_u^2 \cdot \text{age}_i \quad (2)$$

Las variables específicas utilizadas son:

- $\text{pred}_{u,i}$: una predicción de la clasificación de que el usuario u asignará el ítem i , como generado por un algoritmo de filtrado colaborativo item-item.
- pop_i : el número de veces que el ítem i fue calificado en el último año.
- age_i : 50 menos el número de años transcurridos desde que se liberó el ítem i , fijado al rango de 0-50. Sustraído de 50 para que los elementos más nuevos tengan valores más altos, lo cual es más consistente con las preferencias típicas del usuario.

Método que usan: Este estudio se basa en un conjunto de datos de las calificaciones de los usuarios y las estadísticas de calificación de películas extraídas de la base de datos MovieLens. Incluyen usuarios con al menos 40 calificaciones, para asegurar que todos los usuarios puedan tener al menos 20 calificaciones tanto en sus entrenamientos como en sus juegos de pruebas. La muestra resultante consta de 4.976 usuarios que visitaron MovieLens una mediana de 35 veces y calificaron una mediana de 253 películas.

Realizan un estudio de simulación en línea usando una metodología rating holdout para imitar las listas de recomendación de los top-N de los usuarios. Específicamente, se realiza 5 veces los experimentos de validación cruzada, utilizando el marco de evaluación LensKit [Erreur ! Source du renvoi introuvable.]. En cada pliegue, usan cuatro grupos de usuarios para entrenar el modelo de similitud item-item y miden los resultados para el grupo restante. Para los usuarios de ese grupo se eligen 20 calificaciones al azar como sus datos de entrenamiento, mientras que sus calificaciones restantes son tratadas como sus datos de prueba.

La predicción de calificación es semi-personalizada porque en el experimento, como en el sistema en vivo, no se muestran las películas ya clasificadas para los usuarios. Se arriba a la conclusión que mezclar una pequeña cantidad de popularidad aumenta fuertemente el percentil pop promedio de las listas topN y la mezcla de una pequeña cantidad de edad aumenta fuertemente el percentil medio de la edad. Sin embargo, también se evidencia con el estudio que incluso pesos pequeños sobre la variable de mezcla tendrán una influencia dramática en las recomendaciones resultantes.

Los usuarios de MovieLens añaden artículos a una "lista de deseos" para expresar interés y "ocultar" elementos para expresar una falta de interés. Se simula la presencia de estos elementos en las listas de los 20 usuarios con # en lista de deseos y # oculto. La prueba arroja que la creciente popularidad aumenta simultáneamente ambas acciones, aunque expresan respuestas opuestas al contenido, lo cual se debe a una mayor familiaridad con los elementos de la lista, un usuario puede tener preferencias más fuertes para los artículos de los que ha oído hablar. El aumento de la ponderación de la edad tiene la propiedad de aumentar el número de artículos de la lista de deseos y de disminuir el número de artículos ocultos, aunque el efecto es más sutil que con la popularidad.

3.2 INSPECCIÓN Y CONTROL DE LOS RECOMENDADORES SOCIALES

Los sistemas de recomendación colaborativa comparan las preferencias de los usuarios con todos los demás usuarios, y recomienda los artículos que le gusten aquellos usuarios que tienen preferencias similares [Erreur ! Source du renvoi

introuvable.]. Los recomendadores sociales limitan el conjunto de otros usuarios a tus amigos, aprovechando así las conexiones personales [Erreur ! Source du renvoi introuvable., Erreur ! Source du renvoi introuvable., Erreur ! Source du renvoi introuvable.]. Se dice que los usuarios de los recomendadores sociales pueden no estar satisfechos con sólo una lista estática de recomendaciones, por el contrario, pueden querer inspeccionar y controlar la forma en que el sistema utiliza su red social para seleccionar esta lista de recomendaciones, por al menos dos razones:

Tabla 1. Los usuarios parecen apreciarlo cuando los sistemas de recomendación explican sus recomendaciones [Erreur ! Source du renvoi introuvable., Erreur ! Source du renvoi introuvable., Erreur ! Source du renvoi introuvable., Erreur ! Source du renvoi introuvable.]. En los recomendadores sociales, donde los usuarios conocen a las personas en las que se basan las recomendaciones, el sistema puede proporcionar tal explicación mostrando cómo la superposición entre las preferencias de uno y las de los amigos resultaron en un conjunto de recomendaciones. Este "gráfico de recomendación" incrementa la Transparencia [Erreur ! Source du renvoi introuvable., Erreur ! Source du renvoi introuvable.] de un sistema, lo que podría tener un efecto positivo efecto sobre la experiencia de los usuarios.

Tabla 2. Los usuarios parecen apreciar el control en su interacción con los sistemas de recomendación. Los recomendadores tienen que reunir las preferencias de los usuarios, y diferentes tipos de métodos de obtención de preferencias proporcionan diferentes niveles de control. En un recomendador que aprovecha las redes sociales como Facebook, el sistema puede usar los "gustos" de los usuarios para construir un modelo de preferencia y la superposición con los gustos de sus amigos para calcular las recomendaciones. Sin embargo, los usuarios pueden sobre este proceso, ya que quizá no les guste bien, o pueden valorar las preferencias de un amigo más allá (o de) la cantidad de superposición mutua en "gustos". Por lo tanto, los usuarios pueden querer dar un peso adicional (o menor) a algunas de las artículos y / o algunos de sus amigos.

El trabajo relacionado muestra que la inspección y el control ha resultado una experiencia positiva con los usuarios

Realizándose el estudio con 267 usuarios con el sistema TasteWeights calcula sus recomendaciones en dos pasos. Primero, los pesos se calculan para cada amigo basado en su similitud con el usuario. Específicamente, la similitud del usuario con un amigo se da por la superposición en el ítem escogido "gustos" entre ellos, definido por el coeficiente de correlación de Pearson:

$$W_{friend_i} = \frac{TWCI_{user, friend_i}}{\sqrt{TWI_{user}^2 \cdot TWI_{friend_i}^2}}$$

Donde:

TWCix: es el peso total de los elementos (" Me gusta") que los usuarios x y tienen en común.

TWix: es el peso total de los elementos gustado por el usuario x. Como los usuarios de Facebook sólo pueden escoger "Me gusta" artistas / bandas sin especificar cuánto, los pesos de los artículos se inicializarán a 0,5.

Una vez que se calculan todos los pesos de los amigos, las recomendaciones se generan asignando pesos a los elementos musicales de todos los amigos (excluyendo los elementos que el usuario ya "Me gusta"):

$$W_{rec_i} = \sum_{friend_j \text{ likes } rec_i} W_{friend_j}$$

Aquí, el peso de una recomendación *i* es la suma de los pesos de todos los amigos que las recomendaciones se muestran en orden decreciente de peso de recomendación. [Erreur ! Source du renvoi introuvable.]

Con respecto a la inspección, el sistema muestra un gráfico con los elementos de los usuarios, sus amigos y recomendaciones. Al hacer clic en el gráfico, las conexiones entre estas entidades pueden ser exploradas. El sistema permite dos tipos de control sobre las recomendaciones: los usuarios pueden ajustar el peso de sus elementos (inicializado a 0,5) y sus amigos (inicialmente ponderados por similitud). Cambiando el peso de un elemento influirá en las puntuaciones de similitud, y por lo pesos recomendados y cambiar el peso de un amigo. Los usuarios pueden hacer clic en los elementos, amigos y recomendaciones para ver los enlaces entre ellos. La fase de inspección de la condición de "sólo lista" muestra la lista más a la derecha (recomendaciones) solamente. Sumar o restar una proporción de la puntuación de similitud de ese amigo, y por lo tanto también influye en los pesos de recomendación.

Tanto la inspección como el control tienen un efecto positivo en la experiencia del usuario, principalmente porque una inspección y control del sistema de recomendación es más fácil de entender. La mayor comprensibilidad hace que los usuarios

se sientan más control sobre el sistema, lo que a su vez aumenta la calidad percibida de las recomendaciones, también indicada por un aumento de las calificaciones. Por último, el mayor control percibido y la calidad de la recomendación hacen que los usuarios estar más satisfecho con el sistema[**Erreur ! Source du renvoi introuvable.**].

3.3 CONTROL DE USUARIO EN SISTEMAS DE RECOMENDADORES

Información general y retos en la interacción, por los autores Dietmar Jannach, Sidra Naveed y Michael Jugovac, muestra en su trabajo que los sistemas de recomendaciones tiene que hacerse una parte importante en muchos sitios comerciales, donde en el artículo clasificamos las diferentes técnicas en dos clases:

Técnicas en las que se permite a los usuarios especificar explícitamente sus preferencias.

Técnicas que ponen al usuario en control en el contexto de la recomendación en el resultado.

La primera técnica que usan es cuando le permite a los usuarios especificar sus restricciones y preferencias explícitamente utilizando formularios de perfil de usuario estático. De esta forma le permite al sistema inferir indirectamente sus preferencias a partir de los datos introducidos por los usuarios, por ejemplo en este caso se utilizó esta técnica para ver los intereses de géneros, artistas entre otros atributos para recomendar películas. Puntualizar que con estas formas estáticas cada vez que cambian los intereses de los usuarios, tienen que adaptar manualmente su configuración de manera que refleje adecuadamente sus nuevos intereses.

Con la segunda técnica es cuando ya tienen los ajustes dinámicos de las recomendaciones, una vez que se ha calculado un conjunto de recomendaciones, una forma simple de permitir a los usuarios influir en lo que se presenta es proporcionarles mecanismos para filtrar y volver a clasificar los elementos basados en sus características. Esta funcionalidad de post-filtrado se implementó, por ejemplo, en el MovieCritic [20] y los sistemas MetaLens [21], donde los usuarios podrían para ejemplo incluyen o excluyen películas de ciertos géneros. En el sistema MetaLens, los usuarios también podrían indicar la importancia relativa de las características individuales.

Dándole el control al usuario donde le proporciona una explicación de las recomendaciones que hace el sistema puede ser beneficioso y de gran apoyo a que los resultados sean satisfactorio ya que ayuda a los usuarios a entender por qué se recomendaron ciertas preferencias dado que los mecanismos de control del usuario a menudo requieren que los usuarios entiendan o al menos tengan una intuición de la lógica de razonamiento del sistema, y esto a su vez podría conducir a una mayor satisfacción y confianza en el sistema.

3.4 PERMITIR QUE LOS USUARIOS ELIJAN ALGORITMOS DE RECOMENDACIÓN: UN ESTUDIO EXPERIMENTAL

Los autores Michael D. Ekstrand, Daniel Kluver, F. Maxwell Harper y Joseph A. Konstan explican que los sistemas de recomendación no son de talla única; diferentes algoritmos y fuentes de datos tienen diferentes puntos fuertes, mejor o peor para diferentes usuarios. En el artículo se muestran algoritmos para recomendar y permite a los usuarios elegir que algoritmo desea utilizar para que se muestre sus recomendaciones. Se examinan los datos de registro de las interacciones de los usuarios con una nueva función y cómo cambian los usuarios entre los algoritmos recomendados, y se realiza una selección de un algoritmo final a utilizar. También se observan las propiedades de los algoritmos que experimentaron los usuarios y examinan su relación con el comportamiento del usuario. [**Erreur ! Source du renvoi introuvable.**]

En el artículo utilizan cuatro algoritmos. Cada algoritmo fue identificando a los usuarios usando un nombre de código, derivado de las clases comunes de personajes de rol, para que pudieran ser memorables pero no revela a los usuarios exactamente qué algoritmo utilizan; una descripción muy breve acompaña cada nombre del algoritmo.

- El algoritmo Baseline predice las calificaciones utilizando un elemento de usuario personalizado. Este algoritmo fue llamado el Peasant, y fue descrito como "no personalizado".
- El recomendador de Pick-Groups es un item-item colaborativo. Filtro que utiliza calificaciones de elementos sintéticos derivadas de la elección de diferentes grupos de películas [23]. Su objetivo es proporcionar una experiencia de un usuario mejorada para los nuevos usuarios del sistema. Este algoritmo se llamó el Bardo y fue descrito como "basado en la asignación de puntos de grupo de película".
- El recomendador de item item [24], llamado Guerrero y descrito como "basado en clasificaciones", es un item-item de filtrado colaborativo. Utiliza la similitud de coseno sobre los vectores de clasificación centrada en el elemento, un

tamaño de vecindad máximo de 20, el mínimo vecindad de 2, y un peso de similitud de vecindad umbral de 0,1. El ítem CF fue el único recomendador disponible en el servicio antes de desplegar la característica recomendable.

- El recomendador SVD, llamado Wizard y también descrito como "basado en las calificaciones", es un factorizador de factorización de matriz utilizando el algoritmo FunkSVD [24] con 50 características, 125 por rasgo, y restando el ítem del usuario media personalizada antes de factorizar la matriz.

Todos los algoritmos se construyen con el kit de herramientas LensKit. Computar Top-N, la clasificación prevista del algoritmo es el factor de clasificación principal, pero se mezcla con la popularidad del artículo:

$$\widehat{s}_{ui} = 0.9 \cdot \text{rank}(s_{ui}) + 0.1 \cdot \text{rank}(p_i)$$

S_{ui} : Es la puntuación.

P_i : Es el número de calificaciones que el ítem recibió en los últimos 365 días.

$\text{rank}(x)$: normaliza su entrada a un rango, devolviendo 1 para el valor más grande (a través de todos los elementos) y 0 para el valor menor valor.

Esta mezcla es el resultado de pruebas empíricas que equilibra la popularidad con el rango de predicción, lo cual lleva a una mayor satisfacción con las listas de recomendación de la parte superior-N.

Una vez en el sistema, los usuarios pueden cambiar su algoritmo haciendo clic. Esto toma efecto inmediato; una vez que el usuario seleccionó un recomendado diferente, el sistema volvería a cargar la lista en la página actual. El sistema se organiza en torno a tres funciones principales:

- Recomendaciones de películas: la vista predeterminada muestra un conjunto de recomendaciones de películas con imágenes relevantes, el cartel de la película, y la calificación pronosticada.
- Detalles de la película: al hacer clic en una imagen de película, aparecerá más detalles como metadatos de producción, etiquetas, calificación promedio estadísticas, etc.
- Búsqueda: una función de búsqueda basada en palabras clave, con opciones para buscar por varios atributos de película. Los resultados de la búsqueda se muestran de la misma manera que las recomendaciones, y la calificación prevista del recomendado es un componente de la función de clasificación de resultados de búsqueda. La elección del usuario del algoritmo recomendado persistió la aplicación, que afecta a todo el uso de las predicciones para la visualización o clasificación de películas. Esto significa que sólo recomendaría artículos para los que podría encontrar un barrio con una similitud total de al menos 0,1.

Los usuarios usaron la función de conmutación recomendada y, a menudo, cambiaron a un recomendador diferente que su asignado inicialmente, incluso si ya estaban usando un recomendador personalizado.

Se realizó un experimento en el que se les dio a los usuarios la capacidad de seleccionar el algoritmo que estaría proporcionando sus recomendaciones en una aplicación de recomendación de películas. Los usuarios hicieron uso del control, típicamente experimentando con las diferentes opciones para encontrar un recomendador satisfactorio y mantener su elección por el resto de su uso del sistema. Se arriba a que SVD es el algoritmo más preferido, seguido de cerca por item-item, y finalmente la línea de base y recomendadores de grupo. Esto demuestra que los usuarios tienen preferencia por recomendaciones personales, y mientras que la preferencia entre item-item y SVD fue cercana, se prefirió SVD por más usuarios. Dando la elección de los usuarios puede promover su uso a largo plazo del sistema. Se trata de una investigación inicial de la dinámica de dar a los usuarios control de los medios por los cuales se calculan sus recomendaciones. Los sistemas anteriores dan a los usuarios solo una cierta recomendación.

Luego de realizar un estudio de los anteriores artículos acerca de cómo se puede dar el control a los usuarios en los sistemas de recomendación y haber analizado cada uno de los procedimientos y métodos que exponen se realiza un resumen apoyados en la tabla 1 comparativa que permite valorar las diferentes opciones.

Tabla 1. Resumen de la investigación

Investigación	Tipo de Sistema de recomendación	Área de aplicación	Procedimientos para probar el control del usuario en el sistema	Resultados
Poner a los usuarios en control de sus recomendaciones	Híbrido	Este estudio se basa en un conjunto de datos de las calificaciones de los usuarios y las estadísticas de calificación de películas extraídas de la base de datos de MovieLens .	Se muestra a los usuarios que se unieron a MovieLens en seis meses, incluimos usuarios con al menos 40 calificaciones, para asegurar que todos los usuarios puedan tener al menos 20. La muestra resultante consta de 4.976 usuarios; estos usuarios habían visitado MovieLens una mediana de 35 veces y habían calificado una mediana de 253 películas. Se realiza un estudio de simulación offline usando una metodología Ratingholdout para simular listas de recomendación de Top-N de los usuarios. Específicamente, se lleva a cabo 5 veces de validación cruzada experimentos, utilizando el marco de evaluación LensKit . En cada pliegue, se usan cuatro grupos de usuarios para entrenar el modelo de similitud item-item y se miden resultados para el grupo restante.	Se construye y evalúa un sistema que incorpora modificadores de popularidad y de reciente actualización, permitiendo a los usuarios expresar conceptos como "mostrar elementos más populares". Se arriba a la conclusión de que los usuarios que reciben estos controles evalúan las recomendaciones resultantes de maneras más positiva. Además, encontramos que los usuarios divergen en su configuración preferida, lo que confirma la importancia de dar control a los usuarios.
Control de usuario en Sistemas de Recomendadores	Híbrido	El trabajo se basa en un estudio de encuestas en el que se recopilan comentarios de los usuarios, implementado funciones de control de usuarios en Amazon.com .	Se realiza un estudio en dos fases basado en encuestas en el que se pide a los usuarios de Amazon.com acerca de su conocimiento y comportamiento de uso con respecto a los mecanismos de retroalimentación implementados en el sitio. Todos los participantes eran estudiantes de ciencias de la computación	Los resultados indican que aunque los mecanismos proporcionados en Amazon.com eran conocidos por muchos participantes, dudan en utilizarlos, que puede ser debido al esfuerzo adicional o las consecuencias poco claras de sus acciones. Además, las respuestas de los usuarios en general indican una satisfacción

			<p>y, al mismo tiempo, clientes regulares de Amazon haciendo varias compras al año.</p> <p>Fase 1: 75 estudiantes participaron en la primera parte. La hoja de encuesta mostraba capturas de pantalla de la funcionalidad de Amazon y comprendía 15 preguntas con opciones de respuesta de escala Likert de 5 puntos. Las preguntas fueron, por ejemplo, acerca de si los participantes saben o no la funcionalidad, si encuentran la funcionalidad clara, y si han utilizado o piensan usarla en el futuro.</p> <p>Fase 2: La segunda fase, que tuvo lugar unas semanas más tarde, se centró especialmente en las razones por las que los usuarios harían clic o no en las recomendaciones y sobre las posibles razones para no utilizar la funcionalidad de retroalimentación. 26 estudiantes de la población de la primera fase devolvieron las hojas de la encuesta que, además de un conjunto de elementos de cuestionario a escala Likert, incluían dos campos de texto libre donde los participantes podían expresar razones para no utilizar las funcionalidades proporcionadas.</p>	<p>limitada y la confianza en el sistema de recomendaciones y retroalimentación.</p> <p>Proporcionar mecanismos que sean comprensibles para los usuarios y que tengan un efecto inmediato sobre las recomendaciones parece ser necesario pero no suficiente, lo que requiere mejores mecanismos para poner a los usuarios en control. Por ejemplo, sistemas más fáciles de usar podrían proporcionar formas de interacción menos tediosas o indicar claramente que los cambios de perfil pueden deshacerse para reducir el temor de los usuarios a consecuencias no deseadas.</p>
Permitir que los usuarios elijan algoritmos de recomendación: un estudio experimental	Filtrado colaborativo	Este experimento tiene lugar en el contexto del lanzamiento de una nueva versión del servicio MovieLens , recomendación de películas. La nueva versión agrega soporte para algoritmos recomendadores múltiples y da a los usuarios la	La nueva versión del servicio de MovieLens admite algoritmos recomendadores múltiples, seleccionables por usuario, y proporciona a los usuarios un control para seleccionar el algoritmo que están utilizando. En este estudio sólo se consideran a los usuarios	En ese estudio, los usuarios no tenían una preferencia medible entre item-item y SVD, en el contexto de revisar una sola lista de recomendaciones de 10 ítems. Los resultados sugieren que más usuarios prefieren SVD cuando tienen la oportunidad de interactuar con los

		<p>capacidad de cambiar su algoritmo. Los usuarios son asignados al azar a uno de los algoritmos como su condición inicial. Esto nos da la oportunidad de estudiar tres cosas: las formas en la que los usuarios aprovechan la posibilidad de cambiar el algoritmo proporcionando sus recomendaciones, el algoritmo o los algoritmos que los usuarios prefieren, y el impacto del algoritmo asignado en cuanto al comportamiento del usuario.</p>	<p>previamente existentes que se registran en el nuevo sitio. El servicio admite cuatro algoritmos. Cada algoritmo fue identificando a los usuarios usando un nombre de código: el Baseline, el Pick-Groups, el Item-Item y el SVD. Todos los algoritmos se construyen con el kit de herramientas LensKit. Para calcular listas de Top-N, la clasificación prevista del algoritmo es el factor de clasificación principal, pero se mezcla con la popularidad del elemento. Para medir la precisión de los algoritmos en la historia de cada usuario antes de entrar en el experimento se ponen todas las calificaciones de todos los usuarios en un conjunto de entrenamiento. Para cada usuario en el experimento: Se descartó todas las calificaciones después de ingresar al experimento. Se usan las 5 calificaciones más recientes antes de ingresar al experimento en un conjunto de calificaciones de prueba. Se ponen las calificaciones restantes del usuario en el conjunto de entrenamiento. Luego se ejecuta cada algoritmo (con la excepción de Pick-Groups; es difícil hacer recreaciones históricas de ese algoritmo fuera de una instancia en ejecución del servicio de recomendación) y se miden: Precisión de la predicción (RMSE) para las calificaciones de la prueba. Precisión de Top-N (Recall) para encontrar las calificaciones recientes del</p>	<p>algoritmos en un contexto a largo plazo. Sin embargo, muchos usuarios prefirieron aún el recomendador de artículos. Además, si bien se observa una fuerte correlación entre la novedad y la preferencia del usuario (más fuerte que la diversidad), la direccionalidad de esta correlación se invierte: los usuarios eran más propensos a seguir con el algoritmo que también fue más novel (artículos menos populares recomendados). Esto proporciona evidencia adicional de que el impacto negativo de la novedad se concentra principalmente en las reacciones iniciales de los usuarios y que después de adquirir experiencia puede incluso ser una influencia positiva en la satisfacción del usuario.</p>
--	--	---	--	--

			<p>usuario entre las 24 mejores recomendaciones. Diversidad (semejanza intra-list, con similitud coseno sobre los datos descriptivos de atributos como la similitud de la película) de una lista de recomendaciones de 24 ítems.</p> <p>No todas las películas tienen suficientes datos para un cálculo de similitud, por lo que se normaliza la semejanza intra-list dividiéndola por el ILS que se logra si todos los pares de películas del genoma recomendadas tuvieran una similitud de 1.</p> <p>Popularidad (rango de popularidad promedio, donde 1 es la película más popular) de películas en una lista de 24 elementos. Se utilizan 24 ítems para cada lista de recomendaciones.</p>	
--	--	--	--	--

Los sistemas de recomendación para las diferentes aplicaciones existentes son de gran importancia porque permiten realizar sugerencias a los usuarios basándose en la preferencia de estos por un grupo de elementos con características específicas, haciendo más cómodo a los usuarios consultar y buscar la información que realmente necesitan. Para ello es también importante que los usuarios tengan el control en estos tipos de sistemas para acercarse mucho más a la información que realmente desea encontrar. Para este tipo de control se hace necesario que el usuario al menos tenga una noción de cómo trabajan estos Sistemas de Recomendación y hasta podría ser importante que conozcan qué algoritmo utilizan para hacer las recomendaciones, por tanto, muchos de estos sistemas están facilitando el control a los usuarios a que escojan el algoritmo para la recomendación o les proporcionan cambiar valores o darle un peso a los ítem según sus gustos o cambiar sus preferencias a partir de las recomendaciones que el mismo sugiere, siendo así más certera la información brindada. Además, para un futuro, se puede estudiar cómo mezclar en un Sistema de Recomendación las diferentes formas de darle control al usuario, por ejemplo, que puedan dar un peso a los ítems según sus gustos y al mismo tiempo seleccionar el algoritmo que desean para su recomendación, o cambiar los valores de preferencia y que escojan el algoritmo. Lo cual hace más eficiente la recomendación obtenida para el usuario

4 CONCLUSIÓN Y TRABAJOS FUTURO

Los cuatro artículos científicos analizados que estudian cómo dar el control a los usuarios en Sistemas de Recomendación, confirman la influencia positiva en la satisfacción del usuario cuando pueden controlar las recomendaciones.

Para trabajos futuros quedan abiertas las oportunidades de investigación en los beneficios que pueden traer consigo las interfaces de sistemas recomendadores más interactivas en términos de confianza del usuario, transparencia del sistema y satisfacción del usuario. Además se pretende entender cómo, las diferentes formas en que un usuario puede controlar la interfaz, pueden influir en su rendimiento y satisfacción teniendo en cuenta sus características personales.

Los resultados analizados demuestran que los sistemas de recomendación, específicamente el social, se benefician de perfecciones que mejoran su control. Los recomendadores que dan a los usuarios el control sobre los pesos de los ítems conducen a un mayor control percibido, la calidad de la recomendación y la satisfacción general del sistema.

En este artículo, se encuentra que los usuarios que reciben estos controles evalúan las recomendaciones resultantes de manera más positiva que sus recomendaciones originales: califican las recomendaciones para ser más personalizadas e identifican los ítems o artículos que en realidad esperan ver. Estos resultados ponen de relieve la importancia del control del usuario, basándose en estos datos, cualquier recomendador optimizado que se implemente no coincidirá con los deseos de una gran fracción de los usuarios.

REFERENCIAS

- [1] PÉREZ, Adriana Almaraz; CLOSE, John Goddard. *Sistemas de recomendación. Robots Autónomos: Navegación*, 2015.
- [2] NIETO, Sergio Manuel Galán. *Filtrado colaborativo y sistemas de recomendación. Inteligencia en Redes de Comunicaciones*. Madrid. [Links], 2007.
- [3] VERBERT, Katrien, et al. Visualizing recommendations to support exploration, transparency and controllability. En *Proceedings of the 2013 international conference on Intelligent user interfaces*. ACM, 2013. p. 351-362.
- [4] JANNACH, Dietmar; NAVEED, Sidra; JUGOVAC, Michael. *User Control in Recommender Systems: Overview and Interaction Challenges*.
- [5] HARPER, F. Maxwell, et al. Putting users in control of their recommendations. En *Proceedings of the 9th ACM Conference on Recommender Systems*. ACM, 2015. p. 3-10.
- [6] M. D. Ekstrand, M. Ludwig, J. A. Konstan, and J. T. Riedl. Rethinking the Recommender Research Ecosystem: Reproducibility, Openness, and LensKit. In *Proceedings of the Fifth ACM Conference on Recommender Systems, RecSys '11*, pages 133–140, New York, NY, USA, 2011. ACM.
- [7] L. Uden, J. Sinclair, Y. H. Tao, and D. Liberona, "Learning Technology for Education in Cloud: MOOC and Big Data: Third International Workshop, LTEC 2014 Santiago, Chile, September 2-5, 2014 Proceedings," in *Communications in Computer and Information Science*, 2014.
- [8] F. Ricci, L. Rokach, B. Shapira, and P. B. Kantor, *RecommenderSystems Handbook*. 2011.
- [9] M. J. Pazzani and D. Billsus, "Content-Based Recommendation Systems," *Adapt. Web*, vol. 4321, pp. 325–341, 2007.
- [10] J. A. Itmazi, "Sistema Flexible De Gestión De Elearning Para Soportar El Aprendizaje En Las Universidades Tradicionales Y Abiertas," *Programa Dr.*, p. 351, 2005.
- [11] Herlocker, J.L., Konstan, J.A. and Riedl, J. 2000. Explaining collaborative filtering recommendations. *Proc. of the 2000 ACM conference on Computer supported cooperative work (Philadelphia, PA, 2000)*, 241–250.
- [12] O'Donovan, J., Gretarsson, B., Bostandjiev, S., Hollerer, T. and Smyth, B. 2009. A Visual Interface for Social Information Filtering. *2009 Intl. Conf. on Computational Science and Engineering (Vancouver, Canada, 2009)*, 74–81.
- [13] O'Donovan, J., Smyth, B., Gretarsson, B., Bostandjiev, S. and Höllerer, T. 2008. PeerChooser: visual interactive recommendation. *Proceedings of the 26th annual SIGCHI conference on Human factors in computing systems (Florence, Italy, 2008)*, 1085–1088.
- [14] Zhao, S., Zhou, M.X., Yuan, Q., Zhang, X., Zheng, W. and Fu, R. 2010. Who is talking about what: social map-based recommendation for content-centric social websites. *Proceedings of the fourth ACM conference on Recommender system (Barcelona, Spain, 2010)*, 143–150.
- [15] Cramer, H., Evers, V., Ramlal, S., Someren, M., Rutledge, L., Stash, N., Aroyo, L. and Wielinga, B. 2008. The effects of transparency on trust in and acceptance of a content-based art recommender. *User Modeling and User-Adapted Interaction*. 18, 5 (Aug. 2008), 455–496.
- [16] Felfernig, A. 2007. Knowledge-Based Recommender Technologies for Marketing and Sales. *Intl. J. of Pattern Recognition and Artificial Intelligence*. 21, 2 (2007), 333–354.
- [17] Chen, L. and Pu, P. 2011. Critiquing-based recommenders: survey and emerging trends. *User Modeling and UserAdapted Interaction*. 22, 1-2 (Oct. 2011), 125–150.
- [18] Tintarev, N. and Masthoff, J. 2011. Designing and Evaluating Explanations for Recommender Systems. *Recommender Systems Handbook*. F. Ricci, L. Rokach, B. Shapira, and P.B. Kantor, eds. Springer US. 479–510
- [19] KNIJNENBURG, Bart P., et al. Inspectability and control in social recommenders. En *Proceedings of the sixth ACM conference on Recommender systems*. ACM, 2012. p. 43-50.
- [20] Swearingen, K., Sinha, R.: Beyond algorithms: An HCI perspective on recommender systems. In: *ACM SIGIR Recommender Systems Workshop*. (2001) 1–11
- [21] Schafer, J.B., Konstan, J.A., Riedl, J.: Meta-recommendation systems: usercontrolled integration of diverse recommendations. In: *CIKM '02*. (2002) 43–51

- [22] BOLLEN, Dirk, et al. Understanding choice overload in recommender systems. En Proceedings of the fourth ACM conference on Recommender systems. ACM, 2010. p. 63-70.
- [23] Chang, S., Harper, F.M. and Terveen, L. 2015. Using Groups of Items for Preference Elicitation in Recommender Systems. In Proc. ACM CSCW '15 (2015), 1258–1269.
- [24] Sarwar, B., Karypis, G., Konstan, J. and Reidl, J. 2001. Itembased collaborative filtering recommendation algorithms. In Proc. WWW '01 (2001), 285–295.
- [25] Kramer, A.D.I., Guillory, J.E. and Hancock, J.T. 2014. Experimental evidence of massive-scale Netflix Update: Try This at Home: 2006. <http://sifter.org/~simon/journal/20061211.html>. Accessed: 2010-04-08.
- [26] Paterek, A. 2007. Improving regularized singular value decomposition for collaborative filtering. In Proc. KDD Cup and Workshop 2007 (Aug. 2007).
- [27] EKSTRAND, Michael D., et al. Letting users choose recommender algorithms: An experimental study. En Proceedings of the 9th ACM Conference on Recommender Systems. ACM, 2015. p. 11-18.