

Recomendación de contenidos audiovisuales para familias y grupos de amigos, basado en clasificaciones TV-anytime multidimensionales

Recommendation of audiovisual contents for families and groups of friends based on Multidimensional TV-Anytime Classifications

Rafael Sotelo¹

Recibido: Junio 2010

Aceptado: Septiembre 2010

Resumen.- La llegada de la Televisión Digital y los Grabadores Digitales Personales permiten suponer que cambiará la manera que la gente mira televisión. La alta eficiencia de la codificación digital y los nuevos medios de transmisión digital llevan a un aumento de los contenidos ofrecidos al televidente. Se hacen necesarias herramientas automáticas para la recomendación de contenidos. Por otra parte, los grabadores digitales permitirán un modelo de consumo no lineal, permitiendo la creación (automática) de agendas de grabación o reproducción personalizadas considerando los intereses de un individuo o un grupo. Este artículo presenta una aproximación a la recomendación de contenidos para grupos de personas, basado en descripciones TV-Anytime de los contenidos, y de técnicas de razonamiento semántico.

Palabras Clave: Televisión Digital, TV-Anytime, sistemas recomendadores, recomendación para grupos, recomendación para familias

Summary.- The advent of Digital TV and Personal Digital Recorders promise to change the way people watch TV. The higher efficiency of digital coding will lead to increasing the number of contents offered to the user, demanding automatic tools for content recommendation. In the other hand, digital recorders will permit a non-linear consumption model, enabling the creation of (automatic) personalized schedules that combine the appealing contents for a specific user or group of users. This paper presents an approach to content recommendation for groups of people, based on TV-Anytime descriptions of TV contents and semantic reasoning techniques.

Key words: Digital TV, TV-Anytime, recommender system, group recommendations

1. Introducción.- El presente trabajo está basado en Sotelo [1]. La televisión digital (DTV) está desplegándose en todo el mundo, ofreciendo muchas ventajas a los usuarios finales, tales como una mejor calidad de audio y video, la interactividad, la movilidad y una mayor eficiencia que permite aumentar el número de canales a emitir, incluso habilitando la alta definición.

Al mismo tiempo, irrumpe en el mercado el receptor digital con almacenamiento local ("Personal Digital Recorder" o PDR), un dispositivo de consumo, de precios módicos, capaz de grabar cientos o miles horas de video. Se podrá programar grabaciones, incluso automáticamente, fusionando contenidos obteniendo un canal virtual. Esto cambiará la naturaleza lineal tradicional

¹ Dr. Ing. Departamento Ingeniería Telemática, Universidad de Montevideo, rsotelo@um.edu.uy

de la televisión, multiplicando las posibilidades disponibles para el usuario final, quien puede resultar fácilmente abrumado por este nuevo escenario.




Figura 1 – Los nuevos avances tecnológicos pueden traer confusión al usuario

En este contexto, es necesario desarrollar agentes que recomienden programas para los usuarios, mejorando así su experiencia de visualización. Estos agentes emplean varias estrategias para comparar los contenidos a emitirse, con los perfiles de los usuarios y su historial de uso, permitiendo entregarles las recomendaciones o incluso generarles un canal personal (con capacidad de grabación automatizada).

Algunas propuestas anteriores [2] se centran principalmente en recomendaciones personalizadas, basadas en el perfil de un consumidor en particular. El número de televisores por hogar ha aumentado en las últimas décadas, permitiendo que los miembros del hogar vean la televisión de forma individual. Además, muchas de las nuevas tecnologías (por ejemplo, la radiodifusión para los dispositivos personales) permiten una experiencia personal cuando se ve la televisión, lo que resalta la importancia de este modelo de recomendación.

Sin embargo, la televisión es muy a menudo una experiencia de grupo, porque se ve la televisión en familia o con amigos. Masthoff [3] cita algunos trabajos que establecen que (i) la televisión es el medio que se comparte más a menudo con la familia, (ii) ver la televisión juntos es una de las actividades más compartidas entre padres e hijos, (iii) los jóvenes desean ver la televisión con sus amigos, y (iv) la televisión es el tema de conversación más popular de los jóvenes con los amigos.

La recomendación para una persona puede no ser adecuada u óptima para todos los miembros del grupo, y por ello es necesario desarrollar nuevos motores de recomendación que se centren en los diferentes tipos de grupos que ven la televisión.

Chorianopoulos [4] señala que es necesario seguir investigando en el campo de recomendar contenidos de televisión para los grupos y que un área muy prometedora es la aplicación de métodos de recomendación en pequeñas redes de grupos de espectadores de televisión (por ejemplo, amigos y familia), con el fin de mejorar la experiencia compartida de la televisión. Recientemente se han realizado algunas aproximaciones [5, 6, 7] basadas en la fusión de las estrategias de Teoría Social de la Elecciones [3]. Estos motores tienen en cuenta los perfiles personales y el historial de uso de cada uno de los individuos del grupo. Sin embargo, suelen

obtener buenos resultados exclusivamente para grupos de personas con intereses similares, tal vez el caso de los amigos (grupos homogéneos). Esto no es generalmente el caso de las familias, donde el perfil de usuario individual del padre, la madre y del niño probablemente difieran (grupos heterogéneos). En este último caso, el proceso conduce a pobres recomendaciones. En consecuencia, queda mucho por hacer para definir los algoritmos y herramientas capaces de hacer frente a tales diferencias derivadas de la composición del grupo.

En este sentido, este documento presenta una nueva evolución de la herramienta AVATAR, un recomendador de televisión conocido, que ahora ha sido ampliado con la capacidad para hacer recomendaciones para grupos, identificando y aplicando diferentes técnicas de procesamiento según la caracterización del grupo.

En el resto del artículo se estructura de la siguiente manera. La sección 2 presenta una visión general de las diferentes tecnologías que jugarán un papel importante en la implementación de los próximos modelos de televisión. En la sección 3 se destacan los principales aspectos del recomendador AVATAR. La sección 4 presenta algunos trabajos realizados con anterioridad en el ámbito de la recomendación del grupo. La sección 5 describe nuestro enfoque para construir con éxito las recomendaciones de los grupos, especialmente en el caso de los heterogéneos. Finalmente, en la sección 6 se extraen algunas conclusiones y se señala el trabajo futuro.

2. Escenario Tecnológico.- En los últimos años, se han normalizado varias tecnologías interesantes, procedentes tanto del ámbito de la televisión, como del área de la computación, que desempeñarán un papel central en la evolución de la DTV. Estas tecnologías, desarrolladas inicialmente en forma aislada, han alcanzado ahora un nivel de madurez que permite importantes sinergias que surgen de su integración.

La más importante de estas tecnologías es el Multimedia Home Platform (MHP) [8]. Esta norma, desarrollada por el Consorcio DVB, define un marco genérico común que permite que aplicaciones interoperables sean emitidas y ejecutadas en receptores con hardware específico e implementaciones de software de cualquier fabricante. MHP normaliza el modelo de aplicaciones, la integración con el software del receptor de DTV y la API (Application Programming Interface) para acceder a los recursos de hardware en cualquier equipo compatible. Así como MHP proporciona aplicaciones de televisión interactiva normalizadas, la norma de metainformación TV-Anytime [9] estandariza un formato de datos común para describir los contenidos de televisión, los usuarios y el consumo de contenidos. La Fase 1 de la especificación TV-Anytime estandariza los servicios multimedia basados en el almacenamiento digital en las plataformas de usuarios, que combina la inmediatez de la televisión con la flexibilidad de Internet. De esta manera, TV-Anytime permite al usuario encontrar, navegar y gestionar los contenidos de una amplia variedad de fuentes, incluyendo la radiodifusión tradicional, TV interactiva, Internet, y el almacenamiento local en un PDR, como se muestra en la Figura 2. Además, TV-Anytime describe los procedimientos para la gestión de derechos y la protección de contenidos, así como los mecanismos para referenciar contenidos, independientemente de su ubicación y la hora de emisión.

Mientras que la Fase 1 de TV-Anytime se centra principalmente en las redes unidireccionales, la

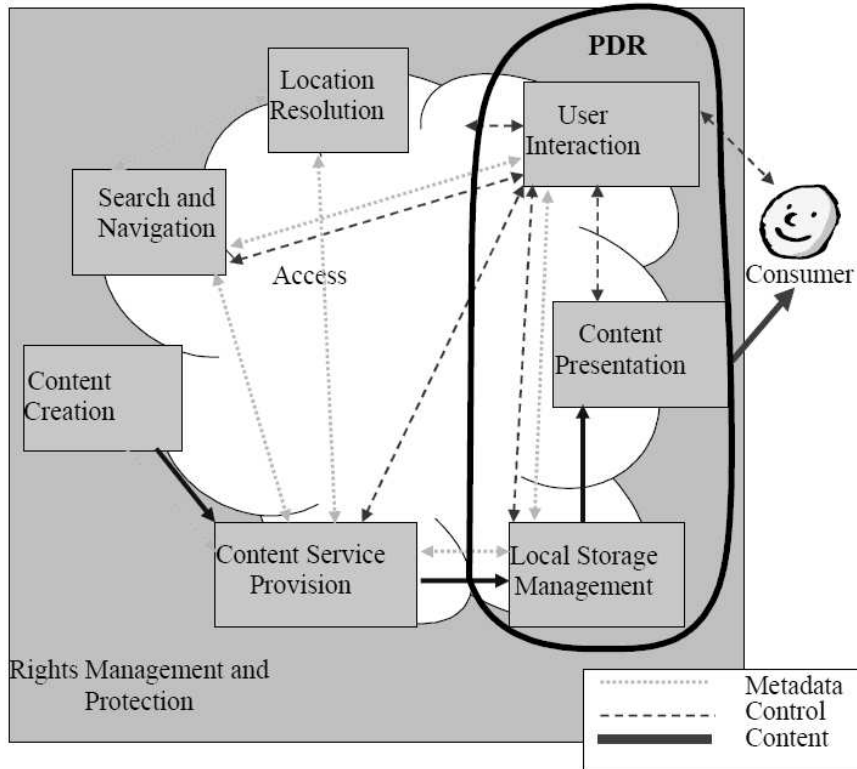


Figura 2 – Algunas capacidades previstas por la especificación TV-Anytime

Fase 2 tiene en cuenta aspectos bidireccional, introduciendo por ejemplo, la capacidad de intercambiar perfiles personales. En particular, esta capacidad permite: (i) a los proveedores a recibir información detallada y completa de una amplia gama de dispositivos PDR de diferentes usuarios, (ii) al PDR a intercambiar directamente perfiles según sea necesario, y (iii) a los consumidores a "llevar" sus perfiles y otros datos de carácter personal [10]. TV-Anytime permitirá el desarrollo de servicios web que puedan recuperar la información del usuario, allanando el camino para que el PDR y el servicio puedan comunicarse. Dado que la información personal es confidencial, TV-Anytime requiere que el usuario especifique quién está autorizado para solicitar a su perfil personal, y proporciona los mecanismos de seguridad correspondientes [11]. Esto permite que el PDR reúna los perfiles de los usuarios, lo que es necesario para ofrecer recomendaciones para un grupo de usuarios que verá la televisión juntos (la recomendación del grupo).

A diferencia de MHP (oficialmente aprobados y desarrollados en muchos países), TV-Anytime está todavía en una fase embrionaria. Está claro que se necesitan más proyectos y aplicaciones innovadoras para propulsar su despliegue, especialmente aquellos que mejoren la experiencia del consumidor de televisión de una manera realista, orientadas al consumidor.

En este sentido, los medios de personalización con TV-Anytime están cobrando impulso en la actualidad como un mecanismo prometedor que sienta las bases de modelos de negocio novedosos en la prestación de servicios personalizados para la televisión digital, cuya utilidad es indudable, habida cuenta de la sobrecarga de contenidos disponibles en el flujo digital. Las estrategias tradicionales de personalización se basan principalmente en técnicas sintácticas, lo que conduce a recomendaciones muy pobres [12]. Para combatir estas limitaciones, es necesario razonar sobre la semántica de los programas de TV disponibles y descubrir relaciones ocultas

entre esos contenidos y las preferencias del espectador, más allá de una simple comparación basada en la sintaxis. Estos procesos de razonamiento, tradicionalmente empleados en el ámbito de la Web Semántica, requieren una representación formal del conocimiento del dominio (conocida como *ontología*), donde se modelan las descripciones semánticas de los programas de televisión y las relaciones existentes entre ellos. La sinergia entre los sistemas de recomendación y las ontologías ya ha sido explorada por Middleton [13], observándose un incremento significativo en la exactitud de la recomendación. Como consecuencia, en los sistemas de recomendación de televisión, las ontologías son herramientas que favorecen el desarrollo de algoritmos de procesamiento que mejoran la calidad de las actuales recomendaciones personalizadas, completando así el escenario compuesto por PDR (hardware), MHP (software), y TV-Anytime (datos).

3. AVATAR: un sistema recomendador para individuos.- En esta sección se resume el funcionamiento interno de la estrategia para los espectadores individuales adoptadas en el sistema de recomendación AVATAR (ver Blanco [14] para más detalles algorítmicos), que ha sido convenientemente ampliada para hacer frente a las recomendaciones de un grupo de espectadores viendo la televisión juntos. Estas extensiones incluyen la ontología multidimensional compatible con TV-Anytime y la técnica de modelado de usuario descrita a continuación, junto con la estrategia de la recomendación de grupos que se explicará en la sección 5.

3.1 Una ontología multidimensional del dominio de la televisión.- Teniendo en cuenta el máximo provecho de las capacidades de TV-Anytime, hemos ideado un modelo ontológico mejorado que corresponde con el sistema de clasificación de contenido multidimensional de TV-Anytime. Las descripciones de los programas a emitir son recibidas en formato TV-Anytime, incluyendo sus clasificaciones en estos esquemas (tales clasificaciones las realizan los productores de contenidos). Las instancias de los programas a emitir se añaden a la base de datos del sistema, clasificándolos en una o varias de nuestras jerarquías, lo que permite comparaciones en múltiples dimensiones a fin de calcular la similitud. En cuanto a estas dimensiones, nuestra implementación actual funciona con cuatro jerarquías extraídas de los sistemas de clasificación *Intention*, *Format*, *Content* e *Intended Audience*, establecidos en la norma TV-Anytime. Ellas refieren respectivamente a la intención con que es hecho un programa (por ejemplo, entretener, educar, informar), al formato del programa (documental, *talkshow*, evento, *cartoon*, *show*), al género del programa (informativo, deportes, ficción o drama, entretenimiento, musicales) y a la audiencia objetivo del programa (clasificado por grupos etarios u ocupacionales).

Nuestra ontología incluye también otros atributos semánticos de los programas de televisión, como tema, el tiempo y la información geográfica, y los créditos involucrados, como se muestra en la Figura 3, donde podemos ver un documental sobre el uso de barcos de vapor en España durante la Revolución Industrial con la participación de Gerardo Meliá como director. Como explicaremos más adelante, estos atributos permitirán descubrir las relaciones semánticas entre los contenidos mediante una inferencia semántica, lo que conduce a mejores recomendaciones.

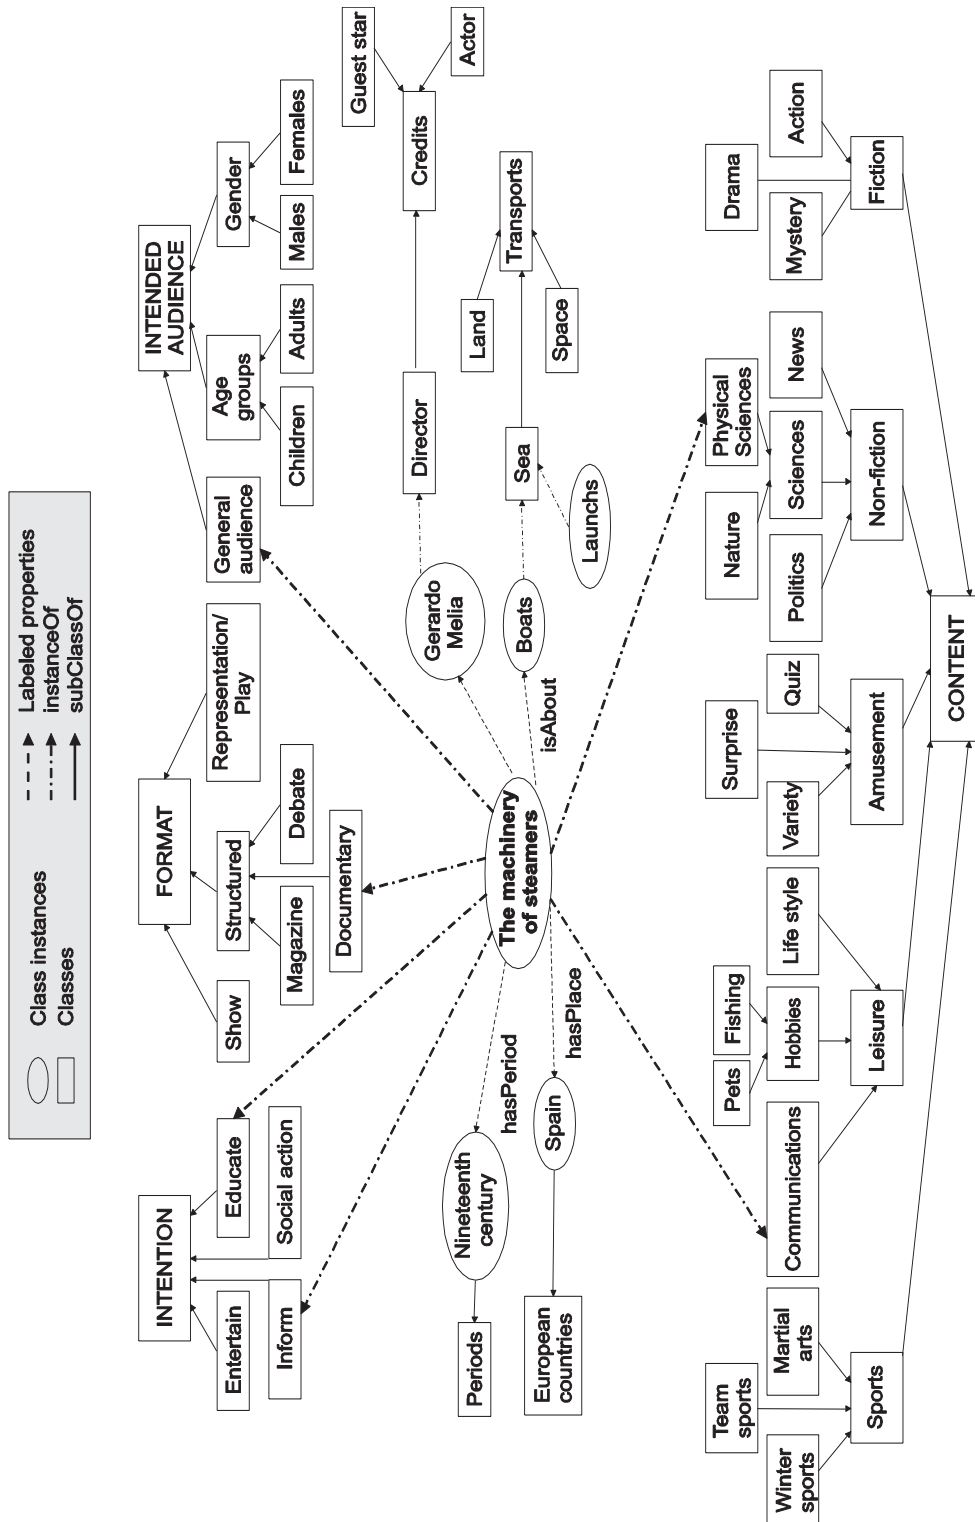


Figura 3 – Un breve extracto de nuestra ontología multidimensional compatible con TV-Anytime, incluyendo las jerarquías correspondientes a Intention, Format, Intended Audience y Content de los programas de televisión.

3.2 Modelado de usuario.- En nuestro enfoque, los perfiles de espectador consisten en extractos de la ontología multidimensional de la televisión que contiene los programas que un determinado individuo ha calificado en el pasado, donde cada dimensión consta de un índice numérico llamado DOI (grado de interés) que cuantifica su grado de interés en dicho contenido. Como se explica Blanco en [15], el DOI para un determinado programa puede ser explícitamente formulado por el espectador, o deducido de medidas indirectas, como el tiempo que él o ella pasa mirando el programa.

El DOI toma valores en el rango [-1,1], con -1 representando el mayor disgusto o interés negativo y 1 representando la mayor aceptación. Partiendo del índice DOI de cada programa, nuestro enfoque infiere el nivel de interés de los usuarios tanto en los atributos de este programa como en las clases en las que se clasifica el mismo en nuestra ontología multidimensional de la TV. En concreto, los índices DOI del contenido se propagan a través de cada jerarquía de clases y los atributos de la siguiente manera:

- El DOI de un atributo se toma como el promedio de los índices DOI de los programas a los que está vinculado.
- Del mismo modo, en cada una de las cuatro jerarquías de nuestra ontología de televisión, los índices DOI de las clases más específicas se calculan como el promedio de los índices DOI de los programas clasificados en ellos. Hacia arriba en la jerarquía, cada clase C contribuye al DOI de su superclase inmediata con un valor dado por (1), donde *sib* (C) es el número de clases hermanas de C.

$$\frac{DOI(C)}{1 + sib(C)} \quad (1)$$

Ilustraremos esta propagación del DOI hacia arriba en la jerarquía, con el siguiente ejemplo. En la Figura 4 se observa un extracto de la jerarquía *Content*, en la que se destaca especialmente la subclasificación 3.1 “NON FICTION/INFORMATION”.

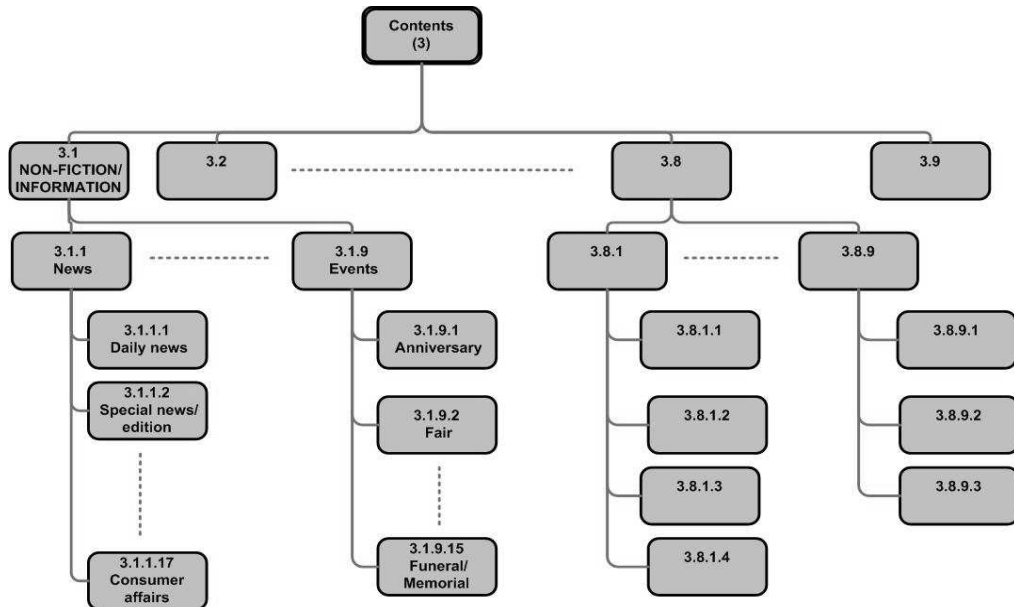


Figura 4 – Extracto de la jerarquía *Content*

Si un usuario tiene un DOI de 0,5 por la clase 3.1.1.2, de acuerdo a (1) aportará 0,5/17 a su superclase 3.1.1, debido a que tiene 16 clases hermanas. Análogamente, suponiendo que el usuario tiene un DOI de 0,7 por la clase 3.1.1, la clase 3.1 recibirá de ésta un aporte de 0,7/9, ya que tiene 9 clases hijas.

En resumen, nuestros perfiles de espectador almacenan la lista de programas de televisión que el usuario vio en el pasado, y cada programa está asociado a un vector cuyos valores contienen los índices DOI de (i) este programa, (ii) sus atributos, y (iii) sus clases en la ontología de la televisión.

3.3 Nuestra estrategia de recomendación para usuarios individuales.-La estrategia de recomendación adoptada en AVATAR combina dos de las técnicas más populares de filtrado con el fin de decidir si un determinado programa TP se sugiere a un determinado usuario U :

- **Basado en filtrado de contenido:** Esta técnica sugiere TP a U si es similar a los contenidos que este televidente ha disfrutado en el pasado.
- **Filtrado colaborativo:** Por el contrario, el filtrado colaborativo sugiere el contenido de TP a U si este programa ha resultado de interés a otros individuos con preferencias similares (en lo sucesivo, sus *vecinos*).

Como veremos más detalladamente en las secciones siguientes, la contribución de esta estrategia de recomendación es el hecho de que ambas técnicas de filtrado se mejoran con el razonamiento de los procesos semánticos sobre la ontología de la televisión. Estos procesos permiten deducir nuevos conocimientos sobre las preferencias del espectador, más allá de los enfoques basados puramente en sintaxis adoptados en los sistemas de recomendación tradicionales (ver Adomavicius [12] para un estudio en profundidad). De esta manera, nuestra estrategia de razonamiento conduce a mejores y más diversas recomendaciones, incluyendo programas estrechamente relacionados con las preferencias de los usuarios (por ejemplo, podemos asociar un programa sobre la *Fauna*, con otro sobre la *Flora*, porque ambos están relacionados con la *Naturaleza*, aun cuando sus respectivos atributos son diferentes).

3.4 Nuestro filtrado basado en contenido.- Este proceso de filtrado cuantifica un valor de coincidencia entre el programa TP y el usuario U , mediante la medición de la semejanza entre TP y los contenidos incluidos en su perfil. Para ello, hemos propuesto una similitud métrica realizada por razonamiento semántico, a la que llamaremos *métrica de similitud semántica*. Como se muestra en (2), el valor de similitud entre TP y U se calcula promediando los niveles de similitud semántica entre TP y cada programa almacenado c_i en el perfil de U , ponderados por sus respectivos índices DOI. Como es de esperar, el valor de igualdad resultante es alto cuando TP es muy similar a los contenidos que han sido muy atractivos para el usuario.

$$matching(U, TP) = \frac{1}{N_U} \cdot \sum_{i=1}^{N_U} c_i \quad (2)$$

Nuestra métrica de similitud semántica cuantifica semejanzas entre los contenidos teniendo en cuenta dos componentes:

- El primero (llamado *similitud jerárquica* o $Sim_{Hie}(TP, c_i)$) mide su cercanía en cada una de las cuatro jerarquías de nuestra ontología de la TV (ver fig. 2). Esta cercanía se calcula por (3), donde la *profundidad* de un programa es su nivel en la jerarquía, y el *LCA* de dos programas identifica su *antepasado común más bajo* (*Lowest Common Ancestor*) en esa jerarquía. De hecho, la similitud jerárquica entre las preferencias del usuario y el programa de destino se computará para cada jerarquía y luego será promediada.

$$Sim_{Hie}(TP, c_i) = \frac{depth(LCA(TP, c_i))}{Max(depth(TP), depth(c_i))} \quad (3)$$

- El segundo componente (llamado *similitud inferencial* o $Sim_{Inf}(TP, c_i)$) descubre las asociaciones entre los programas que comparten atributos semánticamente relacionadas entre sí: en concreto, o bien comparte los mismos *atributos*, o *atributos "hermanos"* (por ejemplo, *Boats* y *Launchs* en la Figura 3, que comparten la clase padre *Sea - Transports*).

Este enfoque conduce a (4), donde $DOI_U(SA_j)$ es el nivel de interés del usuario U en los atributos compartidos (SA). Como se explica en la sección 3.4, este nivel se obtiene automáticamente de las calificaciones específicas asignadas por el usuario a los programas relacionados con esos atributos.

$$Sim_{Inf}(TP, c_i) = \frac{1}{\#SA} \sum_{j=1}^{\dots} \dots \quad (4)$$

Una vez que ha sido calculada la similitud entre TP y cada programa c_i en el perfil U , se obtienen los componentes $Sim_{Hie}(TP, c_i)$ y $Sim_{Inf}(TP, c_i)$, finalmente ponderados y agregados por un parámetro configurable, cuya valor depende tanto del contexto de aplicación del sistema de recomendación que adopta nuestra estrategia de filtrado, como de la ontología de dominio utilizada para el razonamiento. Este valor es finalmente incluido en (2), por lo que el nivel de coincidencia resultante permite decidir si TP se recomienda al espectador U .

3.5 Nuestro filtrado colaborativo.- El objetivo de nuestro filtrado colaborativo es predecir el nivel de interés del usuario U en el programa objetivo mediante la explotación de las preferencias de sus vecinos y la ontología multidimensional de la televisión. Si el nivel previsto de interés es mayor que un umbral configurable, el programa TP finalmente se sugerirá a U .

Con el fin de formar el vecindario de U , hemos definido un *enfoque basado en la taxonomía* que aprovecha la estructura jerárquica de nuestra ontología multidimensional para descubrir solapamientos entre las preferencias de dos usuarios, aun cuando ambos hayan visto programas de televisión diferentes. En concreto, nuestro enfoque revela semejanzas entre las preferencias de dos espectadores cuando se han evaluado los programas categorizados en virtud de un *ancestro común* en las jerarquías de modelado en la ontología multidimensional de la televisión. Por ejemplo, nuestro enfoque detecta que un espectador que ha disfrutado de un documental sobre los animales (clasificados en la clase *Nature* en la Figura 3) y un espectador que le ha gustado un programa sobre la ingeniería mecánica (que pertenece a *Physical Sciences*) son vecinos porque ambos tienen en *Ciencias* un ancestro común en la jerarquía *Content*. Dejando aparte los detalles algorítmicos, cuanto mayor es el número de ancestros comunes entre los perfiles de dos espectadores, mayor será el valor de la correlación entre sus respectivas preferencias, ya que indica una coincidencia con mayor especificidad. Por último, las personas cuyos valores de correlación (en relación con el usuario U) son mayores que un determinado umbral se seleccionan como sus vecinos.

Una vez creado el vecindario de U , nuestro filtrado colaborativo predice lo que será su calificación para el programa objetivo TP . Se promedian los índices DOI de cada vecino N_k por el programa TP , ponderado por los valores de correlación medida entre U y los vecinos, como se muestra en (5), donde M es el tamaño del vecindario.

$$PredRating(U, TP) = \sum_{k=1}^M \dots \quad (5)$$

De esta explicación, se deduce que la calificación de U en TP es alta cuando este programa ha sido muy atractivo para los espectadores vecinos, y cuando sus respectivas preferencias están fuertemente correlacionadas. En este escenario, TP también parece ser un interesante programa para U .

4. Trabajo Previo en Recomendación a Grupos

4.1 Grupos.- Los últimos años han presenciado una fuerte actividad de investigación en sistemas automatizados de recomendación personal, especialmente favorecido por el aumento asombroso de la actividad comercial en Internet.

Sin embargo, como se subraya en la introducción, en el diseño de un sistema de recomendación para la televisión, debemos considerar el hecho de que los usuarios frecuentemente ven la televisión en grupo.

Aunque el caso más común es ver la televisión con otros miembros del hogar (generalmente la familia), podemos encontrar una gran cantidad de escenarios en los que ver la televisión es una actividad social. No es raro en absoluto, especialmente entre los jóvenes, reunirse para ver una película, un partido de fútbol, un capítulo de una serie, un programa de entrevistas o un programa de entretenimiento.

Es fácil imaginar otros casos en que la recomendación de programas para los grupos es indudablemente útil: por ejemplo, en el transporte público y centros de esparcimiento. Incluso podemos pensar en aplicaciones relacionadas con modernos fenómenos como las redes sociales de Internet.

La gama de campos de interés es aún mayor si se amplía la recomendación para grupos a otros productos o servicios: los grupos de turistas en una corta visita a una ciudad grande, hacer un menú para una cena compartida, o la selección de música ambiente, sólo por nombrar algunos.

Un factor importante a tener en cuenta cuando se trabaja con grupos es su caracterización respecto a la similitud de sus miembros. De esta manera, si queremos generar recomendaciones de programas de televisión para un grupo, lo primero que hay que hacer es clasificarlos de acuerdo a los intereses y características de sus miembros, en grupos homogéneos o heterogéneos. En términos generales, una familia (ver Figura 5) será un grupo heterogéneo, ya que los intereses particulares del padre en general serán diferentes a los de la madre, y los de ambos no similares a los de los niños, y éstos disímiles entre sí dependiendo de las diferencias de edad.



Figura 5 – Grupo heterogéneo. Los miembros de una familia, constituida por personas con edades y géneros diferentes, tienen generalmente diferentes intereses.

Por otro lado, podemos imaginar que los intereses de un grupo de amigos serán similares (ver Figura 6). Es decir, los intereses no serán *idénticos*, pero *similares*. Los perfiles de usuario de cada miembro serán similares. Es mucho más fácil recomendar para este grupo, ya que se puede sustituir al grupo por un usuario virtual y seguir teniendo una buena recomendación.



Figura 6 – Grupo Homogéneo. Los integrantes de un grupo de amigos comparten muchas características que se traducen en intereses comunes.

4.2 Trabajo de investigación previo.- En la literatura es posible encontrar trabajos de elaboración de recomendaciones para grupos. Masthoff [3] clasificó las diferentes estrategias adoptadas para predecir la satisfacción del grupo para ver un programa de televisión, basándose en la satisfacción de cada miembro.

En una de estas técnicas, cada uno de los miembros vota su alternativa preferida y la que obtiene mayor número de votos gana, mientras que en otros cada usuario puede votar por tantas alternativas como desee. Otros enfoques hacen una nueva lista de puntuaciones con el mínimo (o máximo) de las calificaciones individuales. Sin embargo, a partir de los experimentos descritos en Masthoff [16, 17], se deduce que la mejor técnica de fusión de preferencias en cuanto a la exactitud de la recomendación para el grupo es la que se nombra Promedio Sin Miseria (*Average Without Misery*), donde la lista de puntuaciones se obtiene realizando un nuevo promedio de las calificaciones individuales, pero sin tener en cuenta los valores inferiores a un umbral determinado. De esta forma, se evita recomendar contenidos que disgusten a algunos miembros del grupo. Nadie está a gusto mirando televisión junto con alguien que odia el contenido.

Estas técnicas de fusión han sido ampliamente adoptadas en los sistemas de recomendación aplicados a diversos dominios, tales como *Intrigue* [18] y el *Travel Decision Forum* [19] (que ayudan a planificar las vacaciones a un grupo de turistas que viajan juntos), *MusicFX* [20] (que ajusta la selección de música que se reproduce en un centro de acondicionamiento físico de acuerdo a las personas presentes en la sala), *Let's Browse* [21] (que recomienda páginas web a un grupo de dos o más usuarios que navegan juntos en Internet), y *PolyLens* [22] (que sugiere películas a un grupo de espectadores), por nombrar sólo algunas posibilidades.

A diferencia de nuestra propuesta, estos sistemas de recomendación no explotan ni las capacidades de TV-Anytime para el intercambio de perfiles de los espectadores, ni la capacidad de razonamiento semántico con el fin de seleccionar recomendaciones mejoradas para el grupo.

4.3 Otros trabajos relevantes sobre Recomendación a Grupos.- La fusión de perfiles de usuario ha sido ampliamente estudiada en los últimos años en distintos ámbitos: entornos inteligentes, Salem [23], entrega de información, Kay [24], formación de grupos de estudiantes, Unnas [25] o comunidades virtuales, Cantador [26].

El trabajo de Yu descrito en [5] es especialmente interesante en nuestro contexto. Se centró en la recomendación de contenidos de televisión a un grupo. Allí, están claramente identificadas tres estrategias:

- (i) *Agente Grupal*: los usuarios registran una cuenta común para ellos, teniendo un perfil común (difícil de aplicar si los miembros cambian con frecuencia).
- (ii) *La fusión de las recomendaciones*: se recomienda para cada usuario en función de sus preferencias y luego se realiza la fusión.
- (iii) *La fusión de perfiles de usuario*: se unen todos los perfiles de usuario para generar un perfil de usuario común, sobre el cual se utiliza la estrategia de recomendación.

De acuerdo a experiencias realizadas, particularmente por Cantador [27], la última resulta ser la mejor estrategia. No obstante, este proceso de fusión es crítico en función de dos decisiones fundamentales:

- *Selección de características*, cuya tarea es determinar si una característica debe incluirse en el perfil de usuario común.
- *Asignación de peso*, que evalúa cómo debe ponderarse una característica seleccionada.

Aunque las experiencias descritas por Yu en [5] establecen que la estrategia (iii) es mejor que (ii), los resultados muestran que el sistema hace buenas recomendaciones sólo si las personas que componen el grupo tienen preferencias similares. Si el grupo es heterogéneo, son difíciles de conseguir recomendaciones buenas.

Y por ello, entendiendo que la situación más frecuente cuando un grupo mira televisión, sigue siendo el escenario de la familia (por lo general un grupo heterogéneo), es evidente que queda mucho trabajo por hacer para lograr herramientas útiles para la recomendación a grupos.

5. Nuestro Grupo de Estrategia de la Recomendación.- Nuestro primer paso para hacer las recomendaciones al grupo es caracterizar el grupo de usuarios que verán la televisión juntos: recordemos que tratamos con *grupos homogéneos* cuando todos los miembros comparten preferencias similares; de lo contrario, se consideran *grupos heterogéneos*. En concreto, para cada par de miembros de U_j y U_k de un grupo G , se mide su semejanza por el enfoque basado en la taxonomía propuesta en la sección 3.5.

- En primer lugar, creamos cuatro vectores de clasificación para los usuarios U_j y U_k , incluyendo sus calificaciones en las categorías de las cuatro jerarquías de modelado en la ontología de la televisión, es decir, *Format (F)*, *Intention (I)*, *IntendedAudience (IA)* y *Content (C)*.
- A continuación, se calcula el valor de C_{jk} , correlación entre los vectores de calificación de U_j y U_k para cada jerarquía (identificado por C_{jk-M} , C_{jk-I} , C_{jk-IA} y C_{jk-C}). Luego, se ponderan los cuatro valores como se muestra en (6). El promedio está apropiadamente ponderado en función de la importancia que se le quiere asignar a cada clasificación en nuestra estrategia de recomendación.

$$C_{jk} = \cdot + \cdot + \cdot + \cdot \quad (6)$$

- Por último, se caracteriza el grupo de usuarios de G , por el valor de correlación resultante: si C_{jk} es mayor que un umbral para cada par de miembros U_j y U_k , G es un grupo homogéneo. Si cualquiera de estos valores de correlación es inferior a ese umbral, diremos que el grupo es heterogéneo.

Teniendo en cuenta las diferencias importantes entre ambos tipos de grupos, una vez que el grupo se ha caracterizado esta manera, en nuestro algoritmo se siguen dos enfoques diferentes en función del caso.

A continuación, presentamos estos dos tratamientos diferentes.

5.1 Grupo Homogéneo.- En este caso, como los miembros del grupo tienen intereses similares, se obtiene un *usuario virtual* que representa al grupo, cuyo perfil es la fusión de todos los perfiles individuales, como se muestra en la Figura 7.

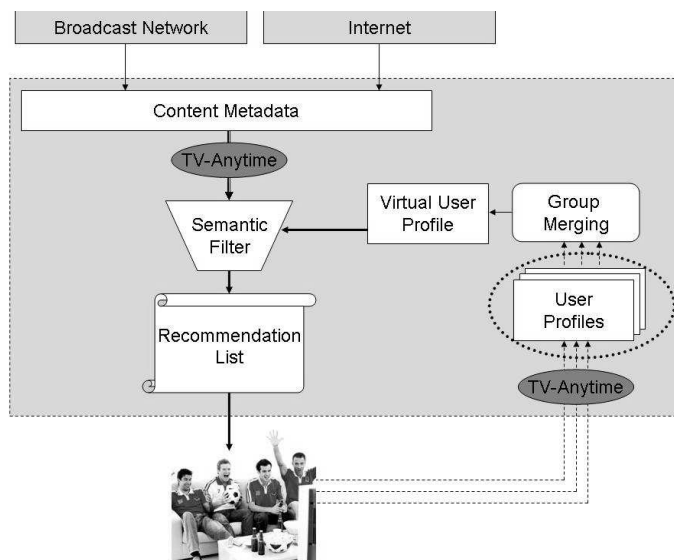


Figura. 7. Recomendando a grupos homogéneos.

La fusión se calcula por la técnica de *Promedio Sin Miseria*: para cada clase, el DOI resultante será -1 si es negativo el DOI de cualquier miembro para esta clase; en caso contrario, será el promedio de los índices DOI de la clase para todos los miembros del grupo.

Luego, nuestra estrategia de recomendación para el grupo recomienda a este usuario virtual utilizando la técnica de filtrado basado en contenido, adoptadas en el proceso de AVATAR original para individuos (véase la sección 3.4).

Esta estrategia ha demostrado ser adecuada para predecir la satisfacción con el contenido recomendado, mientras que evita recomendar una categoría de contenido que no le gusta a algún miembro del grupo.

5.2 Grupo heterogéneo.- En el caso que se esté procesando un *grupo heterogéneo* (es decir, algunas de las correlaciones entre los miembros del grupo no son lo suficientemente altos), los intereses de los usuarios no son compatibles.

En esta situación, los vectores de calificación que representan a los usuarios apuntan a diferentes direcciones. Así, el método anterior, o similares no serán adecuados, ya que la resultante de promediar los vectores individuales será próxima al origen, el punto $(0,0,0, \dots, 0)$, y toda la información sobre los usuarios individuales se perdería. Dicha recomendación sería muy pobre, ya que la riqueza de la descripción de cada usuario sería mucho menor.

Teniendo esto en mente, decidimos usar nuestra técnica de filtrado colaborativo para el proceso del grupo, pero a partir de sus miembros, como se muestra en la Figura 8.

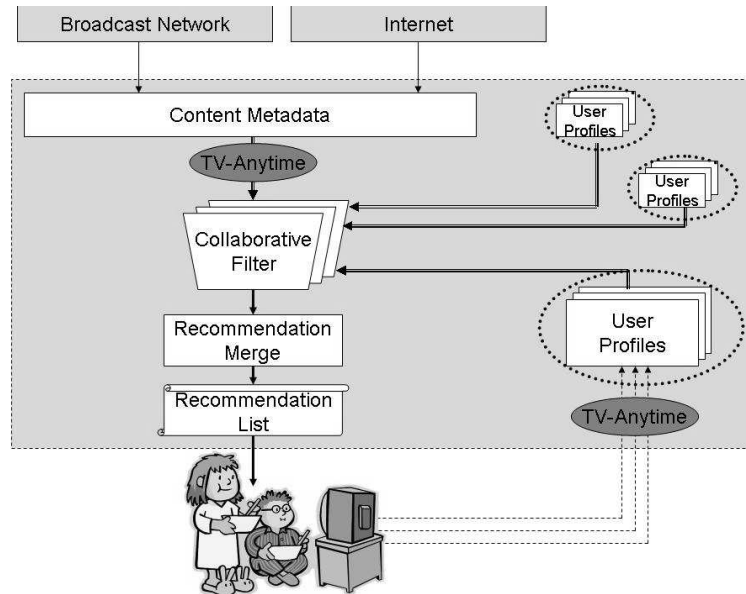


Figura 8. Recomendando a grupos heterogéneos

A los efectos anteriores, se procede como sigue:

- En primer lugar, encontramos el vecindario N_j de cada miembro U_j del grupo G . Según lo que dijimos en la sección 3.5, N_j incluye todos los usuarios U_k tal que la medida de correlación C_{jk} está por encima de un umbral. Téngase en cuenta que estos vecinos pueden estar en cualquier grupo registrado en el sistema.
- Entonces, buscamos grupos conocidos G_m en el sistema, cuyos miembros V_{mn} están todos incluidos en (al menos) uno de los vecindarios encontrados. Es decir, existe i tal que para todo n , V_{mn} pertenece a N_i . Como es natural, esto significa que G y G_m son grupos similares, de tal forma que por cada miembro U de G , hay algún miembro V de G_m con intereses individuales similares. El conjunto G_m así obtenido será considerado el vecindario de G .

En este punto, suponiendo que tenemos un nuevo programa TP que se emitirá en breve, debe decidirse qué grupos pueden estar interesados en este contenido objetivo.

- Nuestra primera etapa consiste en calcular la adecuación de TP para cada miembro V_m de todos los grupos G_m . En caso de que un miembro haya visto este programa, usamos su índice DOI, de lo contrario, el nivel de adecuación se prevé por el razonamiento semántico. Para ello aprovechamos nuestra base técnica de filtrado de contenido y calculamos los niveles de similitud entre el miembro V_m y el programa objetivo TP a través de (2). Este enfoque lleva a la siguiente ecuación.

$$\text{Adequacy}(TP, V_m) = \begin{cases} DOI(TP) & \text{if } V_m \text{ has seen } TP \\ \text{matching}(V_m, TP) & \text{otherwise} \end{cases} \quad (7)$$

- A continuación, calculamos la correspondencia entre cada G_m y TP con la estrategia de *Promedio Sin Miseria* aplicada a todos los miembros del grupo G_m .
- Por último, promediando todos los *matchings* de los grupos de vecinos, se obtiene el interés previsto de G para el contenido de TP .

De esto se deduce que recomendamos *TP* a un grupo si fue apreciado por los grupos con miembros similares. En otras palabras, se recomendará el programa propuesto a una familia, si ha resultado de interés a familias con intereses similares miembro a miembro.

6. Conclusiones y trabajos futuros.- En este artículo se ha presentado un método para predecir el interés de un grupo de personas por un contenido audiovisual, que nos permite hacer recomendaciones precisas para el grupo. Hemos definido grupos homogéneos y heterogéneos, y considerado diferentes algoritmos apropiados para cada tipo de grupo, reflejando hábitos reales de consumo de televisión.

Como requisito para el desarrollo de aparatos electrónicos de consumo interoperables, la metainformación TV-Anytime es utilizada ampliamente para garantizar (i) la disponibilidad de suficiente contenido con las descripciones detalladas, y (ii) la viabilidad de mecanismos compatibles para anotar y recoger perfiles de usuarios.

Además, nuestro enfoque de personalización explota sinergias en la clasificación multidimensional de contenidos basados en esquemas de metainformación TV-Anytime, y técnicas de razonamiento semánticas sobre una ontología de dominio formalizado a partir de estas clasificaciones. De esta manera, mejoramos en gran medida la precisión de métricas de similitud actuales y enfoques tradicionales de los sistemas de recomendación de televisión, descubriendo relaciones ocultas entre los nuevos programas y las preferencias del espectador, más allá de una sintaxis basada en la simple comparación.

Como trabajo futuro, estamos pensando en mejorar nuestro algoritmo actual con consideraciones de la experiencia de consumo real de televisión.

Estamos estudiando para agregar la posibilidad de identificar de forma automática y dar más peso al líder del grupo, comparando las preferencias individuales a los contenidos finalmente vistos. Además, la incorporación de situaciones especiales (es decir, el cumpleaños de un niño), que deben dar lugar a un aumento del peso de un miembro en la decisión grupal.

El contenido puede tener un costo y esto puede ser un factor de decisión, que aún no es considerado. Por último, al igual que Ardissono [18], estamos examinando la pertinencia de buscar grupos homogéneos dentro de los grupos heterogéneos, y tomar en cuenta este hecho en las técnicas de colaboración de nuestra estrategia de recomendación.

7. Bibliografía

1. Sotelo, R.; Blanco, Y.; López Nores, M.; Gil Solla, A.; Pazos Arias, J. TV Program Recommendation for Groups based on Multidimensional TV-Anytime Classifications. *IEEE Transactions on Consumer Electronics*, v. 55 1, p. 248-256, 2009.
2. L. Ardissono, A. Kobsa, and M. Maybury, *Personalized Digital Television*. Kluwer Academic Publishing, 2004.
3. J. Masthoff. Group modeling: Selecting a sequence of television items to suit a group of viewers. *User Model and User-Adapted Interaction*, vol. 14, pp. 37-85, 2004.
4. K. Chorianopoulos, "Personalized and mobile digital TV applications," *Multimedia Tools and Applications*, vol. 36, no. 1-2, pp. 1-10, 2008.
5. Z. Yu, X. Zhou, Y. Hao, and J. Gu, "TV program recommendation for multiple viewers based on user profile merging," *User Modeling and User-Adapted Interaction*, vol. 16, no. 1, pp. 63-82, 2006.
6. R. Tubío, R. Sotelo, Y. Blanco, M. López, A. Gil, J. Pazos, and M. Ramos. "A TV-Anytime metadata approach to TV program recommendation for groups," *Proc. of the 12th annual IEEE International Symposium on Consumer Electronics*, pp. 6-8, 2008.
7. L.M. de Campos, J.M. Fernandez-Luna, J.F. Huete, and M.A. Rueda-Morales, "Group recommending: a methodological approach based on Bayesian networks," *Proc. of IEEE 23rd International Conference on Data Engineering*, pp.835-844, 2007.

8. S. Morris, and A. Smith-Chaigneau. *Interactive TV Standards*. Focal Press, 2005.
9. TV-Anytime Specification Series S-3 on Metadata, 2001 [on line]. Available in <http://www.tv-anytime.org>.
10. ETSI TS 102 822-6-3 V1.1.1 TV-Anytime. Part 6: "Delivery of metadata over a bi-directional network"; Sub-part 3: Phase 2 - Exchange of Personal Profile"
11. ETSI TS 102 822-7 V1.1.1 TV-Anytime; Part 7: Phase 1 - Bi-directional metadata delivery protection.
12. G. Adomavicius, and A. Tuzhilin, "Towards the next generation of recommender systems: a survey of the state-of-the-art and possible extensions," *IEEE Transactions on Knowledge and Data Engineering*, vol. 17, no. 6, pp. 739-749, 2005.
13. S. Middleton, *Capturing Knowledge of User Preferences with Recommender Systems*, PhD thesis. Department of Electronic and Computer Science. University of Southampton, 2003.
14. Y. Blanco, J. Pazos, M. López, A. Gil, M. Ramos, "AVATAR: An Improved Solution for Personalized TV based on Semantic Inference", *IEEE Transactions on Consumer Electronics*, vol. 52, no. 1, pp. 223-231, 2006.
15. Y. Blanco, J. Pazos, A. Gil, M. Ramos, M. López, J. García, A. Fernández, and R. Díaz, "Exploiting synergies between semantic reasoning and personalization strategies in intelligent recommender systems: a case study", *The Journal of Systems and Software*, vol. 81, no. 12, pp. 2371-2385, 2008.
16. J. Masthoff, and A. Gatt, "In pursuit of satisfaction and the prevention of the embarrassment: affective state in the group recommender systems," *User Modeling and User-Adapted Interaction*, vol. 16, pp. 281-319, 2006.
17. J. Masthoff. "Modeling a group of television viewers," *Proc. of the Future TV*, pp. 415-425, 2002.
18. L. Ardissono, A. Goy, G. Petrone, M. Segnan, and P. Torasso, "INTRIGUE: Personalized recommendation of tourist attractions for desktop and handset devices," *Applied Artificial Intelligence*, vol. 17, no. 8, pp. 687-714, 2003.
19. A. Jameson, S. Baldes, and T. Kleinbauer. "Two methods for enhancing mutual awareness in a group recommender system," *Proc. of the Working Conference on Advanced Visual interfaces*, pp. 447-449, 2004.
20. J.F. McCarthy and T.D. Anagnost. "MusicFX: An arbiter of group preferences for computer supported collaborative workouts," *Proc. of the 1998 Conference on Computer-Supported Cooperative Work*, pp. 363-372, 1998.
21. H. Lieberman, N. W. Van Dyke, and A.S. Vivacqua. "Let's Browse: A collaborative Web browsing agent," *Proc. of International Conference on Intelligent User Interfaces*, pp. 65-68, 1999.
22. M. O'Connor, D. Cosley, J. Konstan, and J. Riedl. "PolyLens: A recommender system for groups of users," *Proc. of the European Conference on Computer-Supported Cooperative Work*, pp. 199-218, 2001.
23. B. Salem, and M. Rauterberg, "Multiple User Profile Merging (MUPE): key challenges for environment awareness", *Lecture Notes in Computer Science*, vol. 3295, pp. 196-206, 2004.
24. J. Kay, and W. Niu, "Adapting information delivery to groups of people," *Proc. of workshop on new technologies for personalized information access*, pp. 34-43, 2005.
25. A. Ounnas, H.C. Davis, and D.E. Millard, "Semantic modeling for group formation" *Proc. of Workshop on Personalisation in E-Learning Environments at Individual and Group Level*, pp. 25-35, 2007.
26. I. Cantador, and P. Castells, "Building emergent social networks and group profiles by semantic user preference clustering" *Proc. of the 2nd International Workshop on Semantic Network Analysis*, pp. 40-53, 2006.
27. I. Cantador, P. Castells, and D. Vallet, "Enriching group profiles with ontologies for knowledge-driven collaborative content retrieval" *Proc. of the 15th IEEE international Workshops on enabling technologies*, pp. 358-363, 2006.