

## CAPÍTULO III

## Recomendación a grupos basada en un modelo de consenso de mínimo costo

Raciel Yera  
Álvaro Labella  
Luis Martínez

Los sistemas de recomendación a grupo (SRG) han atraído recientemente la atención tanto del mundo académico como de la industria. Estos se enfocan en la recomendación de ítems que satisfacen las preferencias globales de un grupo de personas, siendo los programas de televisión y los paquetes de viajes turísticos ejemplos típicos de estos ítems. En este sentido, a pesar de estar actualmente bien establecidos varios enfoques básicos para construir los SRG, también se han identificado limitaciones relacionadas con la existencia de conflictos entre las preferencias de los usuarios a la hora de generar las recomendaciones. Por tanto, se hace necesario gestionar de forma adecuada el acuerdo entre los miembros del grupo, para obtener una recomendación grupal que satisfaga los intereses globales del grupo. Esta contribución se enfoca en la propuesta de la aplicación de un modelo de consenso de mínimo costo en un escenario de recomendación a grupos, para solventar la gestión de conflictos en el grupo. Además, se presenta un estudio experimental que muestra la positiva influencia de este modelo en la satisfacción del grupo en relación con las recomendaciones generadas.

*Palabras clave:* sistemas de recomendación a grupo, modelo de consenso de mínimo costo, resolución de conflictos.

## 1. INTRODUCCIÓN

En los últimos años, los sistemas de recomendación (SR) se han convertido en una herramienta necesaria en varios escenarios en línea con vistas a solventar la sobrecarga de información asociada a la selección de las mejores opciones en espacios de búsqueda masivos (Adomavicius y Tuzhilin, 2005; Yera y Martínez, 2017a). Por tanto, los SR son frecuentemente utilizados en varios dominios como el comercio electrónico (Guo, Wang y Li, 2017), el aprendizaje electrónico (Yera y Martínez, 2017b), la salud (Yera, Alzahrani y Martínez, 2019), entre otros.

Además, entre los distintos tipos de ítems a recomendar existe una clase bastante habitual como es, la de los llamados ítems sociales, que suelen ser usualmente consumidos por un grupo de usuarios y no por un usuario de forma individual (Castro, Yera y Martínez, 2017; De Pessemier, Dooms y Martens, 2014). Los programas de televisión y los paquetes de viaje turísticos son típicos ejemplos de este tipo de ítems (Dara, 2020), en los que a pesar de ser consumidos en grupo, los intereses individuales de los usuarios dentro del grupo aún pueden divergir y causar conflictos. Con vistas a generar recomendaciones apropiadas en estos escenarios, los sistemas de recomendación a grupos (SRG) han atraído recientemente la atención de académicos y de la industria para recomendar ítems que satisfagan las preferencias globales de los grupos (Dara, 2020).

Específicamente, los métodos de recomendación a grupo han sido tradicionalmente clasificados en dos categorías fundamentales resultantes de la extensión de la recomendación individual (De Pessemier, Dooms y Martens, 2014): 1) el enfoque de agregación de *ratings*, donde las preferencias individuales de los usuarios se combinan para obtener un perfil unificado que representa las preferencias del grupo, y 2) el enfoque de agregación de recomendaciones, en las que las recomendaciones individuales son inicialmente generadas y posteriormente son agregadas para obtener la lista final de recomendaciones.

A pesar de que estos dos paradigmas de recomendación grupal han sido utilizados ampliamente en los últimos años, algunos trabajos han apuntado que resulta necesario el desarrollo de nuevos métodos que vayan más allá de estos enfoques básicos de agregación (Tran *et al.*, 2018). La agregación por sí sola puede generar pérdida de información y recomendaciones sesgadas, dando lugar a una limitada satisfacción del grupo con las sugerencias generadas. A raíz de lo anterior, el presente estudio tiene como premisa que el logro de un mayor “acuerdo” entre los miembros del grupo, puede dar lugar a una mejor eficacia en la generación de recomendaciones a grupo para producir una mayor satisfacción del mismo con dichas recomendaciones.

La presente contribución se centra en este objetivo para lo que, entre los distintos métodos de consenso presentes en la literatura (Ben-Arieh y Easton, 2007; Labella *et al.*, 2020), se centrará en explorar el efecto de aplicar un modelo de consenso de mínimo costo (Ben-Arieh y Easton, 2007) sobre las preferencias individuales de los usuarios, con vistas a obtener recomendaciones a grupo más satisfactorias. El trabajo se estructura de la siguiente manera. La

sección 2 revisa brevemente los conceptos fundamentales relacionados con los SRG y procesos de alcance de consenso. La sección 3 presenta dos métodos que integran el mencionado modelo de consenso de costo mínimo en un modelo de recomendación a grupo. Estos métodos son evaluados en la sección 4. Finalmente, la sección 5 concluye el trabajo, apuntando a líneas futuras de investigación.

## 2. CONCEPTOS FUNDAMENTALES

Esta sección revisa brevemente los conceptos fundamentales necesarios para el desarrollo del presente trabajo. Específicamente, se presentan conceptos relacionados con sistemas de recomendación, sistemas de recomendación a grupo, y con modelos de consenso de costo mínimo.

### 2.1. Sistemas de recomendación

Los sistemas de recomendación son herramientas centradas en proporcionar a los usuarios aquella información que mejor se corresponde con sus necesidades y preferencias en un espacio de búsqueda sobrecargado de posibles opciones (Adomavicius y Tuzhilin, 2005).

Acorde a su principio de funcionamiento, los sistemas de recomendación se agrupan en cuatro categorías fundamentales (Adomavicius y Tuzhilin, 2005): los sistemas de recomendación basados en contenido (Lops, De Gemmis, y Semeraro, 2011), de filtrado colaborativo (Ekstrand, Riedl, y Konstan, 2010), demográficos (Al-Shamri, 2016), e híbridos (Burke, 2002).

Los sistemas de recomendación basados en el contenido (Lops, De Gemmis, y Semeraro, 2011) se centran en la descripción del ítem y en el perfil de usuario para realizar las recomendaciones. Están conformados por un modelo de los ítems a recomendar, un modelo del perfil de los usuarios del sistema, y una función para calcular la similitud entre los perfiles de los ítems y de los usuarios. Este valor de similitud es la base para la generación de la lista de recomendaciones para el usuario actual.

Por otra parte, los sistemas de recomendación basados en filtrado colaborativo (Ekstrand, Riedl y Konstan, 2010), se basan fundamentalmente en las preferencias de los usuarios sobre los ítems en cuestión. Están conformados a su vez por dos familias de métodos, que son los basados en vecindario y los basados en modelos. Los métodos basados en vecindario (Aggarwal, 2016), en los que para el usuario activo se determinan aquellos usuarios más similares acorde a su patrón de preferencias sobre los ítems del sistema. A continuación, la generación de recomendaciones para este usuario se hace basándose en las preferencias de sus usuarios vecinos (aquellos más similares). En otra dirección, los métodos basados en modelos (Koren, Bell y Volinsky, 2009) utilizan las preferencias de los usuarios para construir un modelo predictivo apoyado en técnicas de aprendizaje automático e inteligencia

computacional, que permita predecir el valor de las preferencias de los usuarios por ítems desconocidos y con este generar las recomendaciones.

De manera paralela y a veces integrada con estas dos categorías previas, han sido desarrollados los sistemas de recomendación demográficos (Al-Shamri, 2016), los cuales explotan los atributos personales de los individuos, tales como país, edad, género, con vistas a generar las recomendaciones.

Finalmente, los sistemas de recomendación híbridos (Burke, 2002) se centran en combinar los paradigmas anteriores, usualmente consolidando información de diferentes fuentes para dar lugar a un mejor desempeño. Entre las técnicas básicas de hibridación indicadas por Burke (2002) se encuentra el intercambio, donde en dependencia de la naturaleza del usuario activo se utiliza uno u otro enfoque de recomendación; la utilización de pesos, donde la salida de varios sistemas de recomendación son directamente combinadas utilizándose determinada ponderación; y la cascada, donde la salida de un sistema de recomendación es refinada por un segundo sistema.

## 2.2. Sistemas de recomendación a grupo

Los sistemas de recomendación a grupo (SRG) se centran en extender los sistemas de recomendación individuales para proporcionar recomendaciones a grupos de usuarios ( $G=\{g_1, \dots, g_m\} \subseteq U$ ) (De Pessemier, Dooms y Martens, 2014). Formalmente, los SRG se enfocan en encontrar el ítem (o el conjunto de ítems) que maximizan la preferencia predicha para los miembros del grupo:


$$\text{Recomendación}(I, G_a) = \arg \max_{i_k \in I} \text{Pr edicción}(i_k, G_a) \quad [1]$$

Actualmente se desarrollan dos paradigmas fundamentales de recomendación grupal, contruidos sobre métodos de recomendación individual:

- Agregación de *ratings*, basado en la creación del perfil de un seudousuario que se obtiene a través de la agregación de las preferencias individuales del grupo. Este

Figura 1.

### Esquema general de la recomendación grupal basada en la agregación de *ratings*



nuevo perfil es usado para generar las recomendaciones destinadas al grupo de usuarios (figura 1).

- Agregación de recomendaciones, el cual agrega las recomendaciones individuales realizadas a cada uno de los miembros del grupo, con vistas a obtener la recomendación grupal (figura 2).

Figura 2.

### Esquema general de la recomendación grupal basada en la agregación de recomendaciones



### 2.3. Modelo de consenso de costo mínimo

En la literatura especializada existe una gran cantidad de modelos de alcance de consenso (Ben-Arieh y Easton, 2007; Labella *et al.*, 2020), los cuales pueden ser clasificados atendiendo a sus diferentes características (Palomares *et al.*, 2014). Entre estas características destaca la capacidad de generar valores de consenso automático o con necesidad de retroalimentación por parte de los miembros del grupo. Debido a las necesidades computacionales y de generación de recomendación de los SRG, en el presente trabajo se emplea el modelo de consenso automático de mínimo costo propuesto por Ben-Arieh y Easton (2007), el cual representa una de las primeras propuestas desarrolladas en esta dirección. Este modelo se enfoca a minimizar el costo asociado a la modificación de las opiniones independientes de los expertos, necesaria para alcanzar un consenso entre los mismos. Este costo mínimo es obtenido a través de la resolución de un modelo de programación matemática cuya función objetivo es:

$$\min \sum_{u=1}^n c_u |\bar{o}_u - o_u| \quad [2]$$

Sujeta a las siguientes restricciones:

$$\bar{o} = \sum_{u=1}^n w_u \bar{o}_u \quad [3]$$

$$|\bar{o}_u - \bar{o}| \leq \varepsilon, u = 1, 2, \dots, n \quad [4]$$

El modelo posee los siguientes parámetros:

- $c_u$ , como el costo de modificar las preferencias del experto  $u$ .
- $o_u$ , como las preferencias iniciales del experto  $u$ .
- $\bar{o}_u$ , como las preferencias finales del experto  $u$ , tras el alcance del consenso.
- $\bar{o}$ , como la preferencia colectiva del grupo de expertos.
- $\epsilon$ , como la máxima posible distancia entre la preferencia colectiva y la individual.
- $w_u$ , como el peso del experto  $u$ .

### 3. CONSENSO DE MÍNIMO COSTO EN UN MÉTODO DE RECOMENDACIÓN A GRUPO

En la presente sección se propondrá la incorporación de un modelo de consenso de mínimo costo en dos escenarios diferentes dentro de un contexto de recomendación a grupos. En un primer momento, se propondrá la utilización del consenso de mínimo costo como método de preprocesamiento de datos (sección 3.1), enfocado en lograr consenso entre las preferencias iniciales de los usuarios del grupo, pudiendo dar lugar a preferencias más eficaces (figura 3). En adelante, este método será referido como consenso enfocado en las preferencias de los usuarios.

En segundo lugar, se utilizará el consenso para refinar las recomendaciones generadas individualmente para cada usuario, como etapa previa a la generación de recomendaciones grupales (figura 4). Este método será referido en lo adelante como consenso enfocado en las recomendaciones individuales.

#### 3.1. Recomendación a grupos con consenso enfocado en las preferencias de los usuarios

La utilización de un modelo de consenso de mínimo costo en el contexto de la recomendación grupal para lograr un alto nivel de consenso en las preferencias de los usuarios y mejorar la eficacia de las recomendaciones, viene dado por las siguientes etapas: 1) análisis del consenso de mínimo costo entre las preferencias de los usuarios, 2) generación de las recomendaciones individuales, 3) agregación de recomendaciones individuales, y 4) recomendación grupal (ver figura 3).

Resulta válido acotar que esta propuesta está alineada con el paradigma de recomendación grupal basado en agregación de recomendaciones (ver sección 2.1). Se deja para trabajos futuros la posible integración de un modelo de consenso de mínimo costo con recomendación basada en agregación de preferencias.

Figura 3.

### Esquema general de la recomendación grupal basada en un modelo de consenso de mínimo costo enfocado en las preferencias de los usuarios



*Análisis del consenso de costo mínimo entre las preferencias de los usuarios:* esta primera etapa de la propuesta aplica el modelo de consenso de mínimo costo a las preferencias de los usuarios en el grupo, con vistas a ajustar estas para lograr el alcance del consenso. Como salida de esta etapa, se obtiene un conjunto de nuevos valores de preferencias, mínimamente modificados.

Específicamente, el modelo de consenso es aplicado independientemente para cada ítem  $i$ , considerando las siguientes asunciones para extrapolar la notación de dicho modelo (sección 2.3), hacia el escenario de recomendación grupal.

- $\forall_{u \in G} (o_u = r_{ui})$  (cada preferencia del usuario sobre el ítem  $i$ , se toma como la opinión del experto  $u$  sobre  $i$ ).
- $\forall_{u \in G} (c_u = 1)$  (el costo de modificar las preferencias de  $u$  es siempre 1).
- $\forall_{u \in G} (w_u = 1/n)$  (el peso del experto  $u$  es siempre  $1/n$ , donde  $n$  es el número de expertos).
- Varios valores de  $\epsilon$  serán estudiados en la sección de experimentos.

*Generación de las recomendaciones individuales:* esta etapa se centra en calcular las recomendaciones individuales generadas para cada uno de los miembros del grupo, basándose en las preferencias que se obtuvieron tras el alcance del consenso en la etapa anterior. Aquí puede ser utilizado un método tradicional de filtrado colaborativo para obtener las preferencias individuales de los usuarios, tales como la recomendación basada en vecindades usuario-usuario, basada en vecindades ítem-ítem, así como métodos basados en factorización matricial. El desempeño de varios de estos métodos en este contexto, será evaluado en la sección de experimentación.

*Agregación de recomendaciones individuales:* en esta etapa se realiza la agregación de las recomendaciones individuales, con vistas a obtener la recomendación grupal. En este trabajo se considerarán como estrategias de agregación a utilizar, a las estrategias “promedio” y “minimización de la miseria”, las que han sido identificadas entre las de mejor desempeño en recomendación grupal (Amer-Yahia *et al.*, 2009; Dwivedi y Bharadwaj, 2015).

La estrategia “promedio”, se centra en agregar los listados de recomendaciones individuales a través del cálculo del promedio de los valores de predicción de las preferencias del grupo para un ítem específico. Este valor promedio es el que se asume como la preferencia global del grupo sobre dicho ítem, y es el que se usa posteriormente para construir la lista de recomendaciones para el grupo. Esta estrategia agrega las recomendaciones de una manera intuitiva y deseable, y se corresponde con una de las maneras en la que un grupo de personas toma decisiones de un modo natural (Masthoff, 2004).

Por otro lado, en la estrategia de “minimización de la miseria”, se asume que el nivel de satisfacción del grupo por las recomendaciones, está asociado al nivel de satisfacción del miembro más insatisfecho del mismo. Por tanto, la meta es obtener al menos un nivel predefinido de satisfacción para todos los miembros del grupo (De Pessemier, Dooms y Martens, 2014). Para implementar esta estrategia, se toma el valor de predicción del grupo para un ítem en específico, como el valor mínimo entre todas las predicciones hechas para los miembros del grupo, con respecto al ítem en cuestión.

*Recomendación a grupo:* una vez que se obtienen los valores de preferencia del grupo por cada uno de los ítems correspondientes, el listado final de recomendaciones se obtiene mediante la ordenación descendente de estos ítems acorde a su valor de preferencia.

### 3.2. Recomendación grupal con consenso enfocado en las recomendaciones individuales

La utilización de un modelo de consenso de mínimo costo en el contexto de la recomendación grupal y enfocado en lograr un mayor consenso en las recomendaciones individuales generadas, viene dado por las siguientes etapas: 1) recomendación individual, 2) análisis del consenso de costo mínimo entre las recomendaciones individuales generadas, 3) agregación de recomendaciones individuales, y 4) recomendación a grupo (ver figura 4).

Figura 4.

#### Esquema general de la recomendación grupal basada en un modelo de consenso de mínimo costo enfocado en las recomendaciones individuales



*Recomendación individual:* tal y como se presentó en la sección 3.1, esta etapa se centra en calcular las recomendaciones individuales generadas para cada uno de los miembros



del grupo. Aunque aquí se puede en principio utilizar cualquier método tradicional de filtrado colaborativo, es importante la utilización en este escenario particular de un método que siempre garantice la generación de predicciones/recomendaciones tales como los basados en factorización matricial, en contraposición con los basados en vecindario que en ocasiones presentan problemas de cubrimiento (Koren, Bell y Volinsky, 2009). Esto resulta necesario dado el hecho de que posteriormente se aplica un modelo de consenso, y que se espera por lo tanto tener disponibles las preferencias individuales de todos los miembros del grupo. A raíz de lo anterior, como método de recomendación se utilizará el SVD tradicional referido por Koren, Bell y Volinsky (2009).

*Análisis del consenso de costo mínimo entre las recomendaciones generadas:* esta primera etapa de la propuesta aplica el modelo de consenso de mínimo costo a las recomendaciones generadas para los usuarios en el grupo, con vistas a ajustar estas para lograr un mayor consenso. Como salida de esta etapa, se obtiene un conjunto de nuevos valores de los *ratings* asociados a los ítems recomendados, mínimamente modificados hacia el logro de un mayor consenso.

Específicamente, el modelo de consenso es aplicado independientemente para cada ítem  $i$ , considerando las siguientes asunciones para extrapolar la notación de dicho modelo (sección 2.3), hacia el escenario de recomendación grupal, operando sobre las recomendaciones individuales.

- $\forall_{u \in G} (o_u = r_{ui})$  (cada *rating* del usuario sobre el ítem  $i$ , se toma como la opinión del experto  $u$  sobre  $i$ ).
- $\forall_{u \in G} (c_u = 1)$  (el costo de modificar los *ratings* de  $u$  es siempre 1).
- $\forall_{u \in G} (w_u = 1/n)$  (el peso del experto  $u$  es siempre  $1/n$ , donde  $n$  es el número de expertos).
- Varios valores de  $\epsilon$  serán estudiados en la sección de experimentos.

*Agregación de recomendaciones individuales:* en esta etapa se realiza la agregación de las recomendaciones individuales consensuadas, con vistas a obtener la recomendación grupal. En este escenario se considerará como estrategias de agregación a utilizar a la “minimización de la miseria”, ya presentada en la sección previa 3.1. Aquí es relevante acotar que un estudio más profundo de la estrategia “promedio” para este contexto se dejará para trabajos futuros, considerando que en principio se obtuvieron resultados modestos respecto a la aplicación de la etapa de alcance de consenso. Esto podría ser esperado, considerando la naturaleza de la operación promedio en la que siempre se esperaría que un promedio de valores y un promedio de valores consensuados, pudiera dar lugar a similares resultados. Aunque es necesario realizar un estudio mucho más profundo para dar validez a esta afirmación.

*Recomendación a grupo:* una vez que se obtienen los *ratings* del grupo por cada uno de los ítems correspondientes, el listado final de recomendaciones se obtiene mediante la

ordenación descendente de estos ítems acorde a su valor de preferencia, de igual forma que el método de la sección 3.1.

En la siguiente sección se realizará una evaluación experimental del marco de recomendación aquí presentado.

## 4. EVALUACIÓN EXPERIMENTAL

La presente sección se centra en evaluar los métodos de recomendación presentados en este trabajo. Con este fin, se detalla primeramente el protocolo de experimentación empleado, incluyendo las bases de datos y métricas de evaluación que se utilizan (sección 4.1). Posteriormente, se presentan y discuten los resultados asociados a la evaluación del método. Finalmente se apuntan posibles trabajos futuros.

### 4.1. Protocolo de experimentación

La presente investigación emplea un protocolo de evaluación ampliamente utilizado para sistemas recomendadores grupales (De Pessemier, Dooms y Martens, 2014), el cual está conformado por los siguientes pasos:

- Dividir la base de datos original de preferencias de usuarios, en los conjuntos de entrenamiento y de prueba.
- Construir los grupos correspondientes, en este caso de manera aleatoria.
- Generar las recomendaciones para cada grupo, utilizando el conjunto de entrenamiento.
- Evaluar individualmente la eficacia de las recomendaciones, de un modo semejante a la recomendación individual, comparando las preferencias obtenidas para el grupo, con las preferencias del usuario del conjunto de prueba.

La implementación del método de recomendación grupal presentado en la sección anterior, requiere inicialmente la identificación de varios componentes adicionales. En el caso de la recomendación grupal basada en consenso y sobre las preferencias individuales de los usuarios (sección 3.1), estos componentes serán:

- El enfoque de recomendación individual que será empleado internamente. En este caso, se evaluarán cuatro de los enfoques de recomendación más utilizados en la literatura, que son los siguientes:
  1. El método de recomendación basada en vecindades usuario-usuario inicialmente presentado por Resnick *et al.* (1994). Aquí se utilizará el coeficiente de correlación de Pearson como medida de similitud, con 40 vecinos.

2. El método de recomendación basada en vecindades ítem-ítem presentado por Sarwar *et al.* (2001). Se utilizará la misma medida de similitud y número de vecinos que el caso anterior.
  3. El método inspirado en la factorización matricial, popularizado por Koren, Bell y Volinsky (2009). Particularmente, en este caso se utilizará la variante inicialmente propuesta por Simon Funk en el Netflix Prize (Bennett y Lanning, 2007). Se utilizarán 100 factores para modelar los usuarios y los ítems.
  4. El método inspirado en la factorización matricial que en adición asume valores implícitos de *ratings*, presentado por Koren (2008). Aquí se consideran 20 factores.
- El esquema de agregación utilizado para combinar las preferencias individuales de los usuarios. Aquí se considerará el esquema “promedio”, expuesto en la sección anterior. Es válido resaltar que este esquema está asociado a la teoría de la elección social (*social choice theory*) (Sen, 1986).
  - El valor de  $\epsilon$ , que representa la máxima posible distancia entre la preferencia colectiva y la individual en el usuario, después de alcanzado el consenso (ver secciones 2.3 y 3). Un valor menor de  $\epsilon$  indica que se está requiriendo un mayor grado de consenso entre las preferencias de los usuarios del grupo, siéndose por tanto más invasivo en la transformación de las preferencias. Por otro lado, un mayor valor de  $\epsilon$  asume la existencia de consenso a pesar de ser mayor la diferencia entre las preferencias de los usuarios del grupo.

En el caso de la recomendación grupal soportada por consenso sobre las recomendaciones individuales generadas (sección 3.2), estos componentes serán:

- El enfoque de recomendación individual empleado internamente. Tal y como se comentó en la sección 3.2, en este caso se utilizará el SVD tradicional propuesto por Simon Funk (Bennett y Lanning, 2007), con 100 factores.
- El esquema de agregación utilizado para combinar las preferencias individuales de los usuarios. Aquí se considerará el esquema “miseria mínima”, expuesto en la sección anterior.
- De manera semejante al método de consenso enfocado en las preferencias, se considerarán varios valores de  $\epsilon$ .

El protocolo de experimentación que aquí se presenta, utilizará la base de datos *Movielens 100K*, compuesta por 943 usuarios, 1.682 películas, y un total de 100.000 valores de preferencia de los usuarios por las películas (Harper y Konstan, 2015). Estos valores de preferencia están en el rango [1; 5]. Aquí es importante indicar que este rango implica que sea necesario realizar un proceso de normalización previo a la aplicación del modelo de consenso de mínimo costo, para llevarlo al rango [0; 1]. Posterior al alcance del consenso, los valores obtenidos son proyectados nuevamente al rango [1; 5].

Como métricas de evaluación, serán utilizadas el error medio absoluto (MAE), y la raíz cuadrada del error cuadrático medio (RMSE), las cuales están entre las métricas más utilizadas en recomendación grupal (Gunawardana y Shani, 2015), fundamentalmente para métodos basados en filtrado colaborativo como el que se presenta en este trabajo.

$$MAE = \frac{1}{|R|} \sum_{r_{ui} \in R} |r_{ui} - r_{ui}^*| \quad [5]$$

$$RMSE = \sqrt{\frac{1}{|R|} \sum_{r_{ui} \in R} (r_{ui} - r_{ui}^*)^2} \quad [6]$$

Las ecuaciones [5] y [6] presentan estas dos métricas de evaluación. En estas, R representa el conjunto de valores de preferencias,  $r_{ui}$  el valor real de la preferencia del usuario, y  $r_{ui}^*$  el valor predicho por el método que se evalúa.

Finalmente, en la ejecución del protocolo previamente descrito, en el contexto de este trabajo serán generados aleatoriamente 20 grupos de cinco usuarios cada uno, para registrar la eficacia de la recomendación.

#### 4.2. Resultados de la evaluación del método de recomendación grupal basado en consenso y sobre las preferencias individuales de los usuarios

Las tablas 1-4 presentan los resultados de la evaluación del método basado en consenso y sobre las preferencias individuales de los usuarios, acorde a la métrica MAE, y utilizando los cuatro métodos de recomendación individual a utilizar en este caso. En cada tabla se presenta primeramente la eficacia de la recomendación obtenida por la propuesta, considerando varios valores de  $\epsilon$ , en el conjunto {0.01, 0.05, 0.1, 0.2, 0.3, 0.4, 0.5}. En una segunda fila, se presenta el valor de la misma propuesta, pero excluyendo la etapa de alcance de consenso, presentada en la sección 2.3.

Tabla 1.

##### Desempeño del SRG con consenso sobre preferencias, utilizando similitud usuario-usuario y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)

Método \ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con UsuarioKNNPearson y consenso	0.8506	0.844	0.8441	0.8486	0.8518	0.8525	0.8529
SRG con UsuarioKNNPearson				0.8526			

La tabla 1 muestra el resultado para la recomendación grupal apoyada por el método UsuarioKNNPearson. En esta se puede apreciar que el uso del método de consenso de costo mínimo mejora con notoriedad la eficacia de las recomendaciones generadas, obteniéndose

el mejor resultado para  $\epsilon=0.05$ . También para  $\epsilon=0.1$  y  $\epsilon=0.2$ , se puede apreciar una mejora importante con respecto a la variante que no considera consenso.

Tabla 2.

**Desempeño del SRG con consenso sobre preferencias, utilizando similitud ítem-ítem y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con ItemKNNPearson y consenso	0.8216	0.8131	0.8078	0.8075	0.8069	0.8081	0.8083
SRG con ItemKNNPearson				0.8081			

En el caso de la recomendación grupal apoyada por el método ItemKNNPearson (tabla 2), los mejores resultados fueron obtenidos para escenarios donde se requirió un nivel menor de consenso que con respecto a UserKNNPearson. En este caso, el mejor desempeño se obtuvo para  $\epsilon=0.3$ .

Tabla 3.

**Desempeño del SRG con consenso sobre preferencias, utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD y consenso	0.8386	0.8302	0.8224	0.8175	0.8161	0.8158	0.8159
SRG con SVD				0.8161			

La tabla 3 por su parte presenta los resultados asociados al método basado en factorización matricial. En contraste con las tablas 1 y 2, aquí es menor el efecto del método de consenso en la recomendación grupal, considerando más discreta la mejora introducida. Aun así, es importante resaltar que para  $\epsilon=0.4$  y  $\epsilon=0.5$ , el método basado en el consenso da lugar a una mejora en el desempeño. Similar comportamiento viene asociado al método de factorización matricial que considera preferencias implícitas (tabla 4), en el que para  $\epsilon$  en el rango  $[0.3; 0.5]$  se mejora el resultado del método base.

Tabla 4.

**Desempeño del SRG con consenso sobre preferencias, utilizando factorización matricial que incluye valores implícitos, y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD++ y consenso	0.8213	0.8131	0.8059	0.8017	0.8011	0.8012	0.8016
SRG con SVD++				0.8019			

Por su parte, las tablas 5-8 presentan el resultado de la métrica RMSE. A diferencia de la métrica MAE, en el cálculo de la eficacia de la recomendación RMSE otorga una mayor penalidad a aquellos escenarios en los que es mayor la diferencia entre la preferencia predicha y la real.

La tabla 5 presenta los resultados para la recomendación grupal apoyada por la similitud usuario-usuario y similitud Pearson (UsuarioKNNPearson). En este caso se puede observar que para los valores de  $\epsilon$  desde 0.01 hasta 0.3, se supera el desempeño del método base sin considerar consenso. Aquí el mejor resultado se obtuvo para  $\epsilon=0.1$ .

Tabla 5.

**Desempeño del SRG con consenso sobre preferencias utilizando similitud usuario-usuario y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con UsuarioKNNPearson y consenso	1.0877	1.079	1.0772	1.089	1.097	1.0984	1.0991
SRG con UsuarioKNNPearson	1.0981						

La tabla 6 por su parte muestra este mismo análisis considerando la similitud ítem-ítem. En contraposición con la métrica MAE para este mismo escenario de experimentación (tabla 2), el mejor resultado aquí estuvo asociado al alcance de un alto consenso ( $\epsilon=0.1$ ). No obstante, para  $\epsilon$  en el rango [0.05; 0.4], la propuesta siempre supera el método base.

Tabla 6.

**Desempeño del SRG con consenso sobre preferencias utilizando similitud ítem-ítem y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método\ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con ItemKNNPearson y consenso	1.0485	1.0396	1.0349	1.0381	1.0397	1.0416	1.0419
SRG con ItemKNNPearson	1.0417						

Finalmente, las tablas 7 y 8 presentan los resultados asociados a los dos métodos de factorización matricial considerados (ver sección 4.1). En el caso particular del método básico de factorización matricial (tabla 7), el margen de mejora de RMSE asociado al método basado en consenso con respecto al método base, es más representativo que utilizando la métrica MAE. Este se obtiene para un valor de  $\epsilon=0.2$ .

A su vez, en el método de factorización matricial que considera información implícita (Koren, 2008), la utilización del consenso en el rango  $\epsilon=[0.2; 0.5]$ , da lugar a una mejora en el método base. El mejor desempeño se obtiene para  $\epsilon=0.2$ , obteniéndose un RMSE de

1.0064, por 1.0101 que obtiene el método base. Este método de factorización matricial es el que obtiene los mejores resultados a nivel global, tanto para MAE como para RMSE.

Tabla 7.

**Desempeño del SRG con consenso sobre preferencias utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método \ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD y consenso	1.0366	1.0304	1.0254	1.0233	1.0237	1.0243	1.0247
SRG con SVD	1.0248						

Tabla 8.

**Desempeño del SRG con consenso sobre preferencias utilizando factorización matricial que incluye valores implícitos y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método \ $\epsilon$	0.01	0.05	0.1	0.2	0.3	0.4	0.5
SRG con SVD++ y consenso	1.0209	1.0137	1.0083	1.0064	1.0076	1.009	1.0098
SRG con SVD++	1.0101						

En la primera parte de esta sección se realizó un análisis comparativo del efecto de la incorporación del consenso, en varios escenarios de recomendación grupal. Resulta necesario, no obstante, llevar a cabo una visualización más profunda del comportamiento del parámetro  $\epsilon$  en cada uno de los métodos, y cómo este afecta la eficacia de la recomendación.


La figura 5 muestra este análisis según la métrica MAE. Se muestra que, más de allá de la introducción de una mayor o menor mejora en la eficacia de la recomendación asociada a la introducción del consenso, el mejor desempeño tiende a venir asociado a valores intermedios de  $\epsilon$ .

La utilización de valores pequeños de  $\epsilon$  se traduce en la demanda de un fuerte nivel de consenso del grupo, lo que a su vez implica la necesidad de transformar una mayor cantidad de valores de preferencias para lograr dicho consenso. Esta importante modificación de preferencias, a pesar de mejorar en algunos casos el método base, no da lugar a la obtención de los mejores resultados posibles.

Por otro lado, el uso de valores grandes de  $\epsilon$  se traduce en una mayor flexibilidad en cuanto a las posibles diferencias en las preferencias de los usuarios, para lograr el nivel de consenso que se asume. Así, en muchos casos no es necesaria la modificación de las preferencias de los usuarios, porque *a priori* ya existe el consenso en estos casos. Esta es la razón por la cual el desempeño del método basado en consenso tiende a igualar al método base, para valores grandes de  $\epsilon$ .

Figura 5.

### Estudio del parámetro $\epsilon$ para la métrica MAE y diferentes escenarios de recomendación grupal



*Nota:* La línea recta representa el desempeño del método sin considerar consenso. a) Soportado por UsuarioKNNPearson. b) Soportado por ÍtemKNNPearson. c) Soportado por factorización matricial. d) Soportado por factorización matricial e información implícita.

Por su parte la figura 6 muestra este mismo análisis para la métrica RMSE. Las conclusiones arrojadas de este análisis coinciden con las asociadas a la métrica MAE, viéndose además una mayor diferencia entre el desempeño de la propuesta y el del método base. En

Figura 6.

### Estudio del parámetro $\epsilon$ para la métrica RMSE y diferentes escenarios de recomendación grupal







Figura 6. (continuación)

### Estudio del parámetro $\epsilon$ para la métrica RMSE y diferentes escenarios de recomendación grupal



*Nota:* La línea recta representa el desempeño del método sin considerar consenso. a) Soportado por UsuarioKNNPearson. b) Soportado por ÍtemKNNPearson. c) Soportado por factorización matricial. d) Soportado por factorización matricial e información implícita.

adición se observa con una mayor claridad que los mejores resultados son obtenidos con valores intermedios de  $\epsilon$ .

#### 4.3. Resultados de la evaluación del método de recomendación grupal basado en consenso y sobre las recomendaciones individuales de los usuarios

Las tablas 9 y 10 presentan los resultados de la evaluación del método basado en consenso y sobre las recomendaciones individuales proporcionadas a los usuarios, utilizando las métricas MAE y RMSE. En cada tabla se presenta primeramente la eficacia de la recomendación obtenida por la propuesta y considerando consenso, considerando  $\epsilon$  en el conjunto  $\{0.03, 0.05, 0.1, 0.3\}$ . En una segunda fila, se presenta el desempeño de la propuesta, pero sin considerar consenso.

Tabla 9.

#### Desempeño del SRG con consenso sobre recomendaciones utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (MAE)

Método/ $\epsilon$	0.03	0.05	0.1	0.3
SRG con SVD y consenso	0.8701	0.8794	0.9037	0.9301
SRG con SVD	0.9301			

Particularmente, la tabla 9 muestra los valores asociados a la métrica MAE, donde se evidencia que para un valor menor de  $\epsilon$  se introduce una disminución más representativa del error de la recomendación. Así, tanto para  $\epsilon=0.03$ ,  $\epsilon=0.05$ , y  $\epsilon=0.1$ , se introducen mejoras

con respecto al método base; aunque resulta necesario utilizar con cautela la configuración de  $\epsilon$  puesto que menor valor implica una mayor deformación de las predicciones inicialmente generadas por el algoritmo de recomendación. Esto podría traer implícito la disminución del grado de personalización del sistema. Por otra parte, para  $\epsilon=0.3$  no se produce ninguna mejora con respecto al método base.

Tabla 10.


**Desempeño del SRG con consenso sobre recomendaciones utilizando factorización matricial y diferentes niveles de consenso, en comparación con un enfoque que no considera consenso (RMSE)**

Método\ $\epsilon$	0.03	0.05	0.1	0.3
SRG con SVD y consenso	1.0747	1.0786	1.0988	1.1270
SRG con SVD	1.1270			

La tabla 10 presenta los valores asociados al RMSE, y da lugar a un razonamiento análogo al obtenido con los valores del MAE. Aquí resulta interesante el hecho que entre  $\epsilon=0.03$  y  $\epsilon=0.05$  no existe una diferencia muy representativa en cuanto al desempeño. Esto podría indicar que no resulta necesario un valor muy pequeño de  $\epsilon$  para obtener resultados cercanos al óptimo, evitándose de este modo una mayor intrusividad del método de consenso de mínimo costo.

Figura 7.

**Estudio del parámetro  $\epsilon$  para la recomendación grupal basada en consenso sobre recomendaciones individuales**



*Nota:* La línea recta representa el desempeño del método sin considerar consenso. a) MAE. b) RMSE.

La figura 7 ilustra gráficamente este resultado, donde se puede corroborar que para valores grandes de  $\epsilon$ , la etapa de alcance de consenso no tiene ningún efecto sobre la recomendación grupal. En adición, para valores pequeños de  $\epsilon$  se logra mejorar de manera considerable la eficacia de la recomendación, aunque en algunos casos al costo de modificar los *ratings* predichos de manera más sustancial.

#### 4.4. Discusión y trabajos futuros

El desarrollo de la evaluación experimental de los métodos presentados en la sección 3, ha indicado que resulta efectiva la introducción de un método de consenso de mínimo costo dentro de un método de recomendación grupal. Se ha probado que en varios escenarios de experimentación diferentes, soportados por diversos métodos de recomendación individual (ver sección 4.1), el uso del consenso de mínimo costo logra mejorar la eficacia de la recomendación.

Esta mejora de desempeño no fue igual en todos los escenarios. En el enfoque basado en consenso sobre las preferencias (sección 3.1), en los métodos basados en vecindades usuario-usuario e ítem-ítem se vio una tendencia a acentuarse más esta mejora, mientras que en los dos métodos basados en factorización matricial esta fue más moderada. Aun así, en todos los casos se logró mejorar el método base.

Por otro lado, en el enfoque basado en consenso sobre recomendaciones individuales (sección 3.2), para las dos métricas de evaluación consideradas se logró mejorar el desempeño del método base.

Aquí es importante resaltar la importancia del parámetro  $\epsilon$ , que permite lograr un balance entre la eficacia lograda, y la intrusividad del método de consenso, asociada a la transformación requerida para lograrse el nivel de consenso deseado.

A raíz de estos resultados, se abre un grupo de trabajos futuros a desarrollar. En el futuro inmediato, resulta necesario cuantificar ese nivel de intrusividad llevado a cabo por el método de consenso. Esto permitirá caracterizar mejor el funcionamiento de la propuesta y del parámetro  $\epsilon$ , determinando cuántas preferencias de usuario fueron necesarias modificar para alcanzar el requerido consenso. Otra dirección de trabajo es el empleo de métodos de consenso de mínimo costo más avanzados, tales como el propuesto por Labella *et al.* (2020), considerando que en el presente trabajo se ha empleado uno de los métodos más básicos de esta familia.

## 5. CONCLUSIONES

El desarrollo del presente trabajo permitió llegar a las siguientes conclusiones:

- Existe una insuficiente incorporación de modelos de consenso, acoplados a un escenario de recomendación grupal.
- La incorporación de un modelo de consenso de mínimo costo dentro de varios métodos de recomendación grupal, dio lugar a una mejora en la eficacia en todos los escenarios de recomendación.

- En el caso del método basado en consenso sobre las preferencias individuales de los usuarios, los mejores resultados de eficacia fueron obtenidos para un nivel intermedio de consenso entre las preferencias de los usuarios. Por otro lado, un alto nivel de consenso no garantiza necesariamente un mejor desempeño en la recomendación.
- En el caso del método basado en consenso sobre las recomendaciones individuales generadas, para valores grandes de  $\epsilon$  se asume que ya existe consenso entre los usuarios y, por tanto, se obtiene el mismo resultado que el método base. En cambio, para valores pequeños de  $\epsilon$  el método de consenso sí introduce cambios en las recomendaciones individuales, y este cambio da lugar a una mayor eficacia en la recomendación grupal.

## Referencias

- ADOMAVICIUS, G. y TUZHILIN, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE transactions on knowledge and data engineering*, 17(6), pp. 734-749.
- AGGARWAL, C. C. (2016). Neighborhood-based collaborative filtering. *Recommender systems*, pp. 29-70. Springer.
- AL-SHAMRI, M. Y. H. (2016). User profiling approaches for demographic recommender systems. *Knowledge-Based Systems*, 100, pp. 175-187.
- AMER-YAHIA, S., ROY, S. B., CHAWLAT, A., DAS, G. y YU, C. (2009). Group recommendation: Semantics and efficiency. *Proceedings of the VLDB Endowment*, 2(1), pp. 754-765.
- BEN-ARIEH, D. y EASTON, T. (2007). Multi-criteria group consensus under linear cost opinion elasticity. *Decision support systems*, 43(3), pp. 713-721.
- BENNETT, J. y LANNING, S. (2007). *The netflix prize*. Paper presented at the Proceedings of KDD cup and workshop.
- BURKE, R. (2002). Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction*, 12(4), pp. 331-370.
- CASTRO, J., YERA, R. y MARTÍNEZ, L. (2017). An empirical study of natural noise management in group recommendation systems. *Decision support systems*, 94, pp. 1-11.
- DARA, S. (2020). A survey on group recommender systems. *Journal of Intelligent Information Systems*, 54, pp. 271-295.
- DE PESSEMIER, T., DOOMS, S. y MARTENS, L. (2014). Comparison of group recommendation algorithms. *Multimedia tools and applications*, 72(3), pp. 2497-2541.
- DWIVEDI, P. y BHARADWAJ, K. K. (2015). e-Learning recommender system for a group of learners based on the unified learner profile approach. *Expert Systems*, 32(2), pp. 264-276.
- EKSTRAND, M. D., RIEDL, J. T. y KONSTAN, J. A. (2010). Collaborative filtering recommender systems. *Foundations and Trends in Human-Computer Interaction*, 4(2), pp. 81-173.
- GUNAWARDANA, A. y SHANI, G. (2015). Evaluating recommender systems. *Recommender systems handbook*, pp. 265-308. Springer.
- GUO, Y., WANG, M. y LI, X. (2017). Application of an improved Apriori algorithm in a mobile e-commerce recommendation system. *Industrial Management y Data Systems*.
- HARPER, F. M. y KONSTAN, J. A. (2015). The movielens datasets: History and context. *ACM Transactions on Interactive Intelligent Systems (TIIS)*, 5(4), pp. 1-19.

- KOREN, Y. (2008). Factorization meets the neighborhood: a multifaceted collaborative filtering model. Paper presented at the *Proceedings of the 14<sup>th</sup> ACM SIGKDD international conference on Knowledge discovery and data mining*.
- KOREN, Y., BELL, R. y VOLINSKY, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 42(8), pp. 30-37.
- LABELLA, Á., LIU, H., RODRÍGUEZ, R. M. y MARTINEZ, L. (2020). A cost consensus metric for consensus reaching processes based on a comprehensive minimum cost model. *European Journal of Operational Research*, 281(2), pp. 316-331.
- LOPS, P., DE GEMMIS, M. y SEMERARO, G. (2011). Content-based recommender systems: State of the art and trends. *Recommender systems handbook*, pp. 73-105.
- MASTHOFF, J. (2004). Group modeling: Selecting a sequence of television items to suit a group of viewers. *Personalized digital television*, pp. 93-141. Springer.
- PALOMARES, I., ESTRELLA, F., MARTÍNEZ, L. y HERRERA, F. (2014). Consensus under a fuzzy context: Taxonomy, analysis framework AFRYCA and experimental case of study. *Information Fusion*, 20(15), pp. 252-271.
- RESNICK, P., IACOVOU, N., SUCHAK, M., BERGSTROM, P. y RIEDL, J. (1994). GroupLens: An open architecture for collaborative filtering of netnews. Paper presented at the *Proceedings of the 1994 ACM conference on Computer supported cooperative work*.
- SARWAR, B., KARYPIS, G., KONSTAN, J. y RIEDL, J. (2001). Item-based collaborative filtering recommendation algorithms. Paper presented at the *Proceedings of the 10<sup>th</sup> international conference on World Wide Web*.
- SEN, A. (1986). Social choice theory. *Handbook of mathematical economics*, 3, pp. 1073-1181.
- TRAN, T. N. T., ATAS, M., FELFERNIG, A. y STETTINGER, M. (2018). An overview of recommender systems in the healthy food domain. *Journal of Intelligent Information Systems*, 50(3), pp. 501-526.
- YERA, R., ALZHRANI, A. A. y MARTÍNEZ, L. (2019). A food recommender system considering nutritional information and user preferences. *IEEE Access*, 7, 96695-96711.
- YERA, R. y MARTÍNEZ, L. (2017a). Fuzzy tools in recommender systems: A survey. *International Journal of Computational Intelligence Systems*, 10(1), pp. 776-803.
- YERA, R. y MARTÍNEZ, L. (2017b). A recommendation approach for programming online judges supported by data preprocessing techniques. *Applied Intelligence*, 47(2), pp. 277-290.