UNIVERSIDAD POLITÉCNICA DE MADRID

TESIS DOCTORAL

Recomendación a grupos de usuarios usando el concepto de singularidades

Autor:

Remigio HURTADO ORTIZ

Director:

Dr. Jesús BOBADILLA
SANCHO

Director:

Dr. Fernando ORTEGA
REQUENA

*Trabajo de tesis presentado para obtener el título de
Doctor en Ciencias y Tecnologías de la Computación para Smart Cities
en la*

Escuela Técnica Superior de Ingeniería de SISTEMAS INFORMÁTICOS

Febrero 2020

Declaración de autoría

Yo, Remigio HURTADO ORTIZ, declaro que esta tesis titulada «Recomendación a grupos de usuarios usando el concepto de singularidades» y el trabajo presentado en ella es de mi autoría. Y confirmo que:

- Este trabajo se realizó en su totalidad durante la candidatura para un grado de investigación en esta universidad.
- Los contenidos de este trabajo son originales y no han sido enviados completa o parcialmente para la obtención de algún grado académico o título universitario en esta u otra universidad.
- Donde se ha utilizado trabajos publicados por otros, esto es claramente atribuido a sus autores.
- Donde se ha citado los trabajos de otros autores, las fuentes son siempre proporcionadas. Con la excepción de las fuentes que son de mi autoría.

Firma:

Fecha:

Resumen

Los sistemas de recomendación son sistemas inteligentes que brindan recomendaciones personalizadas a sus usuarios. Estos sistemas ayudan a mitigar parte del problema de sobrecarga de información. El éxito de un sistema de recomendación depende de su algoritmo de filtrado, puesto que este bloquea la información que resulta irrelevante para el usuario. El filtrado colaborativo es un algoritmo que emite recomendaciones a los usuarios mediante la recopilación de las preferencias de una enorme comunidad de usuarios. Este tipo de filtrado ha demostrado proporcionar recomendaciones más precisas que otros métodos. Las técnicas de filtrado colaborativo más populares son: el algoritmo de los *K Nearest Neighbors* (KNN) y el modelo *Matrix Factorization*. Las principales ventajas del filtrado colaborativo son su capacidad para generar recomendaciones novedosas y no requerir información personal de los usuarios. Esta tesis se centra en el gran desafío de extender el diseño de un sistema de recomendación basado en filtrado colaborativo que proporciona recomendaciones a grupos de usuarios sobre productos o servicios que satisfagan a todo el grupo.

Los sistemas de recomendación a grupos de usuarios se enfrentan a desafíos como: diversidad de grupos (homogéneos y heterogéneos), negociación entre miembros para la decisión final (*decision-making*), la explicación de las recomendaciones grupales y la estandarización de su evaluación. Los métodos con los que se miden los resultados no son universales debido a varios factores como: políticas de recomendación, tamaños y distribuciones de los grupos, etc. Actualmente, la tendencia en sistemas de recomendación para grupos de usuarios es desarrollar nuevos enfoques basados en KNN o modelos basados en *Matrix Factorization*. Existen cuatro tipos de enfoques KNN reconocidos en el estado del arte de acuerdo con su enfoque de agregación: fusión de recomendaciones, agregación de predicciones individuales, intersección de vecindarios y agregación de preferencias de usuarios. Los enfoques de agregación de preferencias son los que mejores resultados actualmente ofrecen en *accuracy* y en tiempos de ejecución, debido a que se ha demostrado que cuanto antes se unifique la información de los usuarios del grupo, más eficiente será el cálculo de las recomendaciones sin que la calidad de estas se vea afectada.

En esta tesis se propone un método de recomendación a grupos de usuarios mediante filtrado colaborativo basado en KNN, utilizando un enfoque de agregación de preferencias (*related users*) que se apoya en la generalización del concepto de singularidad. La idea subyacente es la siguiente: dos usuarios son similares si presentan votos singulares en común; por ejemplo, ambos usuarios generalmente escuchan una canción impopular y ambos otorgan un voto bajo. Usando el mismo razonamiento: si un grupo de usuarios comparte votos singulares con otro usuario, es muy probable que sea un vecino adecuado. La condición de singularidad es menos probable que ocurra en la recomendación a grupos (por ejemplo, un grupo de amigos a los que les gusta una película muy poco popular). Esta menor probabilidad nos ayuda a elegir vecinos que se ajusten a las preferencias del grupo. Bajo esta premisa, proponemos la medida de similaridad para grupos de usuarios SMGU. Esta medida de similaridad combina información numérica y no numérica. La información numérica se pondera atendiendo a la singularidad de los votos de los miembros del grupo. La información no numérica puede considerarse valiosa para hacer coincidir

las preferencias del grupo con las preferencias de los vecinos.

Los experimentos se han ejecutado usando conjuntos de datos públicos de sistemas de recomendación. En comparación con los baselines representativos de sistemas de recomendación a grupos de usuarios, los resultados muestran mejoras de calidad de predicción y recomendación cuando se utiliza el método propuesto. Se proporciona una sección dedicada a la cuestión de la reproducibilidad de los experimentos.

Abstract

Recommender systems are intelligent systems that provide personalized recommendations to users. These systems help mitigate the information overload problem. The success of a recommender system depends on its filtering algorithm since it blocks information that is irrelevant to the user. Collaborative filtering is an algorithm that issues recommendations to users by collecting the preferences of a huge community of users. This type of filtering has proven to provide more precise recommendations than other methods. The most popular collaborative filtering techniques are: the K Nearest Neighbors (KNN) algorithm and the Matrix Factorization model. Collaborative filtering has two main advantages: it is able to generate novel recommendations and it not require personal information from users. This thesis focuses on the great challenge of extending the design of a recommender system based on collaborative filtering to provide recommendations to groups of users about products or services that satisfy the entire group.

The recommender systems to groups of users face challenges such as: diversity of groups (homogeneous and heterogeneous), negotiation among group members for the final decision (decision-making), explanation of group recommendations, and evaluation standardization. The methods with which the results are measured are not universal due to several factors such as: recommendation policies, sizes, and distributions of the groups, etc. Currently, the trend in recommendation systems for user groups is to develop new approaches based on KNN or *Matrix Factorization* models. There are four types of KNN approaches recognized in the state of the art according to their aggregation approach: merging recommendations, aggregation of individual predictions, neighborhood intersection, and aggregation of user preferences. Preference aggregation approaches are the ones that currently offer the best results in accuracy and execution times since it has been shown that while the earlier the information of the group's users is unified, the calculation of the recommendations will be more efficient without affecting your quality.

This thesis proposes a method of recommendation to groups of users through collaborative filtering based on KNN, using an approach of aggregation of preferences (related users) that is based on the generalization of the concept of singularity. The underlying idea is the following: two users are similar if they present singular votes in common. For example, both users generally listen to an unpopular song and both give a low vote. Using the same reasoning: if a group of users shares singular votes with another user, it is very likely that it is an adequate neighbor. The uniqueness condition is less likely to occur in the group recommendation (for example, a group of friends who like a very unpopular movie). This lower probability helps us choose neighbors that fit the preferences of the group. Under this premise, we propose the measure of similarity for user groups SMGU. This measure of similarity combines numerical and non-numerical information. The numerical information is weighted according to the singularity of the votes of the members of the group. Non-numeric information can be considered valuable to match group preferences with neighbors' preferences.

The experiments have been executed using public data sets of recommendation systems. Compared with representative baselines of recommender systems to user

groups, the results show improvements in prediction and recommendation quality when the proposed method is used. A section dedicated to the question of reproducibility of experiments is provided.

Agradecimientos

Mi eterna gratitud para Dios, el eje de mi vida, quien me he enseñado que, con su gran ayuda, y por supuesto con gran esfuerzo y disciplina, se logran las metas y hasta lo que humanamente es imposible. Gracias a mi compañera de vida, mi mejor amiga, mi amada esposa, quien ha tenido una enorme paciencia y amor, esenciales para poder culminar esta etapa. Gracias a mis padres por su apoyo y amor incondicional para forjar las bases de este camino. Gracias a mis hermanos por su cariño y aliento en estos años de trabajo arduo. Les agradezco profundamente a mis tutores Jesús Bobadilla y Fernando Ortega quienes me han compartido su gran experiencia para orientarme en esta investigación.

Índice general

Declaración de autoría	iii
Resumen	v
Abstract	vii
1 Introducción	1
1.1 Fundamentos de sistemas de recomendación	3
1.1.1 Recomendaciones para usuarios individuales (RS)	3
Filtrado colaborativo (CF)	8
RS CF basado en memoria	9
RS CF basado en modelos	11
Desafíos de RS en general	12
1.1.2 Recomendación a grupos de usuarios (GRS)	13
1.2 Motivaciones, objetivos e hipótesis	16
1.3 Estructura de la tesis	17
2 Trabajo relacionado	19
2.1 GRS: clasificación	20
2.2 Desafíos de GRS	22
2.3 Evaluación de RS y GRS	23
2.3.1 Evaluación de los sistemas de recomendación	23
2.3.2 Evaluación de sistemas de recomendación de grupos	30
2.4 Tendencias de la investigación de RS	32
2.5 Investigaciones de vanguardia en GRS	34
2.5.1 Enfoques CF basados en memoria: basados en KNN	35
GRS con agregación de predicciones (<i>merged predictions</i>)	38
GRS con mezcla de recomendaciones (<i>merged recommendations</i>)	40
GRS relacionado a vecinos (<i>related neighbors</i>)	42
GRS con agregación de preferencias individuales (<i>related users</i>)	42
2.5.2 Enfoques CF basados en modelos	43
GRS basados en Matrix Factorization	43
GRS basados en grafos	44
GRS con métodos Fuzzy	45
GRS basados en clustering	46
2.5.3 Enfoques híbridos: otros modelos y métodos GRS	46
2.6 Sumario	49
3 Método propuesto	51
3.1 Conceptos previos	52
3.2 Diseño del Método	53
3.3 Formalización	56
3.4 Ejecución de un ejemplo	58

4 Experimentos y resultados	63
4.1 Diseño de experimentos	64
4.1.1 Configuración de experimentos	64
4.1.2 Medidas de calidad	65
4.1.3 Optimización de parámetros	65
4.1.4 Rendimiento del modelo	65
4.2 Resultados y discusión	67
4.2.1 Ajuste de parámetros	67
4.2.2 Comparación de resultados	68
Resultados de la calidad de predicción	68
Resultados de la calidad de recomendación	70
4.2.3 Discusión	72
5 Conclusiones y trabajo futuro	75
A Listado de publicaciones del autor	79
Bibliografía	81

Índice de figuras

1.1	Fundamentos de RS.	4
1.2	Alternativas para combinar CF y CBF	8
1.3	Filtrado colaborativo basado en usuarios	10
1.4	Filtrado colaborativo basado en ítems	10
1.5	Enfoques basados en KNN para recomendar a grupos de usuarios.	15
2.1	Proporción de datos para evaluación	24
2.2	Proceso general de evaluación de RS	24
2.3	Proceso general de evaluación de GRS	25
2.4	Enfoque de Fusión de Recomendaciones.	35
2.5	Enfoque de Agregación de Predicciones.	36
2.6	Enfoque de Intersección de Vecinos.	36
2.7	Enfoque de Agregación de Preferencias de Usuarios.	37
3.1	Fuentes de información utilizadas para diseñar el método propuesto.	53
3.2	Proporción de ítems coincidentes e ítems impopulares.	55
3.3	Singularidad de usuarios y grupos.	56
4.1	Impacto de α y γ y el número de vecinos en los resultados de calidad del método propuesto.	68
4.2	Resultados de predicción a grupos.	69
4.3	Resultados de recomendación a grupos. $\lambda = 0,75$	71
4.4	Resultados de recomendación a grupos. $\lambda = 0,5$	72
4.5	Resultados de recomendación a grupos. $\lambda = 1$	73

Índice de tablas

2.1	Matriz de confusión de <i>Information Retrieval</i> adaptada a los Sistemas de Recomendación	27
3.1	<i>Datatoys</i>	58
3.2	Ejemplo: proporción de elementos coincidentes	59
3.3	Ejemplo: singularidad de usuarios	59
3.4	Ejemplo: número de usuarios en el grupo que han votado el ítem i	60
3.5	Ejemplo: singularidad del grupo	60
3.6	Ejemplo: diferencias numéricas	60
3.7	Ejemplo: combinación de $y_{G,u}$ con $x_{G,u}$	61
4.1	Principales propiedades de los conjuntos de datos utilizados en los experimentos.	64
4.2	Parámetros principales para probar cada dataset.	65
4.3	Parámetros del modelo probado.	65
4.4	Configuración del experimento para optimizar los parámetros del método propuesto.	66
4.5	Parámetros utilizados en los experimentos para ejecutar los baselines.	66

Abreviaciones

RS	Recommender System
CF	Collaborative Filtering
CBF	Content Based Filtering
DF	Demographic Filtering
SF	Social Filtering
CAF	Context-Aware Filtering
GRS	Group Recommender System
KNN	K Nearest Neighbors
MF	Matrix Factorization
EM	Expectation Maximization
SVD	Singular Value Decomposition
NMF	Non-negative Matrix Factorization
BNMF	Bayesian Non-negative Matrix Factorization
SMGU	Singularity-based Measure for Groups of Users
MAE	Mean Absolute Error
NMAE	Normalized Mean Absolute Error
MSE	Mean Squared Error
RMSE	Root of Mean Squared Error
ROC	Receiver Operating Characteristic
HL	Half-Life
DCG	Discounted Cumulative Gain
NDCG	Normalized Discounted Cumulative Gain

Capítulo 1

Introducción

La sobrecarga de información disponible en la Web y los nuevos servicios de e-business provocan que los consumidores modernos estén inundados de una enorme oferta de productos y servicios sin precedentes que debería ajustarse a los gustos y preferencias de los usuarios para incrementar su satisfacción. Los **sistemas de recomendación** (RS, por sus siglas en inglés) (Bobadilla y col., 2013a; Lu y col., 2015) son sistemas inteligentes que brindan recomendaciones personalizadas a los usuarios finales. Los sistemas de recomendación han tomado un rol muy importante en la era de la información, puesto que son capaces de mitigar parte del problema de sobrecarga de información.

Los RS permiten analizar patrones de comportamiento de los usuarios sobre los intereses por determinados productos. Desde el punto de vista de un usuario de RS, en función de sus preferencias anteriores, el sistema recomienda automáticamente una serie de ítems (películas, libros, música, electrónica, ropa, etc.) que están disponibles y que el usuario no ha consumido.

Además de la indudable utilidad comercial de los RS, estos han despertado el interés de una comunidad científica, ya que plantean nuevos desafíos que han llevado al desarrollo de técnicas innovadoras en el campo del aprendizaje automático (*Machine Learning*) y en la minería de datos (*Data Mining*).

A los RS también se les conoce como filtros, porque permiten el paso de la información relevante para el usuario y bloquean la que no lo es, por lo tanto el éxito de un RS depende de su **algoritmo de filtrado**, puesto que este es el encargado de bloquear la información que resulta irrelevante para el usuario, con el fin de generar recomendaciones precisas. El **filtrado colaborativo** (CF, por sus siglas en inglés) es el algoritmo que es capaz de emitir recomendaciones a un usuario valiéndose de los votos de usuarios similares (Bobadilla y col., 2013a). Uno de los métodos más populares es el *K Nearest Neighbors* (KNN). El CF ha demostrado proporcionar recomendaciones más precisas (mejor *accuracy*) que otros métodos. Como consecuencia, varios investigadores de todo el mundo están desarrollando nuevos métodos para mejorar el rendimiento de CF. El CF es uno de los principales temas de investigación en las revistas internacionales.

El CF enfocado en recomendaciones individuales ha evolucionado durante la última década para mejorar el rendimiento de los RS. Al principio, la mayoría de las investigaciones se centraron en aumentar el *accuracy* de KNN CF a través de diferentes medidas de similitud. Cuando se logró un alto *accuracy*, se buscó la mejora de los resultados en nuevas medidas de calidad (por ejemplo, novedad, serendipia o escalabilidad), convirtiéndose en el nuevo desafío para la comunidad de investigación.

Después de eso, como resultado del **Premio Netflix**, se desarrollaron modelos *Matrix Factorization* (MF) que demuestran su superioridad frente al algoritmo KNN. Hoy en día, la mayoría de las contribuciones sobre CF se centran en mejorar el rendimiento de los modelos MF.

Si bien es cierto, los sistemas de recomendación tradicionales son diseñados para usuarios individuales, un gran desafío es diseñar **sistemas de recomendación para grupos de usuarios** (GRS, por sus siglas en inglés) sobre productos o servicios que satisfagan a todo el grupo. Un sistema de recomendación dirigido a grupos de usuarios es necesario cuando varios usuarios desean escoger productos o servicios en conjunto buscando la satisfacción general, por ejemplo: películas, shows de TV, restaurantes, bares, eventos culturales, destinos de viaje, música dentro de un gimnasio, etc. Bajo este escenario existe la necesidad de proporcionar estrategias de recomendación de grupo adecuadas para servicios de video bajo demanda, sitios web de eventos, servicios que brindan información sobre puntos de interés, agencias de viajes, etc.

Los CF enfocados en recomendaciones grupales están siguiendo la misma evolución que CF para recomendaciones individuales. La tendencia es desarrollar nuevas estrategias para proporcionar recomendaciones grupales mediante filtrado colaborativo utilizando KNN o modelos basados en *Matriz Factorization*.

En ese sentido, esta tesis enfrenta este desafío proponiendo un nuevo método GRS CF basado en KNN que mejora la calidad de las predicciones y recomendaciones en comparación al estado del arte. Para explicar los beneficios de nuestro método, primeramente, en este capítulo abordaremos los conceptos fundamentales de sistemas de recomendación individuales y de sistemas de recomendación grupales, seguido de la explicación general, motivaciones e hipótesis, y finalmente se presenta la estructura de la tesis.

1.1 Fundamentos de sistemas de recomendación

1.1.1 Recomendaciones para usuarios individuales (RS)

La Fig. 1.1 ilustra los fundamentos de RS. En la parte inferior de la figura se ilustran cuatro niveles que muestran la clasificación de los datos considerando tres factores:

- **El tipo de datos:** el tipo de datos que se almacena en un CF: usuarios e ítems. Esta es la mínima información necesaria para funcionar.
- **El modo de adquisición:** explícito o implícito. El modo explícito consiste en que el sistema obtiene la retroalimentación directamente, por ejemplo, cuando el usuario le dice al sistema lo que piensa respecto de un ítem emitiendo un voto. El modo implícito consiste en que el sistema obtiene la retroalimentación indirectamente, por ejemplo, a partir del registro de las acciones de un usuario, como la cantidad de veces que ha escuchado una canción, de tal manera que el sistema concluye el voto basándose en esa acción.
- **El nivel del tipo de fuente de información:**
 - **Memory-based (basado en memoria):** utiliza la información tomada de la matriz de votos.
 - **Content-based (basado en contenido):** la información de los perfiles de los usuarios e ítems.
 - **Social-based (basado en información social):** la información resultante de factores sociales, de la interacción con las redes sociales, etc.
 - **Context-based (basado en contexto):** la información usualmente asociada con el Internet de las cosas (*Internet of Things IoT*), como la localización del usuario o de un ítem (dispositivo en movimiento), información recolectada de RFID, tarjetas de crédito, etc.

En la mitad de la Fig. 1.1 se pueden apreciar diversos **algoritmos de filtrado colaborativo**. Estos son **enfoques y frameworks** que utilizan esas fuentes de información para **generar predicciones y recomendaciones**. Entre los enfoques más populares están: KNN, algoritmos genéticos, sistemas Fuzzy, enfoques basados en medidas de similaridad, enfoques de agregación, enfoques basados en grafos y diversos modelos basados en análisis de factores sociales, redes neuronales, Singular Value Decomposition (SVD), Matrix Factorization, redes bayesianas, clustering, etc.

En la parte superior de la Fig. 1.1 se ilustra la **evaluación de las predicciones y recomendaciones** mediante varias **medidas de calidad**. Estas medidas permiten conocer la efectividad de cada enfoque. El *accuracy* es lo primero que los usuarios prestan atención, ya que las predicciones imprecisas o incluso las contrarias perjudican enormemente la confianza en un RS. Existen medidas para comprobar la calidad de las predicciones (*accuracy*) y medidas para comprobar la calidad de las recomendaciones. Las medidas más populares de calidad de predicción son: **MAE**, **RMSE** y **coverage**. Las medidas más conocidas de calidad de recomendación son: *precision*, *recall*, **F1** y **NDCG**. Existen otras medidas que han ido poco a poco cobrando mayor importancia: *diversity*, *novelty*, *serendipity*, *confidence*, *utility*, *risk*, *robustness*, *trust*, etc. Todas estas medidas se definen en el capítulo 2 en la sección 2.3 de evaluación de sistemas de recomendación.

FIGURA 1.1: Fundamentos de RS.

La figura tomada de (Bobadilla y col., 2013a) ha sido traducida y extendida.

Tipos de Filtrado

Las funciones internas para un RS se caracterizan por el algoritmo de filtrado (Bobadilla y col., 2013a). El algoritmo de filtrado es aquel proceso que recopila y analiza una gran cantidad de información sobre los comportamientos, actividades o preferencias para crear recomendaciones. La clasificación más difundida (Lü y col., 2012; Bobadilla y col., 2013a; Ricci, Rokach y Shapira, 2015) identifica los siguientes tipos de filtrado:

- **(a) Filtrado basado en el contenido de la información (CBF):** (Wu, Chang y Liu, 2014) las recomendaciones se basan en el conocimiento que se tiene sobre los ítems que el usuario ha valorado o seleccionado (ya sea de forma implícita o explícita). Se le recomienda productos o servicios similares. Esto permite que se puedan hacer recomendaciones según los datos históricos, por ejemplo, si el usuario activo compró una novela histórica, es probable que se le recomiende un libro de historia o un libro de novela histórica que no haya comprado, ni leído. Un CBF también puede realizar recomendaciones basadas en el contenido de los objetos que el usuario consume o utiliza, como imágenes, sonidos y texto, o recomendaciones de acuerdo a las características de los objetos, por ejemplo lo que el usuario escucha, compra o mira. Una aplicación que usa este tipo de filtrado es YouTube, puesto que recomienda videos (ítems) basándose en su descripción, además en función de los perfiles de los usuarios y de los comentarios.
- **(b) Filtrado demográfico (DF):** (Al-Shamri, 2016) hace recomendaciones basadas en los productos consumidos por usuarios demográficamente similares al usuario activo (edad, género, ubicación, etc.). Este filtrado parte de la suposición de que las recomendaciones deberían ser generadas para determinados nichos demográficos, este enfoque ha adquirido popularidad en la literatura de marketing pero ha sido relativamente menos apropiado en la investigación de sistemas de recomendación. Los principales inconvenientes de la RS basada en datos demográficos son: 1) Los datos demográficos completos no suelen estar disponibles, y 2) Hay demasiada variabilidad en las preferencias de cada grupo demográfico.
- **(c) Filtrado social (SF):** (Tang, Hu y Liu, 2013; Yu y col., 2017) hace uso de las relaciones entre los usuarios: *likes*, *dislikes*, *follows*, etc. Un RS social recomienda a los usuarios en función de las preferencias tomadas de sus redes sociales. El principal problema con este enfoque es que la mayoría de los conjuntos de datos públicos existentes no contienen suficiente información social.
- **(d) Filtrado context-aware (CAF):** (Villegas y col., 2018; Yang y col., 2016) generalmente se asocia con el Internet de las Cosas (IoT), donde se recopila información de contexto: coordenadas de GPS, información de RFID, datos de tarjetas de crédito, etc.
- **(e) Filtrado colaborativo (CF):** (Bobadilla y col., 2013a; Shi, Larson y Hanjalic, 2014) su funcionamiento es el siguiente: al usuario activo se le recomienda ítems que no se han consumido y que han sido votados positivamente por usuarios que tienen preferencias similares a las suyas. Es decir, la información se extrae de todos los usuarios existentes (cientos de miles o millones) y, en función de esa información, se recomienda al usuario objetivo. Ejemplo de aplicaciones que utilizan este tipo de filtrado son Netflix y FilmAffinity. Estas

aplicaciones generan recomendaciones identificando los usuarios similares en función de las películas que los usuarios han votado.

- **(d) Filtrado híbrido:** Se mezclan algunos de los filtrados mencionados anteriormente para realizar recomendaciones. Por ejemplo, Amazon utiliza un filtrado híbrido, en sus tiendas *online* recomienda productos en función de su descripción (CBF) y también en función de los comentarios y votaciones (CF) de los usuarios. Algunos enfoques híbridos son:
 - **Algoritmos genéticos:** se mezclan los algoritmos de filtrado mediante un algoritmo genético. Por ejemplo, (Gao y Li, 2008) utilizan la salida de varios recomendadores para construir vectores de previsión que constituyen las cadenas de cromosomas que requieren los algoritmos genéticos.
 - **Lógica difusa:** mediante la determinación de conjuntos difusos se definen características demográficas, y mediante la fusificación y defusificación se obtienen resultados numéricos que luego sirven como entrada para otras técnicas como los algoritmos genéticos (Al-Shamri y Bharadwaj, 2008).
 - **Redes neuronales:** a través de Mapas Auto Organizados (SOM) se puede realizar un preclustering de grupos de usuarios que pueden guiar mejor las predicciones (Lee, Choi y Woo, 2002), otros enfoques utilizan las salidas de otras técnicas, por ejemplo, toman las medidas de similaridad como punto de referencia en el entrenamiento de redes neuronales y así mejoran las recomendaciones (Bobadilla y col., 2012b).
 - **Redes bayesianas:** por lo general se combina el filtrado colaborativo con el filtrado basado en contenidos para adaptar una topología que permite estimar las distribuciones de probabilidad mediante inferencia probabilística (Campos y col., 2010).
 - **Clustering:** esta técnica se basa en dos fases, la primera consiste en generar diferentes grupos de usuarios utilizando técnicas de clustering y una segunda fase ejecuta la recomendación analizando únicamente el grupo al que pertenece el usuario (Shinde y Kulkarni, 2012).

Comparación entre filtrado colaborativo y filtrado basado en contenidos

Los dos tipos de filtrado más difundidos son el filtrado colaborativo y el filtrado basado en contenidos.

La principal **ventaja de CBF** es que no sufre el problema de *cold-start* (Bobadilla y col., 2012b; Ren y col., 2008). Este problema se da cuando existe un nuevo usuario que no ha alimentado con suficiente información al sistema o cuando se crea un nuevo ítem para el cual no hay votos, estos dos casos son causa de dificultad para realizar predicciones precisas. Por otro lado, CBF sufre básicamente dos **problemas**: el primero, de análisis de contenido limitado y el segundo, de sobreespecialización (Shardanand y Maes, 1995; Bojorque Chasi y Hurtado Ortiz, 2017).

- **El análisis de contenido limitado:** ocurre cuando el sistema tiene información limitada sobre la información de los usuarios o los ítems. Una de las principales causas de la información limitada sobre los usuarios son las cuestiones de privacidad que pueden impedir que los usuarios proporcionen información personal. La información precisa sobre los ítems puede resultar muy difícil y costosa de obtener para determinados tipos de ítems como son las imágenes y la música (información no estructurada).

- **Sobreespecialización/falta de serendipia:** este es uno de los mayores inconvenientes del enfoque basado en contenidos, la falta de novedad en sus recomendaciones. Esto consiste en el efecto donde un ítem se puede recomendar siempre y cuando la relación que existe con otro ítem es alta, por ejemplo, si a un usuario le agrada una película de un género específico protagonizada por unos actores, el sistema recomienda una película de ese mismo género, con los mismos actores, esa recomendación puede que no sea de interés para el usuario, debido a que el sistema no proporciona ítems que sorprenden al usuario, es decir, ítems inesperados que inclinen al usuario hacia áreas o ítems que no pensaba que le gustaban, y le llegan a gustar en gran manera. En pocas palabras, el CBF tiende a generar recomendaciones obvias.

Generalmente, el CBF suele nutrirse de las descripciones textuales de los ítems. El uso de las descripciones textuales implica un conjunto de inconvenientes debido a la **ambigüedad del lenguaje natural**, lo que genera información imprecisa. Entre esos **problemas** (Gemmis y col., 2015) se mencionan:

- **Polisemia:** una palabra tiene múltiples significados.
- **Sinonimia:** varias palabras significan lo mismo.
- **Expresiones multi palabra:** las propiedades del conjunto no son predecibles a partir de las propiedades de las palabras individuales.
- **Named-Entity Recognition:** dificultad para reconocer y clasificar elementos dentro del texto en categorías predefinidas.
- **Named-Entity Desambiguation:** dificultad para determinar identidades/referencias de entidades mencionadas. Es un problema inherente del uso de palabras clave en los perfiles.

Actualmente existe un creciente interés en las tecnologías semánticas y la disponibilidad de varias fuentes de conocimiento abiertas como Wikipedia, DBpedia, Freebase y BabelNet que permiten alimentar los avances en las técnicas de filtrado basado en contenido (Gemmis y col., 2015).

Por otro lado, el CF se basa en los **votos** que los distintos usuarios realizan sobre diferentes ítems, de tal manera que al contar con la suficiente información almacenada en el sistema es posible emitir recomendaciones a los usuarios según la información proporcionada por otros usuarios de características similares (Bobadilla y col., 2013a). Normalmente, la información se estructura como una matriz que almacena las **preferencias (explícitas o implícitas)** de cada uno de los usuarios sobre el conjunto de ítems. Estas matrices (guardadas en conjuntos de datos, también conocidos como *datasets*) son enormemente dispersas porque un usuario típico solo ha podido consumir o votar un subconjunto muy reducido del conjunto de ítems disponibles (miles o decenas de miles).

El CF tiene dos ventajas muy importantes: la capacidad de realizar recomendaciones novedosas y la ventaja de no necesitar información personal de los usuarios registrados. Por lo tanto, no resulta muy costoso recolectar la información de los usuarios, ni mucho menos se requiere ir en contra de su privacidad. Los **inconvenientes** que sufre CF son:

FIGURA 1.2: Alternativas para combinar CF y CBF
Figura traducida de (Bobadilla y col., 2013a)

- **Long tail:** existe una cobertura limitada cuando algunos ítems nunca son recomendados.
- **Cold-start:** existe cuando un nuevo usuario o un nuevo ítem no tiene votos, o tiene muy pocos votos.

En el ámbito de investigación las propuestas de métodos de filtrado colaborativo tienen que abordar la forma de aliviar estos problemas.

Es frecuente que **CBF** y **CF** se combinen para aprovechar las ventajas de los dos (Ren y col., 2008; Bobadilla y col., 2013a). En la Fig. 1.2 se pueden apreciar diferentes alternativas híbridas entre CF y CBF. Estas alternativas se clasifican así:

- Implementar filtrado colaborativo y filtrado basado en contenido por separado y combinar sus predicciones (Fig. 1.2 (A)).
- Incorporar características de filtrado basado en contenido en un enfoque de filtrado colaborativo (Fig. 1.2 (B)).
- Construir un modelo unificado que incorpore características de filtrado colaborativo como de filtrado basado en contenido (Fig. 1.2 (C)).
- Incorporar características de filtrado colaborativo en un enfoque de filtrado basado en contenido (Fig. 1.2 (D)).

Filtrado colaborativo (CF)

Pese a los problemas de CF, los *sistemas de recomendación de filtrado colaborativo* son los más difundidos por su interés práctico y de índole científico, y generalmente ofrecen los mejores resultados de recomendación. Además no necesitan un proceso costoso para recolectar la información sobre características de los ítems o de los usuarios. Por este motivo, **en esta investigación nos centramos en filtrado colaborativo como base.**

Según (Ortega y col., 2016; Hernando, Bobadilla y Ortega, 2016; Lü y col., 2012; Brees, Heckerman y Kadie, 1998) los sistemas de recomendación de filtrado colaborativo pueden ser clasificados en tres grupos:

- **Métodos basados en memoria:** actúan directamente sobre la matriz de votos. La implementación más popular es **KNN**, que realiza las recomendaciones usando los k vecinos más similares del usuario dado.
- **Métodos basados en modelos:** usan un modelo para generar recomendaciones. La implementación más popular es *Matrix Factorization*.
- **Métodos híbridos:** realizan la combinación de las técnicas de los dos métodos anteriores.

RS CF basado en memoria

Existe una amplia variedad de enfoques para extraer la información más relevante de las matrices dispersas de filtrado colaborativo. El enfoque tradicional es el algoritmo **KNN** (Bobadilla y col., 2013b; Bobadilla y col., 2012a), donde se buscan los K usuarios más similares (vecindario) para el usuario activo (usuario objetivo); posteriormente, se recomiendan los ítems no consumidos por el usuario activo que han sido mejor valorados por su vecindario. Este enfoque se clasifica como *basado en memoria* (Bobadilla y col., 2013a; Shi, Larson y Hanjalic, 2014): la información para recomendar se obtiene directamente de la matriz de votos. El proceso explicado se llama **KNN basado en usuario**; también es posible llevar a cabo una recomendación *basada en ítems*, obteniendo conjuntos de vecindario de cada ítem. La similaridad entre dos usuarios o ítems se determina a partir de *medidas de similaridad*, entre las más populares están: Coseno, Coseno Ajustado, Correlación de Pearson, Pearson Restringida, índice de Jaccard, JMSD, MJD, PIP, etc.

Las figuras 1.3 y 1.4 permiten ilustrar las diferencias entre un KNN CF basado en usuarios y un KNN basado en ítems, en este caso se ha tomado como ejemplo un sistema de recomendación de películas, donde BD representa la base de datos o matriz de votos.

- **KNN CF basado en usuarios:** evalúa el interés de un usuario objetivo por un ítem utilizando los votos efectuados por otros usuarios de ese mismo ítem. El proceso de este enfoque es el siguiente:
 1. Cálculo de similaridades: con una medida se calcula la similaridad entre el usuario objetivo y cada uno de los demás usuarios de la base de datos.
 2. Selección de K -vecinos: se seleccionan los usuarios más similares al usuario objetivo. Los usuarios más similares toman el nombre de K -vecinos, K representa la cantidad determinada de vecinos necesarios para realizar la predicción.
 3. Predicción: mediante una función de agregación, normalmente el promedio de los votos de los K -vecinos, se predice la valoración que el usuario objetivo le daría a cada ítem no votado previamente.
 4. Recomendación: Se recomiendan los N -ítems con valores más altos de predicción, N representa la cantidad requerida de recomendaciones.
- **KNN basado en ítems:** evalúa el voto de un usuario por un ítem basado en los votos de los usuarios en ítems similares. El proceso de este enfoque es:

FIGURA 1.3: Filtrado colaborativo basado en usuarios (Bojorque Chasi y Hurtado Ortiz, 2017)

FIGURA 1.4: Filtrado colaborativo basado en ítems (Bojorque Chasi y Hurtado Ortiz, 2017)

1. Cálculo de similitudes: con una medida se calcula la similitud entre el ítem objetivo y cada uno de los demás ítems de la base de datos.
2. Selección de K -vecinos: se seleccionan los ítems más similares al ítem objetivo.
3. Predicción: mediante una función de agregación, se predice la valoración del ítem objetivo para un usuario específico.
4. Recomendación: Se determina si el ítem es o no es del gusto del usuario.

RS CF basado en modelos

Actualmente, los RS basados en CF se diseñan utilizando el enfoque *basado en modelos* (Bobadilla y col., 2013a; Shi, Larson y Hanjalic, 2014): se crea un modelo a partir de la matriz de votaciones y, posteriormente, se obtienen recomendaciones del modelo. El método RS basado en modelos más utilizado es *Matrix Factorization* (Koren, Bell y Volinsky, 2009; Yu y col., 2017; Guan, Li y Guan, 2017): la matriz dispersa de votos se comprime en dos matrices de factores densos (una matriz que contiene la información de los usuarios y otra matriz que contiene la información de los ítems). Una de las matrices tiene dimensión de *usuarios x número de factores*, y la otra matriz tiene dimensión de *ítems x número de factores*. La cantidad de factores suele ser pequeña (10 a 40), y el tamaño de cada una de las dos matrices es mucho menor que el tamaño de la información original (*usuarios x ítems*). Esta información comprimida contiene la esencia de la información original, codificada en factores que se denominan ocultos porque su significado (el concepto de codificación) no se conoce. El proceso de predicción y recomendación de este modelo generalmente mejora la calidad obtenida a través de enfoques basados en memoria. Entre los principales modelos están: SVD (Paterek, 2007; Sarwar, 2001), *Time-Aware factor* (Campos, Díez y Cantador, 2014; Gantner, Rendle y Schmidt-Thieme, 2010), *Matrix Factorization* (Koren, Bell y Volinsky, 2009; Koren y Bell, 2015), *Poisson Matrix Factorization* (Gopalan, Hofman y Blei, 2013), *Non-Negative Matrix Factorization* (Lee y Seung, 1999), *Bayesian Non-Negative Matrix Factorization* (Hernando, Bobadilla y Ortega, 2016), etc.

Comparación entre CF basado en KNN y CF basado en Matrix Factorization

El CF basado en KNN presenta **varias ventajas** que son (Ning, Desrosiers y Karypis, 2015; Bojorque Chasi y Hurtado Ortiz, 2017):

- **Simplicidad:** El método es intuitivo y simple de implementar. En su forma tradicional solamente se requiere la configuración de la cantidad de vecinos.
- **Justificabilidad:** El método provee una concisa e intuitiva justificación para las predicciones. Los vecinos de usuarios o ítems sirven para justificar las recomendaciones, esto puede ayudar a los usuarios a comprender mejor la recomendación y su relevancia; además en un sistema interactivo los usuarios pueden elegir los vecinos que consideran más importantes para la recomendación.

A diferencia de la mayoría de sistemas basados en modelos no requiere una fase de aprendizaje que suele resultar costosa y debe ser ejecutada cada cierto intervalo de tiempo en las aplicaciones comerciales. Sin embargo, estos sistemas tienen un **inconveniente**, generalmente requieren un precómputo *offline* de los vecinos más cercanos, lo que implica un proceso de cómputo **no escalable** en cuanto a tiempo de

ejecución. Es decir, a medida que la entrada de datos es más grande, el rendimiento del sistema se ve más afectado. Por tanto, estos sistemas no son adecuados cuando se tiene gran cantidad de usuarios e ítems. Almacenar los vecinos más cercanos requiere una cantidad pequeña de memoria, lo que proporciona a este enfoque una adecuada escalabilidad espacial.

Por otro lado, los **sistemas de recomendación basados en *Matrix Factorization*** son algoritmos que escalan muy bien, proporcionan una muy buena calidad de predicciones, sin embargo un gran inconveniente que presentan es la dificultad para justificar (explicar) las recomendaciones. Como se mencionó anteriormente, estos sistemas requieren una fase de aprendizaje para determinar las matrices de usuarios e ítems antes de iniciar el sistema de recomendación. Sin embargo, una vez que se ha terminado la fase de aprendizaje se pueden hacer las predicciones rápidamente. Son muy aconsejables en sistemas de recomendación con una gran cantidad de usuarios o ítems.

Es importante resaltar dos conceptos: 1) Cuanta más información reúne un RS, mejores resultados puede proporcionar; es por esto que los RS híbridos (Paradarami, Bastian y Wightman, 2017) generalmente se diseñan en RS comerciales (típicamente: colaboración + contenido + demográfico); y 2) Hay RS basados en modelos diferentes desde el enfoque de MF, aunque su uso no es extendido: enfoques difusos (Perumal, Arputharaj y Sannasi, 2017), algoritmos evolutivos (ants, swarm, etc.) (Horváth y Carvalho, 2017), métodos bayesianos (Hernando, Bobadilla y Ortega, 2016), clustering (Bobadilla y col., 2018), etc.

Desafíos de RS en general

Los desafíos más importantes para los sistemas de recomendación son:

- **Mejorar los procesos de obtención de datos:** (Elahi, Ricci y Rubens, 2016) proporciona un survey de aprendizaje activo en sistemas de recomendación, con el sentido de identificar y adoptar criterios para obtener datos que reflejen mejor las preferencias de los usuarios y permitan generar mejores recomendaciones.
- **Manejar transparencia en su funcionamiento:** (Herlocker, Konstan y Riedl, 2000) indican la importancia de que los sistemas presenten transparencia en el funcionamiento de la recomendación, exponiendo el razonamiento y los datos detrás de una recomendación.
- **Establecer un consenso en los procesos de evaluación:** (Herlocker y col., 2004) presentan las estrategias de evaluación de CF y el análisis de varias métricas.
- **Hacer frente a las nuevas tendencias:** *big social data*, internet de las cosas (IoT), etc. En (Karimi, Jannach y Jugovac, 2018) resumen los aspectos de RS y sus nuevos desafíos. Dicho artículo presenta un análisis exhaustivo de diversas investigaciones, datasets, librerías y metodologías. Además, destaca la importancia de abordar nuevos dominios y nuevos procesos para hacer frente a la información de la Web Social, Web Semántica e IoT. Asimismo en (Jannach y Adomavicius, 2016) se presenta un estudio desde la perspectiva económica de los consumidores y proveedores.
- **Resolver el problema de la dispersión:** este problema se presenta debido a que los usuarios votan muy pocos ítems en relación a la cantidad existente. En

(Bobadilla y Serradilla, 2009) se explica a detalle el efecto de la dispersión en filtrado colaborativo. (Sarwar, 2001) controlan este problema mediante la integración de un enfoque basado en contenidos, además utilizan reducción de dimensionalidad mediante el modelo *SVD* aplicado a filtrado colaborativo.

- **Controlar la gran escala de datos y su heterogeneidad:** (Eirinaki y col., 2018) recopilan los desafíos y problemas en el campo de las redes sociales. Mencionan que el campo de investigación es grande debido a la gran escala de datos, su heterogeneidad, las estructuras que se forman, su tamaño y dinámica. Destacan que el *deep learning* ha abierto el camino a nuevos tipos de RS, a más de ello mencionan varios modelos basados en *non-negative matrix factorization* que han surgido para reducir la dimensionalidad de los datos, con el fin de resolver el problema de dispersión y brindar mejor escalabilidad.
- **Mejorar su diseño para mejorar el accuracy de las recomendaciones.**
- **Afrontar todos los requerimientos de los usuarios** (a más del accuracy): prevenir o controlar el problema *user boredom* que se genera cuando los usuarios cambian sus gustos por el tipo de ítem usual cuando han llegado a una etapa de aburrimiento. Un problema similar es el problema *drift* que ocurre cuando el sistema no es capaz de detectar rápidamente el cambio de intereses del usuario. Otros campos abiertos y de interés en un RS son la diversidad, novedad y cobertura. (Kaminskas y Bridge, 2016) brindan un survey y un análisis interesante sobre estas características importantes en el impacto de una lista de recomendaciones. Ellos demuestran que la diversidad esta correlacionada positivamente en la novedad, y esta a su vez en la cobertura.
- **Direccionar el problema del *cold-star*,** de tal manera que el sistema pueda generar predicciones precisas aun cuando existan usuarios nuevos o ítems nuevos con información escasa (Bobadilla y col., 2012b).
- **Extender su diseño:** a recomendación para grupos de usuarios, recomendación de secuencias y paquetes (*bundles*) de ítems, etc. Precisamente, de este gran desafío nace la motivación de esta tesis y el trabajo futuro. En este documento presentaremos el estado del arte de los RS orientados a grupos de usuarios (GRS) y además proporcionaremos un método GRS CF basado en KNN que mejora el estado del arte. En la siguiente sección introduciremos las características de un GRS.

1.1.2 Recomendación a grupos de usuarios (GRS)

Los sistemas de recomendación se han centrado principalmente en recomendaciones individuales. Anteriormente la mayoría de las investigaciones se preocuparon en mejorar la calidad del KNN CF en cuanto a calidad de predicciones, recomendaciones y otras características como novedad, serendipia, escalabilidad, etc. Hoy las investigaciones estan dirigidas principalmente a mejorar el rendimiento de los modelos basados en *Matrix Factorization* que han demostrado mejor calidad de predicción y recomendación frente a KNN CF. Todos estos esfuerzos han sido destinados a generar recomendaciones a un usuario objetivo.

Ahora bien, existen escenarios en que una persona no busca un interés personal, sino que al ser parte de un conjunto de personas requerirá tomar decisiones y escoger productos en función del grupo para mantener la armonía. Un grupo puede

estar conformado por personas con intereses distintos o similares, en cualquier caso, un grupo necesitará productos de satisfacción general, como, por ejemplo: películas, shows de TV, restaurantes, bares, eventos culturales, destinos de viaje, entretenimiento, música, etc. Un grupo necesitará la dirección adecuada en servicios, como, por ejemplo: video bajo demanda, redes sociales, sitios web de eventos, servicios que brindan información sobre puntos de interés, agencias de viajes, etc. Un grupo a más de buscar el bien común también deseará hallar productos sorprendentes a nivel general, que lleven al grupo a una experiencia inolvidable. Bajo estos escenarios surge la necesidad de nuevas estrategias de recomendación. Los sistemas que atienden esta necesidad y soportan estos mercados son los sistemas de recomendación para grupos de usuarios. Estos sistemas extienden el diseño de los sistemas de recomendación individuales para abarcar nuevas restricciones y funcionalidades con el fin de dar soporte a las decisiones y recomendaciones grupales.

Existen varias estrategias de recomendación a grupos de usuarios (Masthoff, 2011; Feng y Cao, 2017; Masthoff, 2004). En el capítulo 2 se aborda cada estrategia y el trabajo relacionado. El objetivo de cada estrategia es maximizar la satisfacción general.

Aunque la recomendación a grupos de usuarios puede parecer una simple generalización de la recomendación para usuarios individuales, es más compleja:

1. Cuando se elige un enfoque basado en memoria, hay varias posibilidades para abordar el problema. En la Fig. 1.5 se presentan diversas estrategias para recomendación a grupos de usuarios.
2. Si optamos por un enfoque basado en modelos, encontramos que la mayoría de los modelos utilizados en la recomendación a usuarios individuales no son generalizables para la recomendación a grupos de usuarios. Los investigadores adaptan los modelos existentes (Ortega y col., 2016; Hu, Meng y Wang, 2011), o crean nuevos enfoques (Rossi y col., 2017; Chen, Cheng y Lin, 2015).
3. Los métodos con los que se miden los resultados son menos universales en recomendaciones para grupos de usuarios: políticas de recomendación, tamaños y distribuciones de los grupos, etc.

(Jameson y Smyth, 2007) mencionan también que las **diferencias entre los RS individuales y los GRS** son muy numerosas, importantes y complejas. Entre ellas destacan que en un sistema de recomendación grupal:

1. La interpretación de las preferencias explícitas es menos sencilla: los métodos de adquisición de preferencias no han sido adaptados específicamente para recomendación a grupos de usuarios.
2. El proceso de recomendación va más allá de fórmulas numéricas, también se requiere un proceso de adecuación de las configuraciones de la aplicación: se necesitan procedimientos más sofisticados para cubrir las condiciones del grupo dependiendo de sus características y del dominio. Una comunidad virtual de lectura conformada en la web podrá ser numerosa (mayor a 5) y tendrá miembros con características similares (grupo homogéneo), mientras que una familia que busca un destino turístico generalmente estará compuesta por una cantidad más pequeña de miembros con diferentes características (grupo heterogéneo).

FIGURA 1.5: Enfoques basados en KNN para recomendar a grupos de usuarios.

La figura tomada de (Ortega y col., 2013) ha sido traducida y extendida.

- Las explicaciones pueden tomar muchas formas y transmitir tipos diferentes de información: la información relevante debe presentarse efectivamente para todos los miembros del grupo.
- El proceso para llegar a una decisión final puede requerir comunicación y negociación: el sistema debe facilitar la comunicación adecuada entre los usuarios del grupo.

Los tiempos de respuesta en la recomendación a grupos de usuarios son más críticos que en las recomendaciones individuales porque es necesario realizar operaciones adicionales. Cuando se utiliza un enfoque **basado en memoria**, cuanto antes se realice la agregación, más rápido se obtendrán los resultados (Ortega y col., 2013). Un enfoque **basado en modelos** generalmente genera resultados rápidamente; por otro lado, requiere un gran tiempo de aprendizaje para generar el modelo.

La Fig. 1.5 muestra las diferentes opciones disponibles para implementar la recomendación a grupos de usuarios (cuando se utiliza el enfoque basado en memoria). Los cuadros grises muestran las fases habituales de una recomendación realizada con el algoritmo KNN. Las cuatro opciones (a hasta d), que fluyen horizontalmente, representan las estrategias seguidas para hacer recomendaciones a grupos de usuarios. Opción a) *Fusión de recomendaciones*, utiliza las listas de ítems recomendados para cada usuario del grupo y genera una lista unificada. Opción b) *Agregación de predicciones* usa las listas de predicciones más convenientes para cada usuario en el grupo y genera una lista unificada de predicciones (hay más predicciones que recomendaciones). Opción c) *Intersección de vecinos*, empieza desde el vecindario de cada usuario del grupo y genera un vecindario que representa a todo el grupo. Finalmente, opción d) *Agregación de preferencias de usuarios*, crea un usuario virtual que representa a todos los usuarios del grupo: desde el usuario virtual se puede hacer una recomendación individual tradicional.

1.2 Motivaciones, objetivos e hipótesis

Los RS tradicionales se han centrado en proporcionar recomendaciones a usuarios individuales. Sin embargo, hay ciertos escenarios en los que las recomendaciones individuales son inadecuadas: cuando un grupo de amigos va al cine, esperan que el RS recomiende una película que satisfaga las preferencias de todos, no una recomendación para cada amigo. De la misma manera, cuando una familia viaja en vacaciones, requieren un destino adecuado para todos los miembros de la familia. Este tipo de recomendaciones se denominan recomendaciones para grupos de usuarios.

La recomendación a grupos de usuarios es un gran desafío para los sistemas de recomendación, además es todavía un tema nuevo y menos explorado que los RS individuales, por lo tanto, es necesario sumergirse en este campo, específicamente dentro del filtrado colaborativo.

El **objetivo principal** de esta tesis es precisamente profundizar en ese gran desafío y proporcionar un nuevo método de recomendación a grupos de usuarios que ayude a mejorar la calidad del *accuracy* con respecto al estado del arte. (Ortega y col., 2013) proporcionan un enfoque basado en memoria, mientras (Ortega y col., 2016) proporciona un enfoque basado en modelos. El modelo desarrollado en (Ortega y col., 2016) no admite mejoras significativas, mientras que la solución provista en (Ortega y col., 2013) tiene una ruta prometedora para mejorar los resultados. Por lo tanto, nuestra **primera decisión** es introducirnos en la **creación de un enfoque GRS CF basado en memoria**. Este método proporcionará una **nueva métrica para el algoritmo KNN CF** que medirá la similaridad entre un grupo de usuarios y el resto de los usuarios del RS.

Los enfoques publicados generalmente implementan la agregación de vecindarios, o la mezcla de predicciones y recomendaciones (opciones c, b y a respectivamente, en Fig. 1.5). La solución propuesta en (Ortega y col., 2013) proporciona una métrica innovadora (UGSM) que permite encontrar la similaridad existente entre cualquier usuario de RS y el grupo de usuarios a los que se desea recomendar: opción d) en la Fig. 1.5. Esta solución demuestra que cuanto antes se unifique la información de los usuarios del grupo, más eficiente será el cálculo de las recomendaciones sin que la calidad de estas se vea afectada.

Ahora bien, en (Bobadilla, Ortega y Hernando, 2012), se explota el concepto de la singularidad de los votos: los votos "singulares", son más importantes que los votos "habituales"; por ejemplo: en una película que recibe una gran cantidad de votos negativos (o existe ausencia de votos), un voto positivo de un usuario es muy relevante para encontrar su vecindario. El concepto de singularidad ha generado importantes mejoras de *accuracy* cuando se ha aplicado a varios RS datasets públicos.

En esta tesis se propone un método GRS que se apoya en la **generalización del concepto de singularidad**. La idea subyacente es la siguiente: sabemos que dos usuarios son similares si presentan votos únicos en común; por ejemplo, ambos usuarios generalmente escuchan una canción impopular y ambos otorgan un voto bajo. Usando el mismo razonamiento: si un grupo de usuarios comparte votos inusuales con un candidato vecino, es muy probable que sea un vecino adecuado. La condición de singularidad es menos probable que ocurra en la recomendación a grupos (por ejemplo,

un grupo de amigos a los que les gusta una película muy poco popular). Esta menor probabilidad nos ayuda a elegir vecinos que se ajusten muy bien a las preferencias del grupo. En resumen: **el concepto de singularidad se ajusta bien a las particularidades de la recomendación a grupos de usuarios.**

El propósito general de esta tesis es alcanzado mediante los siguiente objetivos específicos:

- Identificar los trabajos de investigación de vanguardia en sistemas de recomendación grupales, con énfasis en filtrado colaborativo.
- Diseñar un nuevo método que incorpore una novedosa medida de similitud para grupos usando el concepto de singularidades que ha dado buenos resultados en RS individuales.

Para lograr estos objetivos, presentamos la hipótesis para esta tesis doctoral:

Los votos singulares son más importantes que los votos habituales en la agregación de preferencias individuales en los sistemas de recomendación basados en filtrado colaborativo para grupos de usuarios.

Sobre la base de esta hipótesis, proporcionamos algunas contribuciones científicas:

- Se proporciona un estado del arte sobre los sistemas de recomendación orientados a grupos de usuarios para facilitar futuras investigaciones. Se hace especial énfasis en filtrado colaborativo. También se presentan algunos desafíos de los RS en general y específicamente de los GRS para ayudar a los lectores a ponerse al día con las fronteras de la investigación.
- En el capítulo 3, el método propuesto para hacer recomendaciones a grupos de usuarios se explica en detalle. El método propuesto utiliza un enfoque de agregación de preferencias de usuarios (*related users*) mediante una nueva medida de similitud creada para grupos de usuarios denominada SMGU. Este enfoque se ha elegido debido a que en (Ortega y col., 2013) se demuestra que un enfoque de agregación de preferencias individuales logra tiempos de ejecución significativamente mejores que los enfoques basados en las opciones b), c), d) en la Fig. 1.5, puesto que actúa en una etapa temprana de KNN. Probamos la efectividad de predicción y recomendación del método propuesto comparándolo con el propio UGSM (Ortega y col., 2013), con el método basado en modelos de (Ortega y col., 2016) y con varios métodos publicados recientemente.

1.3 Estructura de la tesis

Esta tesis está estructurada de la siguiente manera: en el capítulo 2 presentaremos el trabajo relacionado en la recomendación para agrupar el subcampo de usuarios. En el capítulo 3 definiremos y explicaremos el GRS propuesto, su formalización y la ejecución de un ejemplo. En el capítulo 4 presentaremos el diseño de experimentos, los resultados obtenidos y su discusión. En el capítulo 5 proporcionaremos las conclusiones del documento y sugeriremos trabajos futuros. Finalmente, presentaremos las referencias, muchas de ellas de publicaciones muy recientes.

Capítulo 2

Trabajo relacionado

Los sistemas de recomendación de grupos (GRS) son un campo amplio que todavía tiene mucho por explorar. En este capítulo, se proporciona un estado del arte sobre el conocimiento fundamental sobre GRS, con especial énfasis en filtrado colaborativo, para preparar a los lectores para futuras discusiones en capítulos posteriores.

Al comienzo de este capítulo, en la sección 2.1 presentaremos varias clasificaciones de GRS. Luego, en la sección 2.2 describiremos los principales desafíos de GRS. Posteriormente, en la sección 2.3 proporcionaremos varias medidas de calidad para la evaluación de RS y GRS. En la sección 2.4 describiremos diversas investigaciones que afrontan los desafíos generales de RS presentados en la sección 1.1.1. Finalmente, en la sección 2.5 a partir de la clasificación de GRS más común de acuerdo con la taxonomía tradicional que los divide en basados en KNN y basados en modelos, presentaremos los trabajos de investigación de vanguardia de manera integral.

2.1 GRS: clasificación

Existen varias clasificaciones de los GRS, en este documento hemos incluido las más relevantes.

Según (Jameson y Smyth, 2007; Boratto y Carta, 2015b) un sistema puede generar recomendaciones a grupos utilizando tres enfoques diferentes para predecir los votos:

1. **Construcción de modelos de preferencias grupales:** se realiza la predicción de los votos faltantes para cada grupo utilizando el modelo. Enfoque también conocido como **agregación de preferencias o perfiles de usuarios del grupo, o enfoque relacionado a usuarios**.
2. **Agregación de recomendaciones:** se hace la predicción de los votos para los ítems no calificados por cada usuario y luego la fusión de las recomendaciones individuales hechas para los miembros de un grupo.
3. **Agregación de predicciones:** se agregan las predicciones creadas para cada usuario en una preferencia de grupo.

En (Garcia y col., 2012) determinan la clasificación de los GRS basándose en seis características independientes que influyen en el diseño de un GRS. Estas las resumimos así:

1. **Origen de la información:** enfoques simples y enfoques híbridos.
 - (a) Simples
 - (i) basados en contenidos
 - (ii) basados en filtrado colaborativo
 - (iii) demográficos
 - (iv) sociales
 - (v) context-aware
 - (vi) basados en conocimiento
 - (b) Híbridos: combinan varios enfoques simples.
2. **Interacción del usuario con el sistema:** los usuarios pueden ser activos o pasivos. Un grupo activo es aquel cuyos miembros interactúan entre ellos para llegar a un consenso o negociación en las recomendaciones, de tal manera que la satisfacción sea general. En un grupo pasivo los miembros no interactúan entre ellos para establecer una negociación.
 - (a) Con propósito de consenso: para usuarios activos que necesitan una negociación entre los miembros del grupo.
 - (b) Con propósito simple (proveer recomendaciones)
3. **Dominio**
 - (a) Específicos: centrados en un dominio específico como películas, destinos de vacación, música, restaurantes, etc.
 - (b) Generalistas: independientes del dominio.

4. Salida del GRS

- (a) Generadores de una recomendación
- (b) Generadores de una lista ordenada de recomendaciones
- (c) Generadores de preferencias del grupo (no recomendaciones)

5. Tamaño del grupo

- (a) Para grupos pequeños (menor o igual a 5 usuarios)
- (b) Para grupos de cantidad no limitada

6. Enfoque de agregación para hacer las recomendaciones

- (a) Con agregación de recomendaciones individuales.
- (b) Con agregación de perfiles de usuarios: crea un modelo simple con los perfiles de cada miembro. Un perfil puede contener: a) detalles personales y demográficos, b) el modelo de gustos generales del usuario: votos numéricos, lista de características ontológicas, etc., y c) la retroalimentación de la información adquirida por interacción histórica del usuario con el GRS (satisfacción del usuario con las recomendaciones).
 - (i) Creación explícita: si los usuarios usan una cuenta común para indicar sus preferencias.
 - (ii) Creación implícita: al agregar los perfiles o preferencias individuales.

(Boratto y Carta, 2011) indican una clasificación de los distintos grupos que existen y que hay que considerar para seleccionar un método GRS. Ellos determinan que existen grupos con distintas características, como, por ejemplo:

1. **Grupos establecidos** de personas que eligen explícitamente ser parte de un grupo, debido a intereses compartidos, a largo plazo (Ortega y col., 2013; Ortega y col., 2016; Quijano-Sánchez, Díaz-Agudo y Recio-García, 2014).
2. **Grupos ocasionales** de personas que hacen algo ocasionalmente juntas, como visitar un museo (Rossi y col., 2017).
3. **Grupos aleatorios** que comparten un entorno en un determinado momento, sin intereses explícitos que los vinculan (Kim y col., 2010).
4. **Grupos identificados automáticamente** considerando las preferencias de los usuarios y / o los recursos disponibles (Boratto y Carta, 2015a; Boratto y Carta, 2015b). A partir de dicha clasificación ellos sustentan un estado del arte en recomendaciones de grupo para grupos automáticamente detectados con intereses similares.

Otra clasificación de acuerdo a la diversidad de tipos de grupos se da en (Seo y col., 2018). Ellos determinan la existencia de los siguientes tipos de grupos:

1. **Grupos homogéneos:** los estudios de recomendación de grupos homogéneos se centran en los requisitos del proveedor de servicios.
2. **Grupos heterogéneos:** los estudios de recomendación de grupos heterogéneos se centran en la satisfacción de los miembros del grupo.

2.2 Desafíos de GRS

Los GRS son un campo de estudio abierto con muchos desafíos, estos se recopilan en (Masthoff, 2011; Senot y col., 2010). En esta sección resumimos estos desafíos e incluimos otros:

- **El control del ruido natural:** entre las tendencias en los sistemas de recomendación como el problema del cold start, las recomendaciones a grupos y las recomendaciones context-aware, se encuentra el control del ruido natural. Entendiéndose el ruido natural como la información no malintencionada de ciertos usuarios que de forma explícita proporcionan votos que sesgan de manera inconsistente los votos del conjunto en general.
- **La incertidumbre y la escasez de la información de los perfiles de los usuarios:** las preferencias imprecisas y el problema del cold start pueden afectar el accuracy de las recomendaciones. Este desafío está relacionado al control del ruido mencionado previamente.
- **La diversidad de tipos de grupos:** ya sea que un grupo sea homogéneo o heterogéneo, el objetivo de un GRS debe garantizar que todos los miembros de un grupo estén satisfechos con los resultados recomendados.
- **La dinámica social de un grupo:** las complejas relaciones sociales afectan la satisfacción individual. Los recomendadores multicriterio pueden ayudar a aliviar esta área.
- **La recomendación de secuencia de ítems a un grupo:** los ítems subsecuentes pueden afectar la satisfacción del usuario. En (Masthoff y Gatt, 2006; Piliponyte, Ricci y Koschwitz, 2013) se presentan sistemas de recomendación de secuencias de ítems a grupos de usuarios para mejorar la satisfacción del usuario. Ellos analizan el impacto del orden de los ítems.
- **La negociación y decisión final:** es importante fomentar la cooperación en un grupo para establecer con armonía la decisión final.
- **La explicación de las recomendaciones grupales:** es importante mostrar transparencia de la satisfacción que tienen los miembros del grupo para mejorar la comprensión del usuario de tal manera que pueda aceptar nuevas recomendaciones que usualmente no le gustan. Sin embargo, es necesario establecer un balance entre la transparencia y la privacidad para evitar el efecto vergüenza (Masthoff y Gatt, 2006). En (Castro y col., 2015) se detalla el rol de las explicaciones en RS.
- **Evaluación de las recomendaciones grupales:** la validación de las recomendaciones es un desafío amplio. Es fundamental identificar la satisfacción de cada miembro del grupo. En (Shani y Gunawardana, 2011a) se detallan las métricas y metodologías de evaluación de RS en general. En (De Pessemier, Dooms y Martens, 2012) se explica el diseño y evaluación con varios algoritmos y tamaños de grupos, proporcionando sugerencias de la aplicación de algoritmos específicos en diferentes escenarios.

2.3 Evaluación de RS y GRS

Se requiere un proceso de evaluación para validar nuevos métodos RS y GRS, de tal manera que los mejores métodos puedan ser difundidos hacia la comunidad académica y a la industria. Existen varios frameworks de sistemas de recomendación (Jung, 2012; Sun y col., 2017; Ortega y col., 2018a), sin embargo estos tienen dos inconvenientes: el primero es la falta de formalización, aunque las medidas están bien definidas existen una variedad de detalles que pueden conducir a la generación de resultados diferentes en experimentos similares; el segundo inconveniente es la ausencia de estandarización de las medidas de evaluación en aspectos como la novedad, serendipia, diversidad, etc (Bobadilla y col., 2013a). En esta sección recopilaremos las medidas más populares que hemos identificado tanto en sistemas de recomendación individuales, como en sistemas de recomendación para grupos de usuarios. La evaluación en GRS tiene todavía un mayor desafío, puesto que todavía presenta un campo muy amplio que queda por explorar y estandarizar.

2.3.1 Evaluación de los sistemas de recomendación

(Olmo y Gaudioso, 2008; Bojorque Chasi y Hurtado Ortiz, 2017) recopilan las medidas de calidad más utilizadas en los sistemas de recomendación individuales y las clasifican en tres grupos: (1) **Medidas de evaluación de la predicción**, (2) **Medidas de evaluación de la recomendación como conjunto** y (3) **Medidas de evaluación de la recomendación como listas jerárquicas**.

El proceso de validación puede ser online u offline, aunque por circunstancias prácticas se prefiere el *método offline*. El método offline consiste en un proceso de validación de resultados de calidad que generalmente utiliza técnicas de validación cruzada, como *random sub-sampling*, *k-fold cross validation*, *leave-one-out cross validation*, etc.. El proceso de validación requiere dividir un conjunto en: a) *conjunto de entrenamiento* que es utilizado para el aprendizaje del modelo, b) *conjunto de validation* que es utilizado para ajustar los parámetros de entrada del RS o GRS, y c) *conjunto de test* que es utilizado para la validación real. Este proceso permite evitar problemas de *overfitting* y *underfitting*. Generalmente, los porcentajes de porción de cada conjunto son los que se muestran en la Fig. 2.1.

La Fig. 2.2 ilustra el mecanismo general de evaluación de un RS que genera recomendaciones para un usuario individual y la Fig. 2.3 ilustra un GRS que proporciona recomendaciones a un grupo de usuarios. Para la explicación hemos incorporado en las figuras el dominio de películas. *Training BD* es la base de datos para la *fase de entrenamiento* y de *ajuste de parámetros*. *Test BD* es la base de datos de *Test*. En la Fig. 2.2, las entradas son: las preferencias del usuario y *Training BD*. El *enfoque RS* corresponde a cualquier algoritmo que genere recomendaciones individuales. Este enfoque da como salida las predicciones individuales y las Top *N* recomendaciones que posteriormente serán evaluadas con los votos de *Test* del usuario. En la Fig. 2.3, las entradas son: las preferencias de los usuarios de un grupo y *Training BD*. El *enfoque GRS* corresponde a cualquier algoritmo que genere recomendaciones para grupos de usuarios. El enfoque GRS da como salida las predicciones grupales y las Top *N* recomendaciones para el grupo que posteriormente serán evaluadas con los votos de *Test* de los usuarios del grupo.

FIGURA 2.1: Proporción de datos para evaluación

FIGURA 2.2: Proceso general de evaluación de RS

FIGURA 2.3: Proceso general de evaluación de GRS

Medidas de evaluación de la predicción

Las medidas de calidad más utilizadas son:

1. *Accuracy* (exactitud)

- (a) MAE
- (b) NMAE
- (c) RMSE
- (d) MSE

2. *Coverage* (cobertura)

Accuracy

Mide la diferencia absoluta entre la predicción ($p_{u,i}$) y el valor real ($r_{u,i}$). Entre las medidas más populares de accuracy podemos apreciar:

- **MAE:** es el Error Medio Absoluto (*Mean Absolute Error*) donde $\bullet$ es la ausencia de voto ($r_{u,i} = \bullet$ significa que el usuario u no ha votado por el ítem i), sea O_u el conjunto de ítems votados en *test* por el usuario u para los que ha sido posible calcular una predicción $O_u = \{i \in I | p_{u,i} \neq \bullet \wedge r_{u,i} \neq \bullet\}$ se define:

$$MAE = \frac{1}{\#U} \sum_{u \in U} \left(\frac{1}{\#O_u} |p_{u,i} - r_{u,i}| \right) \quad (2.1)$$

- **NMAE:** es el Error Medio Absoluto Normalizado (*Normalized Mean Absolute Error*), se toma en cuenta el rango de votos donde r_{max} indica el valor máximo de un voto y r_{min} el valor mínimo

$$NMAE = \frac{MAE}{r_{max} - r_{min}} \quad (2.2)$$

- **MSE:** es el error medio cuadrático (*Mean Squared Error*):

$$MSE = \frac{1}{\#U} \sum_{u \in U} \frac{1}{\#O_u} (p_{u,i} - r_{u,i})^2 \quad (2.3)$$

- **RMSE:** es la raíz del error medio cuadrático (*Root of Mean Squared Error*):

$$RMSE = \frac{1}{\#U} \sum_{u \in U} \sqrt{\frac{1}{\#O_u} (p_{u,i} - r_{u,i})^2} \quad (2.4)$$

Coverage

Específicamente en CF basado en KNN, coverage calcula el porcentaje de situaciones en el que al menos un k-vecino de un usuario activo puede evaluar un ítem que no ha sido votado por el usuario activo. El problema de coverage surge cuando un sistema de recomendación realiza recomendaciones de alto accuracy solo para una pequeña porción de los ítems que tienen una enorme cantidad de votos. Definido $K_{u,i}$ como el conjunto de vecinos del usuario u quienes han votado por el ítem i sea $C_u = \{i \in I | r_{u,i} = \bullet \wedge K_{u,i} \neq \emptyset\}$ y $D_u = \{i \in I | r_{u,i} = \bullet\}$.

$$coverage = \frac{1}{\#U} \sum_{u \in U} \left(100 \times \frac{\#C_u}{\#D_u} \right) \quad (2.5)$$

Medidas de evaluación de la recomendación como conjunto

El usuario gana confianza cuando está de acuerdo con un conjunto reducido de recomendaciones hechas por el sistema de recomendación (Bobadilla y col., 2013a). Una recomendación como conjunto no considera el accuracy de la recomendación, sino que toma en cuenta la lista de ítems recomendados relevantes que resultan de interés para el usuario (Shani y Gunawardana, 2011b).

Las medidas comunes para evaluar la recomendación como conjunto según (Olmo y Gaudioso, 2008) son:

1. *Precision*
2. *Recall*
3. *ROC*
4. *F1 Score*

Estas medidas son adaptadas del área de *information retrieval* para los sistemas de recomendación. En la **matriz de confusión** de la tabla 2.1, se puede apreciar que existen dos tipos de recomendaciones: a) la recomendación que brinda el sistema y b) la recomendación exitosa, la que el usuario le gusta y acepta como tal. Para el caso de los sistemas de recomendación se suele utilizar un **umbral de aceptación** puesto que la predicción no suele estar de manera binaria (es decir, 1 o 0, positivo o negativo) sino en el rango del voto máximo y mínimo. De esta manera, los votos que superan el umbral se consideran positivos y los que no lo superan se consideran negativos. En la tabla se pueden apreciar que un voto se considera:

- **VP:** el ítem ha sido recomendado y efectivamente le gusta al usuario.
- **FP:** el ítem ha sido recomendado, pero no le gusta al usuario.
- **FN:** el ítem no ha sido recomendado, pero le gusta al usuario.
- **VN:** el ítem no ha sido recomendado y efectivamente no le gusta al usuario.

TABLA 2.1: Matriz de confusión de *Information Retrieval* adaptada a los Sistemas de Recomendación

		Voto real ($r_{u,i}$)	
		Le gusta Relevante ($r_{u,i} \geq \theta$)	No le gusta No relevante ($r_{u,i} < \theta$)
Predicción ($p_{u,i}$)	Recomendado Positivo ($p_{u,i} \geq \theta$)	VP	FP
	No recomendado Negativo ($p_{u,i} < \theta$)	FN	VN

Sea X_u el conjunto de recomendaciones al usuario u , y Z_u el conjunto de n recomendaciones al usuario u . Nosotros representaremos la evaluación de precision y recall para las recomendaciones, al hacer n recomendaciones de *Test* para el usuario u , siendo θ el umbral de relevancia (aceptación). Asumiendo que todos los usuarios reciben n recomendaciones:

- **Precision:** indica la proporción de ítems recomendados relevantes del número total de ítems recomendados.

$$precision = \frac{VP}{VP + FP} \quad (2.6)$$

$$precision = \frac{1}{\#U} \sum_{u \in U} \frac{\#\{i \in Z_u | r_{u,i} \geq \theta\}}{n} \quad (2.7)$$

- **Recall:** indica la proporción de ítems recomendados relevantes del número de ítems relevantes. Esta medida es una tasa de verdaderos positivos (*true positive*) y tiene una medida opuesta denominada **fallout** que mide la tasa de falsos positivos (*false positive*).

$$recall = \frac{VP}{VP + FN} \quad (2.8)$$

$$fallout = \frac{FP}{FP + VN} \quad (2.9)$$

$$recall = \frac{1}{\#U} \sum_{u \in U} \frac{\#\{i \in Z_u | r_{u,i} \geq \theta\}}{\#\{i \in Z_u | r_{u,i} \geq \theta\} + \#\{i \in Z_u^C | r_{u,i} \geq \theta\}} \quad (2.10)$$

$$fallout = \frac{1}{\#U} \sum_{u \in U} \frac{\#\{i \in Z_u | r_{u,i} < \theta\}}{\#\{i \in Z_u | r_{u,i} < \theta\} + \#\{i \in Z_u^C | r_{u,i} < \theta\}} \quad (2.11)$$

- **F1:** es una medida que combina **precision** contra el **recall**, proviene de las medidas F_β , donde β es el contrapeso de una de ellas frente a la otra, lo más usual es utilizar la métrica $F1$ ($\beta = \frac{1}{2}$) para la fórmula 2.12.

$$F_\beta = \frac{precision \times recall}{(1 - \beta) \times precision + \beta \times recall} \quad (2.12)$$

$$F1 = \frac{2 \times precision \times recall}{precision + recall} \quad (2.13)$$

- **ROC:** una alternativa a las medidas **precision** y **recall** es el **análisis Receiver Operating Characteristic**, cuya curva representa el **recall** frente al **fallout**, el

objetivo del análisis *ROC* es retornar la mayor cantidad de recomendaciones relevantes y la menor cantidad de recomendaciones no relevantes.

$$ROC = \frac{recall}{fallout} \quad (2.14)$$

Cada medida tiene un significado intuitivo, así *recall* representa el *coverage* de los ítems útiles que el sistema de recomendación puede obtener, *precision* permite mostrar la capacidad del sistema de recomendación para solamente mostrar ítems útiles. Es evidente que se puede mejorar una de ellas en declive de la otra.

Medidas de evaluación de la recomendación como listas jerárquicas

(Vargas y Castells, 2011; Ziegler y col., 2005; Bobadilla y col., 2013a) indican que en determinadas situaciones los sistemas de recomendación brindan extensas listas de ítems recomendados, en estos casos cobra importancia el orden de la recomendación puesto que es evidente que aquellos ítems que aparecen al inicio de la lista tienen más importancia para el usuario que aquellos que aparecen al final. Los errores incurridos en los ítems de inicio son más graves que los errores en los últimos ítems de las listas, por ello las *medidas de ranking* no se ocupan del *accuracy* o de ítems relevantes de la recomendación, sino del orden en el que aparecen las listas. Las *medidas de ranking o de listas jerárquicas* consideran esta situación. Las medidas más utilizadas provienen del área de *information retrieval*.

Las medidas comunes para evaluar la recomendación como listas jerárquicas son:

- **Half-life:** asume un decrecimiento exponencial del interés del usuario conforme se avanza en la lista desde la parte superior a la inferior. Entiéndase por *half-life* el número de un ítem en la lista tal que existe el 50-50 de probabilidad que el usuario lo revise, estima que tan probable es que un usuario visite un ítem p_i en una lista rankeada (Breese, Heckerman y Kadie, 1998).

$$HL = \frac{1}{\#U} \sum_{u \in U} \sum_{i=1}^N \frac{\max(r_{u,p_i} - d, 0)}{2^{(i-1)/(\alpha-1)}} \quad (2.15)$$

Donde d es el voto irrelevante y α es el número de ítems en la lista (*viewing half-life*).

- **Normalized Discounted Cumulative Gain (NDCG):** asume un decrecimiento del interés del usuario con una curva logarítmica (Järvelin y Kekäläinen, 2002; Baltrunas, Makcinskas y Ricci, 2010) y presta más atención a los posibles elementos relevantes en medio de la lista. *DCG* y *NDCG* de manera general aplican para todos los elementos de la recomendación; mientras que *DCG@n* y *NDCG@n* consideran los primeros n elementos de la lista. *DCG* en las ecuaciones representa la ganancia acumulada descontada (*Discounted Cumulative Gain DCG*), *IDCG* es el *DCG* ideal, $Gain_{u,O_i}$ es la ganancia de relevancia para el elemento O_i dado por el usuario u , y b es el parámetro de libertad definido como la base logarítmica.

$$DCG = \frac{1}{\#U} \sum_{u \in U} \sum_{i=1}^{\#O} \frac{2^{Gain_{u,O_i}} - 1}{\log_b(i+1)} \quad (2.16)$$

$$NDCG = \frac{DCG}{IDCG} \quad (2.17)$$

$$DCG@n = \sum_{i=1}^n \frac{2^{Gain_{u,O_i}} - 1}{\log_b(i+1)} \quad (2.18)$$

$$NDCG@n = \frac{DCG@n}{IDCG@n} \quad (2.19)$$

Otras medidas de calidad

En (Shani y Gunawardana, 2011b) se consideran otras medidas de calidad más allá del accuracy, entre ellas:

- **Diversity** (diversidad): es definida como lo opuesto a similaridad en el caso de lo ítems. Se utiliza principalmente para recomendar al usuario una lista de ítems diversos a los ítems que ha seleccionado, por ejemplo un usuario que adquirió un CD del autor X tal vez no esté interesado en otro CD del mismo autor, por lo que se requiere diversidad en las recomendaciones.

(Smyth y McClave, 2001; Kaminskas y Bridge, 2016) sugieren medir la diversidad de una lista de recomendación R ($|R| > 1$) como la distancia promedio entre pares de elementos en la lista:

$$Diversity(R) = \frac{\sum_{i \in R} \sum_{j \in R \setminus \{i\}} dist(i, j)}{|R|(|R| - 1)} \quad (2.20)$$

La función *dist* puede ser medida de varias formas dependiendo del ámbito, en CF basado en ítems o CF basado en usuarios puede ser medida mediante **el complemento de Jaccard o de la similaridad del Coseno**. Esta distancia también puede ser obtenida desde los vectores de los factores latentes en los modelos de **Matrix Factorization** (Vargas y Castells, 2011; Vargas y Castells, 2014). Otros trabajos que abordan la evaluación de diversidad son (Kunaver y Požrl, 2017; De Pessemier, Dooms y Martens, 2014; De Pessemier, Dooms y Martens, 2012).

- **Novelty** (novedad): en la recomendación expresa recomendaciones que el usuario no conocía. La novedad debería considerarse junto al accuracy, puesto que existen ítems que considerándose no relevantes pueden mejorar la novedad. La novedad es definida típicamente como el complemento de la popularidad de un ítem: $1 - p(i)$, donde $p(i) = \frac{|\{u \in U, r_{u,i} \neq \bullet\}|}{|U|}$. $|U|$ es la cantidad de usuarios que han votado el ítem i .

Una variante es definir la novedad así: $-\log p(i)$, lo que da la autoinformación de un ítem i (**self-information**) (Zhou y col., 2010) y, en comparación con el simple complemento de popularidad, le da más importancia a los ítems muy raros. Dado este contexto, la novedad de una lista de recomendación esta dada por la agregación de las novedades individuales de cada ítem en la lista (Kaminskas y Bridge, 2016; Shani y Gunawardana, 2011a).

$$Novelty(R) = \frac{\sum_{i \in R} -\log_2 p(i)}{|R|} \quad (2.21)$$

- **Serendipity** (serendipia): es una medida que calcula cuan sorprendente es una recomendación. (Ge, Delgado-Battenfeld y Jannach, 2010) asumen que la meta de un recomendador es sugerir ítems que son difíciles de predecir. Ellos combinan la noción de inesperado con la relevancia del artículo.

$$Serendipity(R, u) = \frac{|R_{inesperada} \cap R_{relevante}|}{|R|} \quad (2.22)$$

(De Pessemier, Dooms y Martens, 2014; Kaminskas y Bridge, 2016) presentan investigaciones haciendo énfasis en la evaluación de serendipia.

Existen otras características (Shani y Gunawardana, 2011b; Castro y col., 2015), entre las cuales están:

- **Confidence** (confianza): en la recomendación puede ser definida como la confianza en las predicciones de todo el sistema, es decir existe un nivel de confianza asociado al uso del sistema de recomendación. Una forma de aplicación de confianza en el filtrado colaborativo es utilizar un umbral para la recomendación.
- **Trust** (confianza en el voto): representa la confianza que existe en la predicción para un voto específico, muchas de las veces la confianza en el voto provee una explicación de la recomendación.
- **Utility** (utilidad): permite ajustar la perspectiva de la recomendación, por ejemplo un usuario puede desear recomendaciones en función del precio de los ítems, o una empresa puede desear realizar las recomendaciones en función de los ítems que mejores ingresos representan.
- **Risk** (riesgo): permite asociar la recomendación con un riesgo potencial, es muy utilizado en sistemas de recomendación bursátiles, bancarios, etc.
- **Robustness** (robustez): es la estabilidad de la recomendación ante la falta de información.
- **Privacy** (privacidad): garantiza la privacidad de los datos personales sensibles.

2.3.2 Evaluación de sistemas de recomendación de grupos

Como se menciono anteriormente, la evaluación de los GRS tiene un gran desafío debido a la ausencia de estandarización de las medidas de evaluación (Bobadilla y col., 2013a). La evaluación en GRS tiene un campo muy amplio que queda por explorar y estandarizar. Existen varias características a evaluar en un GRS, como: la calidad de las recomendaciones, la calidad de las predicciones, la satisfacción del usuario, el impacto de las recomendaciones (Salamó, Mccarthy y Smyth, 2012), etc. En esta sección, recopilaremos las medidas que han sido aceptadas en investigaciones recientes. Primeramente, mencionaremos las medidas para evaluar la calidad de recomendaciones, posteriormente medidas para evaluación de las predicciones.

Medidas de evaluación de la calidad de las recomendaciones

En (Ortega y col., 2018b) se definen las medidas de evaluación de calidad de las recomendaciones a grupos de usuarios. Se definen *Precision* y *Recall* para el grupo G como:

$$precision_G^\lambda = \frac{\#TP_G^\lambda}{\#(TP_G^\lambda \cup FP_G^\lambda)} \quad (2.23)$$

$$recall_G^\lambda = \frac{\#TP_G^\lambda}{\#T_G^\lambda} \quad (2.24)$$

Donde TP , FP y T denotan los verdaderos positivos, falsos positivos y conjuntos de recomendaciones esperados, respectivamente:

$$FP_G^\lambda = \{i \in L_G | a_{G,i} < \lambda\} \quad (2.25)$$

$$TP_G^\lambda = \{i \in L_G | a_{G,i} \geq \lambda\} \quad (2.26)$$

$$T_G^\lambda = \{i \in I | a_{G,i} \geq \lambda\} \quad (2.27)$$

Donde $a_{G,i}$ es la proporción de usuarios que pertenecen al grupo G que les gusta el ítem i , L_G es el conjunto de ítems recomendados para el grupo G , y λ es un parámetro que controla la flexibilidad del fallo de recomendaciones a uno o más miembros de usuarios que pertenecen al grupo.

$$a_G^\lambda = \frac{\#\{g \in G | r_{g,i} \geq \theta\}}{\#\{g \in G | r_{g,i} \neq \bullet\}} \quad (2.28)$$

Donde $r_{u,i}$ es el voto en *Test* del usuario u para el ítem i , y θ es un umbral para considerar una rating como: me gusta o no me gusta; por ejemplo, para un rango de ratings 1,..., 5, un valor razonable de θ podría ser 4 (4, 5: me gusta; 1, 2, 3: no me gusta).

Finalmente, $precision@ \lambda$ y $recall@ \lambda$ son el promedio de *Precision* y *Recall* para cada grupo de usuarios.

$$precision@ \lambda = \frac{\sum_G precision_G^\lambda}{\#G} \quad (2.29)$$

$$recall@ \lambda = \frac{\sum_G recall_G^\lambda}{\#G} \quad (2.30)$$

Medidas de evaluación de la calidad de predicciones

- *R-MAE*: para evaluar la calidad de las predicciones, (Ortega y col., 2018b) define *R-MAE* como el error medio absoluto de predicción de los ítems recomendados. Sea L_G el conjunto de ítems recomendados para el grupo G , $\hat{L}_u^G$ el subconjunto de ítems recomendados para el grupo G que han sido votados (en test) por el usuario u :

$$\hat{L}_u^G = \{i \in L_G | r_{u,i} \neq \bullet\} \quad (2.31)$$

$R-MAE_u^G$ es el error de predicción para el usuario u con respecto al ítem recomendado para el grupo G :

$$R-MAE_u^G = \frac{\sum_{i \in \hat{L}_u^G} |r_{u,i} - p_{G,i}|}{\#\hat{L}_u^G} \quad (2.32)$$

$R\text{-}MAE$ es el error promedio de las predicciones realizadas para el grupo G :

$$R\text{-}MAE_G = \frac{\sum_{u \in G} R\text{-}MAE_u^G}{\#G} \quad (2.33)$$

Finalmente, $R\text{-}MAE$ es el promedio $R\text{-}MAE$ para cada grupo de usuarios.

$$R\text{-}MAE = \frac{\sum_G R\text{-}MAE_G}{\#G} \quad (2.34)$$

- **RMSE**: es el error cuadrático medio definido en (Boratto y Carta, 2015a; Boratto y Carta, 2015b). La medida compara el conjunto de *test* con las predicciones: cada voto de un usuario u para un ítem i se compara con la predicción del ítem i para el grupo en el que está el usuario u .

$$RMSE = \sqrt{\frac{\sum_{i=0}^n (r_{u,i} - p_{g,i})^2}{n}} \quad (2.35)$$

Donde $r_{u,i}$ es el voto en *Test* del usuario u al ítem i , $p_{g,i}$ es la predicción del grupo g del usuario u al ítem i y n es el conjunto de votos disponibles en el conjunto de *Test*.

2.4 Tendencias de la investigación de RS

En esta sección se presentan diversas investigaciones recientes que abordan varios de los desafíos listados en la sección 1.1.1. Estas investigaciones han sido orientadas a RS individuales, sin embargo, sirven como base de referencia para los desafíos similares que enfrenta un GRS. Estas investigaciones las hemos clasificado de acuerdo al objetivo relacionado.

- **Control de dispersión y escalabilidad:**

- En (Najafabadi y col., 2017) se direcciona el problema de la **dispersión** mediante **clustering**, reglas de **minería en datos** masivos para obtener información implícita.
- En (Nilashi, Ibrahim y Bagherifard, 2018) se resuelve la dispersión y **escalabilidad** mediante métodos híbridos que combinan **ontologías** y técnicas de **reducción de dimensionalidad** como *Expectation Maximization (EM)* y **SVD**, con el propósito de establecer un trade-off entre el accuracy y el tiempo computacional para generar recomendaciones precisas en tiempo real. Las ontologías y EM proporcionan un **clustering** que permite identificar los ítems y usuarios que ayudan a mejorar la escalabilidad del sistema.
- (Bobadilla y col., 2018) controlan la dispersión mediante la combinación de **Bayesian non-negative Matrix Factorization** y un preprocesamiento basado en clustering (**preclustering**).
- (Ghazarian y Nematbakhsh, 2015) resuelven el problema de la dispersión mediante técnicas de filtrado colaborativo basado en memoria.
- (Bojorque, Hurtado e Inga, 2019; Chalco, Chasi y Ortiz, 2019) comparan diversas **medidas de similitud** en clustering y varias **técnicas de clustering** para mejorar el comportamiento de RS en ambientes con alta dispersión.

- Un método CF reciente diseñado para entornos de **alta dispersión** mediante la combinación de la **información numérica y no numérica basada en la estructura de los votos** es (Zhu y col., 2018). Ellos se enfocan en mejorar el tiempo de predicción sin afectar el accuracy.
- En (Wei y col., 2017) se brinda un RS para **comercio electrónico** aplicando un algoritmo de *clustering self-constructing* para reducir la dimensionalidad de los datos y de tal manera proporcionar un filtrado colaborativo **eficiente**. Su algoritmo reduce mediante un **grafo** la complejidad de las interrelaciones, estableciendo grupos de productos, luego de determinar las preferencias de los usuarios sobre esos grupos mediante *random walks*. Posteriormente, sigue la transformación de las preferencias a grupos de productos a preferencias de productos individuales, que luego son ordenadas y recomendadas.

- **Control de nuevas tendencias:**

- En (Seo y col., 2017) proponen varios RS personalizados aplicados basados en big social data, con el fin de aprovechar el gran crecimiento de las redes sociales. Ellos estudian las relaciones entre usuarios y establecen una medida para calcular la cercanía entre dos usuarios dentro de un círculo social.
- (Ali y col., 2018) presentan un sistema de recomendaciones basado en IoT que se apoya en ontologías difusas para el cuidado de la salud. El sistema permite monitorear de manera eficiente el cuerpo del paciente y recomendar dietas con alimentos y medicamentos específicos.

- **Mejora del accuracy en las recomendaciones:**

- Un sistema que utiliza clustering es (Koohi y Kiani, 2017), ellos se basan en un **clustering subespacial** para controlar estructuras de árbol de los usuarios vecinos. Indican que su método obtiene mejores vecinos debido a la información estructurada.
- En (Koohi y Kiani, 2016) se aplica una técnica de **fuzzy clustering** (Fuzzy C Means o FCM) para usuarios individuales, ellos verifican que los mayores números de cluster no siempre logran mejores resultados. Además, demuestran que la combinación de los centros de gravedad resultantes de la defusificación de FCM y el coeficiente de Pearson correlation dan mejores resultados en accuracy en comparación a otras técnicas de clustering.
- En (Hurtado y col., 2019) se aplica un nuevo enfoque de recomendación basado en métodos soft clustering probabilísticos. Este enfoque mejora el accuracy puesto que ejecuta la recomendación a un usuario activo mediante el análisis de la información con respecto a todos los grupos y no solamente al grupo al que pertenece con mayor probabilidad.

- **Mejora y control de los requerimientos del usuario (a más del accuracy):**

- En (Kunaver y Požrl, 2017) se ofrece un estudio centrado en la **diversidad** como vía para resolver el over-fitting y para mejorar la **experiencia del usuario**. Ellos mencionan que existen algunos aspectos subjetivos de la diversidad, puesto que algunos usuarios no son capaces de identificar las diferencias entre ciertas películas, mientras otros usuarios las consideran completamente diferentes. Debido a esta subjetividad, ha existido mucha

resistencia por parte de la comunidad para aceptar las medidas de validación de diversidad. Ellos sugieren la inclusión de **expertos en psicología** para desarrollar nuevas medidas de diversidad. A más de ello recomiendan **introducir el proceso de diversificación en las etapas de predicción y de recomendación y no como proceso post-recomendación**.

- Un estudio que se enfoca en analizar y ofrecer diversidad, novedad y cobertura es presentado (Kaminskas y Bridge, 2016)
- En (Kapoor y col., 2015) se maneja el problema *user boredom* mediante un modelo oculto de **Semi-Markov** que recomienda ítems que no están en el estado de **aburrimiento del usuario** e ítems que han recuperado el interés del usuario. Ellos mencionan que el estado de aburrimiento llega principalmente en dominios en que se recomiendan flujos de ítems, como música y tiendas de ítems.
- (Kotkov, Wang y Veijalainen, 2016) resume los estudios de **serendipia** para mejorar la **satisfacción del usuario**, de tal manera que el proceso de recomendación genere ítems relevantes, novedosos y que sean significativamente diferentes a los que el usuario ha votado.
- En (Xing y Zhou, 2006) se direcciona el problema *drift* mediante la combinación de datos basados en factores temporales y en similitudes de ítems que permiten manejar un espacio de intereses del usuario, con el fin de seguir e identificar el cambio de interés de un usuario.

- **Control del problema del cold-start:**

- (Wei y col., 2017) direccionan el problema del cold start en ítems, mediante dos modelos que combinan **deep learning** y **filtrado colaborativo time-aware**. Ellos consideran escenarios en que existe un **cold start completo**, es decir cuando no hay votos para un ítem, y un **cold start incompleto**, que ocurre cuando un ítem o usuario tiene muy pocos votos disponibles.
- En (Bobadilla y col., 2012b) mitigan el problema del *cold start* en usuarios mediante una nueva **medida de similitud** determinada a través de **redes neuronales**.

2.5 Investigaciones de vanguardia en GRS

El campo de recomendación a grupos basado en CF presenta una amplia variedad en la forma en que se ha enfocado. Como vimos en la sección 2.1, un GRS puede clasificarse de varias maneras, en esta sección determinaremos la clasificación que nos corresponde con el fin de situar los enfoques de GRS y agruparlos según la solución que implementamos. De esta manera, revisaremos la bibliografía más relevante en el campo de acuerdo a la clasificación que consiste en:

1. Enfoques CF basados en memoria: basados en KNN

- (a) GRS con agregación de predicciones (*merged predictions*)
- (b) GRS con mezcla de recomendaciones (*merged recommendations*)
- (c) GRS relacionado a vecinos (*related neighbors*)
- (d) GRS con agregación de preferencias individuales: usuarios virtuales (*related users*)

FIGURA 2.4: Enfoque de Fusión de Recomendaciones.

2. Enfoques CF basados en modelos

- GRS basados en Matrix Factorization
- GRS basados en grafos
- GRS con métodos Fuzzy
- GRS basados en clustering

3. Enfoques híbridos: otros modelos y métodos GRS

2.5.1 Enfoques CF basados en memoria: basados en KNN

Los enfoques basados en KNN usan directamente la matriz de ratings para hacer recomendaciones a los grupos. La Fig. 1.5 muestra: a) su taxonomía, b) las etapas involucradas en el proceso de recomendación a grupos, y c) las alternativas existentes. En la Fig. 2.4 se ilustra a detalle el enfoque KNN *Merged recommendations* (caso a), en la Fig. 2.5 el enfoque *Merged predictions* (caso b), en la Fig. 2.6 el enfoque *Related neighbors* (caso c), y en la Fig. 2.7 el enfoque *Related users* (caso d). En cada una de estas figuras se resalta en color celeste el paso donde se producen las agregaciones.

Cada una de las áreas grises en la Fig. 1.5 representa una etapa en el proceso de CF en el RS usando KNN. El *paso 1 (Similarity Metric)* utiliza medidas de similitud para obtener la similitud entre cada usuario que pertenece al grupo con respecto al conjunto completo de usuarios (casos a hasta c), o para obtener la similitud entre todo el grupo de usuarios (usuario virtual) con respecto al conjunto completo de usuarios (caso d). En el *paso 2 (Neighborhoods)*, en los casos a) y b) se obtienen los vecinos de cada usuario, en el caso c) se combinan los vecinos de cada usuario del grupo para obtener un conjunto unificado de vecinos y en el caso d) se obtienen directamente los vecinos del grupo. El *paso 3 (Predictions)* genera la predicción del grupo de usuarios en función de las predicciones individuales de cada usuario (caso b) utilizando los métodos de agregación de predicciones, en el caso a) se generan las

FIGURA 2.5: Enfoque de Agregación de Predicciones.

FIGURA 2.6: Enfoque de Intersección de Vecinos.

FIGURA 2.7: Enfoque de Agregación de Preferencias de Usuarios.

predicciones individuales, en los casos c) y d) se generan las predicciones al grupo. Finalmente, en el **paso 4 (Recommendations)** se obtiene la recomendación del grupo de usuarios en base a las recomendaciones hechas a cada uno de sus usuarios (caso a) o las recomendaciones para el grupo de usuarios (casos b, c y d).

Basado en (Ortega y col., 2013; Boratto, Carta y Fenu, 2017) el conjunto de pasos que se muestran en la Fig. 1.5 clasifican los métodos de recomendación más comúnmente usados para grupos de usuarios. Desde (Feng y Cao, 2017), los pasos 1 y 2 corresponden a la **estrategia de modelo agregado** (Berkovsky, Freyne y Coombe, 2009; Freyne y Smyth, 2006), mientras que los pasos 3 y 4 se corresponden con la **estrategia de predicciones agregadas** (Masthoff, 2004).

Métodos de agregación de predicciones

(Masthoff, 2004; Cantador y Castells, 2012; Masthoff, 2015; Beliaikov, Calvo y James, 2015; Yager, 1988) presentan y explican diversos métodos de agregación. (Senot y col., 2010) establece su clasificación en tres categorías:

1. **Estrategias basadas en la mayoría:** fortalecen el más popular.
 - (a) **Borda Count:** crea un *ranking* de ítems en cada usuario. En un usuario el último ítem obtiene 0 puntos, el penúltimo 1 punto, etc. Luego se cuentan los puntos de un ítem en las listas de preferencias de cada uno de los miembros.
 - (b) **Copeland Rule:** cuenta la frecuencia con la que un elemento supera a otros elementos (utilizando votos mayoritarios) menos la frecuencia con la que pierde.
 - (c) **Plurality Voting:** escoge el elemento con más votos
2. **Estrategias basadas en consenso o democráticas:** básicamente promedian todas las opciones disponibles.

- (a) *Average*: realiza el promedio de los votos individuales.
 - (b) *Weighted average*: realiza el promedio de los votos individuales previamente ponderados.
 - (c) *Additive utilitarian*: la sumatoria de los votos individuales.
 - (d) *Average without misery*: realiza el promedio de los votos individuales y después excluye los ítems individuales que no superan un umbral.
 - (e) *Fairness*: los ítems son ordenados como si los individuos los escogieran por turno.
 - (f) *Multiplicative utilitarian*: la multiplicación de los votos individuales.
 - (g) *Approval voting*: cuenta los individuos con calificaciones para el ítem por encima de un umbral de aprobación (por ejemplo, tradicionalmente 4 en MovieLens).
3. *Estrategias Borderline o basadas en roles*: toman en cuenta un subconjunto de los roles de usuario o cualquier otro criterio relevante.
- (a) *Dictatorship o Most respected person*: toma el voto del individuo más respetado.
 - (b) *Least misery*: toma el mínimo de los votos individuales
 - (c) *Most pleasure*: toma el máximo de los ratings individuales

En (Masthoff, 2015) se recopilan las mejores estrategias en diferentes dominios. Ellos resaltan:

- En el dominio de **películas** la mejor estrategia es *Average* (Baltrunas, Makcinskas y Ricci, 2010), que proporciona un mejor equilibrio que *Least Misery* y *Plurality Voting*.
- En el dominio de **TV** las mejores estrategias son *Multiplicative* (Masthoff, 2004) y *Average* (Senot y col., 2010).
- En **recetas**: *Weighted average* (Berkovsky y Freyne, 2010).
- En **destino de vacaciones**: *Multiplicative*, *Borda Count* (Salamó, McCarthy y Smyth, 2012).

A continuación se muestra el trabajo relacionado más relevante relacionado con KNN:

GRS con agregación de predicciones (*merged predictions*)

Varios métodos para sugerir música y películas son provistos por (Christensen y Schiaffino, 2011). Ellos generan recomendaciones grupales utilizando diferentes métodos: fusión de recomendaciones individuales, agregación de predicciones individuales y construcción de modelos de preferencia grupal. Para tratar los votos individuales el método se utilizan técnicas de agregación de predicciones como: *Multiplicative*, *Average*, *Least misery* y *Fairness*.

Para investigar el uso de los datos de grupo agregados en las recomendaciones de CF, (Berkovsky y Freyne, 2010) analiza el impacto de las estrategias de conmutación, la heurística de agregación de datos y las características del grupo en el desempeño

de las recomendaciones.

El ambiente de apoyo a la decisión del grupo Choicla (Stettinger y Felfernig, 2014) avanza en el estado del arte apoyando escenarios de decisión de una manera independiente del dominio. Se utilizan las agregaciones heurísticas: *Plurality Vote*, *Average*, *Least Misery* y *Most Pleasure*, debido a que las preferencias de cada usuario se pueden agregar de diferentes maneras, y no existe una heurística que se ajuste a cada escenario de decisión.

Para combinar predicciones de interacción social, (Chen y Pu, 2013) mejora el conocimiento mutuo entre los miembros del grupo.

El método de minería basado en la reducción de atributos (Jung, 2012) se ha propuesto para seleccionar eficientemente los grupos de usuarios de cola larga (usuarios cuya actividad se concentra en un conjunto pequeño de ítems). Ellos presentan varios métodos para identificar los atributos dominantes de cada usuario.

En (O'Hara y col., 2004; Sprague, Wu y Tory, 2008) se propone un sistema interactivo para elegir **democráticamente** la reproducción de una canción dentro de un **ambiente social** (bar, cafetería, etc.). Este sistema no requiere de perfiles de usuario preestablecidos, ya que utiliza una **agregación aditiva**, la cual suma los votos de cada usuario sobre cada canción y genera una lista. Esta lista define el orden en que se reproducirán las canciones, comenzando por la canción que más votos ha recibido.

En (Amer-Yahia y col., 2009) se propone un RS a grupos basado en **semántica** y orientado a películas. El método que ellos proponen se conforma por la relevancia grupal y el **desacuerdo grupal**. La relevancia grupal utiliza las agregaciones *Average* y *Least Misery* para medir el nivel en que un ítem es de interés a los usuarios del grupo. El desacuerdo grupal se utiliza para definir el nivel en el que los miembros del grupo no están en desacuerdo con otros.

En (Agarwal, Chakraborty y Chowdary, 2017) realizan la recomendación a un grupo de usuarios según las preferencias ordenadas proporcionadas por cada usuario. Para ello, ellos presentan dos agregaciones originales que mejoran la satisfacción general del grupo. Agregaciones: *Hungarian Aggregated Method* y *Least Misery with Priority*.

(Seo y col., 2018) mencionan que muchos métodos de agregación solo consideran altos promedios, conteos y clasificaciones para proporcionar recomendaciones, sin embargo indican que es importante considerar la situación en que existen grupos homogéneos y heterogéneos, puesto que los estudios de recomendación de grupos heterogéneos se centran en la satisfacción de los miembros del grupo, mientras que los estudios de recomendación de grupos homogéneos se centran en los requisitos del proveedor de servicios. Ellos se centran en los grupos heterogéneos, por lo tanto, introducen la importancia de garantizar que la mayoría de los miembros de un grupo estén satisfechos con los resultados recomendados, para lo cual proporcionan un método de agregación que denominan método de nivelación ascendente en que consideran la desviación de un ítem para un grupo como un elemento muy importante.

La mayoría de las recomendaciones en los trabajos de investigación de GRS están diseñadas agregando predicciones individuales.

GRS con mezcla de recomendaciones (*merged recommendations*)

PolyLens (O'Connor y col., 2001) utiliza un algoritmo que combina las listas de recomendaciones de los usuarios y ordena la lista fusionada de acuerdo con el principio de *Least Misery*. Ellos indican que este algoritmo de fusión no funciona bien para grupos grandes, y que la utilidad de los GRS presenta mejores resultados cuando se generaliza el dominio de análisis (por ejemplo: clubes de libros, restaurantes, viajes, etc).

La efectividad de las recomendaciones grupales se obtiene en (Baltrunas, Makcinskas y Ricci, 2010); ellos agregan listas individuales de recomendaciones producidas por un sistema de filtrado colaborativo y comparan la efectividad de las listas de recomendaciones individuales y grupales mediante NDCG. Ellos prueban que no necesariamente la efectividad de una recomendación a un grupo disminuye cuando el tamaño del grupo aumenta. Cuando las recomendaciones individuales no han sido efectivas, el usuario puede obtener mejores sugerencias considerando las recomendaciones del grupo.

(Crossen, Budzik y Hammond, 2002) presenta un entorno que construye una **lista de música** de acuerdo con los gustos grupales. Su sistema aprende las preferencias de los usuarios y obtiene el **conocimiento de la interrelación de los géneros de música y de los artistas**, de tal manera que genera listas de **recomendación ajustadas a la satisfacción de un grupo** de personas y esas listas son completadas de acuerdo con la lógica de la secuencia normal aprendida.

(Garcia, Sebastia y Onaindia, 2011; Garcia y col., 2009; Garcia y col., 2012; Garcia y col., 2010) proponen un RS de actividades turísticas a grupos de usuarios utilizando taxonomías. Las recomendaciones son generadas por **GRSK (Generalist Recommender System Kernel)**. Este es un GRS generalista que se basa en la descripción semántica del dominio, lo que le permite trabajar con cualquier dominio a través de una representación ontológica. Este sistema registra el perfil de cada usuario y modela las recomendaciones individuales considerando la demografía, contenidos y preferencias generales. Finalmente, obtiene las recomendaciones de grupo. Su método pesa las preferencias de todos los individuos en la misma medida de manera que ningún miembro del grupo estará particularmente satisfecho o insatisfecho con las recomendaciones finales. Ellos establecen una comparación entre diferentes GRS en varios dominios, luego centran su investigación en dos dominios, películas y turismo.

En (Kim y col., 2010) se propone un sistema de recomendación grupal orientado a una **comunidad de lectura en línea**. Ellos destacan que las **comunidades virtuales** están emergiendo en Internet y que su procedimiento propuesto de recomendación de grupo puede facilitar y mejorar sus actividades grupales. Ellos mencionan que tradicionalmente las agregaciones de preferencias de usuarios y la fusión de las recomendaciones individuales en una sola lista produce la satisfacción de la mayoría de los miembros del grupo, pero conlleva a la insatisfacción de una pequeña porción. En ese sentido, ellos presentan un **algoritmo que se preocupa en el grupo y en la satisfacción individual**. El sistema propuesto genera una lista de libros para

cada grupo de usuarios, a esta lista se le aplica un **filtrado grupal** considerando las preferencias de cada usuario en cada grupo para mejorar las recomendaciones individuales. Las **recomendaciones grupales** se generan a partir de los libros que no han sido eliminados en el filtrado grupal.

El método propuesto en (McCarthy, McGinty y Smyth, 2007; McCarthy y col., 2006a; McCarthy y col., 2006c; McCarthy y col., 2006e; McCarthy y col., 2006d) es un RS de grupos orientado a viajes con un destino definido, ellos lo definen como *CATS (Collaborative Advisory Travel System)*. Este sistema modela las preferencias individuales de cada usuario, promediando sus votos. Se realizan inicialmente las predicciones individuales y luego se realizan las recomendaciones grupales. Ellos proveen una interfaz de asistencia a grupos de amigos para determinar un plan de vacaciones. Además, explican las interacciones entre usuarios en un espacio compartido y ofrecen un proceso proactivo de recomendaciones que incluye nuevos conjuntos de atención del usuario que pueden no ser recomendados según la crítica actual de los usuarios.

El método propuesto en (Jameson, Baldes y Kleinbauer, 2004; Jameson, 2004a; Jameson, Baldes y Kleinbauer, 2003) es un RS de grupos orientado a **viajes**. Este sistema promete resolver la comunicación asíncrona entre los usuarios. Permite que cada usuario sugiera ítems para ser votados por los demás miembros del grupo (**grupo activo**). Inicialmente se realiza una predicción individual utilizando la agregación *Average*. La recomendación grupal contiene el resultado de la agregación de promedio aplicada en cada ítem.

En (Lorenzi y col., 2008) se propone un RS de grupos multi-agente orientado a **viajes** basado en *DCOP (distributed constraint optimization problem)*. Este sistema permite que un usuario sea representado por un **agente (UA)** que conoce sus preferencias, con el objetivo de que este último, negocie con un **agente (RA)** las recomendaciones relacionadas a viajes. El objetivo de DCOP es encontrar la mejor distribución que permita generar las mejores recomendaciones.

Un sistema que recomienda a grupos de usuarios, mediante la agregación de modelos de preferencia de usuarios y mediante el modelamiento del estado afectivo de los usuarios es (Masthoff, 2015). Ellos demuestran que las recomendaciones grupales pueden ayudar a las recomendaciones individuales aliviando el problema del *cold-start*. En (Salamó, McCarthy y Smyth, 2012) presentan nueve estrategias de agregación de modelos de usuarios para establecer una negociación en las recomendaciones.

En (Ardissono y col., 2005; Ardissono, 2003) se propone un RS de grupos orientado a **viajes** dentro de un área geográfica determinada, ellos lo definen como *INTRIGUE (INTERactive TouRist Information GUIDe)*. Este sistema recomienda lugares turísticos definidos dentro del área que se encuentre el usuario, las recomendaciones se generan para **subgrupos heterogéneos**, luego se fusionan creando una **recomendación grupal** (merged recommendations), la cual da preferencia a grupos heterogéneos más influyentes, como los niños y los discapacitados (Ardissono y col., 2002).

GRS relacionado a vecinos (*related neighbors*)

Este es el enfoque menos utilizado en la literatura científica. En (Bobadilla y col., 2012c) se presenta un método de CF que permite recomendaciones a grupos de usuarios y permite que las recomendaciones se limiten a ítems similares para un conjunto de ítems de referencia. El conjunto de vecinos del grupo de usuarios es obtenido por la unificación del conjunto de vecinos de los usuarios individuales. Este trabajo propone la intersección de un gran número (k) de vecinos de cada usuario del grupo.

GRS con agregación de preferencias individuales (*related users*)

Se propone una **médida de similaridad** de recomendación grupal en (Ortega y col., 2013). Ellos muestran que el rendimiento del sistema mejora notablemente cuando la agregación se realiza en una etapa temprana del proceso de filtrado colaborativo.

(McCarthy y col., 2006b) proporcionan un GRS de colaboración conversacional RS diseñado para ayudar a un grupo de hasta cuatro usuarios. Ellos toman en cuenta ambas preferencias: las preferencias del individuo y del grupo para **fusionar usuarios de un grupo**. Proponen **GUM (Group User Model)** con el objetivo de generar recomendaciones proactivas, es decir, llamar la atención de un usuario a nuevos conjuntos, en caso de que no puedan realizar recomendaciones con la sesión actual de usuarios.

Una estrategia común es fusionar todos los perfiles de usuario para construir un perfil de usuario común (**usuario virtual**) que represente las preferencias del grupo, luego utilizar un enfoque de recomendación para generar una lista de recomendaciones de programas comunes para el grupo, de acuerdo con el perfil del usuario virtual (Yu y col., 2006).

Una aplicación de recomendaciones útiles para grupos de usuarios proporciona **contenido multimedia** personalizado para usuarios de grupos al atender las preferencias de la mayoría (Zhiwen, Xingshe y Daqing, 2005). Las principales contribuciones de este documento son: la identificación del usuario, agregación de perfiles, el algoritmo de **fusión de perfiles de usuarios** y las estrategias de recomendación. El proceso de fusión consiste en seleccionar los ítems que se deben incluir en un perfil y la asignación de pesos a cada ítem.

En (De Carolis, 2011) es presentado el sistema **GAIN (Group Adaptive Information and News)** que mediante una agregación de preferencias genera recomendaciones de noticias a grupos de usuarios a través de un modelado grupal en publicidad generalizada transmitida a través de pantallas digitales.

El sistema **POCKET RESTAURANTFINDER** (McCarthy, 2002) sugiere alternativas de restaurantes a un grupo de gente tomando en cuenta la preferencia de sus miembros (agregación de preferencias). Ellos apoyan un escenario en que un grupo de personas no se conoce bien, o no conoce los restaurantes en el área, por ejemplo, cuando se tiene una conferencia o workshop.

Un modelo híbrido que combina un modelo de preferencias de los usuarios y las recomendaciones individuales es presentado en (Bekkerman, Kraus y Ricci, 2006). Ellos previamente establecen un proceso automático de **negociación de agentes** que

actúan como miembros del grupo. Estos agentes participan en una **negociación cooperativa** analizando la utilidad individual para llegar a un acuerdo aceptable para todo el grupo.

REMPAD (Bermingham y col., 2013) ayuda a **personas con Alzheimer y otras demencias** proporcionando **contenido multimedia** adaptado a un contexto grupal determinado. Ellos utilizan **estrategias de agregación temprana y agregación tardía** de las preferencias de los miembros del grupo utilizando el **razonamiento basado en casos** combinado con un **método basado en contenidos**.

Un sistema de recomendación *e-learning* (*eL_RSs*) para grupos de aprendices se presenta en (Dwivedi y Bharadwaj, 2015). Ellos crean un pseudo perfil de un aprendiz unificado para reflejar las preferencias de todos los miembros del grupo.

En (De Pessemier, Doods y Martens, 2014) presentan una comparación entre estrategias para combinar las preferencias de los miembros de un grupo y las estrategias para combinar las recomendaciones de los miembros. Ellos presentan una evaluación no solo en términos de accuracy, sino también en términos de **diversidad, cobertura y serendipia**. Ellos deducen que el accuracy mejora a medida que aumenta la similaridad entre los miembros del grupo. Presentan un sumario de la comparación entre estrategias y demuestran que la estrategia a aplicar depende del tamaño del grupo y de su composición. Ellos mencionan que en la mayoría de los casos la combinación de estrategias mejora significativamente el accuracy con el costo de empeorar los resultados de diversity, coverage y serendipity.

En (De Pessemier, Doods y Martens, 2012) presentan un sistema de recomendación grupal de **contenido audiovisual**. Su principal contribución es el **estado del arte de la diversidad**. Ellos explican la definición y evaluación de la diversidad, el impacto de la diversificación en la calidad de los resultados de recomendación y el desarrollo de algoritmos de diversificación en sí mismos.

2.5.2 Enfoques CF basados en modelos

Los enfoques basados en modelos crean un modelo a partir de la matriz de ratings. Luego, utilizando el modelo obtienen la recomendación a los grupos. Los principales tipos de modelos que presenta el trabajo relacionado son: Matrix Factorization, modelos basados en grafos, modelos difusos (*Fuzzy*) y modelos basados en clustering.

GRS basados en Matrix Factorization

Algunos métodos de recomendación grupal basados en **SVD** se proponen en (Hu, Meng y Wang, 2011). Sus métodos se dividen en dos categorías: perfiles de agregación basados en SVD (*related users*) y métodos de agregación de predicciones (*merged predictions*). Para la agregación de ratings de los miembros del grupo se utilizan las estrategias: *Least Misery*, *Average Weighted*.

El propósito del documento (Liu y col., 2018) es facilitar actividades académicas grupales en sistemas bibliotecarios basados en big data recomendando artículos

para grupos académicos. La principal contribución es su implementación paralela escalable. Su modelo **CoMF (Collaborative Matrix Factorization)** realiza recomendaciones grupales factorizando simultáneamente la matriz de interacción entre investigador-artículo y la matriz académica de interacción entre grupo-artículo.

Se proponen diferentes enfoques de recomendación basada en factorización matricial a grupos en (Ortega y col., 2016); explican tres métodos originales para asignar el grupo de usuarios al espacio de factores latentes, y comparan los métodos propuestos en tres escenarios diferentes: cuando el tamaño del grupo es pequeño, mediano y grande. Los métodos utilizados son: AF (*After Factorization*), BF (*Before Factorization*) y *Weighted BF*, estos dos últimos métodos, utilizan un **usuario virtual** para representar las preferencias de ítems de los usuarios del grupo.

La información social se usa en (Christensen y Schiaffino, 2013); este trabajo combina un modelo de factorización matricial para estimar votos desconocidas con un **análisis de redes sociales** para evidenciar una posible influencia social. Luego de que el proceso de estimación termina, los valores resultantes de MF varían de acuerdo con la influencia social ejercida para cada miembro del grupo.

En (Wang, Zhang y Lu, 2016) establecen pesos a los usuarios de acuerdo con su grado de importancia en el grupo. Para ello, ellos manejan un **modelo de contribución de cada miembro (MCS)** utilizando la técnica *separable non-negative matrix factorization* en una matriz de votos del grupo para analizar el grado de importancia de cada miembro. Luego, utilizan un **modelo de calificación de promedio local (MLA)** basado en la distancia Manhattan para refinar las predicciones y resolver el problema de cola gruesa (*fat tail*). Ellos integran MCS y MLA y obtienen el **enfoque MC-GR**, el cual usan para generar el GRS denominado **GroTo** que recomienda actividades a grupos de turistas.

GRS basados en grafos

Un enfoque original de recomendación grupal aborda el problema de generar y luego recomendar una secuencia de **obras de arte** para un grupo de visitantes dentro de un **museo** (Rossi y col., 2017). Ellos definen las obras de arte del museo como un grafo. El RS propuesto es **RCLPP (Resource Constrained Longest Path Problem)**, el cual sugiere una ruta que maximiza la satisfacción de los visitantes. Realiza recomendaciones individuales y luego agrega las recomendaciones para generar una recomendación grupal (*merged recommendations*).

En (Bao, Fang y Zhang, 2014) se propone un RS basado en MF denominado **TopicMF**. Ellos representan las relaciones entre usuarios, grupos e ítems como un **grafo tripartito**. Con base en el grafo tripartito, es posible predecir los grados de relevancia entre los grupos e ítems no votados mediante la detección exhaustiva de sus relaciones. Se utiliza **MF** para calificar las predicciones generadas y **NMF** para modelar los ítems.

En (Ji y col., 2018) se propone un modelo basado en tópicos con el fin de inferir las **actividades del grupo**. Su modelo incluye una nueva agregación que no solamente toma en cuenta los intereses individuales de los miembros del grupo, sino también los intereses de subgrupos. De esta manera, ellos hacen recomendaciones utilizando un **esquema basado en pesos**. Su modelo utiliza una **topología mediante un grafo**

que permite optimizar los pesos del modelo.

El método *HeteRS* (*Heterogeneous graph-based Recommendation System model*) propuesto en (Pham y col., 2015), modela información con un **grafo heterogéneo** y considera el problema de recomendación como un *problema de proximidad de nodo query-dependent*. Ellos proponen un modelo general basado en grafos para recomendar eventos en las **redes sociales**. El modelo identifica **patrones temporales** del comportamiento del usuario y los agrega al grafo. *Nodo query-dependent* realiza las siguientes tareas: reagrupación grupo-usuario, recomendación etiqueta-grupo y recomendación evento-usuario.

Folkommender (Kim, Bloess y El Saddik, 2013) es un sistema de recomendación de contenido multimedia para usuarios individuales y para grupos de usuarios utilizando un algoritmo de ranking basado en grafos. Ellos modelan un grafo que contiene enlaces positivos y negativos entre usuarios e ítems. Luego, en el grafo examinan dos *random walks* para cuantificar por separado el grado en que un grupo de usuarios le gustaría o no los ítems. Luego emplean un enfoque de *ranking diferencial* para adaptar las recomendaciones al grupo. El método está enfocado especialmente para grupos pequeños, independientemente de si los usuarios son o no similares entre sí.

GRS con métodos Fuzzy

Un nuevo método de decisiones grupales usando recomendaciones grupales basadas en intervalos de relaciones de **preferencias difusas** y matrices consistentes es presentada en (Chen, Cheng y Lin, 2015). Este método garantiza que cada grupo generado mantendrá preferencias colectivas, lo cual mejora la calidad de las recomendaciones grupales.

Los mismos autores (Cheng, Chen y Huang, 2016) proponen un nuevo método autocrático de toma de decisiones utilizando recomendaciones grupales basadas en el intervalo de clasificación de los **conjuntos difusos** de tipo 2. Ellos utilizan matrices de evaluación con **vectores de ponderación**, para obtener el valor numérico de preferencia sobre cada ítem.

Una toma de decisión grupal con información lingüística difusa multi-granular difusa se presenta en (Yu, Zhong y Zhang, 2018); los autores realizan dos contribuciones principales basadas en modelos: primeramente, un algoritmo que deriva en una matriz de frecuencia de rango para alternativas de un vector de conjunto de términos de lingüística, y en segundo lugar, un enfoque para calcular la matriz de frecuencias ponderada colectiva para todas las alternativas.

En (Myszkorowski y Zakrzewska, 2013) se considera el uso de lógica difusa para modelar grupos de estudiantes. Como representación de cada grupo, suponen números difusos relacionados con los atributos del alumno. Las recomendaciones para nuevos alumnos se determinan considerando la similaridad entre sus características dominantes y los atributos mejor clasificados de los grupos.

GRS basados en clustering

Los sistemas de recomendación grupal se pueden diseñar para detectar automáticamente grupos de usuarios al agruparlos (Boratto y Carta, 2015a); el número de clusters respeta una restricción en el número máximo de listas de recomendaciones que se pueden producir. Ellos demuestran que el modelo que realiza las predicciones individuales (para resolver dispersión), luego el clustering de usuarios y finalmente las predicciones grupales, presenta los mejores resultados.

Un modelo extenso para recomendaciones grupales (Ntoutsis y col., 2012a) explota las recomendaciones de ítems a usuarios similares, que a los miembros del grupo les gustaba en el pasado. Ellos hacen una pre-partición de usuarios en clusters y utilizan los miembros del cluster para recomendaciones. Las recomendaciones de un solo usuario se agregan eficientemente para generar las recomendaciones grupales.

En (Ntoutsis y col., 2012b) se presenta **gRecs**, un GRS que utiliza estrategias de colaboración. Los usuarios se dividen en clusters, por lo que, las recomendaciones para los usuarios son producidas con respecto a las preferencias de los miembros de su grupo sin buscar exhaustivamente usuarios similares en toda la base de usuarios. Para realizar las agregaciones de rating de cada usuario se utiliza la estrategia *Least Misery*.

(Boratto y Carta, 2015a; Boratto y Carta, 2015b; Ortiz, Chasi y Chalco, 2019) también conducen las recomendaciones a grupos de usuarios mediante métodos basados en clustering.

2.5.3 Enfoques híbridos: otros modelos y métodos GRS

En este apartado otros modelos y resultados son abstraídos.

Usando **conceptos ontológicos**, (Ben Ahmed y col., 2015) proporcionan una recomendación de grupo semidimensional **semántica**. Este sistema describe la semántica de los perfiles de grupo y analiza la eficiencia de las recomendaciones.

Las técnicas de **MetaAprendizaje** y estrategias de agregación (Zapata y col., 2015) se usan para seleccionar estrategias de recomendación grupales. El MetaAprendizaje permite identificar el mejor método de agregación de ratings, en función del rating de grupos similares anteriores. Además, se implementa el modelo propuesto en el RS híbrido DELPHOS, que sirve para la búsqueda de objetos en repositorios.

Usando **métodos estocásticos**, (Kim y Saddik, 2015) hacen recomendaciones basadas en el análisis de link-structure de manera probabilística. Link-structure admite calcular los votos para cada grupo, mediante la agregación de preferencias y mediante la agregación de predicciones. Ellos se orientan a sistemas de redes sociales.

En (Lai, 2015) se utiliza la **minería de flujo de conocimiento** (*Knowledge flow mining*), como modelo para hacer recomendaciones mediante tareas que incluyen filtrado colaborativo basado en grupos (GCF) y filtrado basado en contenido de grupos (GCBF). Se integra el **método de minería KF** (*Knowledge Flow*), que proporciona los ítems más relevantes.

Se ha utilizado un RS con **método híbrido**, que combina el filtrado colaborativo basado en el contenido y el conocimiento para grupos de usuarios (Pessemier, Dhondt y Martens, 2017). Las recomendaciones individuales se agregan y generan las recomendaciones de grupo.

En (Recio-Garcia y col., 2009) se presenta un método de recomendaciones grupales a usuarios individuales orientado a películas. Ellos presentan un método que utiliza filtrado colaborativo y considera la **composición de la personalidad del grupo**, mediante la *métrica CWM (Conflict Mode Weight)*. CWM permite determinar los ítems-Top a recomendar a cada grupo, mediante la información personal de cada usuario del grupo.

Los **modelos basados en redes sociales** desempeñan un papel importante en la recomendación a grupos de usuarios cuando se incluye información social en conjuntos de datos. (Sun y col., 2017) proponen un marco de recomendación grupal con conciencia social que utiliza en conjunto las relaciones sociales y los comportamientos sociales para inferir las preferencias de un grupo, y también para modelar la **personalidad** de los miembros del grupo como: tolerancia (voluntad de recibir contenido no preferido) y altruismo (disposición para recibir contenido preferido por amigos).

(Quijano-Sánchez, Díaz-Agudo y Recio-García, 2014; Quijano-Sanchez y col., 2013) proporcionan una aplicación para recomendación a grupos utilizando **información social**, incorporan a su proceso varios **factores humanos** como las relaciones entre ellos. Ellos añaden a su investigación un enfoque (Quijano-Sanchez y col., 2017) aplicado a grupos de usuarios que permite la explicación individual social personalizada para ayudar a los usuarios a comprender los resultados del sistema, a más de provocar en ellos confianza y satisfacción para seguir las recomendaciones. Ellos generan a más de una **explicación textual**, una **explicación gráfica** con el ánimo de explicar porque un ítem recomendado es la **mejor opción para el grupo**. Ellos mencionan que otros métodos solamente explican la técnica de agregación seleccionada (Jameson, 2004b). Ciertos métodos generan explicaciones individuales (Groh, Birnkammerer y Köllhofer, 2012; Knijnenburg y col., 2012; Sharma y Cosley, 2013), pero no están enfocados a explicaciones sobre las preferencias del grupo. El problema del enfoque es el común de los enfoques sociales, puesto que necesita un proceso costoso para incluir aspectos sociales relacionados al comportamiento humano en los grupos. Se requiere más esfuerzo y tiempo para recolección de la información y además de la paciencia de los usuarios. En resumen, **HAPPYMOVIE** es el nombre del GRS social que proporcionan los autores, este sistema permite la recomendación de películas, mediante la **composición de la personalidad** y el establecimiento de un **proceso de confianza** entre los miembros del grupo valiéndose de redes sociales.

El RS propuesto en (Chen, Cheng y Chuang, 2008) es orientado a grupos y probado con datasets de películas. Ellos utilizan un **algoritmo genético (AG)**, el cual analiza los votos de los usuarios, realiza las predicciones grupales y genera una lista top-items la cual se recomienda al grupo. Ellos resaltan que no siempre existen votos disponibles de los miembros similares del grupo, por lo tanto, el GA permite aprender las preferencias de sus subgrupos.

En (Campos y col., 2009; Rueda-Morales y col., 2007) se propone un RS basado en grupos que utiliza **redes bayesianas**. En las pruebas de este sistema se utilizan datos de películas. Este sistema modela los votos de los usuarios para crear relaciones

entre los usuarios, las relaciones se representan por nodos, cada nodo contiene la probabilidad de que un ítem le guste o no a un usuario.

En (Sharon, Lieberman y Selker, 2003) se presenta *CAPS (Context Aware Proxy based System)*, este sistema recomienda páginas web analizando la **experiencia de navegación web** de usuarios colegas. Los usuarios colegas se determinan mediante la similitud entre los hábitos de navegación web del usuario objetivo y los usuarios colegas.

Existen varias investigaciones que establecen enfoques para **detectar y controlar el ruido natural**. En (Castro, Yera y Martínez, 2017) mediante un estudio empírico se aborda el problema del ruido en los GRS. Ellos mencionan que el ruido insertado afecta el proceso de recomendación y su accuracy. El modelo principal que proporcionan permite administrar el ruido a nivel global de todo el dataset y luego a nivel local, es decir dentro de cada grupo, con ello disminuyen el efecto negativo del ruido. En (Yera, Castro y Martínez, 2016; Castro, Yera y Martínez, 2018) el control del ruido es mejorado con **herramientas fuzzy**, de tal manera que, en lugar de tener un control rígido, ellos proporcionan un proceso de clasificación y corrección más flexible y adaptable para mejorar el accuracy.

En (Castro y col., 2015) presentan una novedosa **metodología de consenso** entre las recomendaciones individuales de los miembros del grupo, con el objetivo de garantizar que la lista de productos recomendados al grupo tenga una alta calidad de aceptación por cada uno de sus miembros. Para hacer esto, ellos llevan a cabo un proceso de consenso para acercar las recomendaciones individuales antes de entregar las recomendaciones grupales. (Salamó, McCarthy y Smyth, 2012) se enfoca en como los modelos de usuarios individuales pueden ser agregados para alcanzar un consenso en la recomendación.

En (Masthoff y Gatt, 2006; Piliponyte, Ricci y Koschwitz, 2013) se presenta un **sistema de recomendación de secuencias de ítems a grupos** de usuarios. Ellos construyen el perfil del grupo basándose en los perfiles de los usuarios, lo interesante es que construyen los perfiles de los usuarios mediante **cuestionarios** que son emitidos de tal forma que se evite la vergüenza del usuario. Esto lo logran **prediciendo lo avergonzado que estaría un usuario con la divulgación de su juicio**. Con dichos cuestionarios también son capaces de medir la **satisfacción del usuario** en cuanto a las recomendaciones. La satisfacción es modelada como un **estado afectivo resultado de las recomendaciones**. Ellos analizan el **impacto del orden de los ítems**.

En (Trajkovic, Gutta y Philomin, 2004) presentan un sistema para encontrar y actualizar las preferencias de un grupo en un **sistema de entretenimiento**. Ellos describen un método y los **dispositivos que han patentado** con el fin de establecer las configuraciones de cualquier dispositivo o sistema basándose en las preferencias de los usuarios en un área predefinida.

Un sistema que se enfoca en demostrar como la **ingeniería de software** puede mejorar la usabilidad y la calidad percibida del **soporte a la decisión** es **IntelliReq** (Felfernig y col., 2012). Ellos en la etapa inicial **recopilan los requerimientos** de los miembros para influir en la decisión.

En (McCarthy y Anagnost, 1998) presentan el sistema **MUSICFX** que permite que los usuarios de un **centro fitness** influyan pero no directamente en la **selección de música** en el centro. Ellos proporcionan un sistema inteligente mediante la agregación de las preferencias de los miembros del grupo y **evalúan la satisfacción individual**.

2.6 Sumario

En este capítulo hemos abordado las clasificaciones más populares de los sistemas de recomendación dirigidos a grupos de usuarios. Hemos identificado que existen diversos GRS dependiendo de sus características, como: la fuente de su información, interacción con el usuario, dominio, salida, tamaño y enfoque de agregación para hacer las recomendaciones.

Hemos orientado nuestra investigación a GRS basados en filtrado colaborativo debido a que son los que mejores resultados han logrado, sin necesidad de un proceso costoso de recolección de información.

Los sistemas de recomendación social enfocados a grupos necesitan ser aplicados a entornos más reales para poder obtener la información de los perfiles de los usuarios. (Cantador y Castells, 2012) presentan varias perspectivas de RS sociales en la web para grupos de usuarios. Además, ellos destacan las áreas de oportunidad en este extenso campo. La ventaja de los GRS sociales es que con la información que manejan pueden descubrir que tan satisfechos están los miembros del grupo con las recomendaciones, puesto que son capaces de incorporar la retroalimentación mediante preguntas a los grupos, o los mismos miembros son capaces de considerar los sentimientos de los demás miembros. Ahora bien, obtener la retroalimentación de los usuarios puede llegar a ser muy costoso. A más de ello, se ha demostrado grandes logros en varias investigaciones (Ortega y col., 2013; Baltrunas, Makcinskas y Ricci, 2010; Chen, Cheng y Chuang, 2008) mediante grupos sintéticos, sin la necesidad de dicha información social.

La mayoría de las investigaciones trabajan con grupos pasivos, es decir, que no dependen de una negociación entre los usuarios. El tamaño de los grupos a los cuales son orientados varían entre 2 a 12 usuarios. Solamente el trabajo de (Boratto y Carta, 2015a; Boratto y Carta, 2011) está dirigido a grupos homogéneos muy grandes detectados automáticamente.

La clasificación de GRS más común y de mayor interés científico es con respecto al enfoque de agregación. Pudiendo ser: enfoque con fusión de recomendaciones, enfoque con agregación de predicciones, enfoque con intersección de vecinos y enfoque relacionado a usuarios. Este último enfoque es el que recientemente ha logrado mejores resultados en tiempo de ejecución y en accuracy. Este enfoque normalmente sigue el siguiente proceso: mediante alguna agregación de preferencias individuales se obtiene un usuario virtual que representa al grupo de usuarios, posteriormente continúa el proceso KNN obteniéndose los vecinos más similares a ese usuario virtual mediante alguna medida de similaridad para grupos de usuarios, y finalmente, se calculan las predicciones y recomendaciones al grupo.

Las estrategias de **agregación de recomendación** tienen la ventaja que las recomendaciones del grupo pueden relacionarse directamente a las recomendaciones individuales, lo que facilita su explicación (Herlocker, Konstan y Riedl, 2000). El problema de esta estrategia es que es menos probable obtener recomendaciones inesperadas y sorprendentes. En cuanto a las estrategias de **agregación de preferencias individuales** (*related users*), el modelo de preferencias del grupo es tratado como un pseudo usuario para quien se producen recomendaciones, lo que aumenta la posibilidad de encontrar recomendaciones sorprendentemente valiosas (Masthoff, 2004; Herlocker, Konstan y Riedl, 2000). Una desventaja de este enfoque es que las recomendaciones pueden llegar a estar desorientadas y fuera del alcance de todos los miembros del grupo, y otro inconveniente es que la tarea para explicar las recomendaciones generadas puede ser muy compleja (Stettinger y Felfernig, 2014).

Aparte de los desafíos generales (control del ruido, dispersión, escalabilidad, diversidad, novedad, serendipia, cold-star, etc.) de los sistemas de recomendación en general, un GRS basado en filtrado colaborativo tiene otros retos particulares, puesto que debe controlar la diversidad de tipos de grupos y dar la explicación de las recomendaciones grupales de manera que se pueda satisfacer a todos los miembros del grupo. Es necesario la estandarización de la evaluación de la calidad de los GRS para que los desarrolladores puedan diseñar mejores estrategias y para que la industria pueda seleccionar la mejor.

En este capítulo hemos abordado varias investigaciones en el campo agrupándolas de acuerdo a la clasificación que nos corresponde según la solución que implementamos. En resumen, nuestra solución GRS CF se basa en KNN y se centra en un enfoque de agregación de preferencias (Fig. 1.5 caso d), para ello, mediante un usuario virtual que modela las preferencias del grupo, se obtiene los K vecinos mediante una nueva medida de similaridad para grupos de usuarios denominada SMGU. Nos centramos en grupos pasivos de entre 2 a 10 usuarios, en un dominio generalista (películas y libros). En el siguiente capítulo explicamos a detalle nuestra solución.

Capítulo 3

Método propuesto

Este capítulo explica el método GRS basado en KNN desarrollado y publicado recientemente (Ortega y col., [2018b](#)). En la sección 3.1, explicamos conceptos previos que están directamente relacionados con el diseño propuesto. En la segunda sección 3.2, exponemos los principios generales en los que se basa nuestra medida de similaridad para recomendación a grupos. La tercera sección 3.3, detalla el formalismo matemático y lo relaciona con el diseño explicado, y finalmente, la sección 3.4 proporciona la ejecución de un ejemplo mediante un datatoy.

3.1 Conceptos previos

El método propuesto esta basado en un enfoque de agregación de preferencias de usuarios (*related users*), que se aprecia en las Figuras 1.5 (caso d) y 2.7. Básicamente los pasos del método propuesto son: 1) determinación de un usuario virtual con la agregación de las preferencias de los usuarios del grupo (modelamiento del grupo) y cálculo de similitudes con los demás usuarios de la base de datos, 2) determinación de vecinos para el grupo modelado (usuario virtual), 3) cálculo de predicciones, y 4) selección de las Top-N recomendaciones. Este método incorpora una medida de similitud para grupos de usuarios que combina varias fuentes de información. La medida de similitud propuesta usa el concepto de singularidad (Bobadilla, Ortega y Hernando, 2012) y la combinación de concepto de información numérica y no numérica (Bobadilla, Serradilla y Bernal, 2010; Zhu y col., 2018). *La hipótesis del concepto de singularidad, es que los resultados de CF pueden mejorarse tomando información contextual, extraída de todo el conjunto de usuarios.* La idea principal de la singularidad radica en el hecho de que la contribución de un ítem a la similitud asignada a dos usuarios no debe considerarse absoluta (que es lo que sucede con las medidas tradicionales), sino más bien en relación con el voto otorgado a este ítem por el resto de los usuarios en el sistema. Siguiendo el razonamiento de singularidad expresado hasta sus extremos, si todos los usuarios que han votado por un ítem han emitido el mismo voto, es difícil considerar este ítem como un factor de similitud entre dos usuarios. En el caso opuesto, si solamente dos usuarios han votado de forma diferente al resto por un ítem, esto representa una gran singularidad que debería traducirse en una gran similitud para este ítem.

Las ecuaciones de (Bobadilla, Ortega y Hernando, 2012) definen S_P^i como la singularidad de los votos relevantes sobre el artículo i , y S_N^i como la singularidad de los votos no relevantes relacionados con el ítem i . Los votos relevantes en MovieLens, el dataset de referencia en investigación sobre CF, son 4,5, mientras que los votos no relevantes son 1,2,3. S_P^i y S_N^i son definidos a continuación:

$$S_P^i = 1 - \frac{\#\{u \in U | r_{u,i} \in \{4,5\}\}}{\#U}$$

$$S_N^i = 1 - \frac{\#\{u \in U | r_{u,i} \in \{1,2,3\}\}}{\#U}$$

Donde U es el conjunto de usuarios y $r_{u,i}$ es el voto emitido del usuario u al ítem i .

La combinación del concepto de información numérica y no numérica se propuso en (Bobadilla, Serradilla y Bernal, 2010). Los autores presentan una medida que combina la información numérica de los votos con información independiente de esos valores, en función de las proporciones de los votos comunes y no comunes entre cada par de usuarios. La información numérica se procesa usando el *Mean Squared Differences (MSD)*, mientras que la medida de similitud *Jaccard* se usa para tratar la información no numérica. La medida resultante *JMSD* es simple, proporciona buen *accuracy* y rendimiento, y ha sido altamente citada: $JMSD(u,v) = Jaccard(u,v) * (1-MSD(u,v))$.

FIGURA 3.1: Fuentes de información utilizadas para diseñar el método propuesto.

3.2 Diseño del Método

A partir de los conceptos que se muestran en la sección anterior, mostraremos los elementos constitutivos de la medida de similitud propuesta para grupos de usuarios. Vamos a hacer uso de la Fig. 3.1; nuestra medida está constituida por tres elementos fundamentales:

- (a) **Información numérica (votos)**, contemplada en el elemento 5 de la Fig. 3.1.
- (b) **Información no numérica (estructural)**, contemplada en el elemento 1 de Fig. 3.1.
- (c) **Ponderaciones de importancia de la información numérica**, contemplada en los elementos 2, 3 y 4 de Fig. 3.1. Llamaremos *SMGU* a la medida de similitud propuesta (*Singularity-based Measure for Groups of Users*).

Fuentes de información del método propuesto

1. **Proporción de elementos coincidentes (información estructural)**: La medida *Jaccard* da la proporción existente de votos emitidos por dos usuarios: el usuario activo y cada vecino candidato. La medida de similitud *JMSD* (Bobadilla, Serradilla y Bernal, 2010) muestra una mejora significativa en el accuracy

obtenido cuando *Jaccard* es aplicado a KNN CF en un RS. *SMGU* extiende el comportamiento de *JMSD Jaccard* en dos aspectos:

- (a) **Extensión de Jaccard a grupos de usuarios:** La medida de similaridad *Jaccard*, aplicada a dos usuarios, se puede definir como la relación entre el número de votos comunes (intersección de votos) y el número total de votos (unión de votos). Cuando se trata de un grupo de usuarios, las operaciones de unión e intersección se pueden realizar como se muestra en la parte superior de la Fig. 3.2: cada voto del vecino candidato se compara con el voto del grupo correspondiente.
- (b) **Incorporación del ítem impopular:** *SGMU* incorpora el concepto "singularidad de los ítems" (Bobadilla, Ortega y Hernando, 2012), una de las características de singularidad que incorpora *SMGU* es la ausencia de popularidad de un ítem para los usuarios. La popularidad consiste en la gran cantidad de votos de un ítem con respecto a otros ítems. De manera inversa, la impopularidad de un ítem consiste en una cantidad de votos menor con respecto a los demás ítems. Esta impopularidad apoya el concepto de singularidad. La idea detrás del concepto de singularidad es que los ítems más singulares proporcionan una mejor información para determinar la similaridad entre dos usuarios.

A modo de **ejemplo**, si dos usuarios coinciden en una película que no ha sido ampliamente votada y conocida, es muy probable que tengan gustos similares entre ellos y sean diferentes a los gustos de otros usuarios. Si dos usuarios coinciden en una película conocida, como *Avatar*, esta información no será suficiente para que coincida con ambos usuarios, ya que habrá una gran cantidad de usuarios que también se emparejarán en función de ese ítem popular. Siguiendo este razonamiento, el ítem 1 de la parte inferior de la Fig. 3.2 es más impopular que el ítem 2 porque el ítem 1 contiene menos votos que el ítem 2. Nuestra medida de similaridad propuesta dará más importancia a los vecinos de KNN que coinciden, en el ítem 1.

2. **Singularidad de usuarios:** este parámetro le da mayor importancia a los votos menos populares en cada ítem. Definimos la singularidad de un voto r para un ítem i como la proporción entre votaciones diferentes de r y la totalidad de las votaciones emitidas en i .

Como un **ejemplo**, en la Fig. 3.3, para el ítem 3, la singularidad del voto = 3 es mucho mayor que la singularidad del voto 5; en la Fig. 3.3 el ítem 2, la singularidad del voto 5 es mayor que la singularidad del voto 2.

Para comprender la idea subyacente, podemos considerar un ítem que ha recibido muchos votos positivos (por ejemplo, votos 4 o 5 en "Guerra de las Galaxias"): dos usuarios que emitan un voto "singular" (negativo) a este ítem estarán más relacionados entre ellos que dos usuarios que emitan votos "no singulares" (positivos). Del mismo modo, un ítem que ha sido pobremente votado en su mayoría, nos proporcionará información más relevante de similaridad entre dos usuarios que lo votaron positivamente.

Jaccard aplicado a grupos de usuarios

Impopularidad del ítem

FIGURA 3.2: Proporción de ítems coincidentes e ítems impopulares.

Finalmente, la **singularidad del voto emitido por el usuario u** al ítem i se define como la proporción (*ratio*) entre los votos para el ítem i diferentes a $r_{u,i}$ y la totalidad de los votos emitidos en i : por **ejemplo**, en la Fig. 3.3, el usuario 10 tiene una gran singularidad en el ítem 3, mientras que los usuarios 0, 2, 5 y 8 tienen una pequeña singularidad en el ítem 3. Desde el aspecto de singularidad, con respecto al ítem 3 de la Fig. 3.3, los usuarios u_3 y u_9 son más similares que los usuarios u_0 y u_2 .

3. **Número de usuarios en el grupo que han votado el ítem i** : la medida de similitud propuesta modula los resultados de acuerdo con la cantidad de información disponible; por **ejemplo**: según la Fig. 3.3 en el ítem 2, los resultados del grupo $\langle u_0, u_1, u_2, u_3 \rangle$ tendrán menos importancia que los resultados del grupo $\langle u_5, u_8, u_9 \rangle$, ya que los resultados del primer grupo son tomados usando un solo voto, mientras que los resultados del segundo grupo se toman con tres votos. De esta manera se sigue la misma idea, los ítems más singulares proporcionan una mejor información para determinar la similitud entre dos usuarios.
4. **Singularidad del grupo**: la singularidad de los votos emitidos para los usuarios que pertenecen a un grupo se puede considerar como una **extensión de la singularidad del usuario**. Desde la Fig. 3.3, si consideramos $\langle u_0, u_2, u_5, u_8 \rangle$ como

	U0	U1	U2	U3	U4	U5	U6	U7	U8	U9	U10	U11
Item 1	5	*	*	*	*	2	*	*	*	*	3	*
Item 2	*	*	2	*	*	2	*	*	5	2	*	*
Item 3	5	*	5	4	*	5	2	*	5	4	3	*

FIGURA 3.3: Singularidad de usuarios y grupos.

un grupo de usuarios, con respecto al ítem 3, sus votos no son demasiado singulares, ya que han votado el valor habitual (5). Si consideramos $\langle u_6, u_{10} \rangle$ como un grupo de usuarios, sus votos son singulares con respecto al ítem 3.

5. **Diferencias numéricas:** de manera similar al proceso KNN para usuarios individuales, para determinar el conjunto de vecinos para un grupo de usuarios es necesario hacer uso de la información numérica de los votos. Debemos elegir vecinos de KNN que tengan gustos similares a los del grupo. En (Bobadilla, Serradilla y Bernal, 2010), *Mean Squared Differences (MSD)* se establece como una medida de similitud adecuada en este contexto, porque las **diferencias de votos entre los usuarios están altamente penalizadas**. Nuestra medida de similitud propuesta *SMGU* para grupos de usuarios también utiliza *MSD*.

3.3 Formalización

A continuación, se establecen las ecuaciones que definen la propuesta *SMGU* como una medida de similitud. Esta sección está estructurada numéricamente, de acuerdo con los valores de los elementos que se muestran en la Fig. 3.1. Finalmente, las ecuaciones son unificadas, mostrando el resultado final *SMGU*.

1. Proporción de elementos coincidentes (información estructural):

Definamos p_i como la ausencia de importancia del ítem i basado en sus votos. Aquí, el significado del parámetro es: impopularidad del ítem. Aquellos votos que reciban menos votaciones serán más impopulares.

$$p_i = 1 - \frac{\#\{u \in U | r_{u,i} \neq \bullet\}}{\#U} \quad (3.1)$$

Donde $\bullet$ significa no votado, U es el conjunto de usuarios y $r_{u,i}$ es el voto de un usuario u a un ítem i . Aquellos votos que reciban menos votaciones serán más impopulares.

Definamos $x_{G,u}$ como la similitud entre el grupo G y el usuario u basado en la información no numérica de los votos:

$$x_{G,u} = \frac{\sum_{i \in \{I_G \cap I_u\}} p_i}{\sum_{i \in \{I_G \cup I_u\}} p_i} \quad (3.2)$$

Donde I_G es el conjunto de ítems votados por al menos un usuario del grupo G y I_u es el conjunto de ítems votados por el usuario u .

2. Singularidad de usuarios:

Definamos $s_{u,i}$ como la singularidad del voto del usuario u sobre el ítem i ($r_{u,i}$). Este valor indica la singularidad del voto del usuario para el ítem i , comparado con los votos emitidos por los demás usuarios v para el ítem i .

$$s_{u,i} = \frac{\#\{v \in U | r_{v,i} \neq r_{u,i} \wedge r_{v,i} \neq \bullet\}}{\#\{v \in U | r_{v,i} \neq \bullet\}}, \forall r_{u,i} \neq \bullet \quad (3.3)$$

3. Número de usuarios en el grupo que han votado el ítem i :

Definamos G_i como el subconjunto de usuarios del grupo G que han votado el ítem i .

$$G_i = \{u \in G | r_{u,i} \neq \bullet\} \quad (3.4)$$

4. Singularidad del grupo:

Definamos $s_{G,i}$ como la singularidad de los votos del grupo G sobre el ítem i . Esta singularidad se calcula con la media geométrica de las singularidades de los usuarios en el grupo.

$$s_{G,i} = \sqrt[\#G_i]{\prod_{u \in G_i} s_{u,i}}, \forall s_{u,i} \neq \bullet \quad (3.5)$$

5. Diferencias numéricas (información numérica):

Definamos $\Delta_{G,u,i}$ como la diferencia al cuadrado de los votos de los usuarios del grupo G al ítem i , con respecto al voto del usuario vecino u , para el ítem i . Cabe destacar, que $r_{u,i}$ debe estar normalizado.

$$\Delta_{G,u,i} = \frac{\sum_{g \in G_i} (r_{g,i} - r_{u,i})^2}{\#G_i}, \forall r_{u,i} \neq \bullet \quad (3.6)$$

Donde $r_{u,i}$ debe estar normalizado.

El paso 1 proporciona la información no numérica (estructural), pero combinándose a los pasos 2 a 5 en una sola ecuación provee información numérica. Vamos a definir $y_{G,u}$ como la similaridad entre el grupo G y el usuario u , basado en la información numérica de los votos. Lo que hacemos es usar *Mean Squared Differences*, ponderando sus valores con tres parámetros: a) singularidad de candidato a vecino para cada ítem, b) singularidad de grupo para cada ítem, y c) número de votos en el grupo para cada ítem:

$$w_{G,u,i} = s_{u,i} s_{G,i} \#G_i \quad (3.7)$$

Donde $w_{G,u,i}$ es el peso que tiene el ítem i en la similaridad entre el grupo G y el usuario u .

$$y_{G,u} = 1 - \frac{\sum_{i \in \{I_G \cap I_u\}} w_{G,u,i} \Delta_{G,u,i}}{\sum_{i \in \{I_G \cap I_u\}} w_{G,u,i}} \quad (3.8)$$

TABLA 3.1: *Datatooy*

Matriz de votos												
r_{ui}	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_{10}	i_{11}	i_{12}
u_1		1		1	1		0		0			0
u_2	0	1		0	1		1		0			
u_3		1		0	0		0	0				0
u_4		1	1	1	1	1	1		1	0	1	1
u_5	1	0		1		1			1	0		1
u_6	0	1		0	1		0	0	0			0
u_7	1					1		1		1		
u_8	1	1		0	0	0	0		0		1	0
u_9		1		1	0		1			1	1	

Finalmente, la medida de similaridad propuesta $SMGU$, combina la información no numérica de (3.2) e información numérica de (3.8). $\alpha \in [0, 1]$ es un parámetro que cambia la importancia de la información no numérica de los votos frente a la información numérica.

$$SMGU(G, u) = x_{G,u}^\alpha y_{G,u}^{1-\alpha} \quad (3.9)$$

3.4 Ejecución de un ejemplo

En esta sección, mostramos la ejecución de un ejemplo utilizando un *datatoy*. A partir de este ejemplo, mostraremos, paso a paso, el funcionamiento de la medida de similaridad propuesta para recomendaciones a grupos de usuarios.

En la Tabla 3.1 mostramos la matriz de votos (*datatoy*) que hemos diseñado. Los usuarios $\langle u_1, u_2, u_3 \rangle$ conforman el grupo G de usuarios (sombreado celeste). Para simplificar el análisis, hemos utilizado solo dos valores de votos posibles: cero y uno. Al observar los votos cuidadosamente, podemos verificar que los usuarios u_6 y u_8 (sombreado verde) son aquellos que contienen más votos similares a los del grupo G , y por lo tanto, a priori, son candidatos a ser los vecinos de G . Por otro lado, los usuarios u_5 y u_7 (sombreado rosa) contienen más votos diferentes al grupo G : se espera que su similaridad con el grupo sea baja.

En la Tabla 3.2, se analiza el elemento **1. Proporción de elementos coincidentes (información estructural)** de la Fig. 3.1. Primeramente, se muestra la **impopularidad** p_i de cada ítem: ítem i_3 solo ha recibido un voto; es el ítem más impopular. Los ítems i_2 y i_4 han recibido ocho votos y son los ítems menos impopulares. Luego, usando los valores de impopularidad, $x_{G,u}$ realiza la función *Jaccard* entre el grupo de usuarios G y cada candidato a vecino u . Como se esperaba, los usuarios u_6 y u_8 se presentan como candidatos a vecinos del grupo. Como ejemplo, se presentan los cálculos de $x_{G,5}$ y $x_{G,6}$.

$$\#U = 9$$

$$p_3 = 1 - \frac{1}{9} = 0.89$$

$$p_2 = 1 - \frac{8}{9} = 0.11$$

TABLA 3.2: Ejemplo: proporción de elementos coincidentes

Proporción de elementos coincidentes (información estructural)												
	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_{10}	i_{11}	i_{12}
p_i	0.44	0.11	0.89	0.11	0.22	0.56	0.22	0.67	0.33	0.56	0.67	0.33
	u_4	u_5	u_6	u_7	u_8	u_9						
$x_{G,u}$	0.26	0.38	1.00	0.31	0.48	0.18						

$$x_{G,5} = \frac{p_1+p_2+p_4+p_9+p_{12}}{p_1+p_2+p_4+p_5+p_6+p_7+p_8+p_9+p_{10}+p_{12}} = 0.38$$

$$x_{G,6} = \frac{p_1+p_2+p_4+p_5+p_7+p_8+p_9+p_{12}}{p_1+p_2+p_4+p_5+p_7+p_8+p_9+p_{12}} = 1.00$$

Los resultados del elemento **2. Singularidad de usuarios** de la Fig. 3.1, los presentamos en la Tabla 3.3. Se presenta $s_{u,i}$: la singularidad del voto del usuario para el ítem i comparado con los votos emitidos, en el ítem i , por todos los otros usuarios. Hemos marcado, en negrita, los votos más singulares; el voto más representativo es el voto del usuario u_5 para el ítem i_2 : en el datatoy (Tabla 3.1) es el único voto *cero* de los ocho votos emitidos en este ítem. La situación opuesta se puede observar en el ítem i_{11} : cualquiera de sus tres votos *uno* obtiene una singularidad nula, debido a la ausencia de diversidad en los votos. A continuación, se presentan los cálculos de $s_{5,2}$ y $s_{8,11}$.

$$s_{5,2} = \frac{7}{8} = 0.88$$

$$s_{8,11} = \frac{0}{3} = 0$$

TABLA 3.3: Ejemplo: singularidad de usuarios

Singularidad de usuarios												
$s_{u,i}$	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_{10}	i_{11}	i_{12}
u_1		0.13		0.5	0.43		0.43		0.33			0.33
u_2	0.6	0.13		0.5	0.43		0.57		0.33			
u_3		0.13		0.5	0.57		0.43	0.33				0.33
u_4		0.13	0	0.5	0.43	0.25	0.57		0.67	0.5	0	0.67
u_5	0.4	0.88		0.5		0.25			0.67	0.5		0.67
u_6	0.6	0.13		0.5	0.43		0.43	0.33	0.33			0.33
u_7	0.4					0.25		0.67		0.5		
u_8	0.4	0.13		0.5	0.57	0.75	0.43		0.33		0	0.33
u_9		0.13		0.5	0.57		0.57			0.5	0	

En la Tabla 3.4, se observa los resultados del elemento **3. Número de usuarios en el grupo que han votado el ítem i** de la Fig. 3.1. Solamente se muestra la cantidad de usuarios en G que han votado el ítem i ; por ejemplo:

$$\#G_{12} = 2, u_1 \text{ y } u_3 \text{ han votado.}$$

$$\#G_7 = 3, u_1, u_2 \text{ y } u_3 \text{ han votado.}$$

La Tabla 3.5 presenta los resultados del elemento **4. Singularidad del grupo** de la Fig. 3.1. Los resultados corresponden a las singularidades del grupo para cada ítem $s_{G,i}$. Esta singularidad se calcula utilizando la media geométrica de las singularidades de los usuarios en el grupo; en nuestro ejemplo, el más alto $s_{G,i}$ corresponde

TABLA 3.4: Ejemplo: número de usuarios en el grupo que han votado el ítem i

Número de usuarios en el grupo que han votado el ítem i :												
	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_{10}	i_{11}	i_{12}
$\#G_i$	1	3	0	3	3	0	3	1	2	0	0	2

al valor de singularidad más alto $s_{u,i}$ de los usuarios del grupo: $s_{2,1} = 0.60$. Como ejemplos, se presentan los cálculos de $s_{G,1}$ y $s_{G,7}$.

$$s_{G,1} = s_{2,1} = 0.60$$

$$s_{G,7} = \sqrt[3]{(s_{1,7})(s_{2,7})(s_{3,7})} = \sqrt[3]{(0,43)(0,57)(0,43)} = 0.47$$

TABLA 3.5: Ejemplo: singularidad del grupo

Singularidad del grupo												
	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_{10}	i_{11}	i_{12}
$s_{G,i}$	0.6	0.13		0.5	0.47		0.47	0.33	0.33			0.33

Podemos ver que, en este ejemplo, el ítem i_7 es particularmente relevante para la medida de similitud propuesta $SMGU$, ya que tiene altos valores de $s_{u,i}$ (Tabla 3.2), $s_{G,i}$ (Tabla 3.3) y $\#G_i$ (Tabla 3.4).

TABLA 3.6: Ejemplo: diferencias numéricas

Diferencias numéricas (información numérica)												
$\Delta_{G,u,i}$	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_{10}	i_{11}	i_{12}
u_4		0		0.67	0.33		0.67		1			1
u_5	1	1		0.67					1			1
u_6	0	0		0.33	0.33		0.33	0	0			0
u_7	1							1				
u_8	1	0		0.33	0.67		0.33		0			0
u_9		0		0.67	0.67		0.67					
$y_{G,u}$	u4	u5	u6	u7	u8	u9						
	0.31	0.11	0.78	0	0.57	0.35						

En la Tabla 3.6, se encuentran los resultados del elemento **5. Diferencias numéricas (información numérica)** de la Fig. 3.1. Se muestra los resultados de las diferencias cuadráticas medias calculadas de acuerdo con la ecuación $\Delta_{G,u,i}$. Como ejemplos, se presentan los cálculos de $\Delta_{G,5,4}$ y $\Delta_{G,6,4}$.

$$\Delta_{G,5,4} = \frac{(1-1)^2 + (0-1)^2 + (0-1)^2}{3} = 0.67$$

$$\Delta_{G,6,4} = \frac{(1-0)^2 + (0-0)^2 + (0-0)^2}{3} = 0.33$$

Como era de esperar, los usuarios u_6 y u_8 proporcionan los valores de error más pequeños, mientras que los usuarios u_5 y u_7 reportan los errores más grandes. Siendo $w_{G,u,i} = s_{u,i}s_{G,i}\#G_i$, como ejemplos, se presentan los cálculos de $w_{G,5,1}$ y $w_{G,6,7}$.

$$w_{G,5,1} = (0,4)(0,6)(1) = 0,24$$

$$w_{G,6,7} = (0,43)(0,47)(3) = 0,60$$

Combinando los valores de error con los parámetros de singularidad obtenemos el factor numérico $y_{G,u}$ de la Tabla 3.6.

Finalmente, combinando $y_{G,u}$ con la información estructural $x_{G,u}$, y aplicando el factor α obtenemos los **resultados finales de la medida de similitud SMGU** (Tabla 3.7). Presentamos resultados con varios valores de α ; en todos los casos: estructurales, resultados numéricos y finales, los vecinos esperados u_6 y u_8 han sido elegidos, mientras que u_5 y u_7 han sido rechazados.

TABLA 3.7: Ejemplo: combinación de $y_{G,u}$ con $x_{G,u}$

Matriz de votos												
r_{ui}	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_{10}	i_{11}	i_{12}
u_1		1		1	1		0		0			0
u_2	0	1		0	1		1		0			
u_3		1		0	0		0	0				0
u_4		1	1	1	1	1	1		1	0	1	1
u_5	1	0		1		1			1	0		1
u_6	0	1		0	1		0	0	0			0
u_7	1					1		1		1		
u_8	1	1		0	0	0	0		0		1	0
u_9		1		1	0		1			1	1	
Combinación de $y_{G,u}$ con $x_{G,u}$												
	u_4	u_5	u_6	u_7	u_8	u_9						
$x_{G,u}$	0.26	0.38	1.00	0.31	0.48	0.18						
	u_4	u_5	u_6	u_7	u_8	u_9						
$y_{G,u}$	0.31	0.11	0.78	0	0.57	0.35						
Similitud final (SMGU)												
	u_4	u_5	u_6	u_7	u_8	u_9						
α	0.26	0.38	1	0.31	0.48	0.18		α	0			
α	0.27	0.28	0.94	0	0.51	0.21		α	0.25			
α	0.29	0.21	0.88	0	0.53	0.25		α	0.5			
α	0.3	0.15	0.83	0	0.55	0.29		α	0.75			
α	0.31	0.11	0.78	0	0.57	0.35		α	1			

Capítulo 4

Experimentos y resultados

Este capítulo presenta el diseño de experimentos, las medidas de calidad seleccionadas y los resultados comparando el método propuesto con el estado del arte.

4.1 Diseño de experimentos

Esta sección muestra el diseño de los experimentos. Los experimentos se centran en: a) encontrar los parámetros óptimos para el método propuesto, y b) comparar el método propuesto con el estado del arte. La subsección 4.1.1 describe el entorno diseñado para realizar todos los experimentos; la subsección 4.1.2 indica las medidas de calidad utilizadas para controlar la calidad de las recomendaciones; finalmente, las subsecciones 4.1.3 y 4.1.4, explican los experimentos llevados a cabo para probar el modelo propuesto.

4.1.1 Configuración de experimentos

Los experimentos se han dividido en dos fases:

1. Encontrar los **parámetros óptimos** del método propuesto para cada conjunto de datos.
2. Comparar el método propuesto con el estado del arte de los GRS CF.

Todos los experimentos se han llevado a cabo utilizando datasets públicos ampliamente utilizados por los artículos de investigación de RS. Hemos seleccionado los datasets: **MovieLens** (Harper y Konstan, 2015), **BookCrossing** (Zaier, Godin y Faucher, 2008) and **FilmTrust** (Golbeck y Hendler, 2006). La Tabla 4.1 contiene las propiedades más relevantes sobre estos datasets. Los experimentos han utilizado el framework *Original Software Publication (OSP)* (Ortega y col., 2018a).

TABLA 4.1: Principales propiedades de los conjuntos de datos utilizados en los experimentos.

Conjunto de datos	Número de votos	Número de ítems	Número de usuarios	Escala del voto
MovieLens	10.000.054	10.681	71.567	escala de 5 estrellas, con incremento de 0.5
BookCrossing	433.671	185.973	77.805	1 a 10 puntos
FilmTrust	33.470	2.071	1.508	0.5 a 4 con incremento de 0.5

Los datasets probados no incluyen ninguna información social para poder probar el método propuesto utilizando grupos reales de usuarios, por lo que hemos generado **grupos sintéticos**. Los **usuarios se han agrupado al azar**, no obstante los usuarios que tienen más votos de entrenamiento en común tienen una mayor probabilidad de agruparse. Para realizar los experimentos, hemos dividido usuarios e ítems en **conjuntos de test y de entrenamiento (training)**. Para evitar las fluctuaciones debidas a la selección aleatoria de: usuarios de entrenamiento, ítems de *test* y grupos de *test*, realizamos cada experimento utilizando **10-folds Monte Carlo cross-validation**. La Tabla 4.2 contiene los parámetros principales de cada dataset elegido para la ejecución de los experimentos.

TABLA 4.2: Parámetros principales para probar cada dataset.

Conjunto de datos	Número de grupos de test	Número de usuarios de entrenamiento	Porcentaje de ítems de test
MovieLens	3,550	70,000	15 %
BookCrossing	8,000	70,000	20 %
FilmTrust	350	1,500	25 %

4.1.2 Medidas de calidad

Para la evaluación del método GRS propuesto utilizaremos las medidas de evaluación de GRS mencionadas en la sección 2.3.2, a fin de evaluar la calidad de recomendaciones a grupos de usuarios, utilizaremos las medidas $precision@λ$ y $recall@λ$, y para evaluar la calidad de predicciones utilizaremos la medida $R-MAE$.

4.1.3 Optimización de parámetros

La medida de similaridad propuesta contiene dos parámetros: $α$, que controla la importancia de la información de votos no numérica contra la información numérica de votos, y k , que ajusta el número de vecinos para el grupo en KNN. Se requiere un ajuste adecuado de estos parámetros para cada conjunto de datos a fin de maximizar la calidad de las recomendaciones.

En este experimento, evaluaremos el método propuesto con diferentes combinaciones para ambos parámetros $α$ y k . La Tabla 4.3 contiene los valores probados para cada parámetro. Para seleccionar la configuración óptima de estos parámetros probaremos:

- Medir $R-MAE$, $precision@λ$ y $recall@λ$.
- Recomendar 10 ítems para cada configuración de parámetros.
- Seleccionar el mejor.

La Tabla 4.4 contiene los mejores parámetros obtenidos en el experimento.

TABLA 4.3: Parámetros del modelo probado.

Conjunto de datos	$α$	k
MovieLens	0.0 a 1.0 salto 0.2	50 a 1000 salto 50
BookCrossing	0.0 a 1.0 salto 0.2	50 a 600 salto 50
FilmTrust	0.0 a 1.0 salto 0.2	50 a 600 salto 50

4.1.4 Rendimiento del modelo

Para medir el rendimiento del método propuesto, lo compararemos con los métodos de recomendación de grupos del estado del arte. Los baselines seleccionados para esta comparación son:

- *UGSM* (Ortega y col., 2013)
- *MFGU* (Ortega y col., 2016)

TABLA 4.4: Configuración del experimento para optimizar los parámetros del método propuesto.

Parámetro	MovieLens	BookCrossing	FilmTrust
Tamaño mínimo del grupo	2	2	2
Tamaño máximo del grupo	10	10	10
Número de recomendaciones	10	10	10
θ	4	8	3
π	1	1	1
α	0.2	0.15	0.2
# vecinos	350	75	275

- *C&P* (Boratto, Carta y Fenu, 2017)
- *RWR – M* (Feng y Cao, 2017)
- *RANK* (Baltrunas, Makcinskas y Ricci, 2010)

Algunos de estos métodos de recomendación requieren diferentes parámetros para funcionar. Hemos configurado esos parámetros para maximizar la calidad de la recomendación en cada dataset. La Tabla 4.5 contiene los parámetros de cada modelo en cada experimento, donde k es el número de vecinos y SM es la medida de similitud.

TABLA 4.5: Parámetros utilizados en los experimentos para ejecutar los baselines.

Método	MovieLens	BookCrossing	FilmTrust
UGSM	$k=400$	$k=100$	$k=300$
MFGU	#iteraciones=300 $\lambda=0.055$ #factores=18	#iteraciones=300 $\lambda=0.01$ #factores=6	#iteraciones=300 $\lambda=0.055$ #factores=8
C&P	SM=COR $k=350$	SM=COR $k=70$	SM=COR $k=250$
RWR-M	#iteraciones=25 $\rho=0.15$	#iteraciones=25 $\rho=0.15$	#iteraciones=25 $\rho=0.15$
RANK	SM=COR	SM=COR	SM=COR

Evaluaremos estos métodos utilizando las medidas de calidad previamente definidas: $precision@k$, $recall@k$ y $R-MAE$. El experimento ha sido realizado para dos tamaños de grupos:

- Tamaño de 2 a 5 usuarios**, para probar el rendimiento de cada método de recomendación en pequeños grupos de usuarios (familias, parejas, grupo pequeño de amigos, etc.).
- Tamaño de 6 a 10 usuarios**, para probar el rendimiento de cada método de recomendación sobre un gran grupo de usuarios (equipos, bandas, gran grupo de amigos, etc.).

Además, hemos probado el experimento para múltiples valores de λ (1.0, 0.75 y 0.5) con el fin de medir la satisfacción general del grupo dentro de las recomendaciones realizadas. Cada medida ha sido evaluada para diferentes números de recomendaciones (de 5 a 20).

4.2 Resultados y discusión

Esta sección se divide en tres subsecciones: 1) explica los experimentos realizados para ajustar los parámetros involucrados en el método propuesto, 2) muestra los resultados de predicción y recomendación obtenidos utilizando el método propuesto, luego los compara con los baselines mencionados, y 3) se discute las principales fortalezas e inconvenientes observados.

4.2.1 Ajuste de parámetros

Antes de probar el método propuesto, es necesario **determinar el valor α** de la ecuación (3.9) y el **número de vecinos k** . Es decir, debemos elegir un valor de α que pondere la importancia de la información estructural (no numérica) de los votos con respecto a la información numérica. Cuanto menor sea el valor de α , mayor será el peso que damos a la información numérica y se dará menor importancia a la información no numérica.

La Fig. 4.1 presenta la implementación de los parámetros de la Tabla 4.3 y resume el **impacto producido en cada medida de calidad seleccionada al combinar los valores de α y el número de vecinos k** para cada uno de los conjuntos de datos considerados. En todos los gráficos, los mejores resultados se codifican usando el color amarillo (valores bajos en R_MAE y valores altos en $Precision@k$ y $Recall@k$). Las principales conclusiones de los resultados mostrados en la Fig. 4.1 son:

1. El α **óptimo y el número de vecinos k** , depende en gran medida de la naturaleza de los datos, es decir, del conjunto de datos que estamos utilizando.
2. La **información estructural (no numérica)** ayuda a mejorar los resultados de calidad: cuando α es cero, los resultados de calidad empeoran.
3. En general, es apropiado asignar **valores bajos a α** : deberíamos dar más importancia a la información numérica que a la información no numérica.

Los valores de α y el número de vecinos k presentados en la Tabla 4.4 han sido seleccionados en base a los resultados que se muestran en la Fig. 4.1. Como se esperaba, es interesante observar cómo **el tamaño del conjunto de datos influye en el valor apropiado del número de vecinos**; por ejemplo: en el conjunto de datos más grande (*MovieLens*) el impacto es muy pequeño, mientras que en el conjunto de datos más pequeño (*FilmTrust*) hay una gran diferencia en la calidad de los resultados obtenidos aplicando diferentes tamaños de vecindario.

También es muy interesante observar en *FilmTrust*, el siguiente comportamiento: hay una tendencia a obtener los mejores resultados de calidad al establecer una correlación directa entre α y el número de vecinos. Es decir, a medida que aumentamos el tamaño del vecindario, también debemos aumentar el valor de α . Esto significa que los mejores vecinos (los primeros, los más similares) se seleccionan mejor usando información numérica: con un valor bajo de α . Sin embargo, los vecinos más "forzados" (los últimos, los menos similares) se seleccionan mejor usando información estructural: con un valor de α alto. Nuestro método propuesto puede compensar este efecto aumentando o disminuyendo el valor de α . Las gráficas de R_MAE y $Precision@k$ en *MovieLens*, también muestran esta tendencia, aunque de una manera menos marcada, debido al tamaño mucho mayor de este conjunto de datos:

FIGURA 4.1: Impacto de α y el número de vecinos en los resultados de calidad del método propuesto.

sería necesario utilizar un mayor número de vecinos para apreciar esta tendencia con mayor intensidad.

4.2.2 Comparación de resultados

Resultados de la calidad de predicción

En primer lugar, mostraremos los **resultados de la calidad de predicción** haciendo uso de la medida de calidad R_MAE (Error Medio Absoluto de predicción de los ítems recomendados). La Fig. 4.2 muestra los resultados obtenidos para los tres datasets probados: *MovieLens*, *FilmTrust* y *BookCrossing*. Los baselines usados son: *UGSM* (Ortega y col., 2013), *MFGU* (Ortega y col., 2016) y *C&P* (Boratto, Carta y Fenu, 2017). Los baselines *RWR – M* (Feng y Cao, 2017) y *RANK* (Baltrunas, Makcinskys y Ricci, 2010) no están diseñados para predecir; los usaremos para probar las medidas de calidad de recomendaciones $Precision@k$ y $Recall@k$. Los parámetros de los experimentos se muestran en la Tabla 4.5. Se han llevado a cabo experimentos para diferentes tamaños de grupos: el lado izquierdo corresponde a grupos pequeños de usuarios (grupos que contienen de dos a cinco usuarios) y el lado derecho corresponde a grandes grupos de usuarios (grupos que contienen de seis a diez usuarios).

Las **conclusiones** más relevantes obtenidas de la Fig. 4.2 son:

FIGURA 4.2: Resultados de predicción a grupos.

Error medio absoluto de predicción de los ítems recomendados en los datasets *MovieLens*, *FilmTrust* y *BookCrossing*. Probado para grupos pequeños (lado izquierdo) y grupos grandes (lado derecho). Metodo Propuesto: *SMGU*. Baselines: *UGSM* (Ortega y col., 2013), *MFGU* (Ortega y col., 2016) y *C&P* (Boratto, Carta y Fenu, 2017). Los parámetros de los experimentos se muestran en la Tabla 4.5. Cuanto menor sea el valor, mejor será el resultado.

1. La calidad ofrecida por las medidas de similitud de los baselines varía según el conjunto de datos utilizado y la cantidad de usuarios de los grupos: en algunos casos, *UGSM* supera a *MFGU*, mientras que en otras ocasiones ocurre lo contrario. *C&P* tiende a ser el baseline que proporciona los peores resultados.
2. La medida de similitud propuesta *SMGU* logra los mejores resultados de predicción en todos los casos. *SMGU* y *MFGU* se comportan muy bien cuando se aplica a grandes conjuntos de datos.
3. En general, la calidad de la predicción aumenta a medida que disminuye el tamaño del grupo: este es el resultado esperado, debido a la mayor diversidad de usuarios que componen los grupos más grandes.

Resultados de la calidad de recomendación

Una vez que se ha verificado la superioridad del método propuesto, en calidad de predicción, llevamos a cabo los experimentos que miden la **calidad de la recomendación**; para esto, probamos $precision@λ$ y $recall@λ$, y establecemos los siguientes valores de $λ$: 0.5, 0.75, 1.0. Como ejemplo, el **valor 0.75 significa que hay una proporción del 75 % de usuarios, pertenecientes a cada grupo, que gustan de los ítems recomendados**. Las medidas de calidad de recomendación se han probado utilizando todos los baselines considerados para grupos de usuarios: *UGSM* (Ortega y col., 2013), *MFGU* (Ortega y col., 2016), *C&P* (Boratto, Carta y Fenu, 2017), *RWR – M* (Feng y Cao, 2017) y *RANK* (Baltrunas, Makcinskas y Ricci, 2010). Los parámetros de los experimentos se muestran en la Tabla 4.5. La Fig. 4.3 muestra los resultados de calidad de recomendación. Cada función en la Fig. 4.3 se obtiene a través de los resultados desde 1 hasta 10 recomendaciones. Los experimentos han sido realizados para grupos pequeños de 2 a 5 usuarios (lado izquierdo de la figura) y grupos grandes de 6 a 10 usuarios (lado derecho de la figura).

La Fig. 4.3 muestra la **superioridad de la medida de similaridad propuesta para la mayoría de los resultados de la calidad de recomendación** ($precision@λ$) (cuanto mayor es $precision$, mejor es el resultado). Específicamente, en el dataset más grande: *MovieLens*, la mejora de los resultados ofrecidos por *SMGU* es claramente visible. *MFGU* es el baseline que, en grandes conjuntos de datos, compite mejor con el método propuesto; esto se debe a que, al ser un método basado en modelos, su diseño se adapta mejor a grandes volúmenes de datos. La medida de similaridad propuesta **no siempre obtiene los mejores resultados de Recall**; específicamente, en el dataset *MovieLens*, el método baseline *Rank* mejora a *SMGU* (la razón se explica más adelante). Como se esperaba, los resultados de los grupos pequeños tienden a ser mejores que los resultados de los grupos grandes, debido a la mayor variación de usuarios en grupos grandes.

El conjunto de experimentos realizado para cada dataset, para cada baseline y para la medida de similaridad propuesta ha sido replicado en cada una de las medidas de calidad: $precision@0,5$, $recall@0,5$, $precision@1,0$ y $recall@1,0$. El resultado de estos experimentos se presenta en las figuras 4.4 y 4.5. Los resultados cualitativos son similares a los explicados en ($precision@0,75$ y $recall@0,75$). Los resultados cuantitativos muestran el comportamiento esperado: cuanto más exigente es la calidad solicitada (por ejemplo: el valor más alto de $λ$), los resultados obtenidos de *Precision* y *Recall* serán más bajos.

El método propuesto *SMGU* en su mayoría mejora los resultados del mejor baseline *MFGU* en: *Precision* y *Recall*. Sin embargo, el *Recall* de *SMGU* no siempre es el más apropiado (Fig. 4.3). Nuestro método propuesto obtiene mejores resultados en *Precision* que en *Recall*. La pregunta que surge es la importancia y el significado de cada una de estas medidas de calidad de recomendación. Simplificando, podemos asociar la medida *Precision* con un valor de calidad absoluto, y la medida *Recall* con un valor relativo de calidad: la primera mide el éxito con respecto a un número fijo de recomendaciones, mientras que la segunda mide el éxito con respecto al número de casos en los que es apropiado recomendar. La medida *Precision* se centra en las cantidades (precisión, efectividad) mientras que *Recall* se centra en las cualidades (si realiza recomendaciones complicadas). En resumen, podemos determinar que el método propuesto *SMGU* y el principal baseline *MFGU* son precisos

FIGURA 4.3: Resultados de recomendación a grupos. $\lambda = 0,75$

Precision y *Recall* con una proporción del 75 % de usuarios del grupo que les gustan los ítems recomendados. Datasets *MovieLens*, *FilmTrust* y *BookCrossing*. Número de recomendaciones: 10. Pruebas para grupos pequeños (lado izquierdo) y grupos grandes (lado derecho). Método propuesto: *SMGU*. Baselines: *UGSM* (Ortega y col., 2013), *MFGU* (Ortega y col., 2016), *C&P* (Boratto, Carta y Fenu, 2017), *RWR - M* (Feng y Cao, 2017) y *RANK* (Baltrunas, Makcinskas y Ricci, 2010). Los parámetros de los experimentos se muestran en la Tabla 4.5. Cuanto mayor sea el valor, mejor será el resultado (Para precision & recall).

(un gran número de recomendaciones son correctas), aunque no siempre brindan las recomendaciones más complejas; por ejemplo: al utilizar *MovieLens*, *Rank* obtiene buenos resultados de *Recall*. Cuando se desea hacer una recomendación a un grupo de usuarios, es mejor tener un valor alto de *precision* que un buen *recall*, ya que intentamos maximizar la probabilidad de que a los usuarios del grupo les guste el ítem recomendado.

La Fig. 4.3 muestra los resultados de *Precision* y *Recall* en el rango del número de recomendaciones desde dos (lado izquierdo de cada función) hasta diez (lado derecho de cada función). Podemos observar que, para el dataset *MovieLens*, *SMGU* proporciona los mejores resultados de *Recall* cuando el número de recomendaciones es bajo. Cuando el número de recomendaciones no es bajo, *Rank* proporciona los mejores resultados en *Recall*. *MFGU* no mejora nuestra medida de similaridad propuesta, ni en *Precision*, ni en *Recall*.

FIGURA 4.4: Resultados de recomendación a grupos. $\lambda = 0,5$

Precision y *Recall* con una proporción del 50 % de usuarios del grupo que les gustan los ítems recomendados. Datasets *MovieLens*, *FilmTrust* y *BookCrossing*. Número de recomendaciones: 10. Pruebas para grupos pequeños (lado izquierdo) y grupos grandes (lado derecho). Método propuesto: *SMGU*. Baselines: *UGSM* (Ortega y col., 2013), *MFGU* (Ortega y col., 2016), *C&P* (Boratto, Carta y Fenu, 2017), *RWR – M* (Feng y Cao, 2017) y *RANK* (Baltrunas, Makcinskas y Ricci, 2010). Los parámetros de los experimentos se muestran en la Tabla 4.5. Cuanto mayor sea el valor, mejor será el resultado (Para precision & recall).

4.2.3 Discusión

La medida de similitud propuesta para grupos de usuarios *SMGU* tiene ventajas importantes, pero también algunos inconvenientes que deben analizarse y dar la importancia que merecen. La principal ventaja de *SMGU* es su superioridad en la calidad de predicción y también en la calidad de recomendación, medidas respectivamente, con las medidas de calidad R_MAE y $Precision@λ$.

Las ventajas adicionales de *SMGU* son: a) Mantiene los mejores resultados para los diferentes tamaños de grupos, b) Mejora los resultados de los *baselines* cuando se aplica a conjuntos de datos con diferentes tamaños y diversidades, y c) Recomienda adecuadamente tanto cuando se requiere un reducido número de recomendaciones como cuando se necesita un número mayor.

FIGURA 4.5: Resultados de recomendación a grupos. $\lambda = 1$

Precision y *Recall* con una proporción del 100 % de usuarios del grupo que les gustan los ítems recomendados. Datasets *MovieLens*, *FilmTrust* y *BookCrossing*. Número de recomendaciones: 10. Pruebas para grupos pequeños (lado izquierdo) y grupos grandes (lado derecho). Método propuesto: *SMGU*. Baselines: *UGSM* (Ortega y col., 2013), *MFGU* (Ortega y col., 2016), *C&P* (Boratto, Carta y Fenu, 2017), *RWR - M* (Feng y Cao, 2017) y *RANK* (Baltrunas, Makcinskas y Ricci, 2010). Los parámetros de los experimentos se muestran en la Tabla 4.5. Cuanto mayor sea el valor, mejor será el resultado (Para precision & recall).

Una característica interesante de *SMGU* es su capacidad para ponderar la importancia de la información numérica de los votos con la información no numérica. Este mecanismo de ponderación también sirve para adaptarse al número de vecinos seleccionados en *CF* en el proceso de recomendación y para mantener altos niveles de accuracy. El concepto de singularidad se usa intensivamente en *SMGU*. Este concepto ha demostrado proporcionar buenos resultados en la recomendación a usuarios individuales. En este documento, se muestra que el concepto de singularidad se ajusta bien a las particularidades de la recomendación a grupos de usuarios.

SMGU es una medida de similaridad basada en memoria. La mayoría de los artículos publicados ofrecen soluciones basadas en memoria para recomendaciones a grupos de usuarios, pero el método *MFGU* es basado en modelos. La discusión entre métodos basados en memoria y métodos basados en modelos para grupos de

usuarios, es la misma que en la recomendación a usuarios individuales: cada enfoque tiene sus ventajas y desventajas. Sin embargo, mientras que en la recomendación a usuarios individuales, los métodos basados en modelos suelen ofrecer una mejor accuracy, en nuestro caso la medida de similaridad *SMGU* basada en memoria, mejora los resultados del método *MFGU*.

Capítulo 5

Conclusiones y trabajo futuro

Este capítulo concluye los esfuerzos de investigación hacia CF GRS basados en KNN. Primeramente, se destacan las contribuciones de esta tesis: 1) se proporciona un estado del arte sobre los sistemas de recomendación orientados a grupos de usuarios para facilitar futuras investigaciones; 2) también se propone un método que mediante una nueva medida de similaridad para grupos de usuarios mejora los resultados en comparación al estado del arte. Al final de este capítulo, se plantean trabajos futuros basados en algunas nuevas tendencias en CF GRS.

Se ha orientado la investigación a GRS basados en filtrado colaborativo debido a que es el filtrado que mejores resultados ha logrado, sin necesidad de un proceso costoso de recolección de información. Se ha propuesto un método GRS CF basado en KNN debido a las siguientes razones: los enfoques basados en KNN son superiores en su capacidad para explicar las recomendaciones contra los enfoques basados en modelos (Tintarev y Masthoff, 2011), además los enfoques basados en KNN tienen una ruta prometedora para mejorar los resultados de métodos basados en memoria como (Ortega y col., 2013) y de métodos basados en modelos como (Ortega y col., 2016).

En el estado del arte hemos presentado las clasificaciones más populares de los sistemas de recomendación dirigidos a grupos de usuarios. Hemos identificado que existen diversos GRS dependiendo de sus características, como: la fuente de su información, interacción con el usuario, dominio, salida, tamaño y enfoque de agregación para hacer las recomendaciones. La clasificación de GRS más común y de mayor interés científico es con respecto al enfoque de agregación. Existen cuatro tipos de enfoques: fusión de recomendaciones, agregación de predicciones individuales, intersección de vecinos y agregación de preferencias de usuarios (related users).

El rendimiento de los GRS está relacionado al momento en que se realiza la agregación (Ortega y col., 2013). Esto debido a que antes de la agregación existen muchos procesos diferenciados para cada usuario. Desde la agregación desaparecen esos procesos diferenciados y se lleva un proceso de filtrado colaborativo para el grupo (específicamente para el usuario virtual). Por esta razón, el enfoque de agregación de preferencias individuales es el enfoque que actualmente logra los mejores resultados en tiempo de ejecución y en *accuracy*, puesto que la agregación se realiza en una etapa temprana del KNN sin afectar la calidad de recomendaciones. Este enfoque sigue el siguiente proceso: mediante alguna agregación de preferencias individuales se obtiene un usuario virtual (usuario representativo del grupo), posteriormente continúa el proceso KNN obteniéndose los vecinos más similares al usuario virtual mediante alguna medida de similaridad para grupos de usuarios, y finalmente, se calculan las predicciones y recomendaciones al grupo. Precisamente, nosotros hemos propuesto un método basado en el enfoque de agregación de preferencias de usuarios. En nuestro caso, para obtener los vecinos más similares hemos propuesto una nueva medida de similaridad para recomendar a grupos de usuarios que combina información estructural con información numérica ponderada por singularidades. Los pesos de las singularidades mejoran la calidad de las predicciones y recomendaciones simplemente usando los valores de los votos numéricos regulares. Para cada ítem procesado, proporcionamos tres parámetros diferentes para ponderar la información numérica: 1) Singularidad de los votos del grupo, 2) Singularidad de los votos de los usuarios, y 3) Número de usuarios en el grupo que han votado un ítem. Análogamente, la información no numérica se pondera atendiendo a la popularidad de los ítems.

El estado del arte y el método creado permiten resaltar las principales contribuciones de esta tesis que son: en primer lugar, un estado del arte sobre los sistemas de recomendación orientados a grupos de usuarios para facilitar futuras investigaciones, se hace especial énfasis en filtrado colaborativo, también se presentan tendencias de investigación de RS en general y específicamente de GRS para ayudar a los lectores a ponerse al día con las fronteras de la investigación. En segundo lugar, un método de recomendación a grupos de usuarios que logra una mejor calidad de predicción

y recomendación comparándolo con diversos baselines de referencia. Por lo tanto, el método propuesto se presenta como el más apropiado actualmente para cumplir diversos objetivos y restricciones: a) sistemas de recomendación basados en KNN para grupos de usuarios, b) sistemas que proporcionan recomendaciones continuamente actualizadas, c) explicación de recomendaciones al grupo debido a la superioridad de los enfoques de KNN para explicar las recomendaciones contra los enfoques basados en modelos. El método creado se centra en la suposición de que la singularidad de las evaluaciones emitidas por los usuarios del grupo es una información relevante para encontrar vecinos adecuados. Los resultados confirman esta hipótesis tanto para los resultados de predicción como para los resultados de recomendación.

La recomendación a grupos de usuarios es un área abierta de investigación. Aparte de los desafíos generales (*cold-start*, gran escala de datos, control del ruido, dispersión, escalabilidad, diversidad, novedad, serendipia, etc.) de los sistemas de recomendación basados en filtrado colaborativo, un GRS tiene otros desafíos particulares, entre los cuales podemos mencionar: controlar la diversidad de grupos, la negociación entre miembros para la decisión final (*decision-making*), tiempo de respuesta para generar recomendaciones, la explicación de las recomendaciones grupales, la estandarización de su evaluación, etc.

Existen varios *frameworks* de sistemas de recomendación (Jung, 2012; Sun y col., 2017; Ortega y col., 2018a) en los cuales las medidas de calidad de predicción y recomendación están bien definidas; sin embargo, un inconveniente es la ausencia de estandarización de las medidas de evaluación en aspectos como novedad, serendipia, diversidad, etc. (Bobadilla y col., 2013a). La evaluación en GRS tiene un mayor desafío, puesto que todavía presenta un campo muy amplio por explorar y estandarizar.

A partir de los desafíos de GRS se proponen los siguientes trabajos futuros:

- Medir la calidad de las recomendaciones a un grupo de usuarios es una tarea compleja, no puede ser vista como el promedio de los usuarios pertenecientes al grupo. Para establecer el proceso de evaluación se definirán nuevas medidas de calidad para validar el accuracy de las predicciones grupales.
- Estudiar más allá de los resultados de calidad de accuracy (tales como: novedad, diversidad y serendipia) para cada miembro del grupo.
- Crear estándares y un *framework* común de evaluación de la calidad de los GRS para que los desarrolladores puedan diseñar mejores estrategias y para que la industria pueda seleccionar la mejor.
- Mejorar la medida de similaridad propuesta incorporando nuevos elementos para procesar la similaridad entre los grupos y los candidatos vecinos.
- Explicar las recomendaciones al grupo según los valores de similaridad y los pesos de singularidad.
- Incorporar pesos de singularidad en el proceso de factorización matricial para mejorar la recomendación basada en MF a grupos de usuarios.
- Incluir factores sociales al proceso de la recomendación.
- Estudiar las situaciones de *cold-start* en las recomendaciones. Basándonos en (Masthoff, 2015), podemos crear enfoques de recomendaciones grupales que

pueden ayudar a las recomendaciones individuales aliviando el problema del cold-start.

- En este documento nos hemos centrado en grupos heterogéneos con un tamaño entre 2 a 10 usuarios. A futuro esperamos crear un GRS para grupos de usuarios homogéneos detectados mediante técnicas de *clustering*, además utilizar métodos de reducción de dimensionalidad para realizar *clustering* a partir de matrices densas.
- Crear GRS generalistas mediante la inclusión de taxonomías y ontologías.
- Crear un sistema de recomendación de secuencias de ítems, bundles, paquetes a grupos de usuarios.
- Avanzar a la nueva generación de GRS desarrollando un modelo basado en *Matrix Factorization* capaz de proveer recomendaciones a grupos de usuarios, y no adaptar modelos de recomendación individual. Un enfoque basado en MF generalmente genera resultados rápidamente; por otro lado, requiere un gran tiempo de aprendizaje para generar el modelo.
- Incluir en el mismo modelo de factorización las preferencias de los grupos y de los usuarios. El modelo debe ser capaz de hacer recomendaciones a grupos y a usuarios individuales, además debe establecer la evaluación de la satisfacción individual y grupal.

Apéndice A

Listado de publicaciones del autor

Esta tesis PhD es el resultado de varios años de investigación en el área de sistemas de recomendación. Este trabajo ha dado lugar a 5 artículos indexados en JCR y 3 publicaciones en congreso. En esta tesis PhD yo presento los resultados de uno de los artículos más prominentes, siendo este:

Artículo: Ortega, F., **Hurtado, R.**, Bobadilla, J. y Bojorque, R. (2018). «Recommendation to Groups of Users Using the Singularities Concept». En: IEEE Access 6, págs. 39745-39761. ISSN: 2169-3536. DOI: <https://doi.org/10.1109/ACCESS.2018.2853107>

Factor de impacto: 4.098 (Q1)

La siguiente lista contiene mis demás publicaciones relacionadas a sistemas de recomendación:

Artículo: **Hurtado, R.**, Bobadilla, J., Bojorque, R., Ortega, F., y Li, X. (2019). «A new recommendation approach based on probabilistic soft clustering methods. A scientific documentation case study». En: IEEE Access 7, págs. 7522-7534. ISSN: 2169-3536. DOI: <https://doi.org/10.1109/ACCESS.2018.2890079>

Factor de impacto: 4.098 (Q1)

Artículo: Bobadilla, J., Bojorque, R., Esteban, A. H. y **Hurtado, R.** (2018). «Recommender Systems Clustering Using Bayesian Non Negative Matrix Factorization». En: IEEE Access 6, págs. 3549-3564. ISSN: 2169-3536. DOI: <https://doi.org/10.1109/ACCESS.2017.2788138>

Factor de impacto: 4.098 (Q1)

Artículo: Zhu, B., **Hurtado, R.**, Bobadilla, J. y Ortega, F. (2018). «An efficient recommender system method based on the numerical relevances and the non-numerical structures of the ratings». En: IEEE Access 6, págs. 49935-49954. ISSN: 2169-3536. DOI: <https://doi.org/10.1109/ACCESS.2018.2868464>

Factor de impacto: 4.098 (Q1)

Artículo: Ortega, F., Bobadilla, J., Gutiérrez, A., **Hurtado, R.** y Li, X. (2018). «Artificial Intelligence Scientific Documentation Dataset for Recommender Systems». En: IEEE Access 6, pág. 48543-48555. ISSN: 2169-3536. DOI: <https://doi.org/10.1109/ACCESS.2018.2867731>

Factor de impacto: 4.098 (Q1)

Artículo: **Hurtado, R.**, Bojorque, R. e Inga, C. (2019). «Clustering-Based Recommender System: Bundle Recommendation Using Matrix Factorization to Single User and

User Communities». En: Ahram T. (eds) *Advances in Artificial Intelligence, Software and Systems Engineering*. AHFE 2018. *Advances in Intelligent Systems and Computing* 787. págs. 330-338. Springer, Cham. ISBN: 978-3-319-94229-2.

DOI: https://doi.org/10.1007/978-3-319-94229-2_32

Artículo: Inga, C., Bojorque, R. y **Hurtado, R.** (2019). «Hierarchical Clustering for Collaborative Filtering Recommender Systems». En: Ahram T. (eds) *Advances in Artificial Intelligence, Software and Systems Engineering*. AHFE 2018. *Advances in Intelligent Systems and Computing* 787. págs. 346-355. Springer, Cham. ISBN: 978-3-319-94229-2. DOI: https://doi.org/10.1007/978-3-319-94229-2_34

Artículo: Bojorque, R., **Hurtado, R.** e Inga A. (2019). «A Comparative Analysis of Similarity Metrics on Sparse Data for Clustering in Recommender Systems». En: Ahram T. (eds) *Advances in Artificial Intelligence, Software and Systems Engineering*. AHFE 2018. *Advances in Intelligent Systems and Computing* 787. págs. 291-299. Springer, Cham. ISBN: 978-3-319-94229-2.

DOI: https://doi.org/10.1007/978-3-319-94229-2_28

Artículo: **Hurtado, R.**, Merchán, D. y Enriquez, A. (2019). «A new way to finding better neighbors in recommendation systems based on collaborative filtering». En: IEEE Autumn Meeting on Power, Electronics and Computing (ROPEC 2019). "to be published"

Artículo: Vega, B., **Hurtado, R.** y Morales, D. (2019). «A new approach hybrid recommender system of item bundles for group of users». En: IEEE Autumn Meeting on Power, Electronics and Computing (ROPEC 2019). "to be published"

Bibliografía

- Agarwal, Akshita, Manajit Chakraborty y C. Ravindranath Chowdary (2017). «Does order matter? Effect of order in group recommendation». En: *Expert Systems with Applications* 82, págs. 115 -127. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.03.069>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417417302294>.
- Al-Shamri, Mohammad Yahya H. (2016). «User profiling approaches for demographic recommender systems». En: *Knowledge-Based Systems* 100, págs. 175 -187. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2016.03.006>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705116001192>.
- Al-Shamri, Mohammad Yahya H. y Kamal K. Bharadwaj (2008). «Fuzzy-genetic approach to recommender systems based on a novel hybrid user model». En: *Expert Systems with Applications* 35.3, págs. 1386 -1399. ISSN: 0957-4174. DOI: <http://dx.doi.org/10.1016/j.eswa.2007.08.016>. URL: <http://www.sciencedirect.com/science/article/pii/S095741740700351X>.
- Ali, Farman, S.M. Riazul Islam, Daehan Kwak, Pervez Khan, Niamat Ullah, Sang jo Yoo y K.S. Kwak (2018). «Type-2 fuzzy ontology-aided recommendation systems for IoT-based healthcare». En: *Computer Communications* 119, págs. 138 -155. ISSN: 0140-3664. DOI: <https://doi.org/10.1016/j.comcom.2017.10.005>. URL: <http://www.sciencedirect.com/science/article/pii/S0140366417310587>.
- Amer-Yahia, Sihem, Senjuti Basu Roy, Ashish Chawlat, Gautam Das y Cong Yu (ago. de 2009). «Group Recommendation: Semantics and Efficiency». En: *Proc. VLDB Endow.* 2.1, págs. 754-765. ISSN: 2150-8097. DOI: [10.14778/1687627.1687713](https://doi.org/10.14778/1687627.1687713). URL: <https://doi.org/10.14778/1687627.1687713>.
- Ardissono, L., A. Goy, G. Petrone, M. Segnan y P. Torasso (2002). «Tailoring the Recommendation of Tourist Information to Heterogeneous User Groups». En: *Hypermedia: Openness, Structural Awareness, and Adaptivity*. Ed. por Siegfried Reich, Manolis M. Tzagarakis y Paul M. E. De Bra. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 280-295. ISBN: 978-3-540-45844-9.
- Ardissono, Liliana (2003). «Intrigue: Personalized Recommendation of Tourist Attractions for Desktop and Handset Devices». En:
- Ardissono, Liliana, Anna Goy, Giovanna Petrone y Marino Segnan (feb. de 2005). «A Multi-agent Infrastructure for Developing Personalized Web-based Systems». En: *ACM Trans. Internet Technol.* 5.1, págs. 47-69. ISSN: 1533-5399. DOI: [10.1145/1052934.1052936](https://doi.org/10.1145/1052934.1052936). URL: <http://doi.acm.org/10.1145/1052934.1052936>.
- Baltrunas, Linas, Tadas Makcinskas y Francesco Ricci (2010). «Group Recommendations with Rank Aggregation and Collaborative Filtering». En: *Proceedings of the Fourth ACM Conference on Recommender Systems*. RecSys '10. New York, NY, USA: ACM, págs. 119-126. ISBN: 978-1-60558-906-0. DOI: [10.1145/1864708.1864733](https://doi.org/10.1145/1864708.1864733). URL: <http://doi.acm.org/10.1145/1864708.1864733>.

- Bao, Yang, Hui Fang y Jie Zhang (2014). «TopicMF: Simultaneously Exploiting Ratings and Reviews for Recommendation». En: *28th AAAI conference on artificial intelligence*. Vol. 14, págs. 2-8.
- Bekkerman, Pavel, Sarit Kraus y Francesco Ricci (2006). «Applying cooperative negotiation methodology to group recommendation problem». En: *Proceedings of Workshop on Recommender Systems in 17th European Conference on Artificial Intelligence (ECAI 2006)*, págs. 72-75.
- Beliakov, Gleb, Tomasa Calvo y Simon James (2015). «Aggregation Functions for Recommender Systems». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach y Bracha Shapira. Boston, MA: Springer US, págs. 777-808. ISBN: 978-1-4899-7637-6. DOI: [10.1007/978-1-4899-7637-6_23](https://doi.org/10.1007/978-1-4899-7637-6_23). URL: https://doi.org/10.1007/978-1-4899-7637-6_23.
- Ben Ahmed, Eya, Wafa Tebourski, Wahiba Ben Abdesslem Karaa y Faïez Gargouri (dic. de 2015). «SMART: Semantic multidimensional group recommendations». En: *Multimedia Tools and Applications* 74.23, págs. 10419-10437. ISSN: 1573-7721. DOI: [10.1007/s11042-014-2174-0](https://doi.org/10.1007/s11042-014-2174-0). URL: <https://doi.org/10.1007/s11042-014-2174-0>.
- Berkovsky, Shlomo y Jill Freyne (2010). «Group-based Recipe Recommendations: Analysis of Data Aggregation Strategies». En: *Proceedings of the Fourth ACM Conference on Recommender Systems*. RecSys '10. New York, NY, USA: ACM, págs. 111-118. ISBN: 978-1-60558-906-0. DOI: [10.1145/1864708.1864732](https://doi.org/10.1145/1864708.1864732). URL: <http://doi.acm.org/10.1145/1864708.1864732>.
- Berkovsky, Shlomo, Jill Freyne y Mac Coombe (2009). «Aggregation Trade Offs in Family Based Recommendations». En: *AI 2009: Advances in Artificial Intelligence*. Ed. por Ann Nicholson y Xiaodong Li. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 646-655. ISBN: 978-3-642-10439-8.
- Birmingham, Adam, Julia O'Rourke, Cathal Gurrin, Ronan Collins, Kate Irving y Alan F. Smeaton (2013). «Automatically Recommending Multimedia Content for Use in Group Reminiscence Therap». En: *Proceedings of the 1st ACM International Workshop on Multimedia Indexing and Information Retrieval for Healthcare*. MIIRH '13. Barcelona, Spain: ACM, págs. 49-58. ISBN: 978-1-4503-2398-7. DOI: [10.1145/2505323.2505333](https://doi.org/10.1145/2505323.2505333). URL: <http://doi.acm.org/10.1145/2505323.2505333>.
- Bobadilla, J., F. Serradilla y J. Bernal (2010). «A new collaborative filtering metric that improves the behavior of recommender systems». En: *Knowledge-Based Systems* 23.6, págs. 520 -528. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2010.03.009>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705110000444>.
- Bobadilla, J., F. Ortega, A. Hernando y A. Gutiérrez (2013a). «Recommender systems survey». En: *Knowledge-Based Systems* 46, págs. 109 -132. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2013.03.012>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705113001044>.
- Bobadilla, J., R. Bojorque, A. Hernando Esteban y R. Hurtado (2018). «Recommender Systems Clustering Using Bayesian Non Negative Matrix Factorization». En: *IEEE Access* 6, págs. 3549-3564. DOI: [10.1109/ACCESS.2017.2788138](https://doi.org/10.1109/ACCESS.2017.2788138).
- Bobadilla, Jesús, Fernando Ortega, Antonio Hernando y Ángel Arroyo (2012a). «A balanced memory-based collaborative filtering similarity measure». En: *International Journal of Intelligent Systems* 27.10, págs. 939-946. DOI: [10.1002/int.21556](https://doi.org/10.1002/int.21556). eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/int.21556>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/int.21556>.

- Bobadilla, Jesús, Fernando Ortega y Antonio Hernando (2012). «A collaborative filtering similarity measure based on singularities». En: *Information Processing & Management* 48.2, págs. 204 -217. ISSN: 0306-4573. DOI: <https://doi.org/10.1016/j.ipm.2011.03.007>. URL: <http://www.sciencedirect.com/science/article/pii/S0306457311000409>.
- Bobadilla, Jesus y Francisco Serradilla (2009). «The Effect of Sparsity on Collaborative Filtering Metrics». En: *Proceedings of the Twentieth Australasian Conference on Australasian Database - Volume 92*. ADC '09. Wellington, New Zealand: Australian Computer Society, Inc., págs. 9-18. ISBN: 978-1-920682-73-6. URL: <http://dl.acm.org/citation.cfm?id=1862681.1862686>.
- Bobadilla, Jesús, Fernando Ortega, Antonio Hernando y Jesús Bernal (2012b). «A collaborative filtering approach to mitigate the new user cold start problem». En: *Knowledge-Based Systems* 26, págs. 225-238.
- Bobadilla, Jesús, Fernando Ortega, Antonio Hernando y Jesús Bernal (2012c). «Generalization of recommender systems: Collaborative filtering extended to groups of users and restricted to groups of items». En: *Expert Systems with Applications* 39.1, págs. 172 -186. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2011.07.005>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417411009675>.
- Bobadilla, Jesús, Fernando Ortega, Antonio Hernando y Guillermo Glez de Rivera (2013b). «A similarity metric designed to speed up, using hardware, the recommender systems k-nearest neighbors algorithm». En: *Knowledge-Based Systems* 51, págs. 27 -34. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2013.06.010>. URL: <http://www.sciencedirect.com/science/article/pii/S095070511300186X>.
- Bojorque, Rodolfo, Remigio Hurtado y Andrés Inga (2019). «A Comparative Analysis of Similarity Metrics on Sparse Data for Clustering in Recommender Systems». En: *Advances in Artificial Intelligence, Software and Systems Engineering*. Ed. por Tareq Z. Ahram. Cham: Springer International Publishing, págs. 291-299. ISBN: 978-3-319-94229-2.
- Bojorque Chasi, Rodolfo Xavier y Remigio Ismael Hurtado Ortiz (2017). «Técnicas híbridadas en sistemas de recomendación para optimizar el modelo non negative matrix factorization». Tesis doct. ETSI_Sistemas_Infor. URL: <http://oa.upm.es/48249/>.
- Boratto, Ludovico y Salvatore Carta (2011). «State-of-the-Art in Group Recommendation and New Approaches for Automatic Identification of Groups». En: *Information Retrieval and Mining in Distributed Environments*. Ed. por Alessandro Soro, Eloisa Vargiu, Giuliano Armano y Gavino Paddeu. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 1-20. ISBN: 978-3-642-16089-9. DOI: [10.1007/978-3-642-16089-9_1](https://doi.org/10.1007/978-3-642-16089-9_1). URL: https://doi.org/10.1007/978-3-642-16089-9_1.
- (2015a). «ART: group recommendation approaches for automatically detected groups». En: *International Journal of Machine Learning and Cybernetics* 6.6, págs. 953-980. ISSN: 1868-808X. DOI: [10.1007/s13042-015-0371-4](https://doi.org/10.1007/s13042-015-0371-4). URL: <https://doi.org/10.1007/s13042-015-0371-4>.
- (2015b). «The rating prediction task in a group recommender system that automatically detects groups: architectures, algorithms, and performance evaluation». En: *Journal of Intelligent Information Systems* 45.2, págs. 221-245. ISSN: 1573-7675. DOI: [10.1007/s10844-014-0346-z](https://doi.org/10.1007/s10844-014-0346-z). URL: <https://doi.org/10.1007/s10844-014-0346-z>.

- Boratto, Ludovico, Salvatore Carta y Gianni Fenu (2017). «Investigating the role of the rating prediction task in granularity-based group recommender systems and big data scenarios». En: *Information Sciences* 378, págs. 424 -443. ISSN: 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2016.07.060>. URL: <http://www.sciencedirect.com/science/article/pii/S0020025516305424>.
- Breese, John S, D Heckerman y Carl Kadie (1998). «Empirical analysis of predictive algorithms for collaborative filtering». En: *Proceedings of the 14th conference on Uncertainty in Artificial Intelligence* 461.8, págs. 43-52. ISSN: 15532712. DOI: [10.1111/j.1553-2712.2011.01172.x](https://doi.org/10.1111/j.1553-2712.2011.01172.x).
- Campos, Luis M., Juan M. Fernández-Luna, Juan F. Huete y Miguel A. Rueda-Morales (ago. de 2009). «Managing Uncertainty in Group Recommending Processes». En: *User Modeling and User-Adapted Interaction* 19.3, págs. 207-242. ISSN: 0924-1868. DOI: [10.1007/s11257-008-9061-1](https://doi.org/10.1007/s11257-008-9061-1). URL: <http://dx.doi.org/10.1007/s11257-008-9061-1>.
- Campos, Luis M de, Juan M. Fernández-luna, Juan F. Huete y Miguel A. Rueda-morales (2010). «Combining content-based and collaborative recommendations: A hybrid approach based on Bayesian networks». En: *International Journal of Approximate Reasoning* 51.7, págs. 785-799. ISSN: 0888-613X. DOI: [10.1016/j.ijar.2010.04.001](https://doi.org/10.1016/j.ijar.2010.04.001). URL: <http://dx.doi.org/10.1016/j.ijar.2010.04.001>.
- Campos, Pedro G., Fernando Díez e Iván Cantador (2014). «Time-aware recommender systems: a comprehensive survey and analysis of existing evaluation protocols». En: *User Modeling and User-Adapted Interaction* 24.1, págs. 67-119. ISSN: 1573-1391. DOI: [10.1007/s11257-012-9136-x](https://doi.org/10.1007/s11257-012-9136-x). URL: <https://doi.org/10.1007/s11257-012-9136-x>.
- Cantador, Iván y Pablo Castells (2012). «Group Recommender Systems: New Perspectives in the Social Web». En: *Recommender Systems for the Social Web*. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 139-157. ISBN: 978-3-642-25694-3. DOI: [10.1007/978-3-642-25694-3_7](https://doi.org/10.1007/978-3-642-25694-3_7). URL: https://doi.org/10.1007/978-3-642-25694-3_7.
- Castro, Jorge, Raciél Yera y Luis Martínez (2017). «An empirical study of natural noise management in group recommendation systems». En: *Decision Support Systems* 94, págs. 1 -11. ISSN: 0167-9236. DOI: <https://doi.org/10.1016/j.dss.2016.09.020>. URL: <http://www.sciencedirect.com/science/article/pii/S0167923616301695>.
- (2018). «A fuzzy approach for natural noise management in group recommender systems». En: *Expert Systems with Applications* 94, págs. 237 -249. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.10.060>. URL: <http://www.sciencedirect.com/science/article/pii/S095741741730742X>.
- Castro, Jorge, Francisco J Quesada, Iván Palomares y Luis Martinez (2015). «A Consensus-Driven Group Recommender System». En: *International Journal of Intelligent Systems* 30.8, págs. 887-906. DOI: [10.1002/int.21730](https://doi.org/10.1002/int.21730). URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/int.21730>.
- Chalco, César Inga, Rodolfo Bojorque Chasi y Remigio Hurtado Ortiz (2019). «Hierarchical Clustering for Collaborative Filtering Recommender Systems». En: *Advances in Artificial Intelligence, Software and Systems Engineering*. Ed. por Tareq Z. Ahram. Cham: Springer International Publishing, págs. 346-356. ISBN: 978-3-319-94229-2.
- Chen, Shyi-Ming, Shou-Hsiung Cheng y Tsung-En Lin (2015). «Group decision making systems using group recommendations based on interval fuzzy preference relations and consistency matrices». En: *Information Sciences* 298, págs. 555 -567.

- ISSN: 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2014.11.027>. URL: <http://www.sciencedirect.com/science/article/pii/S0020025514011086>.
- Chen, Yen-Liang, Li-Chen Cheng y Ching-Nan Chuang (2008). «A group recommendation system with consideration of interactions among group members». En: *Expert Systems with Applications* 34.3, págs. 2082 -2090. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2007.02.008>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417407000863>.
- Chen, Yu y Pearl Pu (2013). «Cofeel: Using emotions to enhance social interaction in group recommender systems». En: *Alpine Rendez-Vous (ARV) 2013 Workshop on Tools and Technology for Emotion-Awareness in Computer Mediated Collaboration and Learning*.
- Cheng, Shou-Hsiung, Shyi-Ming Chen y Zhi-Cheng Huang (2016). «Autocratic decision making using group recommendations based on ranking interval type-2 fuzzy sets». En: *Information Sciences* 361-362, págs. 135 -161. ISSN: 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2016.04.035>. URL: <http://www.sciencedirect.com/science/article/pii/S0020025516302845>.
- Christensen, I. y S. Schiaffino (nov. de 2013). «Matrix Factorization in Social Group Recommender Systems». En: *2013 12th Mexican International Conference on Artificial Intelligence*, págs. 10-16. DOI: [10.1109/MICAI.2013.7](https://doi.org/10.1109/MICAI.2013.7).
- Christensen, Ingrid A. y Silvia Schiaffino (2011). «Entertainment recommender systems for group of users». En: *Expert Systems with Applications* 38.11, págs. 14127 -14135. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2011.04.221>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417411007482>.
- Crossen, Andrew, Jay Budzik y Kristian J. Hammond (2002). «Flytrap: Intelligent Group Music Recommendation». En: *Proceedings of the 7th International Conference on Intelligent User Interfaces*. IUI '02. San Francisco, California, USA: ACM, págs. 184-185. ISBN: 1-58113-459-2. DOI: [10.1145/502716.502748](https://doi.org/10.1145/502716.502748). URL: <http://doi.acm.org/10.1145/502716.502748>.
- De Carolis, Berardina (2011). «Adapting News and Advertisements to Groups». En: *Pervasive Advertising*. Ed. por Jörg Müller, Florian Alt y Daniel Michelis. London: Springer London, págs. 227-246. ISBN: 978-0-85729-352-7. DOI: [10.1007/978-0-85729-352-7_11](https://doi.org/10.1007/978-0-85729-352-7_11). URL: https://doi.org/10.1007/978-0-85729-352-7_11.
- De Pessemier, Toon, Simon Doooms y Luc Martens (2012). «Design and Evaluation of a Group Recommender System». En: *Proceedings of the Sixth ACM Conference on Recommender Systems*. RecSys '12. Dublin, Ireland: ACM, págs. 225-228. ISBN: 978-1-4503-1270-7. DOI: [10.1145/2365952.2366000](https://doi.org/10.1145/2365952.2366000). URL: <http://doi.acm.org/10.1145/2365952.2366000>.
- (2014). «Comparison of group recommendation algorithms». En: *Multimedia Tools and Applications* 72.3, págs. 2497-2541. ISSN: 1573-7721. DOI: [10.1007/s11042-013-1563-0](https://doi.org/10.1007/s11042-013-1563-0). URL: <https://doi.org/10.1007/s11042-013-1563-0>.
- Dwivedi, Pragya y Kamal K. Bharadwaj (2015). «e-Learning recommender system for a group of learners based on the unified learner profile approach». En: *Expert Systems* 32.2, págs. 264-276. DOI: [10.1111/exsy.12061](https://doi.org/10.1111/exsy.12061). URL: <https://onlinelibrary.wiley.com/doi/abs/10.1111/exsy.12061>.
- Eirinaki, Magdalini, Jerry Gao, Iraklis Varlamis y Konstantinos Tserpes (2018). «Recommender Systems for Large-Scale Social Networks: A review of challenges and solutions». En: *Future Generation Computer Systems* 78, págs. 413 -418. ISSN: 0167-739X. DOI: <https://doi.org/10.1016/j.future.2017.09>.

015. URL: <http://www.sciencedirect.com/science/article/pii/S0167739X17319684>.
- Elahi, Mehdi, Francesco Ricci y Neil Rubens (2016). «A survey of active learning in collaborative filtering recommender systems». En: *Computer Science Review* 20, págs. 29 -50. ISSN: 1574-0137. DOI: <https://doi.org/10.1016/j.cosrev.2016.05.002>. URL: <http://www.sciencedirect.com/science/article/pii/S1574013715300150>.
- Felfernig, Alexander, Christoph Zehentner, Gerald Ninaus, Harald Grabner, Walid Maalej, Dennis Pagano, Leopold Weninger y Florian Reinfrank (2012). «Group Decision Support for Requirements Negotiation». En: *Advances in User Modeling*. Ed. por Liliana Ardissono y Tsvi Kuflik. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 105-116. ISBN: 978-3-642-28509-7.
- Feng, Shanshan y Jian Cao (ene. de 2017). «Improving group recommendations via detecting comprehensive correlative information». En: *Multimedia Tools and Applications* 76.1, págs. 1355-1377. ISSN: 1573-7721. DOI: [10.1007/s11042-015-3135-y](https://doi.org/10.1007/s11042-015-3135-y). URL: <https://doi.org/10.1007/s11042-015-3135-y>.
- Freyne, Jill y Barry Smyth (2006). «Cooperating Search Communities». En: *Adaptive Hypermedia and Adaptive Web-Based Systems*. Ed. por Vincent P. Wade, Helen Ashman y Barry Smyth. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 101-110. ISBN: 978-3-540-34697-5.
- Gantner, Zeno, Steffen Rendle y Lars Schmidt-Thieme (2010). «Factorization Models for Context-/Time-aware Movie Recommendations». En: *Proceedings of the Workshop on Context-Aware Movie Recommendation*. CAMRa '10. Barcelona, Spain: ACM, págs. 14-19. ISBN: 978-1-4503-0258-6. DOI: [10.1145/1869652.1869654](https://doi.org/10.1145/1869652.1869654). URL: <http://doi.acm.org/10.1145/1869652.1869654>.
- Gao, L. y C. Li (2008). «Hybrid Personalized Recommended Model Based on Genetic Algorithm». En: *2008 4th International Conference on Wireless Communications, Networking and Mobile Computing*, págs. 1-4. DOI: [10.1109/WiCom.2008.2152](https://doi.org/10.1109/WiCom.2008.2152).
- García, Inma, Laura Sebastia y Eva Onaindia (2011). «On the design of individual and group recommender systems for tourism». En: *Expert Systems with Applications* 38.6, págs. 7683 -7692. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2010.12.143>. URL: <http://www.sciencedirect.com/science/article/pii/S095741741001506X>.
- García, Inma, Laura Sebastia, Eva Onaindia y Cesar Guzman (2009). «A Group Recommender System for Tourist Activities». En: *E-Commerce and Web Technologies*. Ed. por Tommaso Di Noia y Francesco Buccafurri. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 26-37. ISBN: 978-3-642-03964-5.
- García, Inma, Laura Sebastia, Sergio Pajares y Eva Onaindia (2010). «GRSK: A Generalist Recommender System.» En: *WEBIST (1)*, págs. 211-218.
- García, Inma, Sergio Pajares, Laura Sebastia y Eva Onaindia (2012). «Preference elicitation techniques for group recommender systems». En: *Information Sciences* 189, págs. 155 -175. ISSN: 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2011.11.037>. URL: <http://www.sciencedirect.com/science/article/pii/S0020025511006220>.
- Ge, Mouzhi, Carla Delgado-Battenfeld y Dietmar Jannach (2010). «Beyond Accuracy: Evaluating Recommender Systems by Coverage and Serendipity». En: *Proceedings of the Fourth ACM Conference on Recommender Systems*. RecSys '10. Barcelona, Spain: ACM, págs. 257-260. ISBN: 978-1-60558-906-0. DOI: [10.1145/1864708.1864761](https://doi.org/10.1145/1864708.1864761). URL: <http://doi.acm.org/10.1145/1864708.1864761>.
- Gemmis, Marco de, Pasquale Lops, Cataldo Musto, Fedelucio Narducci y Giovanni Semeraro (2015). «Semantics-Aware Content-Based Recommender Systems». En:

- Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach y Bracha Shapira. Boston, MA: Springer US, págs. 119-159. ISBN: 978-1-4899-7637-6. DOI: [10.1007/978-1-4899-7637-6_4](https://doi.org/10.1007/978-1-4899-7637-6_4). URL: https://doi.org/10.1007/978-1-4899-7637-6_4.
- Ghazarian, Sarik y Mohammad Ali Nematbakhsh (2015). «Enhancing memory-based collaborative filtering for group recommender systems». En: *Expert Systems with Applications* 42.7, págs. 3801 -3812. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2014.11.042>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417414007386>.
- Golbeck, J. y J. Hendler (ene. de 2006). «FilmTrust: movie recommendations using trust in web-based social networks». En: *CCNC 2006. 2006 3rd IEEE Consumer Communications and Networking Conference, 2006*. Vol. 1, págs. 282-286. DOI: [10.1109/CCNC.2006.1593032](https://doi.org/10.1109/CCNC.2006.1593032).
- Gopalan, Prem, Jake M. Hofman y David M. Blei (2013). «Scalable Recommendation with Poisson Factorization». En: *CoRR* abs/1311.1704. arXiv: [1311.1704](https://arxiv.org/abs/1311.1704). URL: <http://arxiv.org/abs/1311.1704>.
- Groh, Georg, Stefan Birnkammerer y Valeria Köllhofer (2012). «Social Recommender Systems». En: *Recommender Systems for the Social Web*. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 3-42. ISBN: 978-3-642-25694-3. DOI: [10.1007/978-3-642-25694-3_1](https://doi.org/10.1007/978-3-642-25694-3_1). URL: https://doi.org/10.1007/978-3-642-25694-3_1.
- Guan, X., C. T. Li e Y. Guan (2017). «Matrix Factorization With Rating Completion: An Enhanced SVD Model for Collaborative Filtering Recommender Systems». En: *IEEE Access* 5, págs. 27668-27678. DOI: [10.1109/ACCESS.2017.2772226](https://doi.org/10.1109/ACCESS.2017.2772226).
- Harper, F. Maxwell y Joseph A. Konstan (dic. de 2015). «The MovieLens Datasets: History and Context». En: *ACM Trans. Interact. Intell. Syst.* 5.4, 19:1-19:19. ISSN: 2160-6455. DOI: [10.1145/2827872](https://doi.org/10.1145/2827872). URL: <http://doi.acm.org/10.1145/2827872>.
- Herlocker, Jonathan L., Joseph A. Konstan y John Riedl (2000). «Explaining Collaborative Filtering Recommendations». En: *Proceedings of the 2000 ACM Conference on Computer Supported Cooperative Work. CSCW '00*. Philadelphia, Pennsylvania, USA: ACM, págs. 241-250. ISBN: 1-58113-222-0. DOI: [10.1145/358916.358995](https://doi.org/10.1145/358916.358995). URL: <http://doi.acm.org/10.1145/358916.358995>.
- Herlocker, Jonathan L., Joseph A. Konstan, Loren G. Terveen y John T. Riedl (ene. de 2004). «Evaluating Collaborative Filtering Recommender Systems». En: *ACM Trans. Inf. Syst.* 22.1, págs. 5-53. ISSN: 1046-8188. DOI: [10.1145/963770.963772](https://doi.org/10.1145/963770.963772). URL: <http://doi.acm.org/10.1145/963770.963772>.
- Hernando, Antonio, Jesús Bobadilla y Fernando Ortega (2016). «A non negative matrix factorization for collaborative filtering recommender systems based on a Bayesian probabilistic model». En: *Knowledge-Based Systems* 97, págs. 188 -202. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2015.12.018>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705115005006>.
- Horváth, Tomáš y André C. P. L. F. de Carvalho (sep. de 2017). «Evolutionary computing in recommender systems: a review of recent research». En: *Natural Computing* 16.3, págs. 441-462. ISSN: 1572-9796. DOI: [10.1007/s11047-016-9540-y](https://doi.org/10.1007/s11047-016-9540-y). URL: <https://doi.org/10.1007/s11047-016-9540-y>.
- Hu, Xun, Xiangwu Meng y Licai Wang (2011). «SVD-based Group Recommendation Approaches: An Experimental Study of Moviepilot». En: *Proceedings of the 2Nd Challenge on Context-Aware Movie Recommendation*. CAMRa '11. New York, NY,

- USA: ACM, págs. 23-28. ISBN: 978-1-4503-0825-0. DOI: [10.1145/2096112.2096117](https://doi.org/10.1145/2096112.2096117). URL: <http://doi.acm.org/10.1145/2096112.2096117>.
- Hurtado, R., J. Bobadilla, R. Bojorque, F. Ortega y X. Li (2019). «A New Recommendation Approach Based on Probabilistic Soft Clustering Methods: A Scientific Documentation Case Study». En: *IEEE Access* 7, págs. 7522-7534. ISSN: 2169-3536. DOI: [10.1109/ACCESS.2018.2890079](https://doi.org/10.1109/ACCESS.2018.2890079).
- Jameson, Anthony (2004a). «More Than the Sum of Its Members: Challenges for Group Recommender Systems». En: *Proceedings of the Working Conference on Advanced Visual Interfaces*. AVI '04. Gallipoli, Italy: ACM, págs. 48-54. ISBN: 1-58113-867-9. DOI: [10.1145/989863.989869](https://doi.org/10.1145/989863.989869). URL: <http://doi.acm.org/10.1145/989863.989869>.
- (2004b). «More Than the Sum of Its Members: Challenges for Group Recommender Systems». En: *Proceedings of the Working Conference on Advanced Visual Interfaces*. AVI '04. Gallipoli, Italy: ACM, págs. 48-54. ISBN: 1-58113-867-9. DOI: [10.1145/989863.989869](https://doi.org/10.1145/989863.989869). URL: <http://doi.acm.org/10.1145/989863.989869>.
- Jameson, Anthony, Stephan Baldes y Thomas Kleinbauer (2003). «Enhancing mutual awareness in group recommender systems». En: *Proceedings of the IJCAI*.
- (2004). «Two Methods for Enhancing Mutual Awareness in a Group Recommender System». En: *Proceedings of the Working Conference on Advanced Visual Interfaces*. AVI '04. Gallipoli, Italy: ACM, págs. 447-449. ISBN: 1-58113-867-9. DOI: [10.1145/989863.989948](https://doi.org/10.1145/989863.989948). URL: <http://doi.acm.org/10.1145/989863.989948>.
- Jameson, Anthony y Barry Smyth (2007). «Recommendation to Groups». En: *The Adaptive Web: Methods and Strategies of Web Personalization*. Ed. por Peter Brusilovsky, Alfred Kobsa y Wolfgang Nejdl. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 596-627. ISBN: 978-3-540-72079-9. DOI: [10.1007/978-3-540-72079-9_20](https://doi.org/10.1007/978-3-540-72079-9_20). URL: https://doi.org/10.1007/978-3-540-72079-9_20.
- Jannach, Dietmar y Gediminas Adomavicius (2016). «Recommendations with a Purpose». En: *Proceedings of the 10th ACM Conference on Recommender Systems*. RecSys '16. Boston, Massachusetts, USA: ACM, págs. 7-10. ISBN: 978-1-4503-4035-9. DOI: [10.1145/2959100.2959186](https://doi.org/10.1145/2959100.2959186). URL: <http://doi.acm.org/10.1145/2959100.2959186>.
- Järvelin, Kalervo y Jaana Kekäläinen (oct. de 2002). «Cumulated Gain-based Evaluation of IR Techniques». En: *ACM Trans. Inf. Syst.* 20.4, págs. 422-446. ISSN: 1046-8188. DOI: [10.1145/582415.582418](https://doi.org/10.1145/582415.582418). URL: <http://doi.acm.org/10.1145/582415.582418>.
- Ji, Ke, Zhenxiang Chen, Runyuan Sun, Kun Ma, Zhongjie Yuan y Guandong Xu (2018). «GIST: A generative model with individual and subgroup-based topics for group recommendation». En: *Expert Systems with Applications* 94, págs. 81-93. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.10.037>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417417307200>.
- Jung, Jason J. (2012). «Attribute selection-based recommendation framework for short-head user group: An empirical study by MovieLens and IMDB». En: *Expert Systems with Applications* 39.4, págs. 4049-4054. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2011.09.096>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417411014199>.
- Kaminskas, Marius y Derek Bridge (dic. de 2016). «Diversity, Serendipity, Novelty, and Coverage: A Survey and Empirical Analysis of Beyond-Accuracy Objectives

- in Recommender Systems». En: *ACM Trans. Interact. Intell. Syst.* 7.1, 2:1-2:42. ISSN: 2160-6455. DOI: [10.1145/2926720](https://doi.org/10.1145/2926720). URL: <http://doi.acm.org/10.1145/2926720>.
- Kapoor, Komal, Karthik Subbian, Jaideep Srivastava y Paul Schrater (2015). «Just in Time Recommendations: Modeling the Dynamics of Boredom in Activity Streams». En: *Proceedings of the Eighth ACM International Conference on Web Search and Data Mining*. WSDM '15. Shanghai, China: ACM, págs. 233-242. ISBN: 978-1-4503-3317-7. DOI: [10.1145/2684822.2685306](https://doi.org/10.1145/2684822.2685306). URL: <http://doi.acm.org/10.1145/2684822.2685306>.
- Karimi, Mozghan, Dietmar Jannach y Michael Jugovac (2018). «News recommender systems – Survey and roads ahead». En: *Information Processing & Management* 54.6, págs. 1203 -1227. ISSN: 0306-4573. DOI: <https://doi.org/10.1016/j.ipm.2018.04.008>. URL: <http://www.sciencedirect.com/science/article/pii/S030645731730153X>.
- Kim, Heung-Nam, Mark Bloess y Abdulmotaleb El Saddik (2013). «Folkommender: a group recommender system based on a graph-based ranking algorithm». En: *Multimedia Systems* 19.6, págs. 509-525. ISSN: 1432-1882. DOI: [10.1007/s00530-012-0298-5](https://doi.org/10.1007/s00530-012-0298-5). URL: <https://doi.org/10.1007/s00530-012-0298-5>.
- Kim, Heung-Nam y Abdulmotaleb El Saddik (2015). «A stochastic approach to group recommendations in social media systems». En: *Information Systems* 50, págs. 76 -93. ISSN: 0306-4379. DOI: <https://doi.org/10.1016/j.is.2014.10.002>. URL: <http://www.sciencedirect.com/science/article/pii/S0306437914001537>.
- Kim, Jae Kyeong, Hyea Kyeong Kim, Hee Young Oh y Young U. Ryu (2010). «A group recommendation system for online communities». En: *International Journal of Information Management* 30.3, págs. 212 -219. ISSN: 0268-4012. DOI: <https://doi.org/10.1016/j.ijinfomgt.2009.09.006>. URL: <http://www.sciencedirect.com/science/article/pii/S0268401209001194>.
- Knijnenburg, Bart P., Svetlin Bostandjiev, John O'Donovan y Alfred Kobsa (2012). «Inspectability and Control in Social Recommenders». En: *Proceedings of the Sixth ACM Conference on Recommender Systems*. RecSys '12. Dublin, Ireland: ACM, págs. 43-50. ISBN: 978-1-4503-1270-7. DOI: [10.1145/2365952.2365966](https://doi.org/10.1145/2365952.2365966). URL: <http://doi.acm.org/10.1145/2365952.2365966>.
- Koohi, Hamidreza y Kourosh Kiani (2016). «User based Collaborative Filtering using fuzzy C-means». En: *Measurement* 91, págs. 134 -139. ISSN: 0263-2241. DOI: <https://doi.org/10.1016/j.measurement.2016.05.058>. URL: <http://www.sciencedirect.com/science/article/pii/S0263224116302159>.
- (2017). «A new method to find neighbor users that improves the performance of Collaborative Filtering». En: *Expert Systems with Applications* 83, págs. 30 -39. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.04.027>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417417302713>.
- Koren, Yehuda y Robert Bell (2015). «Advances in Collaborative Filtering». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach y Bracha Shapira. Boston, MA: Springer US, págs. 77-118. ISBN: 978-1-4899-7637-6. DOI: [10.1007/978-1-4899-7637-6_3](https://doi.org/10.1007/978-1-4899-7637-6_3). URL: https://doi.org/10.1007/978-1-4899-7637-6_3.
- Koren, Yehuda, Robert M. Bell y Chris Volinsky (2009). «Matrix Factorization Techniques for Recommender Systems». En: *Computer* 42.
- Kotkov, Denis, Shuaiqiang Wang y Jari Veijalainen (2016). «A survey of serendipity in recommender systems». En: *Knowledge-Based Systems* 111, págs. 180 -192. ISSN:

- 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2016.08.014>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705116302763>.
- Kunaver, Matevž y Tomaž Požrl (2017). «Diversity in recommender systems – A survey». En: *Knowledge-Based Systems* 123, págs. 154 -162. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2017.02.009>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705117300680>.
- Lai, Chin-Hui (2015). «Applying knowledge flow mining to group recommendation methods for task-based groups». En: *Journal of the Association for Information Science and Technology* 66.3, págs. 545-563. DOI: [10.1002/asi.23185](https://doi.org/10.1002/asi.23185). eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/asi.23185>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/asi.23185>.
- Lee, Daniel D. y H. Sebastian Seung (1999). «Learning the parts of objects by non-negative matrix factorization». En: *Nature* 401, págs. 788-791.
- Lee, Meehee, Pyungseok Choi y Yongtae Woo (2002). «A Hybrid Recommender System Combining Collaborative Filtering with Neural Network». En: *Adaptive Hypermedia and Adaptive Web-Based Systems: Second International Conference, AH 2002 Málaga, Spain, May 29–31, 2002 Proceedings*. Ed. por Paul De Bra, Peter Brusilovsky y Ricardo Conejo. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 531-534. ISBN: 978-3-540-47952-9. DOI: [10.1007/3-540-47952-X_77](https://doi.org/10.1007/3-540-47952-X_77). URL: http://dx.doi.org/10.1007/3-540-47952-X_77.
- Liu, Yezheng, Lu Yang, Jianshan Sun, Yuanchun Jiang y Jinkun Wang (2018). «Collaborative matrix factorization mechanism for group recommendation in big data-based library systems». En: *Library Hi Tech*. DOI: [10.1108/LHT-06-2017-0121](https://doi.org/10.1108/LHT-06-2017-0121).
- Lorenzi, Fabiana, Fernando dos Santos, Paulo R. Ferreira y Ana L. C. Bazzan (2008). «Optimizing Preferences within Groups: A Case Study on Travel Recommendation». En: *Advances in Artificial Intelligence - SBIA 2008*. Ed. por Gerson Zaverucha y Augusto Loureiro da Costa. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 103-112. ISBN: 978-3-540-88190-2.
- Lu, Jie, Dianshuang Wu, Mingsong Mao, Wei Wang y Guangquan Zhang (2015). «Recommender system application developments: A survey». En: *Decision Support Systems* 74, págs. 12 -32. ISSN: 0167-9236. DOI: <https://doi.org/10.1016/j.dss.2015.03.008>. URL: <http://www.sciencedirect.com/science/article/pii/S0167923615000627>.
- Lü, Linyuan, Matúš Medo, Chi Ho Yeung, Yi-Cheng Zhang, Zi-Ke Zhang y Tao Zhou (2012). «Recommender systems». En: *Physics Reports* 519.1, págs. 1-49. ISSN: 03701573. DOI: [10.1016/j.physrep.2012.02.006](https://doi.org/10.1016/j.physrep.2012.02.006). arXiv: [1202.1112](https://arxiv.org/abs/1202.1112). URL: <https://www.sciencedirect.com/science/article/abs/pii/S0370157312000828>.
- Masthoff, Judith (2004). «Group Modeling: Selecting a Sequence of Television Items to Suit a Group of Viewers». En: *Personalized Digital Television: Targeting Programs to individual Viewers*. Dordrecht: Springer Netherlands, págs. 93-141. ISBN: 978-1-4020-2164-0. DOI: [10.1007/1-4020-2164-X_5](https://doi.org/10.1007/1-4020-2164-X_5). URL: https://doi.org/10.1007/1-4020-2164-X_5.
- (2011). «Group Recommender Systems: Combining Individual Models». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach, Bracha Shapira y Paul B. Kantor. Boston, MA: Springer US, págs. 677-702. ISBN: 978-0-387-85820-3. DOI: [10.1007/978-0-387-85820-3_21](https://doi.org/10.1007/978-0-387-85820-3_21). URL: https://doi.org/10.1007/978-0-387-85820-3_21.

- (2015). «Group Recommender Systems: Aggregation, Satisfaction and Group Attributes». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach y Bracha Shapira. Boston, MA: Springer US, págs. 743-776. ISBN: 978-1-4899-7637-6. DOI: [10.1007/978-1-4899-7637-6_22](https://doi.org/10.1007/978-1-4899-7637-6_22). URL: https://doi.org/10.1007/978-1-4899-7637-6_22.
- Masthoff, Judith y Albert Gatt (2006). «In pursuit of satisfaction and the prevention of embarrassment: affective state in group recommender systems». En: *User Modeling and User-Adapted Interaction* 16.3, págs. 281-319. ISSN: 1573-1391. DOI: [10.1007/s11257-006-9008-3](https://doi.org/10.1007/s11257-006-9008-3). URL: <https://doi.org/10.1007/s11257-006-9008-3>.
- McCarthy, Joseph F (2002). «Pocket restaurantfinder: A situated recommender system for groups». En: *Workshop on Mobile Ad-Hoc Communication at the 2002 ACM Conference on Human Factors in Computer Systems*.
- McCarthy, Joseph F y Theodore D Anagnost (1998). «MusicFX: an arbiter of group preferences for computer supported collaborative workouts». En: *Proceedings of the 1998 ACM conference on Computer supported cooperative work*. ACM, págs. 363-372.
- McCarthy, Kevin, Lorraine McGinty y Barry Smyth (2007). «Case-Based Group Recommendation: Compromising for Success». En: *Case-Based Reasoning Research and Development*. Ed. por Rosina O. Weber y Michael M. Richter. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 299-313. ISBN: 978-3-540-74141-1.
- McCarthy, Kevin, Maria Salamó, Lorcan Coyle, Lorraine McGinty, Barry Smyth y Paddy Nixon (2006a). «Cats: A synchronous approach to collaborative group recommendation». En: págs. 86-91.
- McCarthy, Kevin, Maria Salamó, Lorcan Coyle, Lorraine McGinty, Barry Smyth y Paddy Nixon (2006b). «Cats: A synchronous approach to collaborative group recommendation». En: *Florida Artificial Intelligence Research Society Conference (FLAIRS)*, págs. 86-91.
- McCarthy, Kevin, Maria Salamó, Lorcan Coyle, Lorraine McGinty, Barry Smyth y Paddy Nixon (2006c). «Group Recommender Systems: A Critiquing Based Approach». En: *Proceedings of the 11th International Conference on Intelligent User Interfaces*. IUI '06. Sydney, Australia: ACM, págs. 267-269. ISBN: 1-59593-287-9. DOI: [10.1145/1111449.1111506](https://doi.org/10.1145/1111449.1111506). URL: <http://doi.acm.org/10.1145/1111449.1111506>.
- McCarthy, Kevin, Lorraine McGinty, Barry Smyth y Maria Salamó (2006d). «Social interaction in the cats group recommender». En: *Workshop on the social navigation and community based adaptation technologies*.
- (2006e). «The Needs of the Many: A Case-Based Group Recommender System». En: *Advances in Case-Based Reasoning*. Ed. por Thomas R. Roth-Berghofer, Mehmet H. Göker y H. Altay Güvenir. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 196-210. ISBN: 978-3-540-36846-5.
- Myszkowski, Krzysztof y Danuta Zakrzewska (2013). «Using Fuzzy Logic for Recommending Groups in E-Learning Systems». En: *Computational Collective Intelligence. Technologies and Applications*. Ed. por Costin Bădică, Ngoc Thanh Nguyen y Marius Brezovan. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 671-680. ISBN: 978-3-642-40495-5.
- Najafabadi, Maryam Khanian, Mohd Naz'ri Mahrin, Suriyati Chuprat y Haslina Md Sarkan (2017). «Improving the accuracy of collaborative filtering recommendations using clustering and association rules mining on implicit data». En: *Computers in Human Behavior* 67, págs. 113-128. ISSN: 0747-5632. DOI: <https://doi.org/10.1016/j.chb.2016.11.010>. URL: <http://www.sciencedirect.com/science/article/pii/S0747563216307518>.

- Nilashi, Mehrbakhsh, Othman Ibrahim y Karamollah Bagherifard (2018). «A recommender system based on collaborative filtering using ontology and dimensionality reduction techniques». En: *Expert Systems with Applications* 92, págs. 507-520. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.09.058>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417417306577>.
- Ning, Xia, Christian Desrosiers y George Karypis (2015). «A Comprehensive Survey of Neighborhood-Based Recommendation Methods». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach y Bracha Shapira. Boston, MA: Springer US, págs. 37-76. ISBN: 978-1-4899-7637-6. DOI: [10.1007/978-1-4899-7637-6_2](https://doi.org/10.1007/978-1-4899-7637-6_2). URL: https://doi.org/10.1007/978-1-4899-7637-6_2.
- Ntoutsi, Eirini, Kostas Stefanidis, Kjetil Nørnvåg y Hans-Peter Kriegel (2012a). «Fast Group Recommendations by Applying User Clustering». En: *Conceptual Modeling*. Ed. por Paolo Atzeni, David Cheung y Sudha Ram. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 126-140. ISBN: 978-3-642-34002-4.
- Ntoutsi, Irene, Kostas Stefanidis, Kjetil Norvag y Hans-Peter Kriegel (2012b). «gRecs: A Group Recommendation System Based on User Clustering». En: *Database Systems for Advanced Applications*. Ed. por Sang-goo Lee, Zhiyong Peng, Xiaofang Zhou, Yang-Sae Moon, Rainer Unland y Jaesoo Yoo. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 299-303. ISBN: 978-3-642-29035-0.
- O'Connor, Mark, Dan Cosley, Joseph A. Konstan y John Riedl (2001). «PolyLens: A Recommender System for Groups of Users». En: *ECSCW 2001: Proceedings of the Seventh European Conference on Computer Supported Cooperative Work 16-20 September 2001, Bonn, Germany*. Ed. por Wolfgang Prinz, Matthias Jarke, Yvonne Rogers, Kjeld Schmidt y Volker Wulf. Dordrecht: Springer Netherlands, págs. 199-218. ISBN: 978-0-306-48019-5. DOI: [10.1007/0-306-48019-0_11](https://doi.org/10.1007/0-306-48019-0_11). URL: https://doi.org/10.1007/0-306-48019-0_11.
- O'Hara, Kenton, Matthew Lipson, Marcel Jansen, Axel Unger, Huw Jeffries y Peter Macer (2004). «Jukola: Democratic Music Choice in a Public Space». En: *Proceedings of the 5th Conference on Designing Interactive Systems: Processes, Practices, Methods, and Techniques*. DIS '04. Cambridge, MA, USA: ACM, págs. 145-154. ISBN: 1-58113-787-7. DOI: [10.1145/1013115.1013136](https://doi.org/10.1145/1013115.1013136). URL: <http://doi.acm.org/10.1145/1013115.1013136>.
- Olmo, Félix Hernández del y Elena Gaudio (2008). «Evaluation of recommender systems: A new approach». En: *Expert Systems with Applications* 35.3, págs. 790-804. ISSN: 09574174. DOI: [10.1016/j.eswa.2007.07.047](https://doi.org/10.1016/j.eswa.2007.07.047).
- Ortega, F., J. Bobadilla, A. Hernando y A. Gutiérrez (2013). «Incorporating group recommendations to recommender systems: Alternatives and performance». En: *Information Processing & Management* 49.4, págs. 895-901. ISSN: 0306-4573. DOI: <https://doi.org/10.1016/j.ipm.2013.02.003>. URL: <http://www.sciencedirect.com/science/article/pii/S0306457313000174>.
- Ortega, F., B. Zhu, J. Bobadilla y A. Hernando (2018a). «CF4J: Collaborative filtering for Java». En: *Knowledge-Based Systems*. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2018.04.008>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705118301734>.
- Ortega, F., R. Hurtado, J. Bobadilla y R. Bojorque (2018b). «Recommendation to Groups of Users Using the Singularities Concept». En: *IEEE Access* 6, págs. 39745-39761. ISSN: 2169-3536. DOI: [10.1109/ACCESS.2018.2853107](https://doi.org/10.1109/ACCESS.2018.2853107).

- Ortega, Fernando, Antonio Hernando, Jesus Bobadilla y Jeon Hyung Kang (2016). «Recommending items to group of users using Matrix Factorization based Collaborative Filtering». En: *Information Sciences* 345, págs. 313 -324. ISSN: 0020-0255. DOI: <https://doi.org/10.1016/j.ins.2016.01.083>. URL: <http://www.sciencedirect.com/science/article/pii/S0020025516300196>.
- Ortiz, Remigio Hurtado, Rodolfo Bojorque Chasi y César Inga Chalco (2019). «Clustering-Based Recommender System: Bundle Recommendation Using Matrix Factorization to Single User and User Communities». En: *Advances in Artificial Intelligence, Software and Systems Engineering*. Ed. por Tareq Z. Ahram. Cham: Springer International Publishing, págs. 330-338. ISBN: 978-3-319-94229-2.
- Paradarami, Tulasi K., Nathaniel D. Bastian y Jennifer L. Wightman (2017). «A hybrid recommender system using artificial neural networks». En: *Expert Systems with Applications* 83, págs. 300 -313. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.04.046>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417417302968>.
- Paterek, Arkadiusz (2007). «Improving regularized singular value decomposition for collaborative filtering». En: *Proceedings of KDD cup and workshop*. Vol. 2007, págs. 5-8.
- Perumal, S. P., K. Arputharaj y G. Sannasi (ene. de 2017). «Fuzzy family tree similarity based effective e-learning recommender system». En: *2016 Eighth International Conference on Advanced Computing (ICoAC)*, págs. 146-150. DOI: [10.1109/ICoAC.2017.7951760](https://doi.org/10.1109/ICoAC.2017.7951760).
- Pessemier, Toon De, Jeroen Dhondt y Luc Martens (ene. de 2017). «Hybrid group recommendations for a travel service». En: *Multimedia Tools and Applications* 76.2, págs. 2787-2811. ISSN: 1573-7721. DOI: [10.1007/s11042-016-3265-x](https://doi.org/10.1007/s11042-016-3265-x). URL: <https://doi.org/10.1007/s11042-016-3265-x>.
- Pham, T. A. N., X. Li, G. Cong y Z. Zhang (abr. de 2015). «A general graph-based model for recommendation in event-based social networks». En: *2015 IEEE 31st International Conference on Data Engineering*, págs. 567-578. DOI: [10.1109/ICDE.2015.7113315](https://doi.org/10.1109/ICDE.2015.7113315).
- Piliponyte, Auste, Francesco Ricci y Julian Koschwitz (2013). «Sequential Music Recommendations for Groups by Balancing User Satisfaction.» En: *UMAP workshops*.
- Quijano-Sanchez, Lara, Juan A. Recio-Garcia, Belen Diaz-Agudo y Guillermo Jimenez-Diaz (feb. de 2013). «Social Factors in Group Recommender Systems». En: *ACM Trans. Intell. Syst. Technol.* 4.1, 8:1-8:30. ISSN: 2157-6904. DOI: [10.1145/2414425.2414433](https://doi.org/10.1145/2414425.2414433). URL: <http://doi.acm.org/10.1145/2414425.2414433>.
- Quijano-Sanchez, Lara, Christian Sauer, Juan A. Recio-Garcia y Belen Diaz-Agudo (2017). «Make it personal: A social explanation system applied to group recommendations». En: *Expert Systems with Applications* 76, págs. 36 -48. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.01.045>. URL: <http://www.sciencedirect.com/science/article/pii/S095741741730060X>.
- Quijano-Sánchez, Lara, Belén Díaz-Agudo y Juan A. Recio-García (2014). «Development of a group recommender application in a Social Network». En: *Knowledge-Based Systems* 71, págs. 72 -85. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2014.05.013>. URL: <http://www.sciencedirect.com/science/article/pii/S095070511400197X>.
- Recio-Garcia, Juan A., Guillermo Jimenez-Diaz, Antonio A. Sanchez-Ruiz y Belen Diaz-Agudo (2009). «Personality Aware Recommendations to Groups». En: *Proceedings of the Third ACM Conference on Recommender Systems*. RecSys '09. New York, New York, USA: ACM, págs. 325-328. ISBN: 978-1-60558-435-5. DOI: [10.1145/1557019](https://doi.org/10.1145/1557019).

- 1145/1639714.1639779. URL: <http://doi.acm.org/10.1145/1639714.1639779>.
- Ren, L., L. He, J. Gu, W. Xia y F. Wu (2008). «A Hybrid Recommender Approach Based on Widrow-Hoff Learning». En: *2008 Second International Conference on Future Generation Communication and Networking*. Vol. 1, págs. 40-45. DOI: [10.1109/FGCN.2008.48](https://doi.org/10.1109/FGCN.2008.48).
- Ricci, Francesco, Lior Rokach y Bracha Shapira (2015). «Recommender Systems: Introduction and Challenges». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach y Bracha Shapira. Boston, MA: Springer US, págs. 1-34. ISBN: 978-1-4899-7637-6. DOI: [10.1007/978-1-4899-7637-6_1](https://doi.org/10.1007/978-1-4899-7637-6_1). URL: https://doi.org/10.1007/978-1-4899-7637-6_1.
- Rossi, Silvia, Francesco Barile, Clemente Galdi y Luca Russo (dic. de 2017). «Recommendation in museums: paths, sequences, and group satisfaction maximization». En: *Multimedia Tools and Applications* 76.24, págs. 26031-26055. ISSN: 1573-7721. DOI: [10.1007/s11042-017-4869-5](https://doi.org/10.1007/s11042-017-4869-5). URL: <https://doi.org/10.1007/s11042-017-4869-5>.
- Rueda-Morales, M. A., J. M. Fernandez-Luna, L. M. de Campos y J. F. Huete (abr. de 2007). «Group Recommending: A methodological Approach based on Bayesian Networks». En: *2007 IEEE 23rd International Conference on Data Engineering Workshop(ICDEW)*. Vol. 00, págs. 835-844. DOI: [10.1109/ICDEW.2007.4401074](https://doi.org/10.1109/ICDEW.2007.4401074). URL: [doi.ieeecomputersociety.org/10.1109/ICDEW.2007.4401074](https://doi.org/10.1109/ICDEW.2007.4401074).
- Salamó, Maria, Kevin Mccarthy y Barry Smyth (jun. de 2012). «Generating Recommendations for Consensus Negotiation in Group Personalization Services». En: *Personal Ubiquitous Comput.* 16.5, págs. 597-610. ISSN: 1617-4909. DOI: [10.1007/s00779-011-0413-1](https://doi.org/10.1007/s00779-011-0413-1). URL: <http://dx.doi.org/10.1007/s00779-011-0413-1>.
- Sarwar, Badrul Munir (2001). «Sparsity, Scalability, and Distribution in Recommender Systems». AAI9994525. Tesis doct. Minneapolis, MN, USA. ISBN: 0-493-04207-5.
- Senot, Christophe, Dimitre Kostadinov, Makram Bouzid, Jérôme Picault, Armen Aghasaryan y Cédric Bernier (2010). «Analysis of Strategies for Building Group Profiles». En: *User Modeling, Adaptation, and Personalization*. Ed. por Paul De Bra, Alfred Kobsa y David Chin. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 40-51. ISBN: 978-3-642-13470-8.
- Seo, Young-Duk, Young-Gab Kim, Euijong Lee y Doo-Kwon Baik (2017). «Personalized recommender system based on friendship strength in social network services». En: *Expert Systems with Applications* 69, págs. 135 -148. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2016.10.024>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417416305553>.
- Seo, Young-Duk, Young-Gab Kim, Euijong Lee, Kwang-Soo Seol y Doo-Kwon Baik (2018). «An enhanced aggregation method considering deviations for a group recommendation». En: *Expert Systems with Applications* 93, págs. 299 -312. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2017.10.027>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417417307108>.
- Shani, Guy y Asela Gunawardana (2011a). «Evaluating Recommendation Systems». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach, Bracha Shapira y Paul B. Kantor. Boston, MA: Springer US, págs. 257-297. ISBN: 978-0-387-85820-3. DOI: [10.1007/978-0-387-85820-3_8](https://doi.org/10.1007/978-0-387-85820-3_8). URL: https://doi.org/10.1007/978-0-387-85820-3_8.

- (2011b). «Evaluating Recommendation Systems». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach, Bracha Shapira y Paul B. Kantor. Boston, MA: Springer US, págs. 257-297. ISBN: 978-0-387-85820-3. DOI: [10.1007/978-0-387-85820-3_8](https://doi.org/10.1007/978-0-387-85820-3_8). URL: https://doi.org/10.1007/978-0-387-85820-3_8.
- Shardanand, Upendra y Pattie Maes (1995). «Social Information Filtering: Algorithms for Automating "Word of Mouth"». En: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. CHI '95. Denver, Colorado, USA: ACM Press/Addison-Wesley Publishing Co., págs. 210-217. ISBN: 0-201-84705-1. DOI: [10.1145/223904.223931](https://doi.org/10.1145/223904.223931). URL: <http://dx.doi.org/10.1145/223904.223931>.
- Sharma, Amit y Dan Cosley (2013). «Do Social Explanations Work?: Studying and Modeling the Effects of Social Explanations in Recommender Systems». En: *Proceedings of the 22Nd International Conference on World Wide Web*. WWW '13. Rio de Janeiro, Brazil: ACM, págs. 1133-1144. ISBN: 978-1-4503-2035-1. DOI: [10.1145/2488388.2488487](https://doi.org/10.1145/2488388.2488487). URL: <http://doi.acm.org/10.1145/2488388.2488487>.
- Sharon, Taly, Henry Lieberman y Ted Selker (2003). «A Zero-input Interface for Leveraging Group Experience in Web Browsing». En: *Proceedings of the 8th International Conference on Intelligent User Interfaces*. IUI '03. Miami, Florida, USA: ACM, págs. 290-292. ISBN: 1-58113-586-6. DOI: [10.1145/604045.604102](https://doi.org/10.1145/604045.604102). URL: <http://doi.acm.org/10.1145/604045.604102>.
- Shi, Yue, Martha Larson y Alan Hanjalic (mayo de 2014). «Collaborative Filtering Beyond the User-Item Matrix: A Survey of the State of the Art and Future Challenges». En: *ACM Comput. Surv.* 47.1, 3:1-3:45. ISSN: 0360-0300. DOI: [10.1145/2556270](https://doi.org/10.1145/2556270). URL: <http://doi.acm.org/10.1145/2556270>.
- Shinde, Subhash K. y Uday Kulkarni (2012). «Hybrid personalized recommender system using centering-bunching based clustering algorithm». En: *Expert Systems with Applications* 39.1, págs. 1381 -1387. ISSN: 0957-4174. DOI: [10.1016/j.eswa.2011.08.020](https://doi.org/10.1016/j.eswa.2011.08.020). URL: <http://www.sciencedirect.com/science/article/pii/S0957417411011316>.
- Smyth, Barry y Paul McClave (2001). «Similarity vs. Diversity». En: *Case-Based Reasoning Research and Development*. Ed. por David W. Aha y Ian Watson. Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 347-361. ISBN: 978-3-540-44593-7.
- Sprague, David, Fuqu Wu y Melanie Tory (2008). «Music Selection Using the Party-Vote Democratic Jukebox». En: *Proceedings of the Working Conference on Advanced Visual Interfaces*. AVI '08. Napoli, Italy: ACM, págs. 433-436. ISBN: 978-1-60558-141-5. DOI: [10.1145/1385569.1385652](https://doi.org/10.1145/1385569.1385652). URL: <http://doi.acm.org/10.1145/1385569.1385652>.
- Stettinger, Martin y Alexander Felfernig (2014). «Choicla: Intelligent decision support for groups of users in the context of personnel decisions». En: *Proceedings of the ACM RecSys' 2014 IntRS Workshop*, págs. 28-32.
- Sun, L., X. Wang, Z. Wang, H. Zhao y W. Zhu (mar. de 2017). «Social-Aware Video Recommendation for Online Social Groups». En: *IEEE Transactions on Multimedia* 19.3, págs. 609-618. ISSN: 1520-9210. DOI: [10.1109/TMM.2016.2635589](https://doi.org/10.1109/TMM.2016.2635589).
- Tang, Jiliang, Xia Hu y Huan Liu (dic. de 2013). «Social recommendation: a review». En: *Social Network Analysis and Mining* 3.4, págs. 1113-1133. ISSN: 1869-5469. DOI: [10.1007/s13278-013-0141-9](https://doi.org/10.1007/s13278-013-0141-9). URL: <https://doi.org/10.1007/s13278-013-0141-9>.

- Tintarev, Nava y Judith Masthoff (2011). «Designing and Evaluating Explanations for Recommender Systems». En: *Recommender Systems Handbook*. Ed. por Francesco Ricci, Lior Rokach, Bracha Shapira y Paul B. Kantor. Boston, MA: Springer US, págs. 479-510. ISBN: 978-0-387-85820-3. DOI: [10.1007/978-0-387-85820-3_15](https://doi.org/10.1007/978-0-387-85820-3_15). URL: https://doi.org/10.1007/978-0-387-85820-3_15.
- Trajkovic, Miroslav, Srinivas Gutta y Vasanth Philomin (2004). *Method and apparatus for finding and updating user group preferences in an entertainment system*. US Patent App. 10/180,571.
- Vargas, Saúl y Pablo Castells (2011). «Rank and Relevance in Novelty and Diversity Metrics for Recommender Systems». En: *Proceedings of the Fifth ACM Conference on Recommender Systems*. RecSys '11. Chicago, Illinois, USA: ACM, págs. 109-116. ISBN: 978-1-4503-0683-6. DOI: [10.1145/2043932.2043955](https://doi.org/10.1145/2043932.2043955). URL: <http://doi.acm.org/10.1145/2043932.2043955>.
- (2014). «Improving Sales Diversity by Recommending Users to Items». En: *Proceedings of the 8th ACM Conference on Recommender Systems*. RecSys '14. California, USA: ACM, págs. 145-152. ISBN: 978-1-4503-2668-1. DOI: [10.1145/2645710.2645744](https://doi.org/10.1145/2645710.2645744). URL: <http://doi.acm.org/10.1145/2645710.2645744>.
- Villegas, Norha M., Cristian Sánchez, Javier Díaz-Cely y Gabriel Tamura (2018). «Characterizing context-aware recommender systems: A systematic literature review». En: *Knowledge-Based Systems* 140, págs. 173 -200. ISSN: 0950-7051. DOI: <https://doi.org/10.1016/j.knosys.2017.11.003>. URL: <http://www.sciencedirect.com/science/article/pii/S0950705117305075>.
- Wang, Wei, Guangquan Zhang y Jie Lu (2016). «Member contribution-based group recommender system». En: *Decision Support Systems* 87, págs. 80 -93. ISSN: 0167-9236. DOI: <https://doi.org/10.1016/j.dss.2016.05.002>. URL: <http://www.sciencedirect.com/science/article/pii/S0167923616300756>.
- Wei, Jian, Jianhua He, Kai Chen, Yi Zhou y Zuoyin Tang (2017). «Collaborative filtering and deep learning based recommendation system for cold start items». En: *Expert Systems with Applications* 69, págs. 29 -39. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2016.09.040>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417416305309>.
- Wu, Meng-Lun, Chia-Hui Chang y Rui-Zhe Liu (2014). «Integrating content-based filtering with collaborative filtering using co-clustering with augmented matrices». En: *Expert Systems with Applications* 41.6, págs. 2754 -2761. ISSN: 0957-4174. DOI: <https://doi.org/10.1016/j.eswa.2013.10.008>. URL: <http://www.sciencedirect.com/science/article/pii/S0957417413008130>.
- Xing, Sinan Zhan¹ Fengrong Gao² Chunxiao y Lizhu Zhou (2006). «Addressing Concept Drift problem in collaborative filtering systems». En: *ECAI 2006 Workshop on Recommender Systems*, pág. 34.
- Yager, Ronald R (1988). «On ordered weighted averaging aggregation operators in multicriteria decisionmaking». En: *IEEE Transactions on systems, Man, and Cybernetics* 18.1, págs. 183-190.
- Yang, Z., B. Wu, K. Zheng, X. Wang y L. Lei (2016). «A Survey of Collaborative Filtering-Based Recommender Systems for Mobile Internet Applications». En: *IEEE Access* 4, págs. 3273-3287. DOI: [10.1109/ACCESS.2016.2573314](https://doi.org/10.1109/ACCESS.2016.2573314).
- Yera, Raciél, Jorge Castro y Luis Martínez (2016). «A fuzzy model for managing natural noise in recommender systems». En: *Applied Soft Computing* 40, págs. 187 -198. ISSN: 1568-4946. DOI: <https://doi.org/10.1016/j.asoc.2015.10.060>. URL: <http://www.sciencedirect.com/science/article/pii/S1568494615007048>.

- Yu, J., M. Gao, W. Rong, Y. Song y Q. Xiong (2017). «A Social Recommender Based on Factorization and Distance Metric Learning». En: *IEEE Access* 5, págs. 21557-21566. DOI: [10.1109/ACCESS.2017.2762459](https://doi.org/10.1109/ACCESS.2017.2762459).
- Yu, Wenyu, Qiuyan Zhong y Zhen Zhang (mar. de 2018). «Multi-granular hesitant fuzzy linguistic group decision making with incomplete weight information». En: 38, págs. 777-785.
- Yu, Zhiwen, Xingshe Zhou, Yanbin Hao y Jianhua Gu (mar. de 2006). «TV Program Recommendation for Multiple Viewers Based on user Profile Merging». En: *User Modeling and User-Adapted Interaction* 16.1, págs. 63-82. ISSN: 1573-1391. DOI: [10.1007/s11257-006-9005-6](https://doi.org/10.1007/s11257-006-9005-6). URL: <https://doi.org/10.1007/s11257-006-9005-6>.
- Zaier, Z., R. Godin y L. Faucher (nov. de 2008). «Evaluating Recommender Systems». En: *2008 International Conference on Automated Solutions for Cross Media Content and Multi-Channel Distribution*, págs. 211-217. DOI: [10.1109/AXMEDIS.2008.21](https://doi.org/10.1109/AXMEDIS.2008.21).
- Zapata, Alfredo, Víctor H. Menéndez, Manuel E. Prieto y Cristóbal Romero (2015). «Evaluation and selection of group recommendation strategies for collaborative searching of learning objects». En: *International Journal of Human-Computer Studies* 76, págs. 22 -39. ISSN: 1071-5819. DOI: <https://doi.org/10.1016/j.ijhcs.2014.12.002>. URL: <http://www.sciencedirect.com/science/article/pii/S1071581914001657>.
- Zhiwen, Yu, Zhou Xingshe y Zhang Daqing (2005). «An adaptive in-vehicle multimedia recommender for group users». En: *Vehicular Technology Conference, 2005. VTC 2005-Spring. 2005 IEEE 61st*. Vol. 5. IEEE, págs. 2800-2804.
- Zhou, Tao, Zoltán Kuscik, Jian-Guo Liu, Matúš Medo, Joseph Rushton Wakeling y Yi-Cheng Zhang (2010). «Solving the apparent diversity-accuracy dilemma of recommender systems». En: *Proceedings of the National Academy of Sciences* 107.10, págs. 4511-4515. ISSN: 0027-8424. DOI: [10.1073/pnas.1000488107](https://doi.org/10.1073/pnas.1000488107). eprint: <http://www.pnas.org/content/107/10/4511.full.pdf>. URL: <http://www.pnas.org/content/107/10/4511>.
- Zhu, B., R. Hurtado, J. Bobadilla y F. Ortega (2018). «An Efficient Recommender System Method Based on the Numerical Relevances and the Non-Numerical Structures of the Ratings». En: *IEEE Access* 6, págs. 49935-49954. ISSN: 2169-3536. DOI: [10.1109/ACCESS.2018.2868464](https://doi.org/10.1109/ACCESS.2018.2868464).
- Ziegler, Cai-Nicolas, Sean M. McNee, Joseph A. Konstan y Georg Lausen (2005). «Improving Recommendation Lists Through Topic Diversification». En: *Proceedings of the 14th International Conference on World Wide Web. WWW '05*. Chiba, Japan: ACM, págs. 22-32. ISBN: 1-59593-046-9. DOI: [10.1145/1060745.1060754](https://doi.org/10.1145/1060745.1060754). URL: <http://doi.acm.org/10.1145/1060745.1060754>.