

Uso de procesos de alcance de consenso para mejorar la recomendación a grupos

Jorge Castro^{*1}, Francisco J. Quesada², and Luis Martínez²

¹ Dpto. de Ciencias de la Computación e I.A., Universidad de Granada, España

² Departamento de Ciencias de la Computación, Universidad de Jaén, España

Resumen Los Sistemas de Recomendación ayudan a los usuarios a filtrar grandes cantidades de información, mostrando los elementos que mejor satisfacen sus necesidades y/o preferencias. Estos sistemas han sido ampliamente usados en áreas como el comercio electrónico o el turismo. Los Sistemas de Recomendación a Grupos se aplican cuando las recomendaciones se dirigen a un grupo de usuarios, quienes pueden tener preferencias y necesidades distintas e incluso contradictorias. Para mejorar la satisfacción de los miembros se han usado distintas técnicas para la generación de las recomendaciones, como *minimizar la insatisfacción* de los miembros, que asume que un grupo está tan satisfecho como su miembro más insatisfecho, pero no garantiza que sean las mejores para el grupo. En esta contribución se propone una metodología de recomendación a grupos que aplica técnicas de consenso automático para mejorar las recomendaciones a grupo y la satisfacción de los mismos.

Keywords: recomendación a grupos, procesos de alcance del consenso, consenso automático, toma de decisión en grupo

1. Introducción

En el contexto actual hay disponible una cantidad de información que sobrepasa las capacidades de los usuarios a la hora de filtrar y seleccionar la información que satisface sus intereses y necesidades. Para solucionar este problema se utilizan los Sistemas de Recomendación (SR), que filtran de forma automática la información, mostrando a los usuarios aquellos productos (o servicios) que satisfacen sus preferencias.

Los SR clásicos [11] se centran en proveer recomendaciones a usuarios individuales, pero existen productos con características sociales, que tienden a ser consumidos por grupos de usuarios en lugar de individuos, como son las películas a ver, un restaurante para cenar o los puntos de interés turístico a visitar [4].

Los Sistemas de Recomendación a Grupos (SRG) [6], surgen para realizar recomendaciones dirigidas a grupos de usuarios, cuyos miembros expresan sus necesidades mediante preferencias individuales, pudiendo ser diferentes entre cada miembro. En la literatura se ha estudiado cómo agregar las preferencias de los

* jcastro@decsai.ugr.es

miembros para generar una recomendación dirigida al grupo a partir del perfil de preferencias agregado [7]. Una característica interesante de las recomendaciones es que sean satisfactorias para los miembros, por lo que se han aplicado técnicas tales como *minimizar la insatisfacción* [9], que evita recomendar productos no satisfactorios para algún miembro. Sin embargo, esto no garantiza que las recomendaciones tengan un nivel de satisfacción aceptable en el grupo. Nuestro objetivo en esta contribución consiste en mejorar la satisfacción y precisión de las recomendaciones de los SRG.

Para alcanzar dicho objetivo partimos de la idea de que la satisfacción de grupo en los SRG es similar al acuerdo de las soluciones en los problemas de Toma de Decisión en Grupo (TDG) [5]. En estos últimos se aplican Procesos de Alcance de Consenso (PAC) [10] para alcanzar soluciones consensuadas o satisfactorias para el grupo. Estos procesos consisten en varias rondas de discusión en las que los expertos modifican sus preferencias para acercarlas entre sí y alcanzar un mejor nivel de acuerdo.

En esta contribución consideramos las ideas presentadas en [2] sobre el uso de PAC para mejorar las recomendaciones de los SRG, ya que la aplicación del concepto de *consenso* en SRG puede proporcionar mejoras tanto en la satisfacción de grupo como en la precisión de sus recomendaciones.

Esta contribución se organiza de la siguiente manera. En la Sección 2 se revisan los conceptos básicos de SRG y PAC. En la Sección 3 se presenta nuestra propuesta para generar recomendaciones al grupo consensuadas. En la sección 4 se muestra el caso de estudio realizado para evaluar la técnica propuesta. En la sección 5 se destacan las conclusiones.

2. Preliminares

En esta sección se introducen los conceptos básicos de SRG y PAC, necesarios para presentar la propuesta.

2.1. Sistemas de recomendación y recomendación a grupos

Los SR tratan de filtrar y ordenar productos, así como predecir valoraciones para productos no experimentados anteriormente por los usuarios. Para ello, los SR utilizan información sobre los usuarios ($U = \{u_1, \dots, u_m\}$), los productos ($I = \{i_1, \dots, i_n\}$) y las valoraciones de los usuarios sobre los productos ($R \subseteq U \times I \rightarrow D$), dadas en un dominio de valoración determinado (D). Existen distintos tipos de SR, pero los más extendidos en el mundo real son los sistemas de recomendación colaborativos (SRC) [8], que son los que utilizamos en nuestra propuesta. Se centran en estudiar las valoraciones de los usuarios, buscando relaciones entre ellos para generar predicciones. Formalmente, los SR tratan de encontrar el producto o conjunto de productos que maximizan la predicción para el usuario:

$$\text{Recomendación}(I, u) = \arg \max_{i_k \in I} [\text{Predicción}(i_k, u)] \quad (1)$$

Se pueden utilizar distintos procesos de filtrado en SRC. Una técnica sencilla y efectiva es el filtrado colaborativo basado en usuarios (FCBU). Esta técnica se basa en que las preferencias de un usuario sobre los productos pueden ser estimadas utilizando información de usuarios con preferencias similares (véase Figura 1). FCBU se compone de las siguientes fases: (i) se calcula la similitud del usuario activo con cada usuario del sistema, (ii) se selecciona su vecindario a partir de los usuarios más similares, (iii) se calculan las predicciones del usuario activo sobre productos no experimentados anteriormente utilizando el vecindario, y (iv) se recomiendan los productos con mayor predicción.

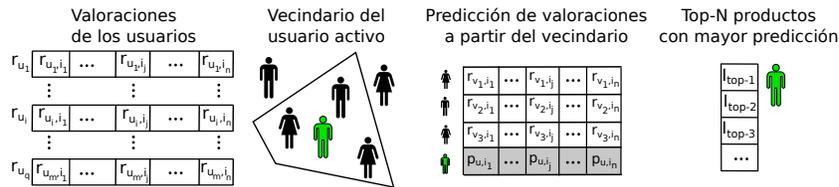


Figura 1. Recomendación individual con filtrado colaborativo basado en usuarios.

Los SRG extienden los SRC de manera que, en lugar de recomendar productos a individuos, recomiendan productos a grupos de usuarios ($G = \{g_1, \dots, g_r\}$) (véase Ecuación 2). Formalmente, los SRG, al igual que los SR, tratan de encontrar el producto o conjunto de productos que maximizan la predicción para el grupo:

$$\text{RecomendaciónGrupo}(I, G) = \arg \max_{i_k \in I} [\text{Predicción}(i_k, G)] \quad (2)$$

Una forma de extender los SRC para ser utilizados con grupos es agregar la información asociada a los individuos para producir la recomendación para el grupo [6]. Dependiendo de en qué parte del proceso de recomendación se aplique la agregación, se puede realizar:

- Agregación de valoraciones: se genera un perfil asociado al grupo, o pseudo-usuario, a partir de las valoraciones de los miembros del grupo.
- Agregación de recomendaciones: se calculan las predicciones para cada miembro del grupo y se agregan para generar las recomendaciones (véase Figura 2). Este es el modelo que utilizaremos en nuestra propuesta.

2.2. Procesos de alcance de consenso en TDG

Un problema de TDG se puede definir como una situación de decisión en la que intervienen varios expertos, $E = \{e_1, \dots, e_p\}$, que intentan encontrar en conjunto la mejor solución de un conjunto de posibles alternativas, $A = \{a_1, \dots, a_q\}$. Las preferencias de los expertos sobre las alternativas suele modelarse en los



Figura 2. Recomendación para grupos por agregación de recomendaciones.

problemas de TDG mediante relaciones de preferencias difusas. Una relación de preferencia difusa P_i asociada a un experto e_i está definida por una función $\mu_{P_i} : A \times A \rightarrow [0, 1]$. Esta función se representa con una matriz de tamaño $q \times q$. Para simplificar, μ_i^{kl} denota $\mu_{P_i}(a_k, a_l)$, es decir, el grado de preferencia de la alternativa a_k sobre a_l según el experto e_i , tal que si $\mu_{P_i}(a_k, a_l) = 0,5$, indica que a_k y a_l son indiferentes, $\mu_{P_i}(a_k, a_l) > 0,5$ a_k es preferida a a_l o $\mu_{P_i}(a_k, a_l) < 0,5$ a_l es preferida a a_k . Asimismo, esta relación de preferencia difusa debe ser recíproca (véase Eq. 3).

$$\mu_{P_i}(a_k, a_l) = 1 - \mu_{P_i}(a_l, a_k) \quad (3)$$

Los procesos de resolución de TDG suelen realizarse con un proceso de selección compuesto por dos fases [12]: (i) agregación y (ii) explotación. Sin embargo, este proceso no garantiza que los expertos compartan la solución alcanzada y por tanto puedan rechazarla. Para evitar el problema anterior se añade en TDG un proceso previo de negociación o PAC, cuyo objetivo consiste en alcanzar un nivel de acuerdo antes de llevar a cabo el proceso de selección para obtener una solución con *un acuerdo mutuo entre los miembros del grupo, donde cada opinión individual haya sido tenida en cuenta* [13].

Los PAC consisten en un proceso iterativo de discusión y modificación de preferencias hasta alcanzar el nivel de acuerdo requerido. Dicho proceso es guiado habitualmente por un moderador cuyas funciones pueden ser automatizadas en ocasiones [10]. Por lo que un PAC realiza iterativamente las siguientes fases (véase Fig. 3):

- Medida del consenso: A partir de las preferencias de cada miembro se calcula $cr \in [0, 1]$, el grado de consenso del grupo.
- Control del consenso: Se comprueba si $cr \geq \mu \in [0, 1]$, siendo μ el nivel de consenso requerido. Si lo es, el nivel de acuerdo es suficiente y el proceso termina. Adicionalmente se puede acordar un número máximo de rondas, para garantizar que el proceso termine aunque no se haya alcanzado el nivel de consenso requerido.
- Guía de cambios: Si no se ha alcanzado el consenso, el moderador indica a los expertos en qué dirección deberían modificar sus preferencias para aumentar el nivel de acuerdo.

Cuando el PAC alcanza el grado de consenso deseado se realiza un proceso de selección para resolver el TDG obteniendo una solución consensuada.

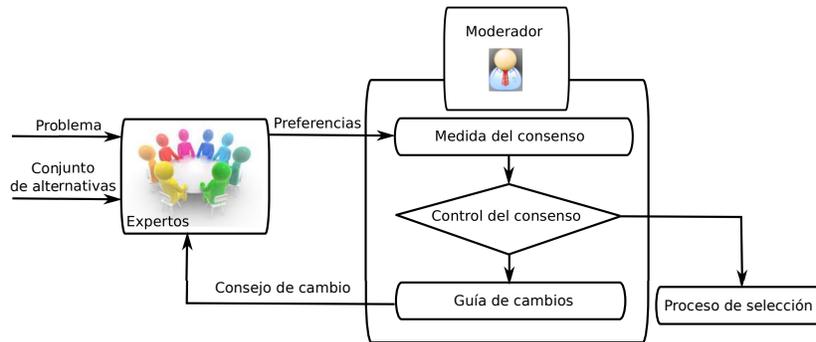


Figura 3. Esquema de Resolución de un TDG con un PAC

En esta contribución se aplica un PAC automático [14], que automatiza las tareas de los expertos y del moderador en el proceso de consenso.

3. Procesos de consenso en recomendación a grupos

En esta sección se introduce la propuesta para generar recomendaciones a grupos con un alto grado de consenso entre los miembros del grupo. Para ello, el sistema propuesto se compone de dos fases (véase Fig. 4):

- *Fase de recomendación:* Se producen recomendaciones para cada miembro a partir de sus valoraciones. Estas recomendaciones serán usadas en la fase de consenso para producir una recomendación para el grupo.
- *Fase de consenso:* Las recomendaciones individuales son utilizadas en un proceso de consenso automático en el que se intenta alcanzar un nivel de consenso determinado y se produce la recomendación para el grupo.



Figura 4. Esquema general de funcionamiento de la propuesta.

3.1. Fase de recomendación

En la fase de recomendación (véase Figura 5) se calculan las recomendaciones individuales para cada miembro utilizando un modelo de FCBU, que produce

una predicción de la valoración que cada miembro daría sobre cada producto. De estas predicciones individuales se eliminan aquellos productos que no han podido ser predichos para algún miembro (fallo de cobertura). A partir de estas predicciones se calculan los órdenes de recomendación para cada miembro, sobre los que se aplicará el PAC.

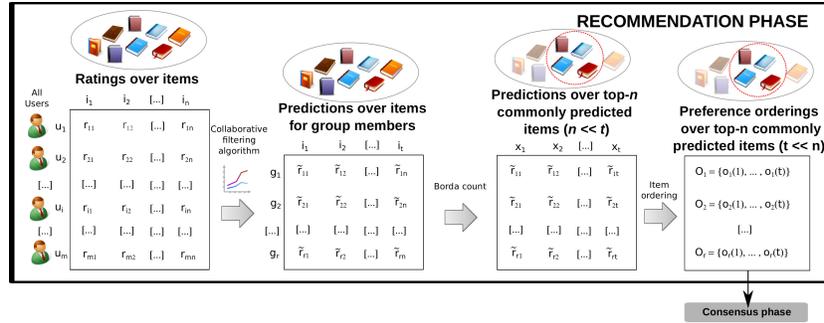


Figura 5. Esquema de funcionamiento de la fase de recomendación.

Vamos a ver en detalle los distintos procesos de la fase de recomendación:

1. Para cada producto no experimentado por ningún miembro se calcula la predicción:

$$\tilde{r}_{g_i i_k} = FCBU(g_i, i_k) \quad i_k \in \{i_l \in I \mid \forall g_i \in G \nexists r_{g_i i_l}\} \quad (4)$$

2. Se obtiene el conjunto de productos para los cuales se pudo predecir una valoración para todos los miembros:

$$I^G = \{i_k \in I \mid \forall g_i \in G \exists \tilde{r}_{g_i i_k}\} \quad (5)$$

3. Se obtiene un orden total del conjunto de productos I^G para cada miembro del grupo atendiendo al valor de predicción del producto para ese miembro:

$$O_{g_i} = \{o_{g_i}(i_1), \dots, o_{g_i}(i_k), \dots, o_{g_i}(i_n)\}, \quad i_k \in I^G \quad (6)$$

4. Se agregan los órdenes de los miembros O_{g_i} para obtener un orden colectivo inicial. En este caso se ha usado el método Borda [1], pero existen otros métodos de agregación de órdenes que se pueden aplicar. A partir del mismo se seleccionan los t mejores para obtener un conjunto reducido de productos $I_t^G \subseteq I^G$. A partir de I_t^G se recalculan los órdenes de cada miembro \tilde{O}_{g_i} , conservando el orden original de dichos productos en O_{g_i} :

$$\tilde{O}_{g_i} = \{\tilde{o}_{g_i}(i_1), \dots, \tilde{o}_{g_i}(i_k), \dots, \tilde{o}_{g_i}(i_t)\}, \quad i_k \in I_t^G \quad (7)$$

3.2. Fase de consenso

Después de obtener el orden de preferencia, \tilde{O}_{g_i} , de cada miembro sobre los t productos seleccionados con el método Borda, la fase de consenso intenta obtener una lista consensuada de recomendaciones para el grupo (véase Figura 6). Esto se puede conseguir utilizando un PAC, aplicando técnicas de consenso automático [15] sobre problemas de TDG con relaciones de preferencias difusas, lo que permite generar una recomendación para el grupo con un alto grado de acuerdo.

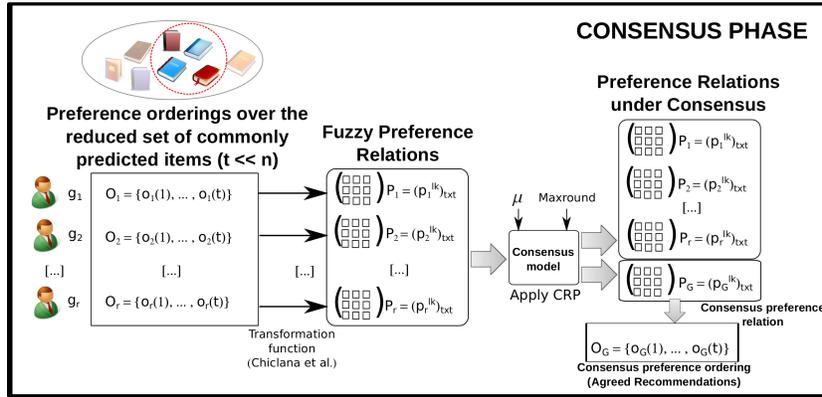


Figura 6. Esquema de funcionamiento de la fase de consenso.

La fase de consenso se compone de los siguientes procesos:

1. Las recomendaciones individuales se expresan como relaciones de preferencia difusas. Para transformar una relación de orden $\tilde{O}_{g_i} = \{\tilde{o}_{g_i}(i_1), \dots, \tilde{o}_{g_i}(i_t)\}$ en una relación de preferencias recíproca $P_{g_i} = (p_{g_i}^{lk})_{t \times t}$, siendo $t = |I_t^G|$, existen distintas técnicas [3]. En nuestro caso aplicaremos la siguiente ecuación:

$$p_{g_i}^{lk} = \frac{1}{2} \left(1 + \frac{\tilde{o}_{g_i}(i_k) - \tilde{o}_{g_i}(i_l)}{t - 1} \right), \quad i_k, i_l \in I_t^G \quad (8)$$

2. Tras obtener las relaciones de preferencias para cada miembro, se aplica un PAC automático [15] sobre las mismas, compuesto por las siguientes fases:
 - Medida del consenso: A partir de las relaciones de preferencias difusas de cada miembro se obtienen matrices de similitud entre cada par de miembros $SM_{ij} = (sm_{ij}^{lk})_{t \times t}$, las cuales se agregan para obtener una matriz de consenso $CM = (cm^{lk})_{t \times t}$, en la que cm^{lk} indica el consenso colectivo entre las alternativas l y k . A partir de la matriz de consenso se calcula $cr \in [0, 1]$, el grado de consenso del grupo.

- Control del consenso: En este paso se comprueba si $cr \geq \mu \in [0, 1]$, siendo μ el nivel de consenso requerido. Adicionalmente se puede establecer el número máximo de rondas, para garantizar que el PAC termine aunque no se haya alcanzado el nivel de consenso requerido. Si $cr \geq \mu$, el proceso termina y se pasa a obtener la preferencia colectiva.
 - Guía de cambio: Si no se ha alcanzado el consenso, las relaciones de preferencias difusas son modificadas, identificando las más lejanas al consenso y modificándolas automáticamente para acercarlas a la preferencia colectiva.
3. A partir de la relación de preferencias difusa colectiva se calcula el grado de no-dominancia de cada alternativa para generar las recomendaciones.

4. Caso de estudio

Para evaluar la técnica propuesta y obtener medidas de su desempeño para compararla con otras técnicas, se ha realizado el caso de estudio que se describe a continuación.

Como técnica de referencia se utiliza la recomendación a grupos que *minimiza la insatisfacción* de los miembros. En el caso de la propuesta, se calculan recomendaciones de los miembros y se aplica el PAC automático descrito, para el que se han evaluado niveles de consenso de 0.8, 0.85 y 0.9. En ambos casos, las recomendaciones individuales se generan mediante FCBU, utilizando 20 vecinos.

El conjunto de datos utilizado en este caso de estudio es *MovieLens 100k*³. Como no contiene información sobre posibles grupos de usuarios, los grupos se han generado mediante una selección aleatoria de 30 grupos de tamaño 5. Para la validación se ha aplicado la técnica *hold-out*, siendo la partición de evaluación el 20% del conjunto de datos original.

4.1. Resultados

El desempeño de las técnicas se ha estudiado utilizando el área bajo la curva ROC, acrónimo de *Receiver Operating Characteristic* (AUC), y la precisión. A continuación se exponen y analizan los resultados para cada medida.

Los resultados para la medida AUC se muestran en la Figura 7. Estos resultados sugieren que aplicar el PAC automático mejora los resultados de referencia. En concreto, el valor óptimo se obtiene para un nivel de consenso de 0.8, descendiendo ligeramente para niveles de consenso mayores. Esto indica que el PAC beneficia el proceso de recomendación si se exige un nivel de consenso adecuado.

En cuanto a los resultados para la precisión, mostrados en la Figura 8, permiten examinar el desempeño de cada técnica con más detalle. En general, la propuesta con un nivel de consenso de 0.8 obtiene los mejores resultados. En concreto, esta configuración mejora para cualquier tamaño de la lista de recomendación a la técnica de referencia, y para 4 recomendaciones o menos, es la

³ Recopilado por el *GroupLens Research Project*, en la Universidad de Minnesota. Accesible en <http://grouplens.org/datasets/movielens/>

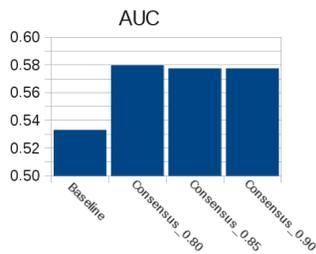


Figura 7. Área bajo la curva ROC (*Receiver Operating Characteristic Curve*) de las técnicas comparadas.

mejor configuración de las estudiadas. Para 5 recomendaciones o más, las tres configuraciones de la propuesta muestran resultados similares, con variaciones menores.

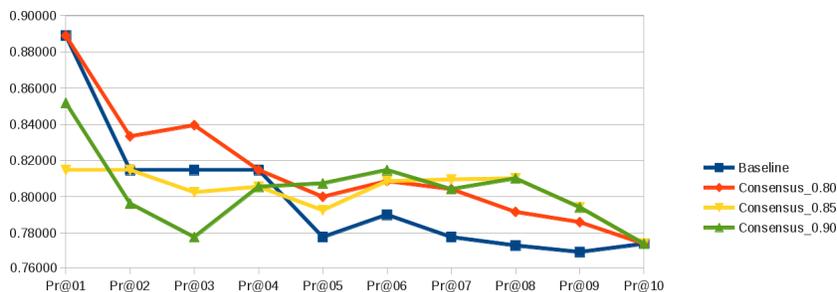


Figura 8. Precisión de las técnicas para distintos tamaños de recomendación.

5. Conclusiones y trabajo futuro

En esta contribución se propone una técnica de recomendación para grupos basada en el uso de un PAC automático. De esta manera se mejora la satisfacción de los miembros con las recomendaciones y los resultados del caso de estudio confirman que esta propuesta además mejora la precisión de las recomendaciones a grupo.

Estos resultados sugieren que la aplicación de PAC en la recomendación aporta mejoras significativas, por lo que la exploración de otros conceptos y técnicas utilizadas en PAC es una línea de investigación interesante.

Como trabajos futuros se propone el desarrollo de una herramienta gráfica que permita a los usuarios de un SRG visualizar el nivel de consenso que el sistema alcanza al generar las recomendaciones, así como la posición de sus

preferencias respecto a las del resto de miembros del grupo y a la recomendación generada por el sistema.

Agradecimientos

Esta contribución está financiada por el Ministerio de Educación de España a través del proyecto de investigación TIN-2012-31263, la Beca de Formación de Profesorado Universitario FPU13/01151, la red de excelencia Lógica Difusa y Soft Computing (LODISCO) TIN2014-56381-REDT y por los fondos FEDER.

Referencias

1. J.C. Borda. Mémoire sur les élections au scrutin. *Historie de l'Académie Royale des Sciences (Paris)*, 1781.
2. J. Castro, F. J. Quesada, I. Palomares, and L. Martínez. A consensus-driven group recommender system. *International Journal of Intelligent Systems*, pages n/a–n/a, 2015.
3. F. Chiclana, E. Herrera-Viedma, S. Alonso, and R.A. Marqués-Pereira. *H. Bustince et al. (eds.), Fuzzy Sets and Their Extensions: Representation, Aggregation and Models*, chapter Preferences and Consistency Issues in Group Decision Making, pages 219–237. Springer, 2008.
4. I. Garcia, L. Sebastia, and E. Onaindia. On the design of individual and group recommender systems for tourism. *Expert systems with applications*, 38(6):7683–7692, 2011.
5. F. Herrera, E. Herrera-Viedma, and J.L. Verdegay. A sequential selection process in group decision making with linguistic assessments. *Information Sciences*, 85(4):223–239, 1995.
6. A. Jameson and B. Smyth. Recommendation to groups. In *The adaptive web*, pages 596–627. Springer, 2007.
7. V. Rao Kagita, A. K Pujari, and V. Padmanabhan. Virtual user approach for group recommender systems using precedence relations. *Inf. Sci.*, 294:15–30, 2015.
8. Y. Koren and R. Bell. Advances in collaborative filtering. In *Recommender Systems Handbook*, chapter 5, pages 145–186. Springer US, 2011.
9. J. Masthoff. Group recommender systems: Combining individual models. In *Recommender Systems Handbook*, chapter 21, pages 677–702. Springer US, 2011.
10. I. Palomares, F.J. Estrella, L. Martínez, and F. Herrera. Consensus under a fuzzy context: Taxonomy, analysis framework AFRYCA and experimental case of study. *Information Fusion*, 20(November 2014):252–271, 2014.
11. F. Ricci, L. Rokach, and B. Shapira. Introduction to recommender systems handbook. In *Recommender Systems Handbook*, chapter 1, pages 1–35. Springer, 2011.
12. M. Roubens. Fuzzy sets and decision analysis. *Fuzzy Sets and Systems*, 90(2):199–206, 1997.
13. S. Saint and J. R. Lawson. *Rules for Reaching Consensus. A Modern Approach to Decision Making*. Jossey-Bass, 1994.
14. Z. Wu and J. Xu. A consistency and consensus based decision support model for group decision making with multiplicative preference relations. *Decision Support Systems*, 52(3):757–767, 2012.
15. Z. Xu. An automatic approach to reaching consensus in multiple attribute group decision making. *Computers & Industrial Engineering*, 56(4):1369–1374, 2009.