

UNIVERSIDAD POLITÉCNICA DE VALENCIA

**Dpto. Sistemas Informáticos y Computación**

Ingeniería Técnica en Informática de Sistemas

**PROYECTO FINAL DE CARRERA**

Impacto de la Colaboración en la  
Elicitación de Preferencias para  
Sistemas Recomendadores de Grupos

Autor: Sergio Pajares Ferrando  
Dirigida por: Dra. Laura Sebastiá Tarín  
Dra. Inmaculada García García

*Departamento de Sistemas Informáticos y Computación  
Universidad Politécnica de Valencia  
Camino de Vera, s/n  
46022 Valencia, Spain  
13 de Septiembre de 2011*



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA

# Índice general

---

<b>1. Introducción</b>	<b>3</b>
1.1. Motivación . . . . .	4
1.2. Objetivos . . . . .	5
1.3. Estructura del PFC . . . . .	6
<b>2. Estado del Arte</b>	<b>7</b>
<b>3. Antecedentes</b>	<b>11</b>
3.1. Arquitectura del Sistema . . . . .	11
3.2. El proceso de recomendación de grupos . . . . .	13
3.3. Técnicas de elicitación de preferencias de grupo . . . . .	14
3.3.1. Técnica de Agregación . . . . .	14
3.3.2. Técnica de Intersección . . . . .	15
3.3.3. Técnica de Intersección Incremental (II) . . . . .	16
3.4. Cálculo de Prioridad . . . . .	17
3.4.1. Cálculo de la prioridad de una preferencia . . . . .	17
3.4.2. Cálculo de la prioridad de un ítem . . . . .	17
<b>4. Intersección Colaborativa Incremental</b>	<b>19</b>
4.1. Presentación . . . . .	19
4.2. Motivación . . . . .	20
4.3. Descripción de la técnica . . . . .	22
4.4. Ejemplo de aplicación . . . . .	24
4.4.1. Ejemplo 1: Resuelve el Inconveniente 1 . . . . .	24
4.4.2. Ejemplo 2: Resuelve el Inconveniente 2 . . . . .	25

<b>5. Evaluación y Resultados</b>	<b>27</b>
5.1. Descripción de las medidas usadas para la evaluación . . . . .	27
5.2. Dominio de Películas . . . . .	28
5.3. Dominio de Turismo . . . . .	30
<b>6. Conclusiones y Trabajo Futuro</b>	<b>33</b>
6.1. Conclusiones . . . . .	33
6.2. Trabajo Futuro . . . . .	34
6.3. Artículos científicos directamente relacionados con este PFC .	34

# 1

## Introducción

El crecimiento de Internet ha sido increíblemente acelerado, hay cantidades desorbitadas de datos casi sobre cualquier tópico, lo que hace de Internet la fuente más completa de información para casi todo. Sin embargo, hay más cantidad de películas, artículos, libros, programas de televisión, lugares turísticos para visitar entre otras cosas, de los que las personas podemos manejar efectivamente, con lo cual hay una sobrecarga de información hacia el usuario. El tiempo medio que emplea un usuario para realizar una búsqueda sobre el conjunto total de tópicos es demasiado, y los procesos de búsqueda tradicionales pueden ser infructíferos la mayoría de las veces o al menos con resultados poco exitosos de acuerdo a las preferencias del usuario.

Un Sistema Recomendador (SR de aquí en adelante) es una herramienta que ayuda al usuario a obtener la información que necesita de acuerdo a sus preferencias. Un SR (i) toma decisiones basado en información disponible, (ii) requiere de un método sofisticado para filtrar información, y (iii) generalmente se aplica en algún dominio concreto, por ejemplo: películas, música, restaurantes, email, e-commerce, etc. Por tanto, los SRs tratan de ser un paso adelante en el contexto de la recuperación de información tradicional, que se da por palabras clave del tópico que se desea encontrar a través de un buscador (Google, Lycos, etc.). Estos buscadores (i) normalmente nos encuentran

una información muy general y estática, es decir, se ofrece sistemáticamente la misma información a todos los usuarios, independientemente del perfil de éstos, y (ii) muestran grandes volúmenes de información que el usuario debe procesar posteriormente para seleccionar aquellos elementos que pueden ser de su interés. Sin embargo, el objetivo de los SRs es recomendar o sugerir a los usuarios ítems o productos concretos (películas, programas de televisión, lugares turísticos para visitar, etc.) basándose en sus preferencias, es decir ofrecer *una recomendación personalizada acorde con las preferencias del usuario en particular*. Por ejemplo, el viajero gastronómico situará en primer lugar sus preferencias culinarias, para luego organizar los lugares o monumentos a visitar alrededor del mismo. Por otro lado, el usuario que viaja con niños evitará visitar museos durante un largo tiempo e incluirá en su viaje la visita a algún jardín o parque de atracciones.

Los Sistemas Recomendadores intentan simular la interacción con un agente humano que sea capaz de recomendarles [16]. Los servicios de ocio y turismo, y cine son escenarios típicos de aplicación de los Sistemas Recomendadores. Además también son usados por sitios web de comercio electrónico como herramientas de marketing para incrementar ventas al presentar al usuario aquellos productos que desea (o desearía) comprar. Es así como se construye una base de conocimiento de necesidades concretas respecto a lo que gusta o no a los clientes, lo cual puede verse como reflejado en un incremento de la lealtad de los clientes. El SR nos recomendará unos ítems u otros dependiendo de nuestro perfil de usuario.

Sin embargo estas herramientas de personalización (SRs) en ocasiones pueden ser insuficientes cuando lo que queremos es una recomendación conjunta para dos, tres, diez,  $n$  usuarios, de diferentes lugares antes de efectuar un viaje, o de diferentes películas antes de acudir al cine, etc. Para este propósito surgieron los Sistemas Recomendadores de Grupos (SRGs) donde el proceso de recomendación llega a ser más complejo que en un SR. Un ejemplo de SRG es *Polylens* [15] o *MusicFX* [6]. Específicamente, este tipo de sistemas plantea desafíos a las técnicas de recomendación, como son la necesidad de adquirir las preferencias del grupo, ayudar al grupo en el proceso de toma de decisiones de cuál es la mejor opción y explicar al grupo las razones de una recomendación. El presente Proyecto Final de Carrera (PFC) se contextualiza dentro de tales SRGs.

## 1.1. Motivación

En el Proyecto Final de Carrera (PFC) de la titulación de *Ingeniería Informática*, el alumno presentó tres técnicas de elicitación de preferencias

para sistemas recomendadores de grupos (SRG): Agregación, Intersección e Intersección Incremental. Con el objetivo de extender tal trabajo, el presente PFC va un paso adelante en el diseño de técnicas de elicitación de preferencias, y presenta una técnica colaborativa incremental. Además se pretende comprobar experimentalmente la eficacia de la nueva técnica comparándola con las anteriores. Este proyecto se desarrollará en el marco de dos dominios diferentes: Ocio y turismo en la ciudad de Valencia, como primero, y el cine como segundo. Es frecuente que en tales dominios no sólo se soliciten recomendaciones individuales, sino también a grupos de usuarios, por lo que hay que tener en cuenta las preferencias de varios usuarios y además la recomendación debe adecuarse a los gustos de la mayoría de usuarios del grupo. Los siguientes puntos definen las principales motivaciones de este proyecto:

1. El aumento del volumen de datos y variedad de los mismos, que actualmente hay en infinidad de bases de datos, y que son normalmente accesibles vía Internet, está creciendo desorbitadamente.
2. Las decisiones colectivas suelen ser un problema. Este caso se da cuando un grupo de personas solicita un conjunto de recomendaciones para el grupo de acuerdo a sus preferencias y gustos.

## 1.2. Objetivos

Nuevamente el presente proyecto está orientado a problemas de recomendación de grupos. Teniendo cierto conocimiento con respecto a los gustos y preferencias de uno o varios usuarios, el objetivo será obtener una recomendación de agrado al grupo.

El estado de partida de este PFC es un Sistema Recomendador para grupos que implementa tres técnicas básicas de elicitación de preferencias: Agregación, Intersección e Intersección Incremental (ver Capítulo 3). El principal objetivo de este PFC es extender el pasado PFC analizando, diseñando, implementando y testeando nuevas técnicas que mejoren las prestaciones de las anteriores a nivel de satisfacción de grupo. Más específicamente, el objetivo es analizar el impacto de la colaboración de usuarios externos al grupo en el proceso de recomendación. Una vez implementada esta nueva técnica, se testeará en dos dominios de aplicación distintos: los lugares turísticos en la ciudad de Valencia y las películas de cine.

Aunque se trabajará con diferentes bases de datos funcionando bajo MySQL, se dejará preparado para poder trabajar con cualquier tecnología de bases de datos. Se utilizará Java como lenguaje de programación.

### 1.3. Estructura del PFC

En esta sección presentaremos la organización que hemos seguido en esta memoria de PFC.

- El Capítulo 2 ofrece un estado del arte en Sistemas Recomendadores de Grupos.
- El Capítulo 3 resume las tres técnicas de elicitación de preferencias que fueron presentadas en el PFC de Ingeniería Informática.
- El Capítulo 4 presenta la nueva técnica de recomendación para grupos que está basada en un sistema recomendador colaborativo.
- El Capítulo 5 evalúa experimentalmente la nueva técnica y la compara con las otras tres previas. Esta evaluación se hará en dos dominios diferentes.
- El Capítulo 6 representa las conclusiones y trabajo futuro del presente PFC.

# 2

## Estado del Arte: Sistemas Recomendadores para Grupos

Los sistemas de recomendación se ocupan tradicionalmente de hacer recomendaciones de ítems a usuarios individuales. Ha sido recientemente cuando se está empezando a trabajar en el desarrollo de técnicas que permitan proponer recomendaciones a grupos de usuarios simultáneamente [8]. El presente capítulo resume los trabajos más significativos sobre Sistemas Recomendadores para Grupos (SRGs).

Como ya dijimos, este tipo de sistemas plantea problemas específicos a las técnicas de recomendación, como son la necesidad de adquirir las preferencias del grupo, ayudar al grupo en el proceso de toma de decisiones de cuál es la mejor opción y explicar al grupo las razones de una recomendación. La mayoría de SRGs se pueden dividir en (i) aquellos que trabajan directamente con ítems y no necesitan que cada ítem esté catalogado en preferencias, y (ii) aquellos que trabajan con un perfil de preferencias. Un ejemplo de (i) es *Let's browse* [12] que se trata de un sistema que recomienda páginas web a grupos de dos o más personas que están navegando en la red juntos. Por otra parte un ejemplo de (ii) es *Travel Decision Forum* [7], que se trata de un sistema que ayuda a un grupo de usuarios a acordar unas determinadas caracterís-

ticas de unas vacaciones que planeen juntos. Otro sistema recomendador de tipo (ii) es *PolyLens* [15], que se trata de un sistema que recomienda películas a grupos de usuarios. Sin embargo este último no siempre requiere que el usuario especifique sus preferencias. Es una extensión del sistema *MovieLens* [18], basado en técnicas de filtrado colaborativo, donde los usuarios no describen explícitamente sus preferencias en el dominio de las películas, sino que puntúan las películas individualmente en una escala de 1 a 5 estrellas. Este sistema elabora una recomendación a un grupo de usuarios agregando cada una de las preferencias de cada uno de los miembros del grupo. Este PFC se centra en (ii), es decir SRGs que trabajan a nivel de preferencias de usuario.

Una vez que el sistema ha adquirido el conocimiento necesario sobre los usuarios [14][1], puede elaborar un perfil de grupo de usuarios con el que trabajar en el proceso de recomendación. Dependiendo del tamaño y la homogeneidad del grupo, puede ser difícil encontrar una recomendación que sea adecuada para cada miembro del grupo de manera individual [1]. En la mayoría de los casos, el recomendador debe escoger aquella opción que satisfaga al mayor número de usuarios del grupo, de acuerdo con sus preferencias individuales. Generalmente el mecanismo más usado para combinar las preferencias individuales de los usuarios y construir el perfil de grupo es la Agregación.

A continuación se detallan las tres aproximaciones básicas seguidas en la literatura para resolver el problema de combinar preferencias de usuarios:

- Mezclar las recomendaciones que se harían por separado a cada uno de los miembros del grupo. Es un método simple de agregación donde se unen las soluciones del sistema recomendador para cada componente del grupo en una única lista. Este método fue implementado por *PolyLens* [15].
- Agregar las valoraciones/puntuaciones para cada usuario. Para cada ítem candidato y para cada miembro del grupo, el sistema predice cómo ese usuario evaluaría dicho ítem, y devuelve una colección de ítems que tengan las valoraciones/puntuaciones previstas más altas. Un ejemplo de esto es el *Pocket RestaurantFinder* [13].
- Construir un modelo/perfil de las preferencias del grupo. En este enfoque el sistema usa la información sobre las preferencias individuales de los componentes del grupo para construir un modelo de preferencias para el grupo en sí. Uno de los primeros sistemas en construir tales perfiles de usuario es *Let's Browse* [12]. Esta alternativa es la que

seguiremos en el presente PFC. Más concretamente en el siguiente capítulo describiremos tres técnicas para construir dicho perfil de grupo.



# 3

## Antecedentes: Técnicas de Recomendación para Sistemas Recomendadores de Grupos

Este capítulo resume el trabajo realizado por el alumno en el PFC para la titulación de Ingeniería Informática, el cual representa el estado de partida del presente PFC para la titulación de Ingeniería Técnica en Informática de Sistemas.

### 3.1. Arquitectura del Sistema

En la Figura [3.1](#) se muestra un esbozo de la arquitectura del sistema recomendador. A continuación describiremos cada uno de sus componentes principales:

- Los usuarios finales, quienes forman un grupo y desean obtener una recomendación para un dominio de aplicación concreto.
- La interfaz de usuario, que permite la interacción entre usuarios y el Sistema Recomendador de Grupos.

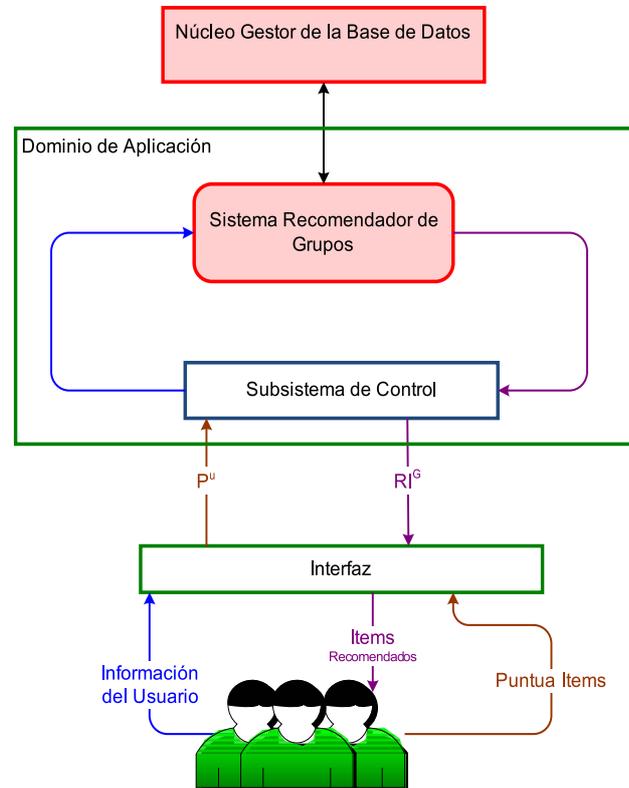


Figura 3.1: Arquitectura general del Sistema.

- El Sistema Recomendador de Grupos, que implementa cada uno de los sistemas recomendadores individuales y cada una de las técnicas de elicitación de preferencias que explicaremos en las próximas secciones de este capítulo.
- El subsistema de control, quien se encarga de las comunicaciones entre las interfaces y el Sistema Recomendador de Grupos.
- El modulo Núcleo Gestor de la Base de Datos, que implementa un middleware de acceso a bases de datos. Aunque no es objeto de la presente memoria, dicho middleware permite el acceso a cualquier tipo de base de datos con varios modelos (relacional y basado en objetos), y sobretodo permite hacer consultas sin necesidad de conocer SQL, dado que incorpora un traductor de lenguaje natural a SQL.

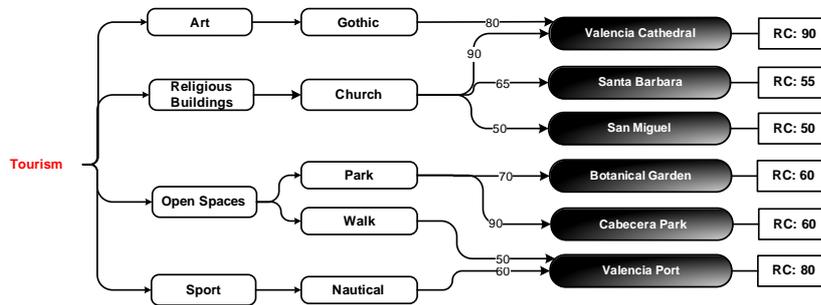


Figura 3.2: Parte de la ontología de Turismo en la ciudad de Valencia.

## 3.2. El proceso de recomendación de grupos

Un grupo de usuarios  $G$  está formado por un conjunto de miembros ya registrados en el sistema. Haremos uso de una ontología para representar el conjunto de preferencias de dominio y los ítems asociados a cada una de ellas. La Figura 3.2 es parte de la ontología del dominio de Turismo en la ciudad de Valencia.

La primera tarea del SRG es obtener el conjunto de preferencias de cada uno de los miembros del grupo, de acuerdo a los perfiles de usuario. Dicho conjunto de preferencias individuales de un usuario es lo que llamaremos el *modelo de preferencias de usuario*, y será denotado como  $P^u$ . Este modelo está compuesto por preferencias de la forma  $(f, d^{Gf})$ , donde  $f$  es una característica definida en la ontología del dominio, y  $d^{Gf} \in [0, 100]$  es el grado de interés estimado del grupo  $G$  sobre la característica  $f$ . Estas preferencias son calculadas por medio de cuatro técnicas de recomendación **individuales** (BRT)<sup>1</sup>: Demográfico (D), Basado en preferencias (GLF), Colaborativo (CF) y Basado en contenido (CB). Las preferencias obtenidas por cada BRT (ver User Manager en la Figura 3.3), son totalmente independientes entre ellas. El proceso de combinación de preferencias de cada uno de los BRT, queda fuera de este resumen, pero puede encontrarse en el PFC que el alumno realizó para la titulación de *Ingeniería Informática*.

Una vez cada usuario ha construido un modelo  $P^u$  de preferencias, el SRG calcula un modelo de preferencias de grupo  $P^G$ . Tanto las preferencias individuales como las preferencias del grupo, se representan siguiendo una misma tupla formada por la característica y su grado de interés. Por ejemplo, un grupo podría tener la siguiente preferencia  $(Art/Gothic, 80)$ . Para obtener tal modelo de preferencias de grupo es necesario aplicar una de las técnicas de elicitación que veremos a continuación: Agregación, Intersección e Inter-

<sup>1</sup>BRT, Basic Recommendation Techniques

sección Incremental. Por tanto, las técnicas de recomendación, en ningún caso trabajan directamente con los ítems específicos a obtener, sino con un conjunto de preferencias (también conocido como restricciones).

Una vez el SRG ha obtenido el modelo de preferencias de grupo  $P^G$ , debe calcular (por medio de un Sistema Recomendador Híbrido) una lista de ítems recomendados  $RI^G$ . Este conjunto está formado por tuplas de la forma  $RI^G = \{(i, d^{Gi})\}$ , donde  $i$  es el ítem a recomendar (por ejemplo: la película Toy Story), y  $d^{Gi}$  es el grado de interés estimado del grupo  $G$  en el ítem  $i$  (por ejemplo 80).

En resumen, el proceso de recomendación a un grupo de usuarios se divide en los siguientes pasos:

1. Se modelan las preferencias individuales de cada usuario  $u$  del grupo  $G$ , obteniendo el conjunto  $P^u$ .
2. Estas preferencias individuales serán posteriormente combinadas por medio de una técnica de elicitación de preferencias de grupo (ver sección 3.3), para obtener un conjunto de preferencias comunes al grupo  $P^G$ .
3. Se extrae la lista de recomendaciones  $RI^G$  que casa con estas preferencias del grupo.

### 3.3. Técnicas de elicitación de preferencias de grupo

En esta sección veremos tres técnicas básicas para el cálculo de preferencias de un grupo: Agregación, Intersección e Intersección Incremental, que son las que fueron implementadas en el pasado PFC del alumno. Cada una de las técnicas se ilustra en la parte derecha de la Figura 3.3.

#### 3.3.1. Técnica de Agregación

La Agregación [4] es una de las técnicas más sencillas para combinar modelos de preferencias de usuario. El procedimiento que se aplica es el siguiente: todas las preferencias de cada uno de los  $P^u$  son directamente agregadas al conjunto  $P^G$ . Seguidamente se calcula el grado de interés de una preferencia  $f$  para un grupo  $G$ , como la media<sup>2</sup> de los grados de interés

---

<sup>2</sup> Como veremos en la sección 3.4, además de la media como mecanismo del cálculo de la prioridad de una preferencia, el SRG permite otra serie de mecanismos para tal fin, como son la mediana, la máxima, etc.

### 3.3. TÉCNICAS DE ELICITACIÓN DE PREFERENCIAS DE GRUPO<sup>15</sup>

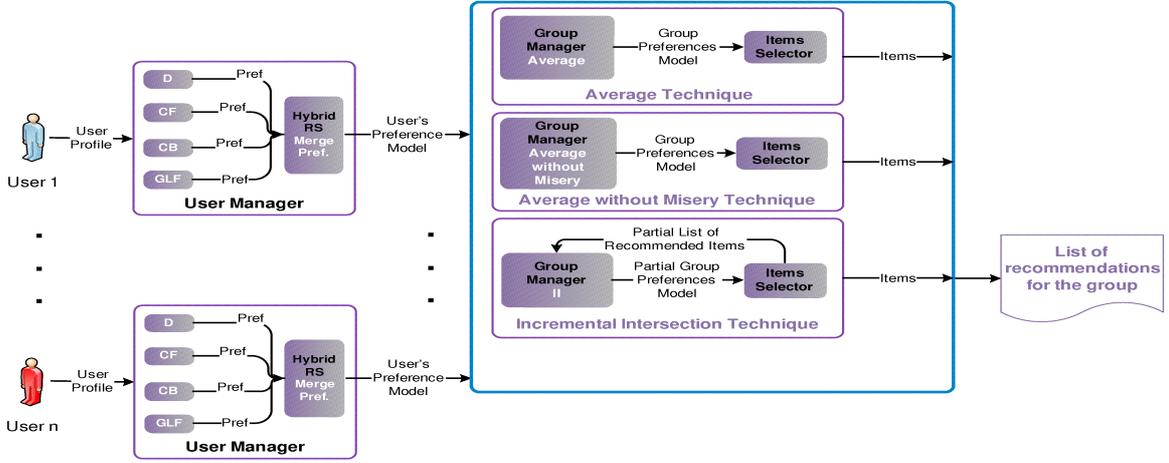


Figura 3.3: Pasos en el proceso de recomendación de grupos.

de cada uno de los usuarios  $u$  de  $G$  respecto a  $f$ , es decir la media de cada uno de los  $d^{uf} \mid d^{uf} \in P^u$ . De este modo, puede ocurrir que una preferencia que está incluida en el conjunto  $P^G$ , no aparezca en alguno de los conjuntos  $P^u$ . Por lo tanto una preferencia será añadida a  $P^G$  si y solo si aparece en al menos un modelo de preferencias de usuario  $P^u$ . Se asume que si una preferencia no la tiene un usuario, entonces su ratio es 0 a la hora de calcular el promedio para establecer un ratio común para la preferencia en el conjunto  $P^G$ .

La ventaja de esta técnica es que siempre funciona para cualquier grupo de usuarios, independientemente de qué preferencias tengan tales usuarios en su  $P^u$ . La desventaja es que el conjunto de preferencias del grupo puede en ocasiones no ser del agrado de todos los miembros del grupo, dando lugar a recomendaciones que no son aceptadas por todos los usuarios del grupo.

#### 3.3.2. Técnica de Intersección

Esta técnica (también conocida como AWM, Average without misery [5]) calcula el conjunto  $P^G$  teniendo en cuenta sólo aquellas preferencias que aparecen en todos los modelos de preferencias de cada uno de los miembros del grupo. Por lo tanto, todas las preferencias de  $P^G$  aparecen en cada uno de los  $P^u$ . Del mismo modo que en la técnica anterior, para calcular el ratio de una preferencia en el grupo se aplica la media<sup>2</sup> de cada uno de los ratios individuales ( $d^{uf}$ ) sobre tal preferencia.

La gran ventaja de esta técnica es que el conjunto de preferencias o restric-

ciones, tendrán un nivel alto de satisfacción por parte de todos los miembros del grupo. Por contra, la desventaja de esta técnica es que si el grupo de usuarios es muy heterogéneo, podemos llegar a tener un conjunto de preferencias para un grupo vacío, porque podrían no existir preferencias comunes a los integrantes del grupo.

### 3.3.3. Técnica de Intersección Incremental (II)

Esta técnica combina las ventajas de la agregación y la intersección. Supongamos que  $NR$  es el número de recomendaciones solicitadas por un grupo de usuarios. Esta técnica calcula el número de restricciones compartidas por todos los miembros de un grupo  $G$ , y seguidamente calcula una lista de ítems  $m$ , que casan con estas preferencias. Entonces hasta aquí hace lo mismo que la técnica de intersección. Ahora bien, para solucionar aquella desventaja de la intersección, comprueba si  $m < NR$ ; si es cierto, significa que no es posible encontrar  $NR$  ítems con la técnica de la Intersección. Entonces, II repite el mismo cálculo, pero considerando ahora restricciones compartidas por un subgrupo  $G_{N-i}^G$  de usuarios de  $G$ . Y este proceso se repetirá, aumentando  $i$ , hasta que logremos obtener un conjunto de  $NR$  ítems. Entonces terminará cuando obtengamos  $NR$  ítems recomendados, ó hasta que el número de miembros considerados en un grupo sea de un solo usuario, en ese caso ya no podremos seguir más. A continuación detallaremos cada uno de los pasos implementados por esta técnica:

1. II crea una lista de restricciones  $P_N^G$ , agregando todas las preferencias de todos los miembros del grupo, incluyendo cada una de las preferencias individuales. Cada restricción de la lista, lleva asociado un valor  $u$ , que indica el número de usuarios cuyo  $P^u$  contiene esa restricción o característica. Y en el caso de que la preferencia se dé en más de un usuario, la prioridad de la preferencia es calculada como la media (ver sección 3.4) de cada uno de los  $d^{uf}$ .
2. El número de inicial de usuarios es inicializado al número de miembros del grupo, de modo que  $N=|G|$ .
3. Todas las restricciones (preferencias) satisfechas por el grupo de  $N$  usuarios se unen en una lista  $P^G$ .
4. Los ítems que hagan matching con las restricciones de  $P^G$ , son añadidos a  $RI^G$  (lista de recomendaciones finales). Esta lista está ordenada de acuerdo a la prioridad computada por cada ítem.

5. Si el número de ítems recomendados es mayor o igual al número de ítems pedidos, entonces la lista  $RI^G$  es devuelta. En cualquier otro caso, el tamaño del nuevo grupo será de  $N - 1$  usuarios, y el proceso II vuelve al punto 3.

## 3.4. Cálculo de Prioridad

Esta sección resume el cálculo de prioridad tanto para una preferencia del grupo, como para un ítem a recomendar.

### 3.4.1. Cálculo de la prioridad de una preferencia

Aunque en cada una de las tres técnicas anteriores hemos aplicado la media como mecanismo para el cálculo de cada preferencia  $d^{Gf}$  del conjunto  $P^G$ , el SGR contempla más posibilidades:

1. Máxima de las prioridades de cada usuario.
2. Suma de las prioridades de cada usuario
3. Media de las prioridades de cada usuario.
4. Media de las prioridades de todos los usuarios, incluido aquellos que no tienen puntuada la preferencia.
5. Mediana de las prioridades de cada usuario.

Por tanto, el administrador del sistema debe indicar qué alternativa de las anteriores se usará en el cálculo de la prioridad y qué técnica de recomendación para grupos se aplicará. Ambas características, deberán ser elegidas en la ventana de configuración, previo al cálculo de la recomendación.

### 3.4.2. Cálculo de la prioridad de un ítem

En el proceso de formación de un conjunto de ítems recomendables a un grupo de usuarios, el SRG es el encargado del cálculo de la prioridad de dichos ítems. Recordando que un ítem es elegido como respuesta a un conjunto de restricciones, lo más común es que existan varias restricciones o preferencias que proporcionen como salida ese ítem  $n$ .

La prioridad de ese ítem se puede calcular de diferentes maneras:

- Hybrid Ratio Max: Elegir la máxima prioridad de todas las restricciones.

- Hybrid Ratio Avg: Media de las prioridades de las restricciones asociadas.
- Hybrid Ratio Avg Group Restriction: Media de todas las restricciones, pertenecientes a la lista de restricciones del grupo, y que casan con el ítem en cuestión.

Por ejemplo, en la Figura 3.2, el ítem *Valencia Cathedral* está descrito por las tuplas (*Religious Building-Church*, 90) y (*Art-Gothic*, 80). Imaginando que tanto la primera preferencia como la segunda estaban incluidas en el perfil del grupo, entonces si calculamos la prioridad del ítem *Valencia Cathedral* como la media de las prioridades, esto daría un ratio de 85. Sin embargo, como vimos en el pasado PFC, en el cálculo total también influye (positivamente o negativamente) el contador de visitas (RC) de cada uno de los ítems. Por ejemplo, en la Figura 3.2, el ítem *Valencia Cathedral* tiene un ratio de 90. Aquellos ítems que tengan un alto grado de aceptación serán priorizados en el proceso de recomendación. De este modo, el ratio de *Valencia Cathedral* podría pasar de ser 85 a ser por ejemplo 95, debido a su alto grado de aceptación cuando fue recomendado en ocasiones anteriores.

# 4

## La Técnica Intersección Colaborativa Incremental

Este capítulo es el más importante del PFC y presenta la técnica Intersección Colaborativa Incremental para el Sistema Recomendador de Grupos presentado en el capítulo anterior. Dicha técnica se añade las tres técnicas anteriores: Agregación, Intersección e Intersección Incremental.

### 4.1. Presentación

Las opiniones/sugerencias de los usuarios del sistema son un punto importante a tener en cuenta en cualquier proceso de recomendación. Estos usuarios juegan el papel de expertos en un tema. Para este propósito los Filtros Colaborativos (CF) o Sistemas Recomendadores Colaborativos son a menudo muy usados. Recordemos que el funcionamiento de un CF es el siguiente: (i) acumula recomendaciones de usuarios sobre los ítems, (ii) identifica similitudes entre usuarios, y (iii) usa los usuarios similares como fuente de información para el proceso de recomendación. De hecho, tal y como vimos en el capítulo 2, usamos un Recomendador Colaborativo como una BRT.

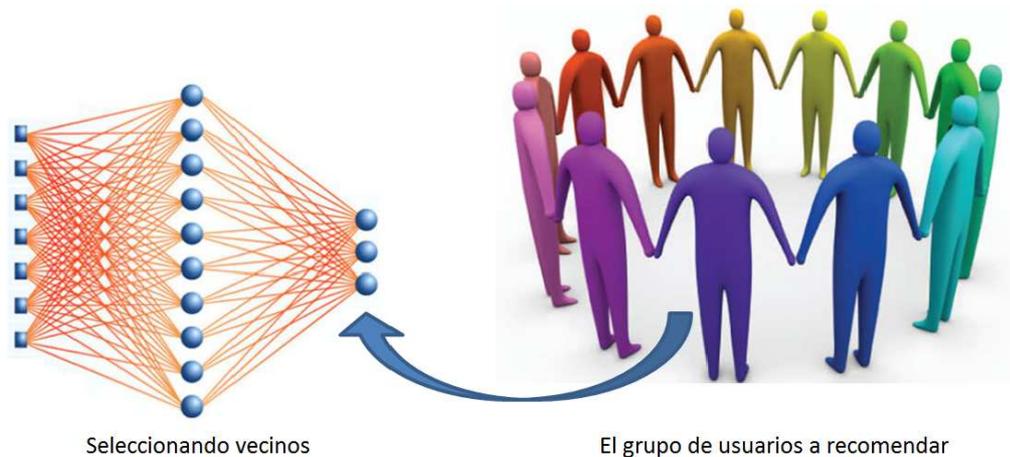


Figura 4.1: La técnica ICI gráficamente.

Nosotros creemos que estos usuarios expertos, que a menudo son conocidos como **vecinos** [17] pueden mejorar significativamente las actuales técnicas de elicitación de preferencias para grupos (ver Figura 4.1). Más concretamente, la idea es que la opinión de otros usuarios se tenga en cuenta en el proceso de elicitación de preferencias de un grupo de usuarios. Cabe destacar que no todas las opiniones pueden ser buenas, sino que debemos seleccionar qué usuarios son adecuados para opinar en cada proceso de recomendación por tener gustos similares al grupo a recomendar. En las siguientes secciones presentaremos la nueva técnica que hemos llamado **-Intersección Colaborativa Incremental-** (ICI).

## 4.2. Motivación

Existen dos principales inconvenientes que pueden darse en el proceso de recomendación para grupos de usuarios:

1. El grupo tiene pocas preferencias en común, y no se obtienen suficientes ítems.
2. El grupo tiene muchas preferencias en común y es difícil discriminar los mejores ítems para el grupo.

El problema 1 está parcialmente resuelto por la técnica Intersección Incremental como ya vimos en el capítulo 2. Por su parte para el problema 2 no

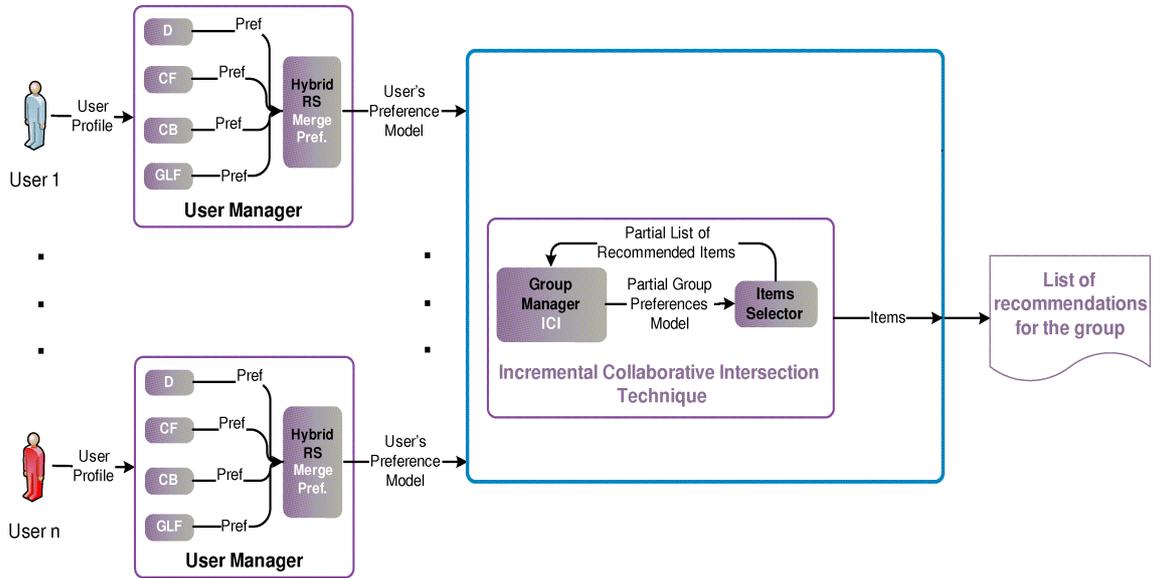


Figura 4.2: Pasos que sigue la técnica ICI.

existen técnicas capaces de enfrentarse a tal problema. A pesar de lo importante que podría resultar la opinión de expertos (usuarios que no pertenecen al grupo actual a recomendar) a la hora de elicitar las mejores preferencias tanto para el problema 1 como para el 2, no existen técnicas que tengan en cuenta este aspecto (al menos hasta donde nosotros conocemos).

Por tanto, resulta atractivo diseñar una técnica que no sólo tenga en cuenta la información de cada uno de los miembros del grupo, sino además también la opinión de diferentes expertos como ayuda al proceso de elicitación. Como muestra la Figura 4.2, la técnica ICI sigue dos pasos. El primero consiste en construir un modelo de preferencias inicial  $P^G$ , y el segundo extiende dicho modelo usando una técnica colaborativa. Más concretamente, el algoritmo que propondremos en la siguiente sección, construye un modelo de preferencias de grupo llamado  $P^G$  (paso 1 en la figura 4.3), el cual es sucesivamente refinado con nuevas preferencias adoptadas por usuarios que tienen los mismos gustos que los miembros del equipo (paso 2 en la figura 4.3). Este segundo paso se repetirá incrementalmente hasta que el número de recomendaciones pedidas haya sido satisfecho.

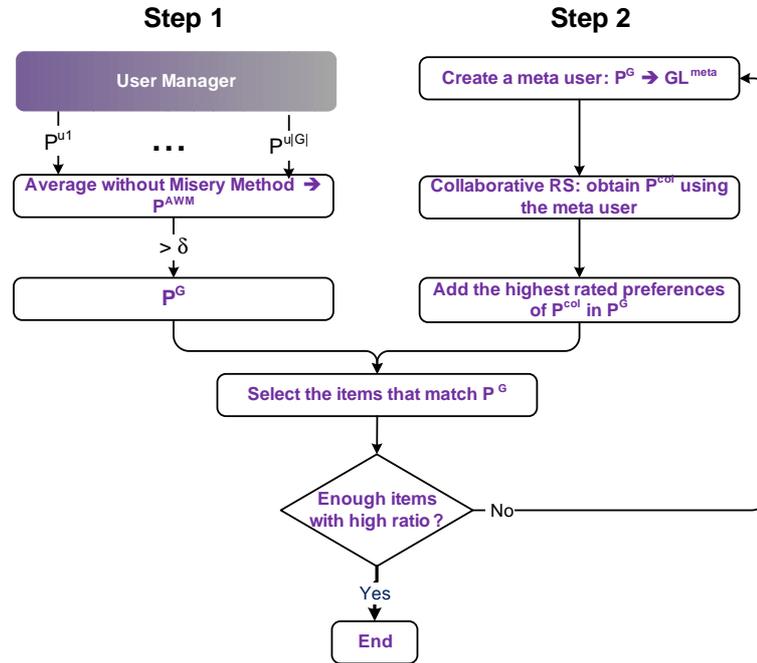


Figura 4.3: Resumen: Intersección Incremental Colaborativa.

### 4.3. Descripción de la técnica

Como vimos en la sección 3.3.3, una técnica incremental es aquella que elicitaba un modelo de preferencias de grupo parcialmente, y lo va refinando iterativamente. En cada iteración obtiene una lista de recomendaciones que casan con las preferencias seleccionadas. El proceso se repite hasta que se haya obtenido el número de recomendaciones pedido por el grupo. Sin embargo a diferencia de la técnica de Intersección Incremental, aquí  $P^G$  es extendido teniendo en cuenta la información suministrada por un sistema recomendador colaborativo.

En lo que sigue explicaremos el **primer paso** más detalladamente. La entrada es el modelo de preferencias individual  $P^u$  de cada uno de los miembros del grupo. Aplicando la técnica de la Intersección, obtenemos el conjunto  $P^{Int}$ , es decir el conjunto de preferencias compartidas por todos los usuarios del grupo, cuyo valor  $d^{Gf}$  excede de un umbral establecido. Partiendo de tal conjunto  $P^{Int}$ , solamente seleccionaremos aquellas preferencias que superen otro determinado umbral  $\delta$  (estas preferencias formarán el conjunto  $P^{high}$ ), y de este modo construiremos el modelo inicial de preferencias de grupo  $P^G$ . El resto de preferencias (formarán el conjunto  $P^{low}$ ) son descartadas por el momento. Obviamente es preferible que el valor de  $\delta$  sea tan alto como sea

posible con el objetivo de seleccionar únicamente las mejores preferencias (las mejor puntuadas) en esta primera iteración. A continuación el Item Selector calcula un conjunto de ítems a recomendar teniendo en cuenta el conjunto de preferencias en  $P^G$ . Si el número de ítems a recomendar es suficiente para los requerimientos especificados por el grupo  $N$ , entonces el proceso termina en este punto. En caso contrario pasamos al paso 2 y el proceso continúa (hasta que el número de recomendaciones ofrecido sea igual a  $N$ ).

El objetivo del **segundo paso** es extender  $P^G$  con nuevas preferencias del conjunto  $P^{low}$ , usando para ello un Sistema Recomendador Colaborativo que nos ayude en tal elección de preferencias de grupo. Seguiremos los siguientes pasos.

- Haremos uso de un **meta-usuario**, como un usuario que representa una abstracción de todos los miembros del grupo. Inicialmente las preferencias de dicho meta-usuario serán el conjunto de preferencias del grupo elicadas hasta el momento, es decir  $GL^{meta} = P^G$ .
- A continuación se selecciona un conjunto de usuarios (los cuales no forman parte del grupo), como usuarios vecinos y los cuales deberán tener un perfil muy parecido al del *meta-usuario*. Un usuario externo  $u'$  al grupo  $G$ , se considera vecino si tiene un grado de similaridad suficiente con respecto al conjunto de preferencias del grupo, es decir si  $P^{u'}$  es similar a  $GL^{meta}$ .
- Seguidamente les pediremos a estos vecinos que nos recomienden un conjunto de preferencias de acuerdo a sus *experiencias pasadas*. Dicho conjunto pedido será etiquetado como  $P^{col}$ . Cada una de las preferencias que forman esta lista, será una tupla formada por:  $(f, d^{metaf})$ , donde  $f$  es la preferencia y  $d^{metaf}$  es el grado de interés del meta-usuario en la preferencia  $f$ . Este valor es calculado por medio de un recomendador colaborativo sobre aquellos vecinos seleccionado anteriormente.
- Seguidamente ordenamos de mayor a menor todas las preferencias del conjunto  $P^{col}$  de acuerdo a su valor  $d^{metaf}$ .
- La técnica continúa seleccionado aquellas preferencias de  $P^{col}$  con un valor  $d^{metaf}$  superior a un determinado umbral  $\alpha$ , con el objetivo de completar las preferencias actuales del grupo de usuarios a recomendar. Tales nuevas preferencias son insertadas en  $P^G$  como tuplas de la forma  $(f, d^{Gf})$ , donde  $d^{Gf}$  se calcula como el ratio que la característica  $f$  tiene en  $P^{col}$  por un factor de ponderación  $\varpi_{col} = 0,8$ , más el ratio que esa misma característica  $f$  tiene en el conjunto  $P^{low}$  por otro factor

de ponderación  $\varpi_{low} = 0,2$ . El resultado de sumar  $\varpi_{col}$  y  $\varpi_{low}$ , siempre debe dar uno. De este modo en cada iteración la lista  $P^G$  es extendida con nuevas preferencias y el modelo de preferencias de grupo que almacena el meta-usuario va siendo cada vez más preciso al incorporar nuevas preferencias incrementalmente. De este modo, podemos afirmar que cuantas más preferencias tenga el conjunto  $P^G$ , mejores resultados (con más precisión) ofrecerá el sistema recomendador colaborativo. Aquí finaliza el paso 2.

Finalmente si el número de recomendaciones pedido ha sido conseguido, el proceso termina; en caso contrario el segundo paso es ejecutado de nuevo, aplicando nuevamente un recomendador colaborativo sobre el modelo de preferencias del meta-usuario. Este procedimiento incremental en el que cada vez el perfil del meta-usuario contiene más y más preferencias, continuará hasta que el proceso de recomendación obtenga el número de recomendaciones pedido.

## 4.4. Ejemplo de aplicación

En esta sección mostraremos dos breves ejemplos con el objetivo de visualizar cada uno de los pasos que sigue la técnica que hemos presentado anteriormente. Cada escenario se refiere a uno de los inconvenientes que anteriormente presentamos. Veremos como la técnica ICI es capaz de hacer frente a ambos escenarios.

Supondremos un grupo de tres usuarios  $u^1$ ,  $u^2$  y  $u^3$  quienes desean obtener un conjunto de 3 recomendaciones sobre lugares turísticos de la ciudad de Valencia.

### 4.4.1. Ejemplo 1: Resuelve el Inconveniente 1

A continuación enumeraremos cada una de las etapas del proceso de recomendación:

1. Primeramente obtenemos el conjunto de preferencias individuales de cada usuario tal por medio de diferentes técnicas básicas BRT. Nos damos cuenta de que los usuarios son muy diferentes y sólo coinciden en la preferencia *Sport-Nautical* les gusta a los tres.
2. **Step 1:** En segundo lugar, aplicamos la técnica de la Intersección sobre cada todos los conjuntos  $P^u$ . Generamos un conjunto de ítems a recomendar en base a las preferencias intersectadas. Concretamente se

Iteración	Preferencias	Ítems (grado de interés/usuarios satisfechos)
1	(Sport-Nautical, 57) (Int.)	Valencia Port (66/3)
2	(Open Spaces-Park, 80) (CF)	Botanical Garden (70/2) Cabecera Park (69/2)

Tabla 4.1: Ejemplo 1: Intersección Incremental Colaborativa.

genera el ítem *Valencia Port* con un valor  $d^{GValenciaPort} = (80 + 60 + 57)/3 = 66$ , tal y como muestra la primera iteración en la tabla 4.1. Dado que el número de recomendaciones pedidas por el grupo era un total de 3, debemos pasar al segundo paso.

- Step 2:** El principal objetivo es extender el conjunto  $P^G$ . El meta-usuario se define inicialmente con un conjunto  $GL^{meta} = \{(Sport - Nautical, 57)\}$ . Suponiendo que la técnica ha seleccionado un conjunto de vecinos más próximos al grupo teniendo en cuenta la anterior preferencia *Sport - Nautical*, estos han recomendado incluir dos nuevas preferencias  $P^{col} = \{(Open Spaces-Park, 80), (Open Spaces-Walk, 45)\}$  en el conjunto de preferencias del grupo  $P^G$ . Asumiendo que  $\alpha = 70$ , la preferencia con  $d^{Gf} \geq \alpha$  es *Open Spaces-Park*. De modo que esta preferencia es seleccionada y es añadida al conjunto  $P^G$ , es decir que ahora  $P^G = \{(Sport-Nautical, 57), (Open Spaces-Park, 80)\}$ . Seguidamente generamos las siguientes nuevas recomendaciones: *(Botanical Garden, 70)*, *(Cabecera Park, 69)* (ver la última columna de la tabla 4.1). Dado que ahora el número total de recomendaciones es 3, el proceso de recomendación termina en este punto.

#### 4.4.2. Ejemplo 2: Resuelve el Inconveniente 2

Nuevamente supondremos un grupo formado por tres usuarios, pero esta vez, tal y como ilustra la tabla 4.2 los usuarios son muy homogéneos en cuanto a preferencias se refiere. Concretamente los tres usuarios tienen tres preferencias comunes.  $P^{int}$  contiene todas las preferencias de todos los usuarios del grupo  $P^{int} = \{(Sport - Nautical, 57), (Open Spaces - Park, 37), (Religious Buildings - Church, 37)\}$ . Dado que los usuarios son muy similares, se procede a dividir el conjunto  $P^{int}$  en  $P^{high}$  (conjunto de preferencias que superan un determinado umbral) y  $P^{low}$  (conjunto de preferencias que no superan tal umbral). Más concretamente  $P^{high} = \{(Sport - Nautical, 57)\}$  y  $P^{low} = \{(Open Spaces - Park, 37), (Religious Buildings -$

Usuarios	Lista de Preferencias $P^u$
$u^1$	(Sport-Nautical, 80) (Open Spaces-Park, 70) (Religious Buildings-Church, 20)
$u^2$	(Sport-Nautical, 50) (Open Spaces-Park, 20) (Religious Buildings-Church, 20)
$u^3$	(Sport-Nautical, 40) (Open Spaces-Park, 20) (Religious Buildings-Church, 70)

Tabla 4.2: Ejemplo 2: lista de preferencias para cada usuario del grupo.

Iteración	Preferencias	Ítems (grado de interés/usuarios satisfechos)
1	(Sport-Nautical, 57) (Int.)	Valencia Port (66/3)
2	(Open Spaces-Park, 80) (Plow)	Cabecera Park (74/3) Botanical Garden (67/3)

Tabla 4.3: Ejemplo 2: Intersección Incremental Colaborativa.

$Church, 37\}$ ). A continuación igualamos  $P^G = P^{high}$  con el objetivo de aplicar un Sistema Recomendador Colaborativo que proporcionándole como entrada el conjunto  $P^G$  nos diga cuáles son las mejores preferencias (conjunto  $P^{col}$ ) a seleccionar en el proceso de elicitación. En este caso el conjunto de vecinos nos proporciona el siguiente conjunto de preferencias  $P^{col} = \{(OpenSpaces - Park, 80), (OpenSpaces - Walk, 45)\}$ , y por tanto se selecciona la preferencia  $(OpenSpaces - Park, 80)$  porque estaba incluida en el conjunto de preferencias del grupo  $P^{low}$ , y ahora el conjunto  $P^G$  pasa a estar formado por  $\{(Sport - Nautical, 57), (OpenSpaces - Park, 80)\}$ . Tenga en cuenta que lo que se ha hecho es básicamente refinar el conjunto de preferencias de  $P^G$  en base a aquellas preferencias  $P^{col}$  que estaban en el conjunto  $P^{low}$ . En la última columna de la tabla 4.3 podemos ver los ítems que se han ido generando en cada una de las iteraciones para las preferencias seleccionadas. Teniendo en cuenta los pesos  $\varpi_{col} = 0,8$  and  $\varpi_{low} = 0,2$ , los ratios de los ítems se han calculado de la siguiente manera:  $d^{GCabeceraPark} = (60 + 90 + (80 \times 0,8 + 37 \times 0,2))/3 = 74$ .

Los dos anteriores ejemplos muestran la utilidad de la técnica ICI tanto para obtener nuevas preferencias para el grupo, como para filtrar un conjunto de preferencias dado. En la siguiente sección evaluaremos experimentalmente la técnica en este dominio del Turismo, y en otro segundo dominio relacionado con la recomendación de películas.

# 5

## Evaluación y Resultados

Una vez desarrollada la técnica, ha llegado el momento de saber si aplicando la técnica de elicitación propuesta en el capítulo anterior las recomendaciones que ofrece nuestro Sistema Recomendador de Grupos son buenas o no. Es decir, si éstas se ajustan a los gustos de los usuarios del grupo.

Este capítulo presenta los experimentos llevados a cabo en dos dominios diferentes, uno de turismo en la ciudad de Valencia y otro de películas de cine. Tales experimentos servirán como método de evaluación de la propuesta hecha en este proyecto. Más concretamente, la sección 5.1 explica las métricas usadas en la evaluación. Las secciones 5.2 y 5.3 presentan los experimentos llevados a cabo en cada dominio, comparando la técnica implementada con las tres técnicas básicas que fueron presentadas en el anterior PFC: Agregación, Intersección e Intersección Incremental.

### 5.1. Descripción de las medidas usadas para la evaluación

Actualmente existen diferentes tipos de medidas usadas para evaluar la calidad de las recomendaciones que ofrece un Sistema Recomendador, tales

como la precisión o el error medio absoluto (conocido como MAE). Nosotros hemos optado por usar la medida MAE dado que las últimas publicaciones de gran impacto en recomendadores han usado dicha medida [2].

En primer lugar, nosotros definimos  $MAE^u$  como una medida de la desviación de las recomendaciones para el grupo con respecto a las recomendaciones individuales que tal usuario  $u$  obtuvo antes de formar parte del grupo. Dado un conjunto de recomendaciones  $RI^G$  de  $N$  ítems para un determinado grupo  $G$ , tal que  $u \in G$ , la media de error absoluto para un usuario  $u$  se define como:

$$MAE^u = \frac{\sum_{i=1}^N |d^{ui} - d^{Gi}|}{N} \quad (1)$$

donde  $d^{ui}$  es el grado de interés estimado del usuario  $u$  en el ítem  $i$ . Este valor es obtenido por un Sistema Recomendador individual (recomendación ofrecida para un solo usuario [3], [11]). Por lo tanto  $MAE^u$  indica cómo de adecuada es la recomendación del grupo para el usuario  $u$ . Cuanto más bajo sea el valor de  $MAE^u$ , más adecuada habrá sido la recomendación del grupo para dicho usuario. Más concretamente, nosotros mediremos dos aspectos:

- $MAE^G$ : La precisión de las recomendaciones de grupo para todos los miembros.
- $D^G$ : El grado de interés de cada miembro no presenta una alta desviación o distancia. Una distancia baja indica que todos los miembros del grupo han sido satisfechos de una manera uniforme. Es decir, esta medida es interpretada como la diferencia de satisfacción entre cada uno de los miembros del grupo.

## 5.2. Dominio de Películas

MovieLens es un sistema recomendador con una interfaz web<sup>1</sup>. Además ofrece un repositorio de datos compuesto por más de 900 perfiles de usuario con sus respectivas historiales de interacción con el sistema (recomendaciones efectuadas y puntuadas por ellos) y un conjunto de 1682 películas. La ontología de preferencias que usan está formada por 20 preferencias: Acción, Aventuras, Ciencia Ficción, etc. Los usuarios que nosotros hemos elegido aleatoriamente para testear la técnica tienen una media de 15 preferencias y 45 películas que han visto y han puntuado personalmente tras la recomendación. Además cada película tiene almacenada las siguientes características:

---

<sup>1</sup>[www.grouplens.org](http://www.grouplens.org)

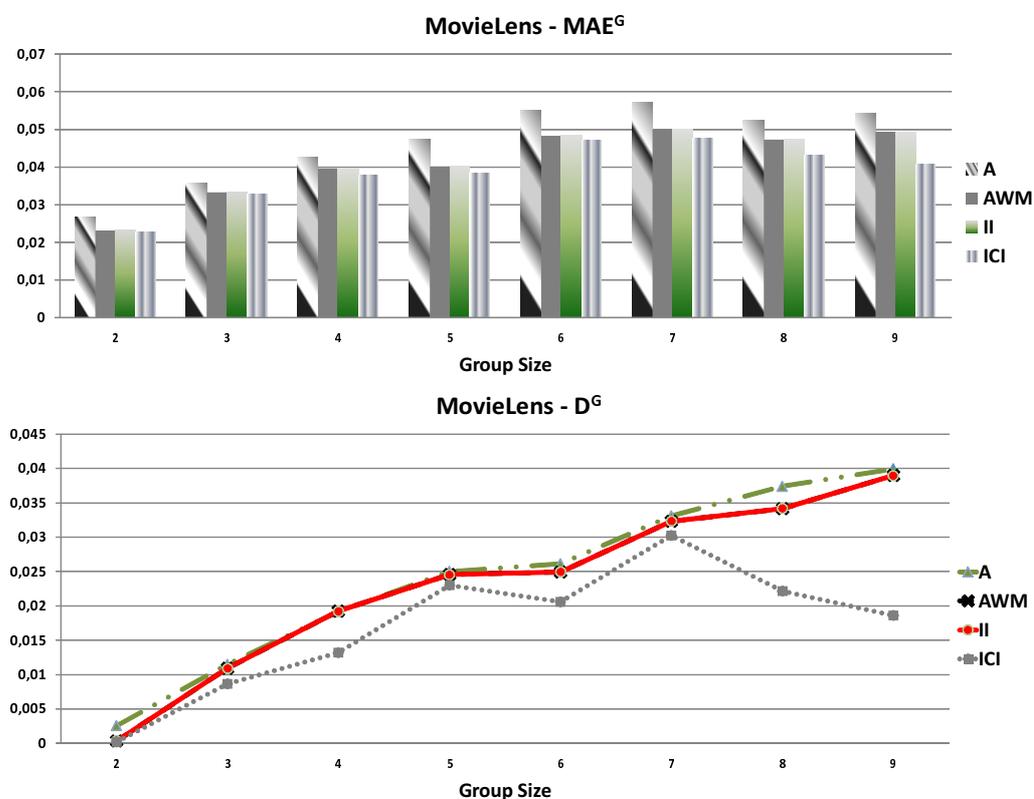


Figura 5.1: Comparando la técnica ICI con el resto de técnicas en el dominio de películas.

el título de la película, la fecha de publicación, la URL, el género y la lista de puntuaciones o ratings dados por los usuarios a los que se les recomendó la película y la vieron.

Hemos usado grupos formados aleatoriamente entre 2 y 9 usuarios. El número de recomendaciones que cada grupo solicitó fue en todos los casos 10. La figura 5.1 muestra los resultados obtenidos en estos experimentos. Cada barra representa la media  $MAE^G$  para todos los grupos de cada tamaño y para cada técnica de elicitación. La segunda gráfica dentro de la misma figura muestra la distancia entre cada uno de los miembros del grupo ( $D^G$ ) para cada técnica de elicitación. Ambas medidas que anteriormente hemos explicado  $MAE^G$  y  $D^G$  pueden tomar valores entre 0 y 1.

Como muestra la figura 5.1 el  $MAE^G$  para todas las técnicas es extremadamente bajo. Por este motivo podemos afirmar que las recomendaciones ofrecidas a los grupos son normalmente bien aceptadas por los usuarios. Además dado que  $MAE^G$  varía entre un mínimo de 0.0226 y un máxi-

mo de 0.057, podemos afirmar que no existe una diferencia significativa de  $MAE^G$  con respecto al tamaño de los grupos, algo que demuestra la escalabilidad de nuestro sistema. Del mismo modo ocurre cuando comparamos los  $D^G$  para cada uno de los tamaños de grupo usados.

A continuación compararemos los resultados obtenidos. La Agregación, Intersección e Intersección Incremental no mejoran en ningún caso a la ICI con respecto al  $MAE^G$ . Respecto al  $D^G$  los resultados para todas las técnicas son muy similares, excepto a partir de los grupos formados por 7 usuarios, donde la desviación ofrecida por la ICI es significativamente menor que cualquiera de las otras técnicas. Además como se puede ver, la desviación de la ICI es siempre menor que cualquiera de las otras tres técnicas.

Dado que los valores obtenidos en  $MAE^G$  como  $D^G$  para la técnica ICI son en la mayoría de los casos menores que cualquiera de las tres técnicas anteriores, podemos afirmar que dicha técnica ICI ofrece mejores recomendaciones a los grupos que cualquiera de las otras tres. Finalmente, un aspecto a destacar es que todas las técnicas son capaces de satisfacer el número de recomendaciones pedido por cada grupo (en nuestro caso 10).

### 5.3. Dominio de Turismo

El dominio de turismo ha sido desarrollado por nosotros mismos por medio de un pase de encuestas. Este repositorio referente a actividades turísticas en la ciudad de Valencia, tiene una ontología formada por 115 preferencias estructuradas en dos niveles y almacena un total de 158 lugares de Valencia. Los perfiles de usuarios almacenados corresponden a usuarios reales y hemos almacenado información demográfica así como qué preferencias son del agrado de cada usuario. Los usuarios también han puntuado los ítems o lugares de Valencia.

Del mismo modo que hicimos con el dominio de películas elegiremos grupos de 2 a 9 personas de un conjunto de usuarios seleccionados aleatoriamente. El número total de recomendaciones que cada grupo solicita es nuevamente 10. La figura 5.2 muestra los resultados obtenidos en estos experimentos. La interpretación respecto a las gráficas es la misma que la que hemos explicado previamente en el dominio de películas.

Como muestra la figura 5.2, el  $MAE^G$  de todas las técnicas es bastante variable, desde 0.04 a 0.4. Esto indica que es más complejo el presente dominio de turismo que el anterior. Es a partir de los grupos de 6 personas donde se observa un error pronunciado de la técnica ICI. Esto ocurre porque como vimos en la sección anterior la ICI depende inicialmente de un modelo de preferencias elicitado por la técnica I. Si esta técnica I no es capaz de

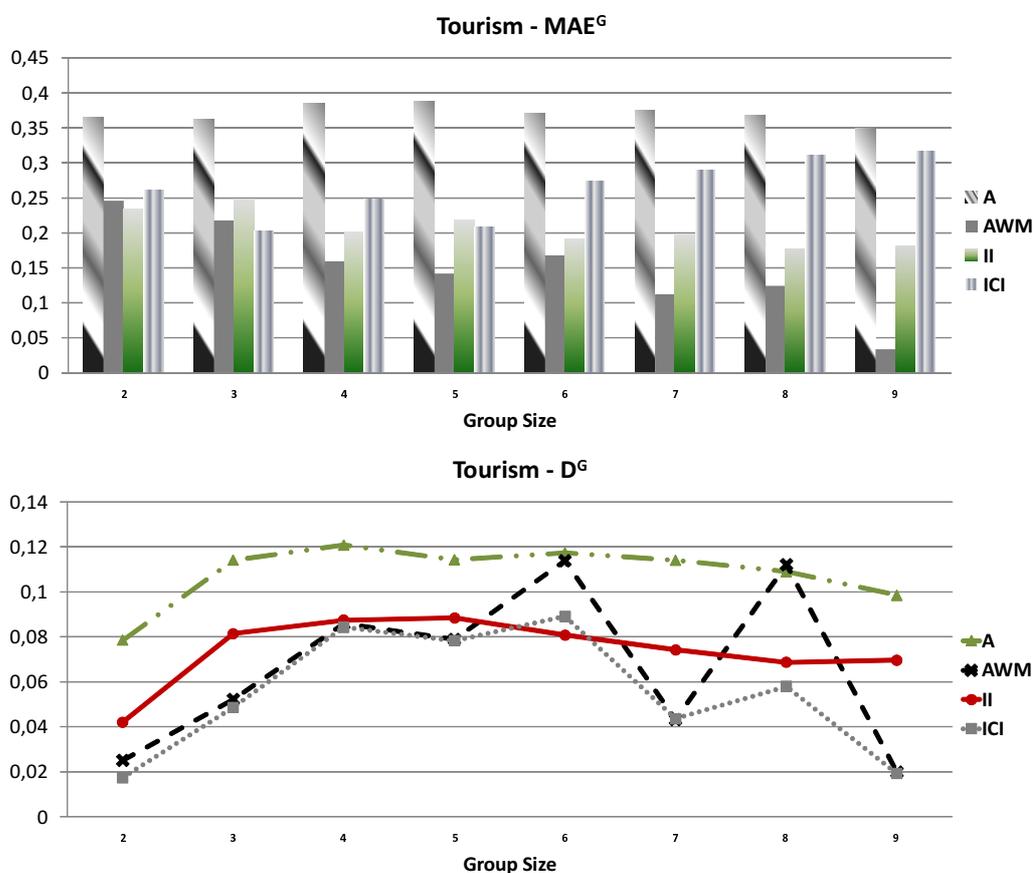


Figura 5.2: Comparando la técnica ICI con el resto de técnicas en el dominio de turismo.

elicitar un buen conjunto de preferencias difícilmente la ICI podrá refinar correctamente el conjunto de preferencias de grupo. Sin embargo respecto al  $D^G$  hay claras diferencias entre las distintas técnicas. Concretamente la técnica ICI presenta siempre una desviación inferior al resto de técnicas al igual que ocurría en el dominio de películas.

A diferencia del anterior dominio, podemos concluir que en este dominio la mejor técnica de elicitación resulta ser la Intersección Incremental y no la ICI.



# 6

## Conclusiones y Trabajo Futuro

Este último capítulo contiene las principales conclusiones de este PFC así como las líneas futuras de trabajo. Además presentará las publicaciones científicas directamente relacionadas con el PFC y que han sido aceptadas durante el desarrollo del mismo.

### 6.1. Conclusiones

La principal contribución del PFC es la propuesta, implementación y evaluación de una técnica de elicitación de preferencias de grupo llamada Intersección Incremental Colaborativa. Esta técnica nace con el objetivo de mejorar las tres técnicas básicas: Agregación, Intersección e Intersección Incremental. Para ello tiene en cuenta la opinión de expertos que no pertenecen al grupo a recomendar durante el proceso de elicitación de preferencias de grupo. La selección de expertos se hace en función de un mecanismo de distancias que permite saber cómo de diferentes son dos usuarios de la base de datos. Los resultados han mostrado que esta nueva técnica mejora notablemente la precisión de las recomendaciones para grupos de usuarios grandes en el dominio de películas, en comparación con las tres técnicas básicas anteriormente implementadas.

## 6.2. Trabajo Futuro

Como trabajo futuro existen diferentes direcciones que aparentemente parecen prometedoras. Una de ellas es la extensión del presente Sistema Recomendador de Grupos a una arquitectura de sistemas Multi-agente [9, 10]. Otra de ellas es extender la ICI con algún mecanismo más preciso de cálculo de similitudes. Un ejemplo sería incluir una red social dentro de la arquitectura que nos permitiese representar relaciones de confianza entre diferentes usuarios de la base de datos. Si un usuario tiene mucha confianza con algún otro usuario es porque realmente se fía de él y en ese caso podría ser un candidato a ser un usuario experto quien participase en la técnica ICI. Además sería novedoso combinar las ventajas de la técnica ICI y la técnica II, en una nueva técnica que diese solución a los problemas que resuelven ambas técnicas.

Otra posible extensión sería diseñar algún mecanismo capaz de dar razones a favor o en contra de usar cada técnica en cada momento determinado. Por ejemplo suponiendo que trabajamos con un dominio de películas y con un grupo formado por 8 usuarios, pues en ese caso se recomienda usar la técnica de elicitación ICI.

## 6.3. Artículos científicos directamente relacionados con este PFC

En esta sección se presentan los artículos directamente relacionados y que han sido realizados durante el desarrollo del PFC por el alumno.

1. I. Garcia, L. Sebastia, S. Pajares and E. Onaindia. *The generalist recommender system GRSK and its extension to groups*. Lecture Notes in Business Information Processing (LNBIP), Springer. In Press(2011).
2. I. Garcia, L. Sebastia, S. Pajares and E. Onaindia. *GRSK: A Generalist Recommender System*. Proceedings of the 6th International Conference on Web Information Systems and Technology. Vol.I. pp.211-218(2010).
3. I. Garcia, L. Sebastia, S. Pajares and E. Onaindia. *Approaches to Preference Elicitation for Group Recommendation*. 11th International Conference on Computational Science and Its Applications (ICCSA 2011), In Press (2011).

# Bibliografía

---

- [1] A. Jameson. More than the sum of its members: challenges for group recommender systems. In *Proceedings of the working conference on Advanced visual interfaces*, pages 48–54. ACM, 2004.
- [2] B.M. Sarwar, G. Karypis, J.A. Konstan and J. Riedl. Item-based collaborative filtering recommendation algorithms. In *10th Int'l WWW Conference*, 2001.
- [3] I. Garcia, L. Sebastia, S. Pajares and E. Onaindia. Grsk: A generalist recommender system. In *International Conference on Web Information Systems and Technologies (Webist)*, 2010.
- [4] J. Masthoff. Selecting news to suit a group of criteria: An exploration. In *Proceedings of the Fourth Personalized TV workshop, associated with AH04*, 2004.
- [5] J. Masthoff. Group recommender systems: combining individual models. *Recommender Systems Handbook*, pages 677–702, 2011.
- [6] J. McCarthy and T. Anagnost. Musicfx: An arbiter of group preferences for computer supported collaborative workouts. In *Proceedings of the ACM 1998 Conference on CSCW*, pages 363–372, 1998.
- [7] A. Jameson, S. Baldes, and T. Kleinbauer. Two methods for enhancing mutual awareness in a group recommender system. In *Proceedings of the working conference on Advanced visual interfaces*, pages 447–449. ACM, 2004.

- [8] A. Jameson and B. Smyth. Recommendation to groups. In *The adaptive web*, pages 596–627. Springer-Verlag, 2007.
- [9] L. Sebastia, I. Garcia and A. Giret. A multi agent architecture for tourism recommendation. In Springer, editor, *Advances in Intelligent and Soft Computing. International Conference on Practical Applications of Agents and Multiagents Systems, Workshop on Artificial Intelligence and Distributed Systems (PAAMS-AIDS)*, volume 2 of *Trends in Practical Applications of Agents and Multiagents Systems.*, 2010.
- [10] L. Sebastia, I. Garcia and A. Giret. A multi agent architecture for single user and group recommendation in the tourism domain. In *International Journal of Artificial Intelligence (IJAI)*. To appear, 2011.
- [11] L. Sebastia, I. Garcia, E. Onaindia and C. Guzman. e-tourism: a tourist recommendation and planning application. In *International Journal on Artificial Intelligence Tools (WSPC-IJAIT)*, volume 18, pages 717–738, 2009.
- [12] H. Lieberman, N. Van Dyke, and A. Vivacqua. Let’s browse: a collaborative browsing agent. *Knowledge-Based Systems*, 12(8):427–431, 1999.
- [13] J.F. McCarthy. Pocket restaurantfinder: A situated recommender system for groups. In *Proceedings of the Workshop on Mobile Ad-Hoc Communication at the 2002 ACM Conference on Human Factors in Computer Systems, Minneapolis*, 2002.
- [14] K. McCarthy, M. Salamó, L. Coyle, L. McGinty, B. Smyth, and P. Nixon. Cats: A synchronous approach to collaborative group recommendation. In *Proceedings of the Nineteenth International Florida Artificial Intelligence Research Society Conference, Melbourne Beach, FL*, 2006.
- [15] M. O’connor, D. Cosley, J.A. Konstan, and J. Riedl. Polylens: A recommender system for groups of users. In *ECSCW 2001*, pages 199–218. Springer, 2002.
- [16] C. Plua and A. Jameson. Collaborative preference elicitation in a group travel recommender system. In *Proceedings of the AH Workshop on Recommendation and Personalization in eCommerce. Malaga, Spain.*, pages 148–154, 2002.
- [17] B.M. Sarwar, J.A. Konstan, A. Borchers, J. Herlocker, B. Miller, and J. Riedl. Using filtering agents to improve prediction quality in the grouplens research collaborative filtering system. In *Proceedings of the*

*1998 ACM conference on Computer supported cooperative work*, pages 345–354. ACM, 1998.

- [18] J. Schafer, D. Frankowski, J. Herlocker, and S. Sen. Collaborative filtering recommender systems. *The Adaptive Web*, pages 291–324, 2007.