

**MODELO PARA RECOMENDACIÓN DE CONTENIDO EN VIVO Y  
ALMACENADO EN TELEVISIÓN DIGITAL INTERACTIVA BASADO EN  
PERFILES GRUPALES**

**RODRIGO DAVID ESCOBAR PALACIOS**

**Tesis de grado presentada como requisito  
para optar al título de Magíster en Ingeniería**

**Asesor**

**EDWIN MONTOYA MÚNERA, Ph.D.**

**MEDELLÍN  
UNIVERSIDAD EAFIT  
FACULTAD DE INGENIERÍA  
2012**

A mis padres y a Veruska

## **AGRADECIMIENTOS**

Fueron varias las personas que ayudaron de manera directa o indirecta a la exitosa culminación de esta investigación. Primero quiero agradecer a mis padres y esposa, quienes siempre fueron un apoyo incondicional y estuvieron apoyándome y dándome ánimos tanto en los buenos momentos como en los momentos difíciles. Gracias, sin ustedes la realización de este logro hubiera sido muchísimo más difícil.

Quiero agradecer a Róger Góez, con quien durante varios meses pude intercambiar ideas y conceptos sobre sistemas de recomendación. Al Dr. Edwin Montoya quien a pesar de sus muchas ocupaciones, pudo revisar mis progresos y brindarme su asesoría. Al Ingeniero Juan Carlos Montoya y al Centro de investigación e innovación de excelencia ARTICA, por brindarme su confianza y permitirme tener un contacto directo con las tecnologías de televisión interactiva y el desarrollo de aplicaciones para la misma. También quiero agradecer al Ingeniero Robin Castro y a la Ingeniera Beatriz Melo por el apoyo que me brindaron cuando decidí emprender los nuevos caminos que me conducirían finalmente a la realización de esta investigación.

También quiero agradecer a mis compañeros Ricardo Otero y Carolina Herrera por los ánimos y el apoyo que me brindaron las veces que me encontré con dificultades durante la realización de este trabajo. Finalmente agradezco a Juan Felipe Salazar, Liliana Salazar y Rafael González por su confianza al permitirme ausentarme de mi puesto de trabajo durante varias horas cada semana, para acudir a mis reuniones semanales en la Universidad EAFIT.

## GLOSARIO

**DOCUMENTO:** Unidad de información almacenada por el sistema y disponible para su recuperación.

**INDEXACIÓN:** Proceso mediante el cual se generan los descriptores de un documento.

**METADATOS:** Descriptores que contiene información sobre un documento o sobre el contenido del mismo.

**MULTIMEDIA:** Multiplicidad de formatos en los que un documento está disponible.

**RECUPERACIÓN DE INFORMACIÓN:** Área de la ciencia y la tecnología que trata de la adquisición, representación, almacenamiento, organización y acceso a elementos de información.

## ABREVIATURAS Y SIGLAS

**DTV:** Televisión digital

**DVB:** Difusión de video digital

**DVR:** Grabadora digital de video

**EPG:** Guía de programación electrónica

**GEM:** MHP globalmente ejecutable

**HTML:** Lenguaje de marcado de hipertexto

**IPTV:** Televisión IP

**ITV:** Televisión interactiva

**MAE:** Error medio absoluto

**MHP:** Plataforma multimedia para el hogar

**OCAP:** Plataforma de aplicaciones de OpenCable™

**PVR:** Grabadora personal de video

**QBE:** Consulta por ejemplo

**QBK:** Consulta por palabra clave

**RMSE:** Error cuadrático medio

**VoD:** Video en demanda

## TABLA DE CONTENIDO

<b>INTRODUCCIÓN</b> .....	<b>27</b>
<b>OBJETIVOS</b> .....	<b>29</b>
<b>1 TELEVISIÓN INTERACTIVA: DEFINICIÓN, ESTÁNDARES Y ANTECEDENTES</b> .....	<b>31</b>
<b>1.1 ANTECEDENTES</b> .....	<b>31</b>
<b>1.2 HISTORIA</b> .....	<b>32</b>
<b>1.3 TIPOS DE COMPAÑÍAS EN EL NEGOCIO DE LA ITV</b> .....	<b>36</b>
<b>1.4 TIPOS DE TELEVISIÓN INTERACTIVA</b> .....	<b>37</b>
1.4.1 Clasificación Microsoft.....	38
1.4.2 Clasificación Mark Gawlinski.....	38
<b>1.5 ESTÁNDARES PARA TELEVISIÓN INTERACTIVA</b> .....	<b>44</b>
1.5.1 Ámbito declarativo.....	44
1.5.2 Ámbito procedimental.....	45
<b>1.6 METADATOS</b> .....	<b>45</b>
<b>1.7 ESTÁNDARES ABIERTOS</b> .....	<b>46</b>
<b>2 BÚSQUEDA Y RECUPERACIÓN DE INFORMACIÓN MULTIMEDIA</b> .....	<b>50</b>
<b>2.1 SISTEMAS DE RECUPERACIÓN DE INFORMACIÓN</b> .....	<b>50</b>
2.1.1 Recuperación de información multimedia. ....	53
2.1.2 Objetivos de los sistemas búsqueda y recuperación de información. ....	54
<b>2.2 DISEÑO DE SISTEMAS DE RECUPERACIÓN DE INFORMACIÓN BASADOS EN CONTENIDOS</b> .....	<b>54</b>
2.2.1 Indexación.....	54

2.2.1.1	Indexación manual.....	55
2.2.1.2	Indexación semiautomática.....	55
2.2.1.3	Indexación automática. ....	55
2.2.1.4	Indexación en Tiempo Real (Real Time Indexing - RTI). ....	56
2.2.1.5	Indexación en No Tiempo Real (Not Real Time Indexing - NRTI).....	56
2.2.2	<b>BÚSQUEDA.</b> .....	57
2.2.2.1	Paradigmas de búsqueda de información.....	58
2.2.2.2	Modelos de Búsqueda de Información.....	59
<b>3</b>	<b>METADATOS</b> .....	<b>62</b>
<b>3.1</b>	<b>TIPOS DE METADATOS</b> .....	<b>63</b>
<b>3.2</b>	<b>ALMACENAMIENTO DE METADATOS</b> .....	<b>65</b>
3.2.1	El estándar mpeg 7. ....	66
3.2.2	Doublin core metadata initiative. ....	66
<b>4</b>	<b>SISTEMAS DE RECOMENDACIÓN</b> .....	<b>68</b>
<b>4.1</b>	<b>SISTEMAS DE RECOMENDACIÓN PARA TELEVISIÓN</b> .....	<b>73</b>
<b>5</b>	<b>SISTEMA DE RECOMENDACIÓN PROPUESTO</b> .....	<b>81</b>
<b>5.1</b>	<b>DISEÑO DE UN MODELO HÍBRIDO USANDO PERFILES GRUPALES</b> <b>83</b>	
5.1.1	Conjunto de datos. ....	84
5.1.2	Perfil de usuario. ....	84
5.1.3	Correlación usuario – usuario. ....	86
5.1.4	Ítems. ....	88
5.1.5	Función de castigo. ....	89
5.1.6	Imputación demográfica. ....	91
5.1.7	Predicción. ....	91
5.1.8	Función de fusión. ....	92
5.1.9	Límite de predicción positiva. ....	92
<b>6</b>	<b>EVALUACIÓN DEL MODELO Y RESULTADOS</b> .....	<b>95</b>

<b>6.1</b>	<b>DISEÑO DEL EXPERIMENTO.....</b>	<b>95</b>
6.1.1	Conjuntos de datos de entrenamiento y evaluación.....	96
6.1.2	Procedimiento. ....	97
<b>6.2</b>	<b>ARQUITECTURA TI.....</b>	<b>98</b>
<b>6.3</b>	<b>MÉTRICAS DE EVALUACIÓN .....</b>	<b>100</b>
<b>6.4</b>	<b>COMPARACIÓN CON EL MODELO DE LÍNEA BASE.....</b>	<b>103</b>
<b>6.5</b>	<b>ANÁLISIS DE RESULTADOS .....</b>	<b>104</b>
6.5.1	Evaluación del modelo en individuos. ....	104
6.5.2	Evaluación del modelo en parejas .....	109
6.5.3	Evaluación del modelo en tríos .....	115
6.5.4	Evaluación del métricas de error .....	121
<b>7</b>	<b>CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>125</b>
	<b>BIBLIOGRAFÍA.....</b>	<b>127</b>

## LISTA DE FIGURAS

<b>Figura 1. Winky Dink and you .....</b>	<b>33</b>
<b>Figura 2. Control Remoto Zenith .....</b>	<b>33</b>
<b>Figura 3. TiVo Personal Video Recorder .....</b>	<b>34</b>
<b>Figura 4. EPG de Sky TV .....</b>	<b>39</b>
<b>Figura 5. Muestras de teletexto analógico (izq.) y digital (der.).....</b>	<b>40</b>
<b>Figura 6. Muestras de Walled Garden de telewest .....</b>	<b>41</b>
<b>Figura 7. Televisión Mejorada (Enhanced TV) .....</b>	<b>42</b>
<b>Figura 8. Arquitectura para el despliegue de MHP .....</b>	<b>47</b>
<b>Figura 9. Arquitectura para el despliegue de OCAP.....</b>	<b>48</b>
<b>Figura 11. Componentes básicos de un sistema de recomendación personalizado</b>	<b>69</b>
<b>Figura 12. Operación de un sistema de recomendación.....</b>	<b>72</b>
<b>Figura 13. Esquemas de filtrado para sistemas de recomendación .....</b>	<b>74</b>
<b>Figura 14 – Componentes de un Sistema de Recomendación .....</b>	<b>81</b>
<b>Figura 15 - Componentes del modelo propuesto .....</b>	<b>83</b>
<b>Figura 16. Proporción de usuarios por grupo de edad .....</b>	<b>86</b>
<b>Figura 17. Proporción de usuarios por género sexual.....</b>	<b>86</b>
<b>Figura 19. Número de ítems por género.....</b>	<b>89</b>
<b>Figura 20. Gráfica de la función de castigo .....</b>	<b>90</b>
<b>Figura 21. Arquitectura Cliente/Servidor utilizada.....</b>	<b>99</b>

<b>Figura 22. Precisión de modelo base vs modelo propuesto .....</b>	<b>105</b>
<b>Figura 23. Recuerdo de modelo base vs modelo propuesto .....</b>	<b>106</b>
<b>Figura 24. F1-Score de modelo base vs modelo propuesto .....</b>	<b>107</b>
<b>Figura 25. Comparación de MAE entre el modelo base y el modelo propuesto.....</b>	<b>108</b>
<b>Figura 26. Comparación de RMSE entre el modelo base y el modelo propuesto ...</b>	<b>109</b>
<b>Figura 27. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a parejas.....</b>	<b>110</b>
<b>Figura 28. Recuerdo de modelo base vs modelo propuesto .....</b>	<b>111</b>
<b>Figura 29. Comparación del F1-Score entre el modelo base y el modelo propuesto aplicado a parejas.....</b>	<b>112</b>
<b>Figura 30. Mejora de la precisión entre el modelo base y el modelo propuesto cuando es aplicado a parejas. ....</b>	<b>113</b>
<b>Figura 31. Mejora del recuerdo entre el modelo base y el modelo propuesto cuando es aplicado a parejas.....</b>	<b>114</b>
<b>Figura 32. Mejora del F1-score entre el modelo base y el modelo propuesto cuando es aplicado parejas.....</b>	<b>115</b>
<b>Figura 33. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a tríos .....</b>	<b>116</b>
<b>Figura 34. Comparación de recuerdo entre el modelo base y el modelo propuesto aplicado a tríos .....</b>	<b>117</b>
<b>Figura 35. F1-Score de modelo base vs modelo propuesto. ....</b>	<b>118</b>
<b>Figura 36. Mejora de la precisión entre el modelo base y el modelo propuesto cuando es aplicado a tríos.....</b>	<b>118</b>
<b>Figura 37. Mejora del recuerdo entre el modelo base y el modelo propuesto cuando es aplicado a tríos.....</b>	<b>119</b>

<b>Figura 38. Mejora del F1-score entre el modelo base y el modelo propuesto cuando es aplicado tríos. ....</b>	<b>120</b>
<b>Figura 39. Comparación del MAE entre el modelo base y el modelo propuesto.....</b>	<b>122</b>
<b>Figura 40. Comparación del RMSE entre el modelo base y el modelo propuesto ..</b>	<b>123</b>

## LISTA DE TABLAS

Tabla 1. Categorización de las plataformas de iTV .....	43
Tabla 2: Distribución de televidentes por edad en el conjunto de datos.....	85
Tabla 3. Cantidad de ítems por género en el conjunto de datos .....	88
Tabla 4. Comparación de Precisión entre el modelo base y el modelo propuesto. 104	
Tabla 5. Comparación de Recuerdo entre el modelo base y el modelo propuesto. 105	
Tabla 6. Comparación de F1-Score entre el modelo base y el modelo propuesto.. 106	
Tabla 7. Comparación de MAE entre el modelo base y el modelo propuesto .....	107
Tabla 8. Comparación de RMSE entre el modelo base y el modelo propuesto.....	108
Tabla 9. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a parejas.....	110
Tabla 10. Comparación de Recuerdo entre el modelo base y el modelo propuesto aplicado a parejas.....	111
Tabla 11. Comparación del F1-Score entre el modelo base y el modelo propuesto aplicado a parejas.....	112
Tabla 12. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a tríos .....	115
Tabla 13. Comparación de Recuerdo entre el modelo base y el modelo propuesto aplicado a tríos .....	117
Tabla 14. Comparación del F1-Score entre el modelo base y el modelo propuesto aplicado a tríos. ....	117
Tabla 15. Comparación del MAE entre el modelo base y el modelo propuesto .....	121

**Tabla 16. Comparación del RMSE entre el modelo base y el modelo propuesto.... 122**

## RESUMEN

Actualmente, la oferta de contenido multimedia (música, imágenes, videos, juegos, entre otros) es muy amplia y con tendencia al aumento en los próximos años. Adicionalmente, el acceso a dichas ofertas es cada vez más fácil gracias a las nuevas tecnologías embebidas en televisores, computadores, dispositivos móviles, etc., las cuales permiten a los usuarios permanecer conectados a diferentes generadores de contenido desde casi cualquier lugar del mundo. La gran cantidad de contenido disponible hace que resulte muy complicado conocer todas las opciones que se nos presentan. Los sistemas de recomendación han sido creados para ayudar a los usuarios a conocer las opciones que más le pueden resultar interesantes, de forma que no tengan la necesidad de buscar entre todas las opciones disponibles. La televisión, por ser un medio de comunicación y entretenimiento utilizado a diario por la gran mayoría de los seres humanos, es un ámbito en el que la oferta de contenido ha crecido y continúa creciendo de manera exponencial a medida que los televidentes pueden contar con servicios de televisión en Internet, videograbadoras personales (Personal Video Recorder - PVR), televisión por suscripción y televisión gratuita, entre otros tipos de servicio. Por lo tanto la posibilidad de contar con un sistema que tenga la capacidad de seleccionar una pequeña fracción del contenido televisivo que pueda satisfacer los gustos del televidente, se ha convertido en una necesidad.

Se han elaborado numerosas propuestas de sistemas de recomendación que se encargan de presentar a un usuario los contenidos que pueden resultarle más interesantes. Básicamente existen dos tipos de sistemas de recomendación: basados en filtrado por contenido y basados en filtrado colaborativo. Usualmente

se obtiene una mejora cuando se usan los dos esquemas anteriores para formar un sistema de recomendación híbrido.

En este documento se presenta el modelo de un sistema híbrido de recomendación de contenidos que, haciendo uso del conocimiento del perfil de los usuarios y sin requerir más información, presenta mejoras sustanciales en comparación con uno de los modelos propuestos recientemente. Más aún, se muestra que el sistema supera a dicho modelo cuando se aplica a grupos de televidentes conformados por dos o tres personas.

**PALABRAS CLAVES:** RECUPERACIÓN DE INFORMACIÓN, SISTEMA DE RECOMENDACIÓN, FILTRADO DE INFORMACIÓN, IPTV, BÚSQUEDA DE INFORMACIÓN, FILTRADO COLABORATIVO, FILTRADO BASADO EN CONTENIDO, TELEVISIÓN IP.

## INTRODUCCIÓN

La implementación de los diversos estándares de televisión digital, la expansión de IPTV junto con la convergencia de servicios y la convergencia de redes han hecho posible que el ser humano cuente con una muy amplia disponibilidad de contenido televisivo a la que puede acceder haciendo uso de diversas tecnologías y desde una gran cantidad de dispositivos que se encuentran disponibles en el mercado. Con toda esa información disponible y en aumento, es difícil que los televidentes haciendo uso de las herramientas tradicionales, como la Guía Electrónica de Programas (Electronic Program Guide - EPG) y los canales guía, puedan conocer muchas de las opciones de contenido televisivo que le podrían resultar atractivas. Por lo tanto se vuelve de vital importancia tener un sistema con la capacidad de sugerir a los televidentes las opciones que más se adapten a sus preferencias y necesidades al igual que ha ocurrido con muchos servicios en Internet cuando se presenta sobrecarga de información (Por ejemplo google, youtube y Amazon). Con el fin de satisfacer esa necesidad aparecen los sistemas de recomendación de contenido, cuyo objetivo es ayudar a los usuarios en la selección del contenido que pueda resultarle más atractivo.

Desde hace algunos años se han realizado varios estudios y propuestas para sistemas de recomendación de programas de televisión, pero la gran mayoría de éstos se han centrado en las recomendaciones realizadas a televidentes como individuos. Además, aquella minoría que ha tenido como objetivo la búsqueda de mecanismos para realizar recomendaciones a un grupo, entendido como un conjunto de dos o más personas que se reúnen en frente de un único televisor

para contemplar las imágenes transmitidas por televisión, se ha basado solamente en la correlación de los datos de preferencias de cada uno de los individuos que conforman el grupo, pero no en las preferencias de un grupo como una entidad, lo cual permitiría mejorar las recomendaciones que se hacen a un televidente y a un grupo de televidentes que es precisamente el estudio que se realiza en esta tesis.

El desarrollo de esta tesis propone y evalúa un modelo, es decir una forma o técnica compuesta por varios pasos sistemáticos, basado en memoria cuyo resultado es la generación de recomendaciones mejoradas para un individuo o un grupo de individuos que ven televisión juntos. En el primer capítulo se presenta una introducción a la historia y la evolución de la televisión interactiva, se exploran las clasificaciones realizadas por algunos autores y se introduce un tipo especial de datos que resulta muy importante para los procesos de filtrado, recuperación de información y recomendación de contenidos: los metadatos. En el segundo capítulo se introducen las técnicas más utilizadas para la búsqueda y recuperación de información. Los modelos de búsqueda y los procesos de indexación que son base para los procesos de recomendación de contenidos. Además se analizan algunos estándares de metadatos utilizados para búsqueda y recuperación de información multimedia. Luego, en el tercer capítulo, se realiza una introducción a los sistemas de recomendación, las técnicas más usadas, su clasificación, su evaluación y el estado actual de este tipo de sistemas. En el cuarto capítulo se presenta en detalle el diseño del sistema propuesto y, finalmente, en el quinto capítulo se evalúa la eficacia del sistema propuesto en comparación con un modelo de línea base presentado en la literatura del estado del arte.

## **OBJETIVOS**

### **OBJETIVO GENERAL**

Proponer un modelo o técnica para sistemas de recomendación de contenido en vivo y almacenado en televisión digital interactiva basado en perfiles grupales.

### **ESPECÍFICOS**

- Diseñar el esquema funcional del sistema de recomendación.
- Proponer un sistema de generación de perfiles de usuario que permita identificar sus preferencias.
- Proponer una forma de generación de perfiles de grupo que permita identificar las preferencias del grupo como una entidad.
- Proponer un esquema de filtrado basado en contenido.
- Proponer un esquema de filtrado basado en colaboración de grupos.
- Proponer una forma que permita asociar el perfil de un televidente con un perfil grupal.
- Identificar la infraestructura necesaria para la implementación de un prototipo de sistema de recomendación.
- Implementar un prototipo de sistema de recomendación que permita evaluar el modelo de recomendación propuesto.

# **1 TELEVISIÓN INTERACTIVA: DEFINICIÓN, ESTÁNDARES Y ANTECEDENTES**

Aunque no hay un consenso generalizado alrededor de lo que es la televisión interactiva, se puede decir que la televisión interactiva es cualquier servicio o aplicación de la televisión o las compañías que ofrecen el servicio de televisión, que les permite a los televidentes y a las personas o empresas que hacen los programas de televisión, las empresas dueñas de los canales de televisión o los proveedores del servicio entablar alguna forma de dialogo en la que el usuario abandona la pasividad tradicional de televidente y toma acciones, aún si la acción es tan simple como enviar una carta por correo, enviar en email o dibujar una figura en la pantalla del televisor<sup>1</sup>.

## **1.1 ANTECEDENTES**

A pesar de que la interactividad en el ámbito de la televisión puede parecer un fenómeno reciente, desde los primeros días en los que la televisión empezó a llegar a los hogares de todo el mundo, los productores han intentado hacer que sus programas y canales sean más dinámicos y participativos<sup>2</sup>. En el caso de la televisión infantil, por ejemplo, el elemento de interactividad frecuentemente ha intentado hacer que los televidentes canten, salten o bailen, como una forma de interacción con los programas de televisión. A los televidentes adultos también se

---

<sup>1</sup> GAWLINSKI, Mark. Interactive Television Production. Oxford: Focal Press, 2003. p.273. ISBN 0240516796.

<sup>2</sup> IBID, p.273.

les ha intentado proporcionar formas de interactuar con la televisión como, por ejemplo, haciéndoles solicitud de realimentación o pidiéndoles su participación en ejercicios de votación. El teléfono ha sido una herramienta muy útil para adicionar interactividad al servicio de televisión (aún hoy en día, muchos programas de televisión le permiten a los televidentes comunicarse telefónicamente con los programas y productores de televisión)<sup>3</sup>.

Los desarrollos recientes en tecnología han abierto muchas posibilidades para la realización de televisión interactiva. En particular, las tecnologías de transmisión digital han hecho posible enviar mucha información haciendo uso de menos ancho de banda, lo cual ha permitido que los operadores del servicio de televisión puedan enviar información extra de forma más fácil al mismo tiempo que envían la señal de televisión, y además, le han permitido a los televidentes enviar información a los operadores.

## 1.2 HISTORIA

Los siguientes son los eventos más representativos desde el primer intento de proporcionar interactividad al servicio de televisión<sup>4</sup>:

- **1953:** Winky Dink and you, fue el primer programa de televisión interactivo. Los niños ponían una hoja de plástico sobre el televisor y dibujaban sobre ella mientras veían un programa.

---

<sup>3</sup> IBID, p.273

<sup>4</sup> ESTADOS UNIDOS. ITA Interactive Television Alliance. Interactive television: a short history [Online]. (Citada: 13 mar. 2009).< <http://www.itvalliance.org/>>



*Figura 1. Winky Dink and you*

- **1957:** Zenith “Space Command” Remote Controller. El control remoto le permitió al televidente intercambiar entre los trece canales VHF sin tener que acercarse al televisor.



*Figura 2. Control Remoto Zenith*

- **1972:** Televisión por cable. El cable permitió a los televidentes contar con más de 75 canales mediante el uso de un Set Top Box (STB).
- **1977:** Qube. Esta tecnología de Warner Cable le permitió a una cierta cantidad de televidentes obtener información adicional mientras veían un programa, y además podían participar en votaciones en vivo y conferencias electrónicas. Además, QUBE introdujo muchos conceptos que se volvieron centrales para la televisión por cable, como los programas pague por ver (PPV – Pay Per View). Sus dificultades fueron de tipo fiscal<sup>5</sup>.

---

<sup>5</sup> FREED, Ken. When cable went qubist. The Qube network in the Seventies set the mark for interactive TV, but the business case was a bust [Online]. (Citada: 22 mar. 2009).< <http://www.media-visions.com/itv-qube.html>>

- **1984:** Ley de políticas de comunicaciones por cable: esta ley, que tuvo como objetivo la desregulación de la industria de la televisión por cable en Estados Unidos, aceleró la penetración del cable. Las casas con servicio de televisión por cable se incrementaron a 500 millones al final de la década.
- **1994:** Red de servicio completo. Time Warner lanzó este servicio de iTV en Orlando. Funcionó bien, pero ningún cliente estuvo dispuesto a pagar USD 5000 por el STB digital. La Internet parecía más promisoría en ese momento.
- **1995:** Televisión digital por satélite. Con el uso de esta tecnología la capacidad de canales se expandió a 500, por lo cual surgió la necesidad de tener una guía de programación mejorada (EPG – Enhanced Program Guide).
- **1997:** Web TV. La Internet converge a la pantalla de televisión. Web TV fue comprada por Microsoft y fue renombrada a MSNTV.
- **1998:** Digital Cable. Los MSO (Multiple System Operator) empiezan a expandir su infraestructura digital a más de 1.5 millones de casas, dándoles a sus usuarios la posibilidad de acceder a servicios de iTV. A finales de los años 90's este número se expandió a más de 5 millones. Los MSO son operadores de varios sistemas de televisión por cable.
- **1999:** Digital Video Recorder DVR. TiVo y Replay TV cambiaron la forma de ver televisión. En conjunto con Dish network y UltimateTV vendieron más de 3 millones de DVRs al comienzo del año 2000.



*Figura 3. TiVo Personal Video Recorder*

- **2000:** Despliegue de iTV. Los programas de televisión interactiva comenzaron a ser transmitidos por todos los MSO y los operadores de DBS. Wink TV estaba disponible en más de 6 millones de hogares. Open TV, Liberate, Canal + y World Gate hicieron importantes alianzas estratégicas. Más de 20 millones de hogares tenían STB con capacidad de proporcionar alguna forma de interactividad. Las compañías de cable empezaron a impulsar el video bajo demanda (VoD – Video on demand) y las guías de programación interactiva (IPG – Interactive program guide).
- **2001:** Ataques del 9/11. Como consecuencia de los ataques del 11 de septiembre, muchos planes de negociación, incluyendo el de Microsoft con AT&T se congelaron. En respuesta a las caídas financieras sufridas por las empresas que proporcionaban iTV, en 2002 se creó la iTV Alliance con cinco compañías que lideraban las actividades relacionadas con la televisión interactiva (Open TV, Liberate, Canal +, ACTV y World Gate). Para finales del año otras 30 compañías empezaron a formar parte de la iTV Alliance, entre ellas: Disney, Turner, Procter & Gamble, Mediavest, ComCast, Direct TV, Microsoft e Intel.
- **2003:** Liberty Media compra Open TV, Wink y ACTV. News Corp compra Direct TV. Microsoft impulsa Media Center PC a medida que Broadband TV es más accesible desde el hogar. Los operadores de cable toman OCAP como la nueva plataforma para la televisión digital, y planean la transición dentro de los siguientes cinco años. La academia de televisión da el primer premio Emmy a la interactividad al programa de televisión **Nascar In Car On iN Demand**<sup>6</sup>.

---

<sup>6</sup> ESTADOS UNIDOS. Academy of Television Arts and Sciences. Interactive Television Emmy to be Voted Online [Online]. (Citada: 28 feb. 2009).< <http://www.emmys.tv/news/2004/interactive-television-emmy-be-voted-online>>

- **2006:** Los televisores digitales de pantalla plana de 42” alcanzan un precio de USD 1200, el precio equivalente a un televisor a color en 1968. El DVD reemplazó completamente al VCR (Video Cassete Recorder) y se estandarizó la televisión de alta definición. Se creó un negocio alrededor de la televisión móvil. Los TelCos entraron al negocio de la televisión con su propia plataforma de IPTV. La Internet de banda ancha estaba disponible en más del 50% de los hogares norteamericanos.

Actualmente la televisión interactiva está disponible en más del 70% de los hogares norteamericanos. El video bajo demanda, las IPGs, los DVRs son cada vez más ubicuos. Los anunciantes están aprovechando la posibilidad de dirigir mejor sus avisos comerciales a un público específico. Google y Apple están invirtiendo en televisión digital e iTV. El blue ray ganó la batalla por el sistema de almacenamiento para el video de alta definición. En muchos países se ha producido el apagón de la televisión analógica y se espera que se produzcan rápidamente nuevos programas de televisión interactiva.

### 1.3 TIPOS DE COMPAÑÍAS EN EL NEGOCIO DE LA ITV

Las compañías involucradas en el área de la televisión interactiva, pueden ser categorizadas en cinco tipos<sup>7</sup>:

- **Difusores.** Los difusores son los dueños de los canales de televisión y eligen los programas que se transmiten en estos canales. Dichos programas pueden ser creados por sus propios equipos de producción o por compañías productoras externas. Además pueden comprar programas de otros difusores. Algunos ejemplos son la BBC y MTV.

---

<sup>7</sup> GAWLINSKI, Op. Cit., p.273.

- **Compañías de producción.** Las compañías de producción hacen los programas y los servicios de televisión interactiva para los difusores y sus usuarios. Usan la mayor parte de su tiempo en crear y evaluar ideas para nuevos programas y servicios. También crean marcas de programas (Por ejemplo Quien quiere ser millonario) que pueden vender alrededor de todo el mundo.
- **Operadores de plataforma.** Los operadores de plataformas son las empresas que poseen las redes que transportan el video y los servicios interactivos hasta los usuarios. Principalmente se ocupan del transporte de los datos, ya sea vía satélite, cable, terrestre o por redes telefónicas. Algunas veces los operadores pagan a los difusores por sus canales, y algunas veces los difusores pagan a los operadores por el transporte de los programas.
- **Compañías de tecnología.** Estas compañías proporcionan el hardware y el software requerido para la realización de los programas de televisión, los servicios interactivos y la operación de los canales de televisión.
- **Fabricantes de bienes de consumidor.** Son las compañías que quieren vender o hacer llegar un mensaje al televidente, principalmente avisos comerciales.

Es posible que algunas compañías pertenezcan a dos o más de los tipos mencionados.

#### **1.4 TIPOS DE TELEVISIÓN INTERACTIVA**

En el momento no existe una clasificación ampliamente aceptada que describa los diferentes tipos de interactividad. En este documento se presentan dos clasificaciones distintas de la televisión interactiva obtenidas del libro Interactive Television Production.

#### 1.4.1 Clasificación Microsoft.

Para Microsoft hay cuatro tipos de televisión interactiva<sup>8</sup>:

- **Televisión mejorada.** Son los servicios que permiten a los televidentes interactuar con los programas de televisión.
- **Internet Television.** Son los servicios que permiten a los televidentes ver y usar información disponible en la Internet.
- **Personal Television.** Son los servicios que permiten a los televidentes grabar y pausar los programas de televisión.
- **Televisión conectada.** Son los servicios que permiten que el televisor comparta información con diferentes dispositivos en el hogar como los computadores personales.

#### 1.4.2 Clasificación Mark Gawlinski.

Para el autor del libro Interactive Television Production existen otros tipos de televisión interactiva<sup>9</sup>:

- **Guía electrónica de programación(Electronic Programming Guide - EPG).** Es uno de los tipos más importantes y útiles de la televisión interactiva. Su trabajo principal es informar a los televidentes sobre la programación de los canales. Las EPGs muestran la programación directamente en la pantalla del televisor, y los televidentes pueden seleccionar el programa que quieren ver de la lista. Para acceder a las

---

<sup>8</sup>IBID, p.274.

<sup>9</sup>IBID, p.275.

EPGs los televidentes presionan un botón del control remoto que se proporciona con el servicio de televisión.



Figura 4. EPG de Sky TV

- **Teletexto.** Los servicios de teletexto en la televisión interactiva toman su nombre y estilo de una tecnología desarrollada hace más de 30 años. Millones de televidentes particularmente en Europa están familiarizados con la utilidad de la tecnología de teletexto en la televisión analógica, en la cual, los televidentes usualmente presionan el botón de texto en el control remoto mientras ven un programa de televisión y éste les muestra alguna información de texto y gráficos simples que usualmente están relacionados con el canal que está viendo. El audio de del canal permanece mientras se muestra el teletexto al televidente para darle la sensación de que aún permanece en el canal que estaba viendo antes de solicitar el teletexto y la navegación por la información de teletexto se hace basada en números de páginas.



Figura 5. Muestras de teletexto analógico (izq.) y digital (der.)

En la televisión digital, la funcionalidad del teletexto es muy similar a la de la televisión analógica, su evolución se hace notable sobre todo en que en el teletexto digital se muestran fotografías, es posible el uso de miles de colores y se han añadido funcionalidades relacionadas con la mensajería instantánea y el correo electrónico. Pero se continúa accediendo al teletexto pulsando un botón en el control remoto, se da la sensación al televidente de que aún está en el mismo canal manteniendo el audio o insertando la imagen del canal en las imágenes del canal de teletexto. Para la navegación en el canal de teletexto algunos operadores mantienen el estilo basado en números de páginas, aunque otros lo han evolucionado a accesos más amigables a través de menús.

- **Walled Gardens.** Algunos operadores de plataformas de televisión interactiva ofrecen una colección de diferentes contenidos interactivos y servicios de diferentes compañías en un ambiente seguro y fácil de entender que comúnmente es conocido como un walled garden. Cada uno de los servicios en un walled garden está preparado especialmente para su uso en televisión y tiene un acuerdo comercial con el operador de la plataforma. Los servicios se acceden mediante menús en el televisor a los

cuales acceden usando el control remoto. El término walled garden se usa, porque hay un límite definido que previene que el televidente pueda acceder a contenido no regulado.

Generalmente la parte más popular de un walled garden es la sección de juegos. De hecho existen walled gardens que solo ofrecen juegos. Estos juegos van desde juegos de acción hasta juegos de estrategia.



Figura 6. Muestras de Walled Garden de telewest

- **Television mejorada.** Puede definirse como cualquier servicio de televisión interactiva que mejora un programa de televisión mientras éste se presenta. Los proveedores de servicios de televisión mejorada usualmente adicionan capas de texto y gráficos a los programas de forma que los televidentes puedan interactuar mientras lo ven. Por ejemplo algunos servicios de televisión interactiva dan la oportunidad a los televidentes de intentar responder preguntas antes de que sean respondidas por la persona cuestionada en un programa tipo examen (Por ejemplo ¿Quién Quiere Ser Millonario?) de forma tal que al final del programa los televidentes pueden ver sus resultados y compararlos con la persona que se encontraba en el estudio de televisión o permitiendo la realización de competencias entre

televidentes. También se puede mejorar un programa permitiendo a los televidentes elegir entre diferentes flujos de audio y video de un mismo programa. Por ejemplo en un partido de fútbol el televidente puede elegir la cámara con la que quiere ver el partido y elegir si quiere escuchar los comentarios del público en el estadio o los comentarios de los narradores profesionales.



Figura 7. Televisión Mejorada (Enhanced TV)

A diferencia de los esquemas de producción de televisión tradicionales, la televisión mejorada requiere varios sistemas interconectados que ejecutan un rol distinto y con compatibilidad limitada. Es decir, que una mejora específica a un programa de televisión podría ejecutarse en un único modelo de Set Top Box que ejecuta una versión particular de un middleware de alguna compañía dentro de un ambiente de aplicación de otra compañía y sobre un único tipo de transporte. La idea actual es romper este tipo de restricciones haciendo uso de estándares abiertos como MHP, OCAP o GEM, los cuales describen más abajo en este documento.

- **VoD y Near VoD.** En los servicios de video bajo demanda el usuario decide cuando ver el contenido y tiene control total sobre la reproducción del mismo. Es decir que puede adelantar, atrasar, pausar el video sin que afecte el servicio de otros televidentes. En los servicios de Near Video on

demand el proveedor transmite un programa varias veces en unos horarios determinados y el usuario decide en cuál de esos horarios ve el video.

- **PVR.** Al igual que con los servicios de video bajo demanda, los PVR fueron desarrollados debido a la popularidad de los VCR. Existen dos diferencias principales entre los VCR y los PVR:
  - La información no se almacena en un casete sino en un STB usualmente equipado con un disco duro.
  - Los PVR pueden grabar y reproducir al mismo tiempo.

<b>Platform</b>	<b>Representative Example</b>
Personal / Digital Video Recorder (PVR / DVR)	TiVo
Video On Demand (VOD)	Comcast ON DEMAND
Electronic / Interactive Programming Guides (EPG / IPG)	Gemstar-TV Guide's GUIDE Plus+
Web TV	MSN TV / WebTV
Web-Based Synchronous (Two Screen)	TNT Interactive
Web-Based Asynchronous	PBS Love & Diane: An Interactive Timeline
Media Centers (PVR, Web connection, TV feed)	Microsoft Media Center
Mobile Devices	American Idol
Game Consoles	Battlestar Galactica prototype

Tabla 1. Categorización de las plataformas de iTV<sup>10</sup>

<sup>10</sup> LU, Karyn Y. Interaction design principles for interactive television. Atlanta, 2005, p.219. Trabajo de grado (Master of Science in Information Design and Technology). Georgia Institute of Technology. School of Literature Communication and Culture.

## 1.5 ESTÁNDARES PARA TELEVISIÓN INTERACTIVA

Los estándares para iTV todavía se encuentran en un estado de mejoramiento en términos de desarrollo e implementación. Se han hecho esfuerzos para la estandarización en tres ámbitos<sup>11</sup>:

- Ámbito declarativo
- Ámbito procedimental
- Metadatos

La mayoría de los estándares de televisión interactiva incorporan dos o más de las anteriores funcionalidades.

### 1.5.1 Ámbito declarativo.

El ámbito declarativo le permite al diseñador crear contenido en un lenguaje de alto nivel como HTML que luego será mostrado por una máquina de gráficos. En el caso de la televisión interactiva puede estar dentro del Set Top Box (STB). En un sistema de cable, donde los Set Top Boxes no tienen la suficiente capacidad de cómputo, la máquina de gráficos puede estar en el equipo de la cabecera del proveedor.

Las implementaciones de televisión interactiva como Liberate y OpenTV se basaron en estándares desarrollados por el W3C y la IETF; Entre los estándares desarrollados también se encuentran: Advanced Television Enhancement Forum (ATVEF), Declarative Data Essence (DDE - 1), Society of Motion Picture and Television Engineers 343M (SMPTE 343M), DTV Application Software Environment (ATSC DASE), Digital Video Broadcasting Multimedia Home Platform (DVB MHP), Open Cable Applications Platform (OCAP).

---

<sup>11</sup> Halle, T. (2003). Standards for interactive television: A brief state of the union. (Citada 8 de abril de 2009) <<http://etvcookbook.org/reference/standards.html>>

### **1.5.2 Ámbito procedimental.**

En el ámbito procedimental, las aplicaciones son ejecutadas directamente sobre el sistema operativo del Set Top Box. Los primeros esfuerzos de implementar televisión interactiva en Set Top Box de bajo consumo de potencia, usaron un ámbito procedimental, porque con una aplicación se puede mostrar más fácilmente la televisión interactiva que en un navegador encargado de mostrar los contenidos declarativos. Algunos sistemas propietarios como Wink y OpenTV aún usan esta solución, pero la mayoría de los esfuerzos de estandarización actuales están centrados alrededor de JAVA, el cual además es la base comercial de los middleware producidos por Liberate, Canal + y algunos otros. MHP, OCAP y DASE son estándares procedimentales basados en la máquina virtual de JAVA, así que en un alto nivel son muy similares.

### **1.6 METADATOS**

Los metadatos por su parte se han vuelto cada vez más importantes para la iTV. Los metadatos son datos que describen otros datos. Usualmente es un archivo en formato XML que contiene atributos de una cierta parte del contenido.

Los atributos descritos por los metadatos de un programa pueden incluir desde simples datos de la EPG hasta un índice completo de las diferentes escenas hasta los contenidos mejorados con la información de derechos de protección del contenido. Algunos estándares que han hecho uso de los Metadatos son: OCAP, TV Anytime y MPEG 7.

## 1.7 ESTÁNDARES ABIERTOS

Algunas soluciones de middleware propietarias han estado disponibles por muchos años desde que fueron desarrolladas por empresas como OpenTV, NDS, Canal +, PowerTV y Microsoft, pero en este momento nos encontramos en un mercado emergente para middleware basados en estándares abiertos. MHP es actualmente el líder en el desarrollo de este mercado acompañado de OCAP y ACAP. El primer despliegue de MHP se produjo en Finlandia en los inicios del año 2002<sup>12</sup>.

La importancia de los estándares abiertos radica en que garantizan que los dispositivos que cumplen con ellos estarán en capacidad de funcionar juntos sin importar el fabricante. Los clientes generalmente no están interesados en estos detalles y se preocupan solamente por el uso que le dan y se sienten tranquilos con el simple hecho de que hagan bien el trabajo para el que están hechos.

- **MHP.** MHP es un middleware o API que permite a las aplicaciones y servicios interactivos ser accedidos independientemente del hardware en el que se ejecuten. MHP puede ser visto como una evolución natural del trabajo de DVB hacia el software de televisión interactivo y las aplicaciones que empezarán a dar valor agregado en la transición de la televisión analógica a la televisión digital. La primera versión de la especificación de MHP fue liberada el 23 de febrero del año 2000 y desde entonces, el trabajo alrededor de esta especificación se ha expandido no sólo a la realización de mejoras del API, sino a aspectos como la red del hogar, los PVR, las

---

<sup>12</sup> MORRIS, Steven y SMITH-CHAIGNEAU, Anthony. Interactive TV Standards. A Guide to MHP, OCAP, and JavaTV. Oxford: Focal Press, 2005. p.1. ISBN 0240806662.

aplicaciones móviles, el transporte en redes IP y algunas otras tecnologías<sup>13</sup>.

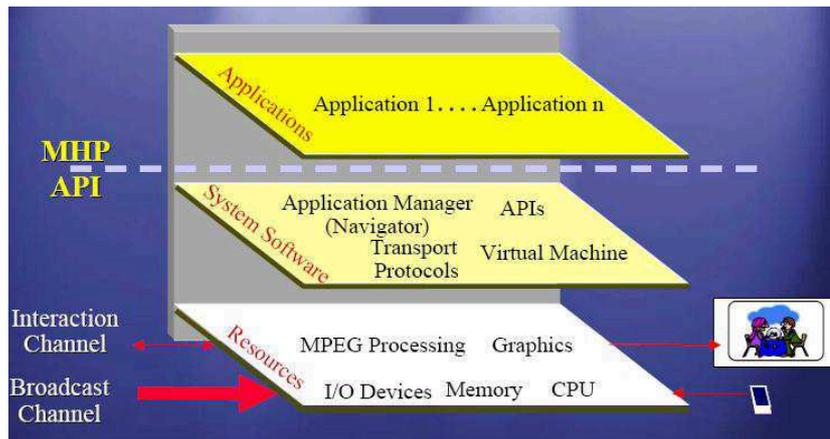


Figura 8. Arquitectura para el despliegue de MHP<sup>14</sup>

- **OCAP.** OCAP está basado en MHP y proporciona una especificación para un middleware común para los sistemas de cable en los Estados Unidos. Fundamentalmente hace en la televisión por cable lo mismo que MHP en DVB<sup>15</sup>.

<sup>13</sup> IBID, p.8.

<sup>14</sup> LUETTEKE, George. Multimedia Home Platform. En: DIGITAL VIDEO BROADCASTING SEMINAR (1:2001:Taipei) Presentación DVB Seminar. Taipei, 2001. p.59.

<sup>15</sup> MORRIS, Op. Cit., p.8.

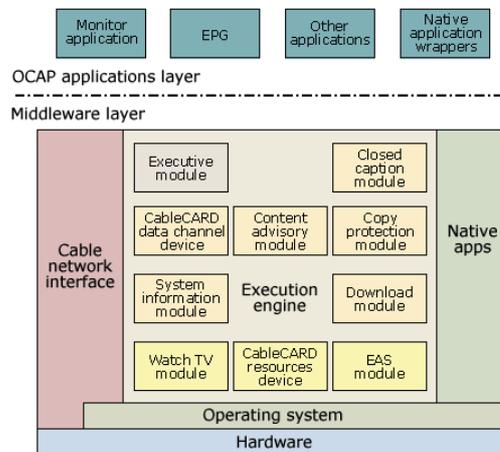


Figura 9. Arquitectura para el despliegue de OCAP<sup>16</sup>

- **Globally Executable MHP – GEM.** La especificación GEM es un subconjunto de MHP que ha sido diseñado para tener en cuenta las dificultades de interoperabilidad entre varias especificaciones de middleware abiertos<sup>17</sup>. Estas dificultades incluyen:
  - Dificultades técnicas de interoperabilidad provenientes de estándares previos como OCAP y DASE.
  - Dificultades relacionadas con los sistemas de transmisión como la elección de la modulación, los mecanismos de entrega, entre otros.
  - Diferentes requerimientos de mercado de los operadores de las plataformas de televisión.

Así GEM es un marco de trabajo que pretende crear armonía entre distintas organizaciones en sus especificaciones técnicas, como la selección de un único motor de ejecución y un conjunto de APIs común. La meta es que las

<sup>16</sup> LUETTEKE, Op. Cit., p.59.

<sup>17</sup> MORRIS, Op. Cit., p.8.

aplicaciones y el contenido sean interoperables entre todas las plataformas basadas en GEM.

## 2 BÚSQUEDA Y RECUPERACIÓN DE INFORMACIÓN MULTIMEDIA

Desde finales de la década pasada ha habido un rápido crecimiento en el uso e intercambio de medios digitales como imágenes, video y audio. A medida que se incrementa el uso de este tipo de contenido, la efectividad de las técnicas de búsqueda y recuperación se hacen cada vez más importantes para facilitar el acceso a este tipo de información.

### 2.1 SISTEMAS DE RECUPERACIÓN DE INFORMACIÓN

Un sistema de recuperación de información, es un sistema con capacidad de almacenamiento, recuperación y mantenimiento de información compuesta por texto, imágenes, audio, video y otros tipos de información multimedia. Aunque la forma de un objeto en un sistema de recuperación de información puede variar, la búsqueda y recuperación basada en la descripción textual ha sido la única que hasta el momento ha logrado un funcionamiento adecuado, generalmente los otros tipos de datos se han enlazado a información textual para su búsqueda y recuperación, pero se han empezado a crear algunas técnicas que permitan la búsqueda de información en otros tipos de medio (Por ejemplo EXCALIBUR's Visual RetrievalWare, VIRAGE video indexer)<sup>18</sup>.

Un sistema de búsqueda y recuperación de información consiste de uno o varios programas de software que permiten a un usuario encontrar más fácilmente la información que necesita. El sistema puede usar hardware de cómputo estándar o

---

<sup>18</sup> KOWALSKI, Gerald y MAYBURY, Mark. Information Storage and Retrieval Systems-Theory and Implementation. 2 ed. S.L: Kluwer Academic Publishers, 2000.282p.

especializado para permitir la función de búsqueda y para convertir fuentes no textuales a un medio en el que se pueden realizar búsquedas (Por ejemplo Transcripción de audio a texto)<sup>19</sup>. La recuperación de la información puede estar dirigida a la búsqueda e indexación de información en documentos, la búsqueda y generación de metadatos que describan documentos, o, también, la búsqueda en bases de datos, ya sea a través de internet o una intranet e independientemente del tipo de documento (texto, audio, video, etc.).

El éxito de un sistema de recuperación de información es muy subjetivo, pues depende de la información que necesita un usuario y la tolerancia que el mismo pueda tener a la información innecesaria arrojada por el sistema. Bajo algunas circunstancias la información necesaria puede definirse como toda la información que está en el sistema relacionada con la necesidad del usuario. En otros casos puede definirse como la información suficiente en el sistema para completar una tarea. Por ejemplo, un agente financiero que recomienda una compra de un millón de dólares de otra compañía, necesita estar seguro de que toda la información relevante sobre la compañía ha sido revisada para realizar la recomendación. Por el contrario, un estudiante solamente requiere las suficientes referencias en un documento de investigación para satisfacer las expectativas del profesor, las cuales nunca están completamente incluidas. Un sistema que soporta recuperación razonable, requiere menos características que uno que requiere recuperación comprensiva, pues este último generalmente arroja mucha más información al usuario de la que necesita. Esto hace que sea más difícil para el usuario filtrar la información relevante poco útil. En los sistemas de recuperación de información el término relevante es usado para representar un ítem que contiene información necesaria. En realidad la definición de relevancia no es una clasificación binaria, sino una función continua. Desde el punto de vista del usuario, los términos relevante y necesario son sinónimos, pero desde la

---

<sup>19</sup> KOWALSKI, Gerald y MAYBURY, Mark. Information Storage and Retrieval Systems-Theory and Implementation. 2 ed. S.L: Kluwer Academic Publishers, 2000.282p.

perspectiva del sistema, cierta información puede ser relevante a los parámetros de búsqueda, aunque no sea relevante o necesaria para el usuario (Por ejemplo El usuario ya conocía la información).

Las dos medidas más usadas comúnmente y asociadas con los sistemas de recuperación de información son la precisión y el recuerdo (precisión y recall). Cuando un usuario decide realizar una consulta en un sistema de búsqueda de información sobre un tema en particular, la base de datos se divide lógicamente en cuatro segmentos como se muestra en la figura 10. Los ítems relevantes son aquellos que contienen información que ayuda al usuario a responder su pregunta. Los ítems no relevantes son aquellos ítems que no proporcionan ninguna información útil. Hay dos posibilidades con respecto a cada ítem: puede ser recuperado o no recuperado por la consulta del usuario. La precisión y el recuerdo se definen de la siguiente forma:

$$\textit{precisión} = \frac{\textit{Número de ítems relevantes recuperados}}{\textit{Número total de ítems recuperados}}$$

$$\textit{recuerdo} = \frac{\textit{Número de ítems relevantes recuperados}}{\textit{Número total de ítems relevantes}}$$

Donde número total de ítems relevantes es el número de elementos relevantes en la base de datos. Número total de ítems recuperados es el número de ítems recuperados por la consulta. Número de ítems relevantes recuperados es el número de elementos recuperados que son relevantes a la búsqueda que necesita realizar el usuario. La precisión mide la sobrecarga asociada con una búsqueda particular de un usuario. Si una búsqueda tiene 85% de precisión, significa que el 15% del esfuerzo del usuario se usa en la revisión de elementos no relevantes. El recuerdo mide el grado de efectividad con que el sistema procesa una consulta en

particular para recuperar elementos relevantes que le interesan al usuario. El recuerdo es un parámetro muy útil, pero no es calculable por los sistemas en producción debido al denominador (Si el sistema conociera el número total de elementos relevantes, los hubiera recuperado). Los valores de precisión y recuerdo son proporcionales en inversos. La precisión empieza en 100% y se mantiene ese valor mientras se recuperen los ítems relevantes. El recuerdo empieza en un valor cercano a cero y se incrementa a medida que se recuperan los ítems relevantes hasta que se hayan recuperado todos los ítems relevantes posibles. Cuando se recuperan los N elementos relevantes, solamente se siguen recuperando elementos no relevantes. La precisión se ve afectada por la recuperación de ítems no relevantes, mientras que el recuerdo no se afecta por la recuperación de elementos no relevantes<sup>20</sup>.

Relevantes Recuperados	Relevantes No Recuperados
No relevantes Recuperados	No relevantes No Recuperados

*Figura 10. Clasificación de ítems ante una consulta*

### **2.1.1 Recuperación de información multimedia.**

La recuperación de información multimedia es el proceso de satisfacer la necesidad de información de un usuario por medio de la identificación de texto,

<sup>20</sup> KOWALSKI, Gerald y MAYBURY, Mark. Information Storage and Retrieval Systems-Theory and Implementation. 2 ed. S.L: Kluwer Academic Publishers, 2000.282p.

gráficos, audio (hablado y no hablado), y videos relevantes en una colección de documentos<sup>21</sup>.

### **2.1.2 Objetivos de los sistemas búsqueda y recuperación de información.**

El éxito de un sistema de información depende de la capacidad de minimizar el esfuerzo que un usuario debe hacer para encontrar la información que necesita. Desde la perspectiva del usuario dicho esfuerzo es el tiempo requerido para encontrar la información que necesita, lo cual incluye, entre otros: la generación de la consulta, la ejecución de la consulta, la búsqueda en los resultados obtenidos por la consulta y la lectura de elementos no relevantes entregados por la consulta, por lo que el éxito de un sistema de búsqueda y recuperación de información es subjetivo y depende de la información que se necesita y la paciencia del usuario<sup>22</sup>.

## **2.2 DISEÑO DE SISTEMAS DE RECUPERACIÓN DE INFORMACIÓN BASADOS EN CONTENIDOS**

Los sistemas de búsqueda y recuperación de información se basan en dos tareas fundamentalmente: indexación de la información y búsqueda de la información.

### **2.2.1 Indexación.**

La indexación es el proceso mediante el cual se generan los descriptores de un documento. Usualmente los descriptores han sido texto que contiene información sobre un documento o sobre el contenido del mismo y que al darles una estructura bien definida son llamados metadatos, pero actualmente se usan técnicas de

---

<sup>21</sup> TIAN, Qi. Multimedia Information Retrieval [Online]. San Antonio: University of Texas at San Antonio, 2007. (Citada: 14 mayo 2009) <<http://lyle.smu.edu/~mhd/8337sp09/mir.pdf> >

<sup>22</sup> KOWALSKI, Op. Cit., p. 4.

generación de descriptores, sobre todo para documentos que contienen audio y video, que se basan en un conjunto de características del documento o una parte del mismo y que son llamados firmas.

La indexación de los documentos multimedia es un proceso complejo al cual actualmente se le dedica mucho esfuerzo en investigación destinada a la automatización del proceso. Se reconocen tres técnicas generación de descriptores de acuerdo a la intervención de computadores y humanos en el proceso de indexación<sup>23</sup>:

#### **2.2.1.1 Indexación manual.**

En esta técnica de indexación un ser humano genera todos los descriptores del documento. La subjetividad de la persona que realiza la indexación es un punto en contra para esta técnica.

#### **2.2.1.2 Indexación semiautomática.**

Cuando se usa esta técnica de indexación, un ser humano realiza una parte del proceso de indexación y los equipos de cómputo realizan el procedimiento restante.

#### **2.2.1.3 Indexación automática.**

Este tipo de indexación se realiza sin la interacción del ser humano. Es decir, que está basada totalmente en el análisis del contenido del documento.

---

<sup>23</sup> SAYKOL, Ediz, GUDUKBAY, Ugur y OLUZOY, Osgur. A semiautomatic object extraction tool for querying in multimedia database [Online]. Ankara: Bilkent University, 2001. (Citada: 07 abr 2009). <<http://www.cs.bilkent.edu.tr/~bilmdg/papers/mis01.pdf>>

Cabe decir, que el volumen de información multimedia que se genera diariamente y se distribuye a través de las redes de comunicaciones hace que sea imposible en la práctica la indexación manual de dicha información. Por ello se intentan hacer avances en los métodos de indexación semiautomática y automática.

Además se reconocen dos técnicas de generación de descriptores de acuerdo al momento en el que se realiza la indexación:

#### **2.2.1.4 Indexación en Tiempo Real (Real Time Indexing - RTI).**

Cuando se usa esta técnica, la indexación del documento se realiza durante la reproducción del mismo.

#### **2.2.1.5 Indexación en No Tiempo Real (Not Real Time Indexing - NRTI).**

En esta técnica el documento multimedia se encuentra almacenado y el sistema realiza la generación de descriptores accediendo al mismo en cualquier instante de tiempo.

Antes del surgimiento de la búsqueda y recuperación basada en contenido todos los medios eran marcados con marcas de texto que permitían que los mismos fueran accedidos por medio de búsquedas basadas en texto. Usando descripciones textuales todos los medios se pueden gestionar, pero con el surgimiento de las bases de datos multimedia, las búsquedas tradicionales basadas en texto, sufren de las siguientes limitaciones<sup>24</sup>:

---

<sup>24</sup> WEI, Chia-Hung y LI, Chang-Tsun. Content-Based Multimedia Retrieval. Introduction, Applications, Design of content-based retrieval systems, Feature extraction and representation, Low-level features, High-level features [Online]. United Kingdom: University of Warwick, 2006. (Citada: 10 jun 2009). < <http://encyclopedia.jrank.org/articles/pages/6567/Content-Based-Multimedia-Retrieval.html> >

- El marcado manual requiere de mucho tiempo y es muy difícil de implementar.
- Las marcas manuales fallan al tener en cuenta las diferentes percepciones subjetivas.
- Algunos contenidos son difíciles de describir correctamente usando palabras.
- Dada la alta producción de contenido multimedia, es prácticamente imposible indexar toda la información multimedia de forma manual.

En un intento por resolver estas dificultades, la recuperación basada en contenido emplea la misma información del medio para indexarse, automática o semiautomáticamente, con una mínima intervención humana.

### **2.2.2 BÚSQUEDA.**

La recuperación de información basada en contenido usa la información de los datos multimedia para representar e indexar los datos. En los sistemas típicos de recuperación, los contenidos de los medios en las bases de datos se extraen y describen por vectores de características multidimensionales, también conocidos como descriptores o firmas. Los descriptores del medio constituyen un conjunto de datos de características<sup>25</sup>.

Para diseñar sistemas de recuperación basados en contenido, el diseñador necesita considerar los siguientes cuatro aspectos:

- Representación y extracción de características
- Reducción de las dimensiones de las características
- Indexación
- Especificaciones de las consultas

---

<sup>25</sup> IBID

### 2.2.2.1 Paradigmas de búsqueda de información.

El proceso de búsqueda en un sistema de recuperación de información puede estar regido por uno de los siguientes dos paradigmas<sup>26 27</sup>:

- Query By Example (QBE)
- Query By Keyword (QBK)

En el paradigma QBK una base de datos se llena de palabras claves u otros metadatos y el usuario ingresa en el sistema las palabras claves que él cree que mejor describen lo que está buscando. En el paradigma QBE los videos se caracterizan con una serie de características apropiadas que constituyen una representación digital de un objeto conocida como descriptor o firma. El usuario debe ingresar en el sistema un video similar al que quiere buscar.

Para encontrar los datos deseados, en un sistema de recuperación de información basada en contenido usualmente se hace uso del paradigma Query By Example, es decir que los usuarios envían consultas al sistema de búsqueda y recuperación de información, y luego el sistema representa las consultas con descriptores. Las distancias (Es decir similitudes) entre los descriptores de la consulta y los descriptores del medio en el conjunto de datos de características se computan y se hace un ranking que permite clasificar los resultados de la búsqueda y dar una respuesta a la consulta con los resultados más similares a la consulta realizada por el usuario.

---

<sup>26</sup> LI, Wei y SUN, Maosong. Incorporating Prior knowledge into multi-label boosting for cross-modal image annotation and retrieval. En: Lecture notes in Computer Science. Octubre, 2006, Vol. 4182. ISSN 0302-9743.

<sup>27</sup> LIM, Joo-Hwee y JIN, Jesse. A structured learning framework for content-based image indexing and visual query. En: Multimedia Systems. Abril, 2005, Vol. 10, no. 4. ISSN 0942-4962.

### 2.2.2.2 Modelos de Búsqueda de Información.

La mayor dificultad de los Sistemas de Recuperación de la información está en predecir los documentos que son los más relevantes para el usuario. Dicha predicción puede llevarse a cabo usando algunos los siguientes métodos o modelos de recuperación:

- **Modelo Booleano.** El modelo de recuperación booleano es uno de los métodos más utilizados para la recuperación de información. Se basa en la agrupación de documentos, los cuales están compuestos por conjuntos de términos y en la concepción de las preguntas como expresiones booleanas, de ahí deriva el nombre de *modelo de recuperación booleano*. La principal característica es la consideración de la relevancia como un carácter puramente binario. Dentro del modelo, se presenta el lenguaje de consulta, y el mecanismo de indización utilizando los denominados índices inversos o archivos fantasmas. El modelo booleano es todavía el modelo dominante en los sistemas comerciales de bases de datos de documentos a pesar de sus inherentes restricciones.
- **Modelo Vectorial.** En el modelo vectorial un documento se enmarca dentro de una colección que tiene unas determinadas características, de forma tal que puede considerarse formalmente como un vector que expresa la relación del documento con cada una de sus  $m$  características.

$$D_i \rightarrow \vec{d}_i = (c_{i1}, c_{i2}, \dots, c_{im})$$

Las características suelen concretarse en la ocurrencia de determinadas palabras o términos en el documento, aunque tenerse en cuenta otros aspectos. Es preciso concretar la importancia de cada una de las características en la caracterización del documento.

- **Modelo Probabilístico.** En este modelo de recuperación, el criterio para recuperar un determinado documento o no es el cálculo de la probabilidad de que éste sea relevante para la consulta del usuario. Para ello es preciso determinar las propiedades que definen el conjunto de documentos relevantes. El modelo probabilístico es capaz de calcular el grado de relevancia entre cada documento para una consulta dada. De esta manera permite ordenar los documentos de la colección en orden descendente de probabilidad de relevancia. Para definir la relevancia del documento y el puntaje asignado, se necesita una hipótesis inicial.
- **Modelo de relevancia por realimentación.** Se trata de un método de mejora de las consultas en el cual se han hecho avances en los últimos años. Consiste en reformular la consulta inicial introducida por el usuario en base a documentos que él mismo considere relevantes. De esta forma la consulta ofrece cada vez resultados más precisos y además se recalculan los pesos de los términos relevantes. Para ello deberán llevarse a cabo varios ciclos interactivos de preguntas al usuario.
- **Modelos basados en el lenguaje.** En la actualidad se están en desarrollo modelos basados en el procesamiento del lenguaje natural, en los cuales una base de conocimientos intentaría interpretar documentos textuales y generar listas de descriptores de forma automática. Pero dado que el lenguaje natural es demasiado ambiguo para que el contenido de los documentos sea extraído de forma automática, se han creado lenguajes de representación del conocimiento (lenguajes controlados, taxonomías, tesauros, ontologías, etc.).
- **El modelo de red de inferencia.** En este modelo se hace uso de los modelos probabilísticos basados en redes bayesianas. Se basa en una red en la que se distinguen dos subredes:

**Red de documentos:** red fija de documentos para cada colección formada por dos tipos de nodos que representan los términos de los documentos y los documentos respectivamente. De un nodo de documento salen arcos hacia los nodos de los términos que han sido indexados.

**Red de consulta:** red que se crea cuando el usuario consulta al sistema y contiene nodos de consulta y nodos de términos, de manera que de un nodo de término salen arcos hacia los nodos de consulta correspondientes.

Una vez que se han estimado las probabilidades, la inferencia se hace instanciando cada documento sucesivamente y calculando la probabilidad de que la consulta sea satisfecha dado el documento que ha sido observado. Una vez que todas las propagaciones se han realizado, se genera la ordenación de documentos correspondiente.

- **Modelos de recuperación basados en lógica difusa.** El principal defecto del modelo probabilístico es la necesidad de una estimación inicial de los pesos de los términos para estimar el grado de relevancia de un documento. En el modelo de lógica difusa los autores no asignan los grados de pertenencia de los documentos a los términos. Además, la aplicación de modelos difusos es idónea para solucionar los problemas de falta de completitud e imprecisión a la hora de indexar un documento.

### 3 METADATOS

El término metadato ha sido utilizado por mucho tiempo como un término autodescriptivo, pero su significado puede tener varias interpretaciones dependiendo del dominio de conocimiento en el que se aplique. Partiendo de una perspectiva etimológica el término metadato se define como datos acerca de datos, por lo tanto se debe notar que los metadatos son datos representacionales de otros datos y están destinados a ordenar y describir la información contenida en un documento entendido como un objeto, de tal forma que se erigen como reveladores tanto de la descripción formal, como del análisis de contenido, en aras de mejorar el acceso a esos objetos de información. Son estructuras de organización de la información, legibles por los computadores, cuya finalidad es hacer útiles los datos, de distintas formas, según sean las necesidades concretas de cada servicio de información digital y según la aplicación que se les otorgue<sup>28</sup>.

Las ontologías, además, permiten dar a los metadatos un significado específico dentro de un dominio de conocimiento, por lo cual el uso de ontologías y metadatos se espera que permitan obtener unos mejores resultados en las tareas de recuperación de información realizadas por los usuarios<sup>29</sup>.

Algunos usos que se han dado tradicionalmente a los metadatos incluyen:

- Identificación y descripción de la información
- Búsqueda y recuperación de la información

---

<sup>28</sup> MÉNDEZ, Eva. Metadatos y recuperación de información. Estándares, problemas y aplicabilidad en bibliotecas digitales. S.I: Ediciones Trea, 2002. 429 p.

<sup>29</sup> IBID, 429 p.

- Ubicación de los documentos

Pero actualmente han empezado tener otras aplicaciones como las que se mencionan a continuación:

- Auditoría y propiedad intelectual
- Formas de acceso
- Actualización de la información
- Preservación y conservación
- Limitación del uso
- Valoración del contenido
- Visibilidad de la información
- Accesibilidad de contenidos

El brokering es otra utilidad destacada de los metadatos<sup>30</sup>. El brokering es el proceso de mediación entre los usuarios y los proveedores de información, que permite reducir el volumen de información y datos que deben tratarse.

### **3.1 TIPOS DE METADATOS**

Los metadatos pueden clasificarse dependiendo de varias características, entre ellas <sup>[21]</sup>:

- El dominio de aplicación. Algunos metadatos pueden estar específicamente destinados a la representación de documentos geográficos, o de museos, o pueden ser de propósito general.
- El Ciclo vital del documento descrito. Se distinguen, entre otros, los metadatos que se usan durante el ingreso de un documento al sistema de recuperación de información, los metadatos para la gestión del documento

---

<sup>30</sup> MÉNDEZ, Eva. Metadatos y recuperación de información. Estándares, problemas y aplicabilidad en bibliotecas digitales. S.l: Ediciones Trea, 2002. 429 p.

luego de estar en el sistema (Por ejemplo Por movimientos o actualizaciones), y los metadatos descriptivos.

- La dependencia del contenido del documento. Pueden existir metadatos que no se refieran al contenido del documento si no a características como la fecha de creación, la ubicación, etc. Mientras que hay otros metadatos que describen el contenido del documento.
- Los atributos que describen del documento

La creación de los metadatos ha sido usualmente realizada por profesionales o por los mismos autores del documento. En las bibliotecas, la creación de los metadatos ha sido tradicionalmente una tarea de profesionales que trabajan con algunas reglas y vocabularios detallados y complejos. El principal problema que tiene esta forma de crear los metadatos es la escalabilidad dada la gran cantidad de datos que se generan diariamente, Una segunda forma de crear los metadatos, es que sean generados directamente por los autores del documento, lo cual también tiene algunas desventajas, pues frecuentemente se producen descripciones inadecuadas. Una tercera forma es aquella en la que los usuarios de los documentos crean metadatos para su propio uso y para compartirlos con los demás usuarios. Aunque esta última forma de crear metadatos puede llevar a obtener resultados poco confiables, día tras día es una opción más explorada que ha sido llamada folcsonomía<sup>31</sup>.

Una Folcsonomía es una indexación social, es decir, la clasificación colaborativa por medio de etiquetas simples en un espacio de nombres llano, sin jerarquías ni relaciones de parentesco predeterminadas. Se trata de una práctica que se produce en entornos de software social cuyos mejores exponentes son los sitios

---

<sup>31</sup> MATHES, Adam. En Cooperative Classification and Communication Through Shared Metadata [Online]. Urbana: University of Illinois at Urbana-Champaign, 2004. (Citada: 08 julio 2009)  
<<http://www.adammathes.com/academic/computer-mediated-communication/folksonomies.html>>

compartidos como del.icio.us (enlaces favoritos) o Flickr (fotos)<sup>32</sup>. Las folcsonomías surgen cuando varios usuarios colaboran en la descripción de un mismo material informativo.

Por otra parte, es posible realizar una indexación más especializada cuando se usa un lenguaje específico, bien determinado y estructurado, y un dominio específico de conocimiento. El término ontología hace referencia a la formulación de un exhaustivo y riguroso esquema conceptual dentro de uno o varios dominios dados; con la finalidad de facilitar la comunicación y la compartición de la información entre diferentes sistemas<sup>33</sup>. Cuando se hace uso de una ontología, el procedimiento de generación de metadatos es más complicado y el personal debe estar muy bien capacitado para usar los términos de la ontología.

### **3.2 ALMACENAMIENTO DE METADATOS**

Hay dos posibilidades para almacenar metadatos: depositarlos internamente, en el mismo documento que los datos, o depositarlos externamente, en su mismo recurso. Inicialmente, los metadatos se almacenaban internamente para facilitar la administración. Hoy, por lo general, se considera mejor opción la localización externa porque hace posible la concentración de metadatos para optimizar operaciones de búsqueda. MPEG-7 hace uso de metadatos almacenados internamente, mientras que Dublin Core propone un almacenamiento externo de los metadatos.

---

<sup>32</sup> MATHES, Adam. El Cooperative Classification and Communication Through Shared Metadata [Online]. Urbana: University of Illinois at Urbana-Champaign, 2004. (Citada: 08 julio 2009) <<http://www.adammathes.com/academic/computer-mediated-communication/folksonomies.html>>

<sup>33</sup> BIEZUNSKI, Michel. A matter of prospectives. Talking about talking about topic maps [Online]. Montreal: Extreme Markup Languages, 2005. (Citada: 10 mar 2009). <<http://antonieta.philo.unibo.it/IUcorso2007-08/materiali/EML2005Biezunski01.pdf>>

### **3.2.1 El estándar MPEG 7.**

MPEG-7 es un estándar para la descripción de características de contenidos multimedia. Proporciona un conjunto de descriptores basados en catálogo (Por ejemplo título, creador, derechos), semántica (información sobre objetos y eventos que aparecen en el documento, Por ejemplo “Marlon Brando fumando”) y estructura (Por ejemplo el histograma de color) que estandarizan la forma de describir el contenido audiovisual. Por lo tanto, MPEG-7 ofrece un mecanismo para describir información audiovisual sin importar el uso que se le pueda dar posteriormente<sup>34</sup>.

Este estándar se usa para que sea posible desarrollar sistemas capaces de indexar grandes bases de material audiovisual (imágenes fijas, gráficos, modelos tridimensionales, audio, discursos, vídeo e información sobre cómo esos elementos están combinados en una presentación multimedia) y buscar en estas bases de materiales manual o automáticamente<sup>35</sup>.

### **3.2.2 Dublin core metadata initiative.**

Dublin Core es un modelo de metadatos de propósito general elaborado y auspiciado por la DCMI (Dublin Core Metadata Initiative), una organización dedicada a fomentar la adopción extensa de los estándares interoperables de los metadatos y a promover el desarrollo de los vocabularios especializados de metadatos para describir recursos para permitir sistemas más inteligentes del descubrimiento del recurso. Las implementaciones de Dublin Core usan

---

<sup>34</sup> VIVANCOS, Pedro. Descripción de contenidos multimedia: introducción al estándar MPEG-7 [Online]. Murcia: Ilustre Colegio de Ingenieros en Informática en la región de Murcia, 2004. (Citada: 13 mayo 2009) <[http://www.cii-murcia.es/informas/jul05/articulos/EI\\_estandar\\_MPEG-7.php](http://www.cii-murcia.es/informas/jul05/articulos/EI_estandar_MPEG-7.php)>

<sup>35</sup> ATARASHI, Ray, KISHIGAMI, Junichi y SUGIMOTO, Shigeo. Metadata and new challenges. En: 2003 SYMPOSIUM ON APPLICATIONS AND THE INTERNET WORKSHOPS (1:2003:). Proceedings of the 2003 Symposium on Applications and the Internet Workshops SAINT'03 Workshops. Washington: IEEE Computer Society, p. 395-398.

generalmente XML y se basan en el Resource Description Framework. Dublin Core se define por ISO en su norma ISO 15836 del año 2003, y la norma NISO Z39.85-2007<sup>36</sup>.

Cabe aclarar que existen otros modelos de metadatos de propósito general y de propósito específico.

---

<sup>36</sup> ATARASHI, Ray, KISHIGAMI, Junichi y SUGIMOTO, Shigeo. Metadata and new challenges. En: 2003 SYMPOSIUM ON APPLICATIONS AND THE INTERNET WORKSHOPS (1:2003:). Proceedings of the 2003 Symposium on Applications and the Internet Workshops SAINT'03 Workshops. Washington: IEEE Computer Society, p. 395-398.

## 4 SISTEMAS DE RECOMENDACIÓN

El objetivo de un sistema de recomendación es sugerir ítems o productos que pueden ser interesantes para los usuarios de un sistema. Por ejemplo, las sugerencias de productos en Amazon o de películas en Netflix son algunos de los sistemas de recomendación más conocidos en el mundo. El diseño de los sistemas de recomendación depende mucho del dominio en particular al que se apliquen y de las características de los datos disponibles para ser analizados. Por ejemplo los usuarios de Netflix y Movielens dan calificaciones entre 1 y 5 a las películas que se encuentran disponibles para ser calificadas. Adicionalmente, el sistema puede tener acceso a información específica de cada usuario del sistema o de cada ítem del mismo<sup>37</sup>.

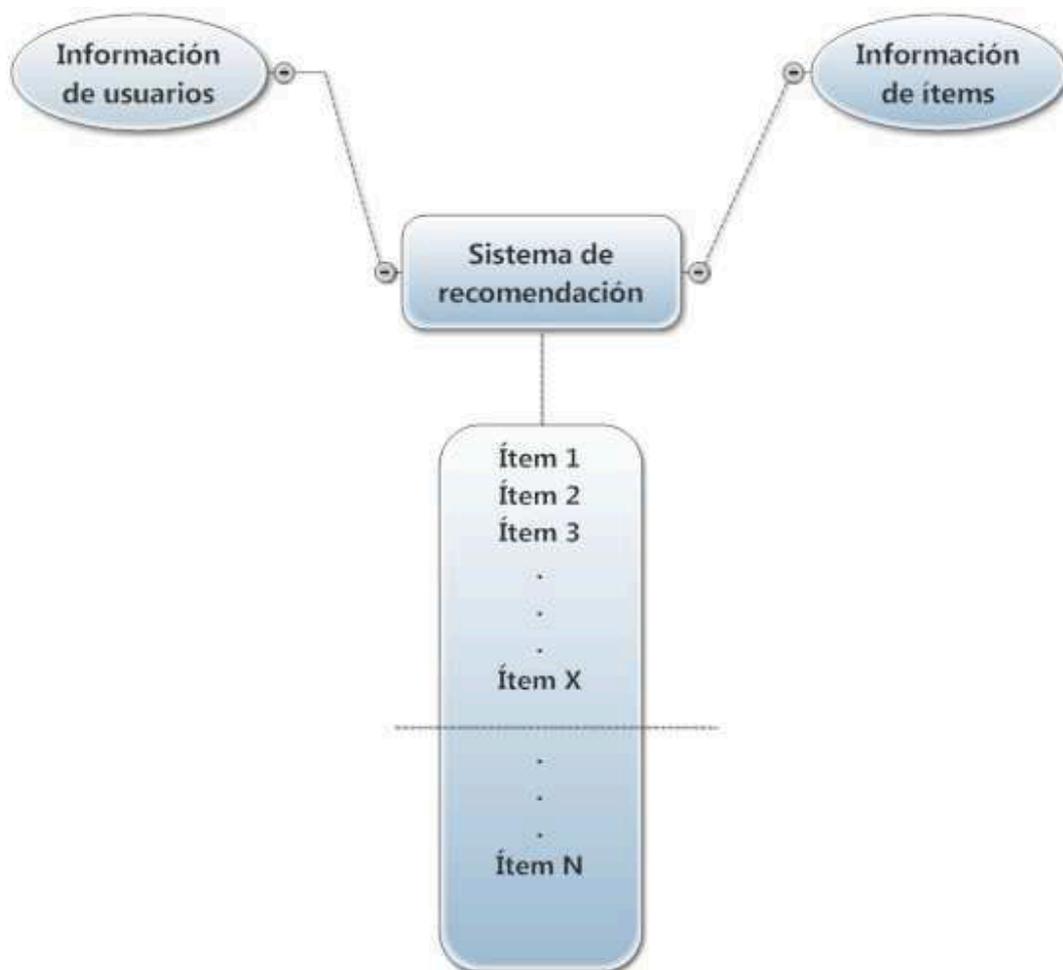
La tarea de recomendación trata de predecir la calificación o rating que un usuario entregará a un ítem que no ha calificado y, de esa forma, como se muestra en la figura 11, los ítems que obtienen una mayor calificación en el proceso de predicción se presentan al usuario como recomendaciones. El usuario al que se le entregan las recomendaciones o para el cual se realiza el proceso de predicción en un momento dado es llamado usuario activo<sup>38</sup>. La entrada en un sistema de recomendación depende del tipo de sistema y los algoritmos que lo conforman.

---

<sup>37</sup> MELVILLE, Prem y SINDHWANI, Vikas. Recommender Systems [Online]. New York: IBM T.J. Watson Research Center, 2010. (Citada 8 septiembre de 2009) <  
<http://people.cs.uchicago.edu/~vikass/recommender.pdf>>

<sup>38</sup> IBID

Generalmente las entradas son votaciones o calificaciones, datos demográficos, datos de contenido o datos contextuales<sup>39</sup>.



*Figura 11. Componentes básicos de un sistema de recomendación personalizado*

La arquitectura de un sistema de recomendación está conformada generalmente por un proceso que se ejecuta fuera de línea o en batch y un proceso que se ejecuta en tiempo real. Generalmente intentan moverse tantas operaciones como

---

<sup>39</sup> BHADANI, Sameer. Recommender Systems Algorithms. Toronto, 2008, 47 p. Trabajo de grado (Bachelor of Applied Science), University of Toronto. Department of Mechanical and Industrial Engineering.

sean posibles al proceso que se ejecuta fuera de línea con el fin de que el proceso que se ejecuta en tiempo real sea lo más rápido posible, pues el primero tiene que encargarse de realizar una gran cantidad de cálculos y requiere mucha memoria y procesamiento. El segundo, por el contrario, debe recibir las solicitudes de los usuarios y debe responder lo más rápido posible.

Los mecanismos usados para la recomendación de contenido pueden categorizarse en dos formas: Basados en filtros por contenido o basados en filtros colaborativos. Los métodos basados en contenido intentan relacionar el perfil de un usuario o una consulta del mismo sobre la información recuperada del contenido y no en base a la opinión o sugerencias de los usuarios. Este método es bastante usado en el procesamiento de documentos de texto usando modelos de búsqueda booleanos, vectoriales, probabilísticos, y de conjuntos difusos, entre otros. Pero para los filtros basados en contenido es difícil organizar los perfiles de usuario, porque los usuarios, especialmente los principiantes, no saben expresar con exactitud lo que buscan. Los filtros colaborativos, por el contrario, realizan recomendaciones basándose en las opiniones de los usuarios y no basados en el contenido de los documentos. Dado que un filtro completamente colaborativo se basa en las opiniones de los usuarios sobre los elementos para hacer las recomendaciones, el sistema puede no estar en la capacidad de hacer recomendaciones de un elemento si no existe ninguna opinión previa sobre el mismo o si el usuario es muy diferente a todos los demás<sup>40 41 42 43</sup>.

---

<sup>40</sup> KIM, Taehwan, JEON, Hochul y CHOI, Joongmin. Personalized Information Retrieval Using the User History. En: International Conference on Multimedia and Ubiquitous Engineering (MUE2008) (2:2008:Busan). Proceedings of the 2<sup>nd</sup> International Conference on Multimedia and Ubiquitous Engineering (MUE2008). Washington: IEEE Computer Society, p. 229-232.

<sup>41</sup> LIANG, Ting-Peng, LAI, Hung-Jen y KU, Yi-Cheng. Personalized Content Recommendation and User Satisfaction. Theoretical Synthesis and Empirical Findings. En: Journal of Management on Information Systems. Enero, 2007. Vol. 23, no. 3, p. 45-70.

<sup>42</sup> BURKE, Robin. Hybrid Recommender Systems: Survey and Experiments. En: User Modeling and User Adapted Interaction. Noviembre, 2002. Vol. 12, no 4, p. 331-370.

En la fase más importante de un algoritmo de filtrado colaborativo, se identifican los usuarios que tienen gustos parecidos. Cuando se usan algoritmos de filtrado colaborativo y algoritmos de filtrado por contenido se conforma un sistema de filtrado híbrido. El sistema propuesto en este documento es un sistema de filtrado híbrido.

Se han estudiado dos formas de hacer filtrado colaborativo: Basado en memoria y basado en modelos. El primer tipo tiene en cuenta toda la información que se encuentra en el conjunto de datos fuente, mientras que el segundo genera una representación más pequeña que refleja las preferencias de los usuarios a partir de toda la información fuente de los usuarios. Aunque la aproximación basada en memoria más simple que la aproximación basada en modelo, tiene algunas desventajas. Principalmente que requiere una capacidad y tiempo de computación que crece de acuerdo con el número de usuarios e ítems causando un problema de escalabilidad. La aproximación basada en modelo trata de resolver algunos de los problemas de la aproximación basada en memoria al confrontar un modelo con cada usuario y no con todos los usuarios, lo cual disminuye la necesidad de tiempo y capacidad de cálculo. Aun así, la fase de construcción del modelo es muy costosa y es más difícil de adaptar cuando las preferencias de los usuarios cambian muy rápido. En el diseño propuesto se usa la aproximación basada en memoria<sup>44</sup>.

---

<sup>43</sup> O'DONNOVAN, John y SMYTH, Barry. Trust in Recommender Systems. En: International Conference on Intelligent User Interface (10:2005:San Diego). Proceedings of the 10th International Conference on Intelligent User Interface. New York: ACM Press, p. 167-174.

<sup>44</sup>MORTENSEN, Magnus. Design and Evaluation of a Recommender System. Tromsø, 2007, 109 p. Trabajo de grado (Master in Computer Science), University of Tromsø. Department of Computer Science.



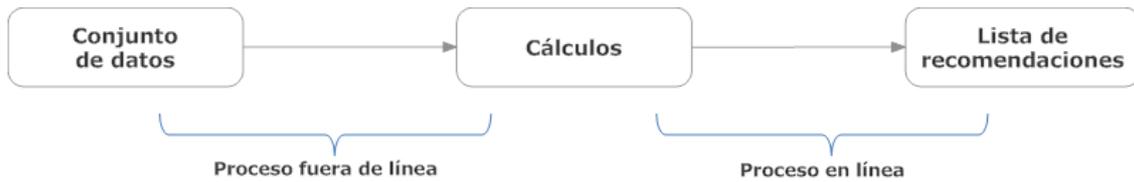


Figura 12. Operación de un sistema de recomendación

Además existen dos métodos para recolectar información de las preferencias del usuario: implícito y explícito. El método explícito le solicita al usuario que exprese sus preferencias o elecciones y usa esta información para construir el perfil del usuario y hacerle recomendaciones. Por ejemplo se le solicita al televidente que ingrese el nivel de interés que tuvo en un programa luego de haberlo visto. Aunque este método captura las preferencias del usuario de forma inmediata, el usuario puede resistirse a proporcionar dicha información por cuestiones de privacidad. El método implícito por otra parte, como se muestra en la figura 13, monitorea el sistema para obtener información sobre las preferencias del usuario y realizar las recomendaciones de acuerdo con su perfil<sup>45</sup>.

La mayor dificultad que encuentra a la hora de implementar sistemas de recomendación radica en que diferentes usuarios tienen diferentes opiniones sobre los programas de televisión que prefieren ver. Aun así, es necesario que dichos sistemas cumplan con las siguientes características:

- Calidad: La mayor parte de los programas que se recomiendan a un usuario deberían ser programas que éste efectivamente quiera ver, o al menos que le resulten interesantes.
- 

<sup>45</sup> LIANG, Ting-Peng, LAI, Hung-Jen y KU, Yi-Cheng. Personalized Content Recommendation and User Satisfaction. Theoretical Synthesis and Empirical Findings. En: Journal of Management on Information Systems. Enero, 2007. Vol. 23, no. 3, p. 45-70.

- **Transparencia:** Debe ser claro para el usuario porqué se le recomienda un programa en particular, de forma que si se le recomienda un programa que a él no le interesa, al menos pueda saber por qué se le recomendó.
- **Realimentación del usuario:** Si a un usuario se le recomienda un programa que no le gusta, debe existir un mecanismo que le permita al usuario comunicárselo al sistema de recomendación de forma que no se le vuelva a recomendar.
- **Adaptación:** Las recomendaciones que se dan al usuario, deben monitorearse con el fin de detectar cambios en sus comportamientos y preferencias de programas.

Otro factor de éxito en un sistema de recomendación es la no intrusión, que se materializa con la capacidad del sistema de detectar los gustos y preferencias del usuario sin tener que solicitarle información explícitamente.

#### **4.1 SISTEMAS DE RECOMENDACIÓN PARA TELEVISIÓN**

Se han construido muchos sistemas de recomendación en los últimos años, pero la minoría de ellos han sido desarrollados teniendo como su fuente de información objetivo la Televisión, la cual presenta retos particulares debido a que el comportamiento de un televidente se diferencia en muchos aspectos del comportamiento, por ejemplo, del usuario de un computador o un dispositivo móvil<sup>46</sup>. Aun así se debe reconocer que con el advenimiento de la televisión interactiva, estos han empezado a tenerse en cuenta por la comunidad investigativa. Uno de los sistemas comerciales de recomendación más exitoso es

---

<sup>46</sup> GUTTA, Srinivas. Tv content recommender system. En: National Conference on Artificial Intelligence y Twelfth Conference on Innovative Applications of Artificial Intelligence (7:2000:Austin). Proceedings of the Seventeenth National Conference on Artificial Intelligence y Twelfth Conference on Innovative Applications of Artificial Intelligence. Boston: The MIT Press, p.1121-1122.

Tivo, pero existen algunas anécdotas con respecto a este sistema que muestran que aún se deben realizar mejoras para poder satisfacer plenamente las necesidades de los usuarios <sup>[12]</sup>. Se requiere, por lo tanto, avanzar en los estudios sobre las necesidades de los usuarios que permitan tener un mejor entendimiento de sus comportamientos y deseos. El estudio de recomendaciones en la vida diaria podría encontrar hábitos interesantes, opiniones y puntos de vista que puedan aplicarse a las recomendaciones en televisión<sup>47</sup>.

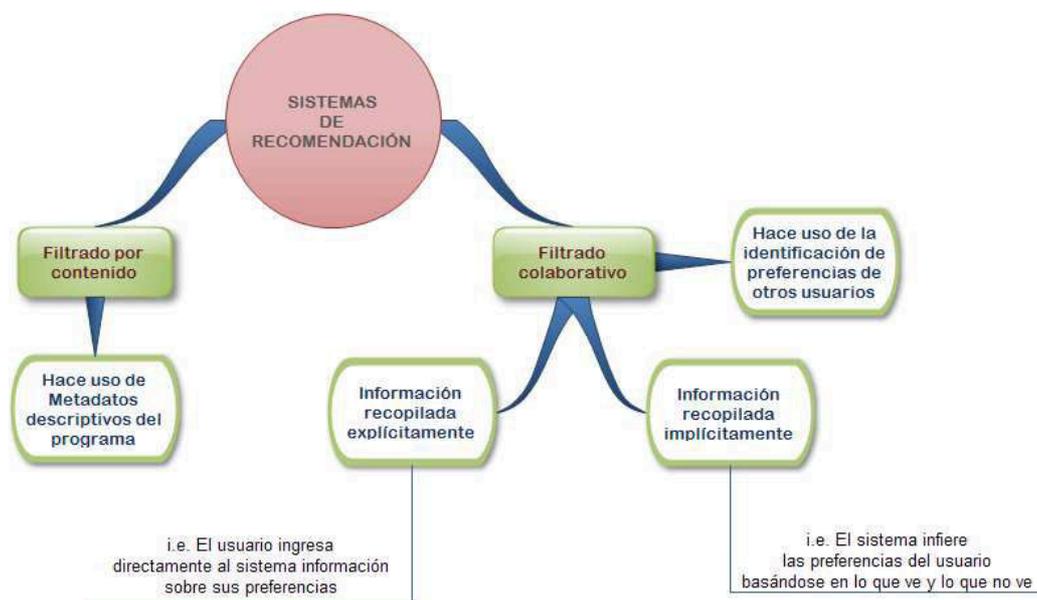


Figura 13. Esquemas de filtrado para sistemas de recomendación

En 1998, Das y Horst<sup>48</sup> propusieron uno de los primeros sistemas de recomendación para la televisión, el cual empleaba técnicas explícitas para

<sup>47</sup> BERNHAUPT, Regina et al. An Ethnographic Study on Recommendations in the Living Room. Implications for the Design of iTV Recommender Systems. En: Lectures notes in Computer Science. Julio, 2008. Vol. 5066.

<sup>48</sup> D. Das and H. Horst: 1998, 'Recommender Systems for TV'. Technical Report WS-98-08 Recommender System, Papers from the 1998 Workshop, Madison, WI. Menlo Park, CA: AAAI Press, pp. 35-36.

generar las recomendaciones. Esta técnica requiere que cada usuario tome la iniciativa y explícitamente especifique sus intereses con el fin de obtener muy buenas recomendaciones, es decir recomendaciones que satisfagan sus expectativas. Este mecanismo tiene la ventaja de que es fácil de implementar, pero molesta a los usuarios que quieren tener una mínima interacción con el sistema de recomendación. Además el sistema propuesto por ellos es estático, por lo que no permite la evolución de los perfiles de usuario con el paso del tiempo.

Bellekens y otros<sup>49</sup>, por su parte, muestran el diseño de un marco de trabajo para acceso personalizado a contenidos de televisión valiéndose de una integración que complementa las ventajas de los espacios virtuales (Por ejemplo la Web), móviles y físicos (Por ejemplo los hogares). Esta integración presenta una ventaja en términos de la identificación del contexto por la característica “personal” de los espacios virtuales y móviles, en los cuales el sistema puede conocer más fácilmente qué usuario lo está usando, en comparación con la televisión, que se considera un ambiente compartido<sup>50</sup>. El ambiente de los computadores y dispositivos móviles son útiles para ayudar a identificar información de contexto como el lenguaje, la ubicación geográfica y la zona horaria. La información contextual es de gran importancia para entender los intereses de los televidentes en diferentes situaciones, grupos sociales y edades. Cada usuario puede tener diferentes intereses en la mañana, el fin de semana, cuando está solo o cuando está viendo televisión con un cierto grupo de amigos. El vocabulario usado está definido basándose en ontologías, esquemas y estándares ya definidos, como: OWL-Time, RDF, TV-Any Time y MPEG7.

---

<sup>49</sup> BELLEKENS, Pieter et al. Sensee framework for personalized access to TV content [Online]. Amsterdam: Departamento de Ciencias de la Computación Universidad de Amsterdam, 2007. (Citada: 17 mayo 2009) <<http://www.cs.vu.nl/~pmika/swc-2007/SenSee.pdf>>

<sup>50</sup> Comisión Nacional de Televisión – CNTV. La Gran Encuesta de la Televisión en Colombia. Septiembre, 2008.

Hsu<sup>51</sup> propone un mecanismo de recomendación híbrido (Es decir hace uso de filtros de contenido y filtros colaborativos) basado en propiedades de usuario, como actividades, intereses, estados de ánimo, experiencias e información demográfica. En este sistema el punto de inicio se encuentra en un formulario de registro cuya finalidad es recolectar datos demográficos, de tendencias de estilo de vida y preferencias de programas de televisión del usuario. El sistema propuesto comprende cuatro módulos:

- Módulo de estereotipos de usuario, perfiles de usuario y perfiles de grupo: Contiene información básica del usuario sobre demografía, estilo de vida y preferencias de programas de televisión. Teniendo en cuenta esta información se puede realizar un análisis que permita crear o asociar el televidente a un perfil grupal que servirá finalmente para recomendar programas a otros usuarios con los que comparta el mismo perfil de grupo. En este caso como se mencionaba inicialmente la idea final es realizar recomendaciones a un televidente basándose en los gustos de otros televidentes.
- Módulo de comunidades televidentes: Es el módulo en el que se realiza el filtro colaborativo para la recomendación.
- Módulo de metadatos de programas: Este módulo se encarga de almacenar los atributos del programa usando las categorías definidas por la Comisión Nacional de Comunicaciones (National Communication Commission - NCC) de Taiwán. Se hace uso en este caso de una red neuronal artificial para relacionar los perfiles de grupo con los metadatos del programa.
- Módulo de contexto del televidente: Almacena los comportamientos del televidente ante diferentes estados de ánimo haciendo uso de botones en el control remoto que sirven para que el usuario indique su estado de ánimo

---

<sup>51</sup> . HSU, Shang et al. AIMED- A Personalized TV Recommendation System. En: Lecture Notes in Computer Sciences. Junio, 2007. Vol. 4471.

actual. Se hace uso de una red neuronal para relacionar los diferentes estados de ánimo con diferentes categorías de programas.

Por otra parte Martens y Pessemier<sup>52</sup> presentan un sistema de recomendación basado en metadatos del estándar TV-anytime para construir los perfiles de usuario y, haciendo un cálculo de probabilidades que relaciona los términos que describen un programa con el perfil del usuario, da un ranking determinado a los programas. Esta propuesta solamente usa el mecanismo de filtrado por contenido.

Silva y otros<sup>53</sup> han propuesto una arquitectura para recomendación de contenidos teniendo en cuenta el contexto y el usuario, pero no describen un mecanismo de recomendación sino simplemente el proceso que se sigue al usar dicha arquitectura. Cesar y Chporianopulos<sup>54</sup> realizaron algunos de estudios sobre un motor de recomendación que usa un clasificador bayesiano y un árbol de decisión para producir recomendaciones implícitas. El sistema de recomendación implícito genera perfiles basados en el historial de programas vistos por el usuario. Se usan dos métodos implícitos: uno basado en métodos bayesianos (modelo bayesiano de dos clases) y un árbol de decisión. Además hace uso de un sistema de recomendación explícito que permite que el usuario ingrese sus preferencias directamente en el sistema mediante una interface de usuario. Los resultados de los sistemas de recomendación implícitos y el explícito pueden ser muy distintos y

---

<sup>52</sup> DE PESSEMIER, Toon y MARTENS, Luc. A profile based recommendation system for TV-anytime annotated content. En: FirW PhD Symposium (8:2008:Gent). Proceedings of the, 8th FirW PhD Symposium. Gent: University of Gent, 4p.

<sup>53</sup> SILVA, Fabio, ALVES, Luiz, BRESSAN, Graca. Personal TVware: A Proposal of Architecture to Support the Context-aware Personalized Recommendation of TV Programs [Online]. Leuven: Catholic University of Leuven, 2009. (Citada: 20 noviembre 2009) <  
[http://soc.kuleuven.be/com/mediac/euroitv2009/docs/adjunct\\_proceedings/posters/SANTOS,%20FABIO,%20et%20al.%20-%20Posters.pdf](http://soc.kuleuven.be/com/mediac/euroitv2009/docs/adjunct_proceedings/posters/SANTOS,%20FABIO,%20et%20al.%20-%20Posters.pdf) >

<sup>54</sup> CESAR, Pablo y CHPORIANOPULOS, Konstantinos. The Evolution of TV Systems, Content, and Users Toward Interactivity. En: Foundations and Trends in Human-Computer Interaction. Marzo, 2009. Vol. 2, no 4, p. 279-374.

por lo tanto se fusionan sus resultados usando una red neuronal que crea un conjunto único y mejorado de recomendaciones.

En 2009 Clark y Uchyigit<sup>55</sup> presentaron un sistema de recomendación que usa dos agentes: uno encargado de la interacción del usuario con el sistema y otro encargado de las recomendaciones propiamente dichas basándose en unos perfiles muy sencillos en los que se asocia un usuario con las categorías de programas de televisión que él prefiere (Por ejemplo comedia, drama, acción, etc.). Para determinar la mejor recomendación se hace uso de un algoritmo que asigna probabilidades a cada palabra existente en la descripción del programa y que corresponda con las palabras asociadas a cada categoría de programas, es decir, que de acuerdo con las palabras en la descripción del programa, se determina a qué categoría pertenece. Por otra parte se usa un clasificador bayesiano ingenuo (Naive Bayes Classifier) para determinar la probabilidad de que un programa dado pertenezca al conjunto de programas que le gustan al usuario en cualquier categoría dados los valores de las características de la descripción del programa.

Por otra parte, Akkermans y otros<sup>56</sup> crearon una EPG llamada iFanzzy que se concentra en el uso de ontologías para personalizar la interacción del usuario con los contenidos mediante el uso de filtros que se encargan de buscar y recuperar contenido televisivo de acuerdo con los gustos y preferencias del usuario, sus características y el contexto de la búsqueda. Su característica principal es el uso de tres filtros: filtro de canales, filtro de estereotipos y filtros colaborativos; y la traducción de las clasificaciones provistas por el estándar TV-anytime en ontologías OWL.

---

<sup>55</sup> UCHYIGIT, Gulden y CLARK, Keith. Agents that Learn to give Personalized TV Program recommendations [Online]. Londres: Department of Computing Imperial College of Science, Technology and Medicine, 2002. (Citada: 20 septiembre 2009) <<http://www.aaai.org/Papers/Symposia/Fall/2002/FS-02-04/FS02-04-009.pdf>>

<sup>56</sup> AKKERMANS, Paul, AROYO, Lora y BELLEKENS, Pieter. ifanzzy: Personalised filtering using semantically enriched tv-anytime content [Online]. Eindhoven: Eindhoven University of Technology, 2005. (Citada: 19 mayo 2009) <<http://kmi.open.ac.uk/events/eswc06/demo-papers/FD36-Lora.pdf>>

Sullivan, Smyth y McDonald<sup>57</sup> presentaron un enfoque de recomendación basado en las técnicas de filtrado de contenido y razonamiento basado en casos (cases-based reasoning - CBR). CBR es un subconjunto del filtrado basado en contenido que se basa en las recomendaciones exitosas hechas anteriormente, específicamente haciendo uso de minería de reglas de asociación para determinar la similitud entre programas a partir de los perfiles de usuario y luego usar el conocimiento de la similitud para llegar a una técnica de recomendación. Las reglas de asociación usadas son de la forma  $A \rightarrow B$ , donde A y B son conjuntos de programas. La confianza de cada regla está determinada por el porcentaje de transacciones que contienen B dado A. Basados en este tipo de reglas y probabilidades el sistema adquiere conocimientos directos (Es decir del tipo  $A \rightarrow B$ ) y conocimientos indirectos dados por la concatenación de reglas y la multiplicación de sus probabilidades en reglas del tipo  $[(A \rightarrow B) \wedge (B \rightarrow C)] \rightarrow A \rightarrow C$ , donde si se tiene que  $A \rightarrow B$  con una probabilidad del 70% y  $B \rightarrow C$  con una probabilidad del 50%, entonces se concluye que  $A \rightarrow C$  con una probabilidad del 35%.

Gutta<sup>58</sup> propuso un sistema de recomendación que busca programas de televisión basado en los gustos del usuario mediante técnicas de personalización implícita, combinando dos herramientas para asistir a los usuarios:

- Motores de búsqueda y visualización de información
- Sistemas de recomendación

---

<sup>57</sup> Sullivan, D., Smyth, B., McDonald, K., Smeaton, A. Interactive Television Personalization: from guides to programs en Personalized Digital Television. Netherland, 2004, 73-91.

<sup>58</sup> GUTTA, Srinivas. .. Tv content recommender system. En: National Conference on Artificial Intelligence y Twelfth Conference on Innovative Applications of Artificial Intelligence (7:2000:Austin). Proceedings of the Seventeenth National Conference on Artificial Intelligence y Twelfth Conference on Innovative Applications of Artificial Intelligence. Boston: The MIT Press, p.1121-1122.

Para ello se vale del desarrollo de una aplicación en la que el front – end es una EPG inteligente que permite a los usuarios buscar y explorar en una base de datos de programas de televisión. Esta EPG es llamada inteligente porque mantiene un perfil adaptativo del usuario y hace recomendaciones de programas de acuerdo con el perfil. La aplicación puede dividirse en tres partes: un ambiente de búsqueda que proporciona las herramientas para que el usuario formule la búsqueda, el ambiente de descripción que se encarga de presentar visualmente los resultados de la búsqueda y la visualización de los resultados en un túnel compuesto de anillos.

## 5 SISTEMA DE RECOMENDACIÓN PROPUESTO

Para encontrar los ítems de contenido que serán recomendados a un usuario en particular, los sistemas de recomendación intentan predecir qué tan llamativo será un ítem para el usuario. El modelo de sistemas de recomendación tradicional, que se toma como base de comparación, hace uso del comportamiento histórico del usuario para predecir qué ítems le resultarán más atractivos del conjunto total de ítems disponibles. En la figura 14 se muestran los componentes del sistema.  $\{ I \}$  es el conjunto total de ítems disponibles,  $\{ I_p \}$  es el conjunto ítems disponibles con sus predicciones respectivas para el usuario activo,  $s$  es la mínima predicción para la cual se considera que un ítem resultará relevante para el usuario y se usa para obtener  $\{ I_R \}$  que es el subconjunto de ítems que pueden ser recomendados. Generalmente se define un número  $n$  de ítems a recomendar y un número  $s$  como el límite mínimo de predicción a partir del cual se puede considerar un ítem como prospecto de recomendación, por lo que del conjunto  $\{ I_R \}$  se deben obtener los  $n$  ítems con mejor predicción para realizar la recomendación al usuario.

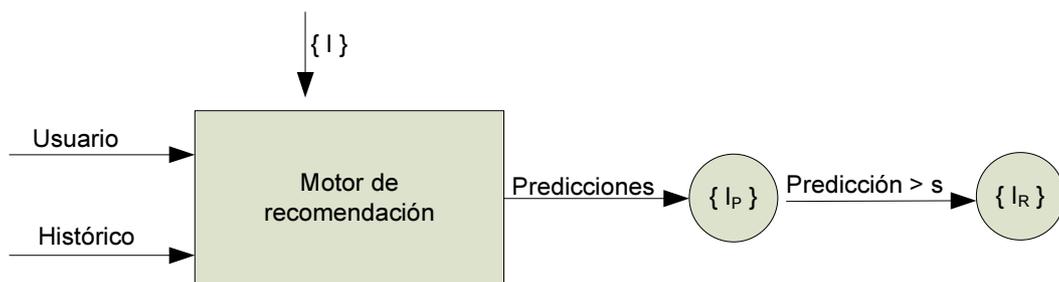


Figura 14 – Componentes de un Sistema de Recomendación

Como puede verse, el motor de recomendación tiene la mayor carga de trabajo y responsabilidad en el sistema de recomendación. La predicción que se realiza

para cada ítem se puede obtener mediante el uso de algoritmos de filtrado colaborativo, filtrado por contenido o una combinación de ambos que generalmente se denomina filtrado híbrido. Todo el proceso hasta la generación de la predicción se ejecuta fuera de línea, pues los cálculos son complejos y requieren un cierto tiempo de procesamiento que expondría al usuario a unos tiempos de respuesta muy altos.

Dado que la gran mayoría de los sistemas de recomendación se han ocupado típicamente de proporcionar recomendaciones a individuos, en los próximos capítulos de este proyecto de investigación se propone una técnica de filtrado híbrido basada en perfiles grupales que tenga como un componente fuerte la personalización del sistema, es decir, que las recomendaciones dependen del usuario activo más que del contenido en sí mismo y cuyo resultado es la generación de recomendaciones mejoradas cuando se comparan con un modelo de línea base, para un grupo de individuos que ven televisión juntos. Adicionalmente se identifica la infraestructura necesaria para la implementación de un prototipo del sistema de recomendación propuesto, se propone una forma de generación de perfiles de grupo que permita identificar las preferencias del grupo como una entidad y finalmente se proponen un esquema de filtrado basado en contenido y un esquema de filtrado basado en colaboración entre grupos. La propuesta presentada busca responder a las siguientes preguntas:

- ¿Cómo se puede recomendar contenido televisivo a un televidente haciendo uso de perfiles de grupales?
- ¿Cómo se puede recomendar contenido televisivo a un grupo haciendo uso de perfiles grupales?

## 5.1 DISEÑO DE UN MODELO HÍBRIDO USANDO PERFILES GRUPALES

La siguiente figura muestra la arquitectura propuesta en términos de los datos y componentes que lo conforman.

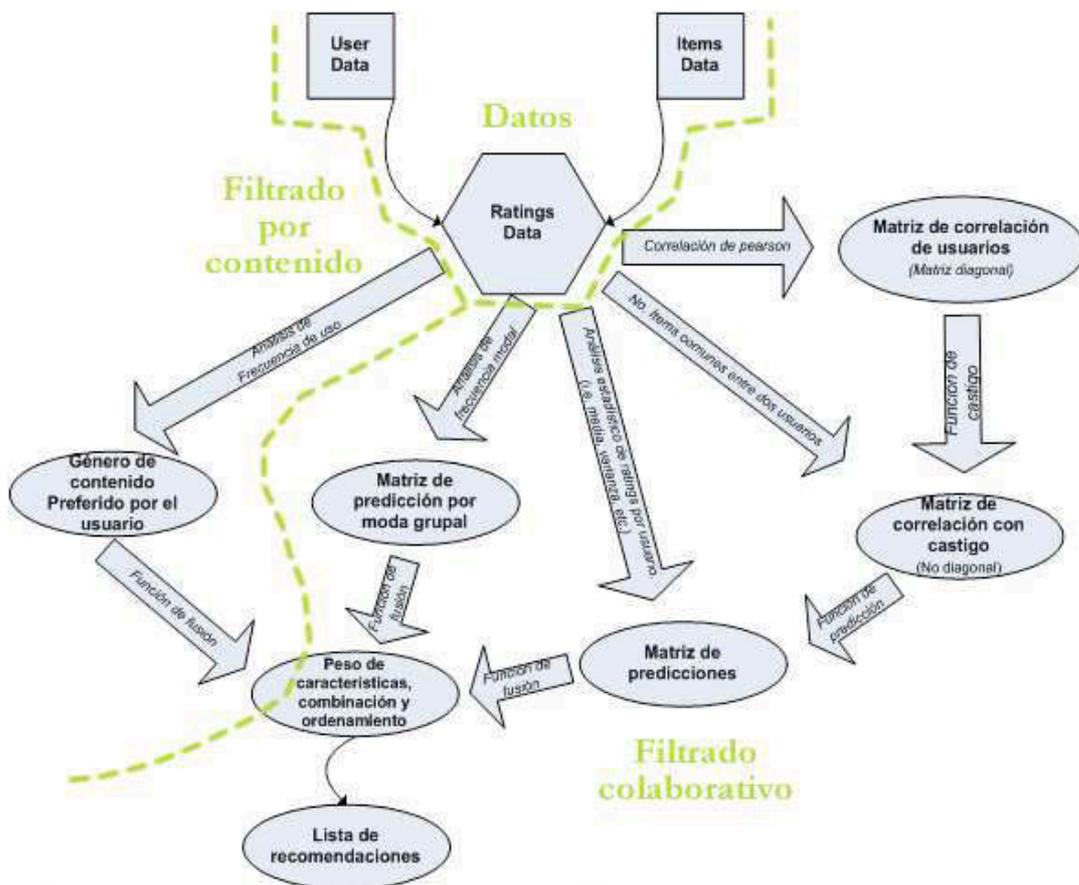


Figura 15 - Componentes del modelo propuesto

El modelo de recomendación propuesto hace uso de los siguientes datos para realizar recomendaciones.

### **5.1.1 Conjunto de datos.**

Uno de los principales problemas que se encuentran a la hora de realizar estudios sobre sistemas de recomendación es la cantidad limitada de conjuntos de datos tomados de un sistema real que permita realizar experimentos a los investigadores. Los conjuntos de datos más usados en el ámbito del contenido audiovisual son aquellos proporcionados por MovieLens. Para la realización de los experimentos y la evaluación de la técnica de recomendación aquí propuesta se usó el conjunto de datos de MovieLens compuesto de 100.000 calificaciones. Los conjuntos de datos de MovieLens fueron creados por el Proyecto de Investigación GroupLens en la Universidad de Minnesota. Este conjunto de datos contiene:

- 100.000 calificaciones entre 1 y 5 (1 siendo la calificación más baja y 5 siendo la más alta) de 943 usuarios sobre 1682 ítems.
- Cada usuario ha calificado al menos 20 ítems
- Información demográfica básica de los usuarios (edad, género, ocupación y código ZIP).

### **5.1.2 Perfil de usuario.**

El perfil de usuario se construye de manera dinámica basado en sus calificaciones hasta el momento de creación o actualización de su perfil. En este caso, el perfil de un usuario se compone de los géneros de contenido preferidos por el usuario (por ejemplo acción, comedia, drama, etc.), del perfil demográfico del mismo y de algunas medidas estadísticas de tendencia central y de dispersión de las calificaciones del usuario como la media, la varianza y la moda. La identificación de los géneros de contenido preferidos por el usuario se realizó mediante un análisis de frecuencia de uso, de forma tal que cuando un usuario ha visto más contenido de un cierto género de contenido, se considera que dicho género es el

que le resulta más atractivo al usuario. Para la creación del perfil demográfico del usuario se tuvo en cuenta su género sexual (hombre o mujer) y su edad. Para la identificación del usuario dentro de un cierto grupo según su edad se usaron los mismos rangos de edad usados por la Comisión Nacional de Televisión en su Gran Encuesta de la Televisión en Colombia como se muestra en la tabla 2<sup>59</sup>.

Grupo	Edad mínima	Edad máxima
1	5	11
2	12	17
3	18	24
4	25	34
5	35	44
6	45	54
7	55	64

Tabla 2: Distribución de televidentes por edad en el conjunto de datos

Con estos dos criterios demográficos se obtienen 16 grupos a los que podría pertenecer cada usuario. La proporción de usuarios por grupo de edad y por género sexual se presentan en las figuras 16 y 17 respectivamente.

---

<sup>59</sup> Comisión Nacional de Televisión (2008). La Gran Encuesta de la Televisión en Colombia. (Citada 07 de julio de 2011) <[http://www.cntv.org.co/cntv\\_bop/noticias/2008/abril/gran\\_encuesta.pdf](http://www.cntv.org.co/cntv_bop/noticias/2008/abril/gran_encuesta.pdf)>

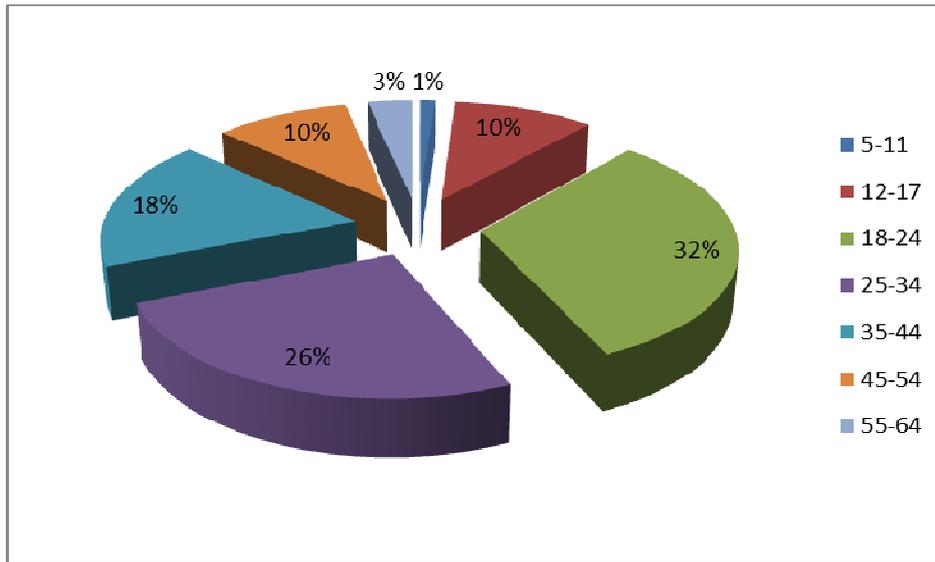


Figura 16. Proporción de usuarios por grupo de edad

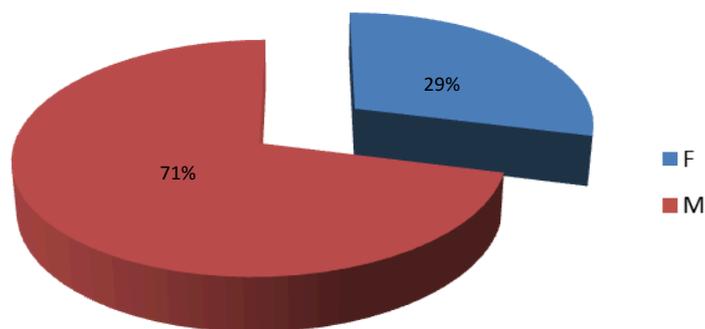


Figura 17. Proporción de usuarios por género sexual

### 5.1.3 Correlación usuario – usuario.

La correlación usuario-usuario es una medida que permite conocer, usando los registros de realimentación o calificaciones de cada usuario, cuales usuarios tienen gustos parecidos. Así, si dos usuarios  $a$  y  $b$  han dado una puntuación

similar a varios ítems, se entenderá que tienen gustos parecidos. El cálculo de correlación se realizó usando el coeficiente de correlación de Pearson para cada par de usuarios  $a$  y  $b$  dependiendo de sus calificaciones para cada ítem  $i$ , de la siguiente forma:

$$s_{a,b} = \frac{\sum_{i=1}^n [(r_{a,i} - \bar{r}_a)(r_{b,i} - \bar{r}_b)]}{\sqrt{\sum_{i=1}^n (r_{a,i} - \bar{r}_a)^2 \sum_{i=1}^n (r_{b,i} - \bar{r}_b)^2}}$$

El cálculo de correlación se aplica a cada par de usuarios en el conjunto de datos de entrenamiento para obtener una matriz de correlación que tiene la forma indicada en la figura 17.

	$u_1$	$u_2$	$u_3$	$u_4$	$u_5$
$u_1$	1	$c_{12}$	$c_{13}$	$c_{14}$	$c_{15}$
$u_2$	$c_{21}$	1	$c_{23}$	$c_{24}$	$c_{25}$
$u_3$	$c_{31}$	$c_{32}$	1	$c_{34}$	$c_{35}$
$u_4$	$c_{41}$	$c_{42}$	$c_{43}$	1	$c_{45}$
$u_5$	$c_{51}$	$c_{52}$	$c_{53}$	$c_{54}$	1

Figura 18. Forma genérica de una matriz de correlación

En la figura 18,  $c_{ij}$  es la correlación entre los usuarios  $i$  y  $j$ . La correlación de Pearson es un número que varía entre -1 y 1, siendo 1 el valor que indica que los dos usuarios tienen gustos idénticos, -1 el valor que indica que los dos usuarios tienen gustos totalmente distintos y 0 el valor que indica que no se puede determinar que exista algún parecido o diferencia acerca de los gustos de los dos usuarios. También puede verse que en la matriz de correlación  $C_{ii}$  es igual a 1 y que  $C_{ij}=C_{ji}$ , por lo que la matriz de correlación es una matriz simétrica.

#### 5.1.4 Ítems.

Los ítems son los elementos que el usuario espera que se le recomienden. El conjunto de datos que se usó está compuesto por 1682 ítems y para su recomendación se tuvieron en cuenta los géneros a los que pertenecen. Un ítem puede pertenecer a uno o más géneros de contenido. En la tabla 3 se muestra la proporción de ítems según el género al que pertenecen.

Género	Cantidad	Porcentaje
Acción	2	0,12%
Aventura	250	14,86%
Animación	135	8,03%
Comedia	122	7,25%
Crimen	505	30,02%
Documental	109	6,48%
Drama	51	3,03%
Fantasía	724	43,04%
Cine negro	22	1,31%
Terror	24	1,43%
Musical	92	5,47%
Misterio	56	3,33%
Romance	61	3,63%
Ciencia Ficción	247	14,68%
Thriller	101	6,00%
Guerra	251	14,92%
Viejo oeste	71	4,22%
Infantil	42	2,50%

Tabla 3. Cantidad de ítems por género en el conjunto de datos

## Número de ítems por género

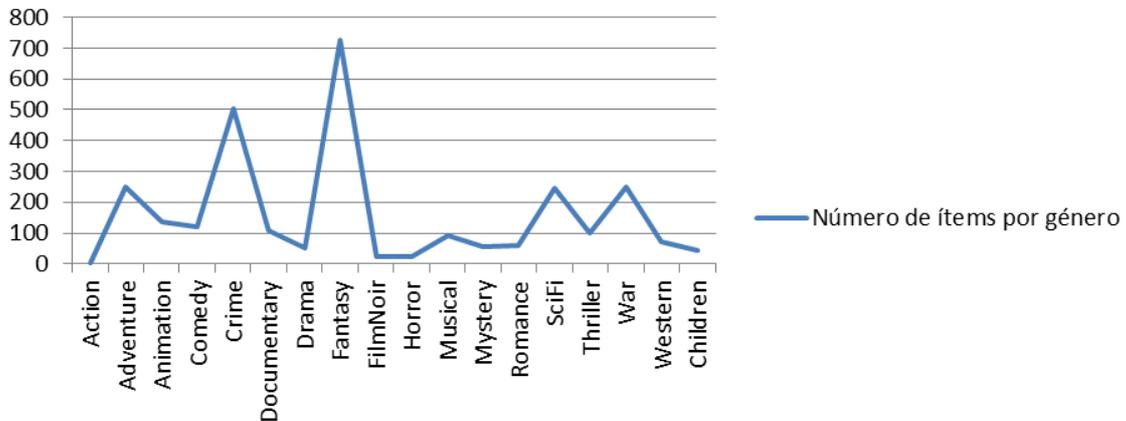


Figura 19. Número de ítems por género

Para la conformación del perfil de usuario se determina la preferencia de un género de contenido según sea la proporción de ítems de un género en particular calificados por un usuario. Así, si el usuario ha otorgado en total 100 calificaciones, y de ellos 30 películas pertenecen al género *Terror*, entonces el género *Terror* tendrá una preferencia del 30% para ese usuario.

### 5.1.5 Función de castigo.

Se propone una función que ha sido llamada de castigo, la cual dependiendo del número de ítems en común que tienen dos usuarios, asigna un peso a la correlación entre dichos usuarios. La función de castigo  $f_c$  se define como:

$$f_c(x) = \begin{cases} e^x - 1; & 0 \leq x \leq \ln 2 \\ 1; & x > \ln 2 \\ 0; & x < 0 \end{cases}$$

Y su gráfica correspondiente en el dominio  $[0, \ln 2]$  es la que se muestra en la figura 20.

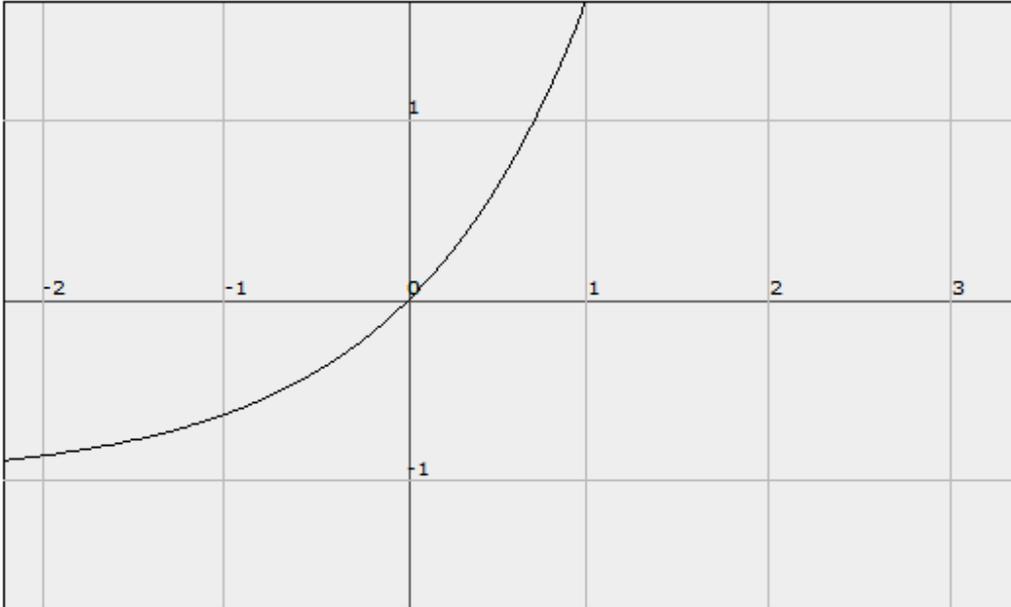


Figura 20. Gráfica de la función de castigo

El valor de  $x$  en la función de castigo es a su vez una función  $f_m$  del número de ítems en común que han visto dos usuarios y depende también del perfil demográfico de ambos usuarios. Sea  $C$  el número de ítems vistos en común por dos usuarios y sea  $P_m$  el percentil  $m$  del número de ítems en común del usuario activo con los otros usuarios, entonces si ambos usuarios pertenecen al mismo grupo demográfico (Es decir son del mismo género sexual y grupo de edad),  $f_m$  se define como:

$$f_m = \frac{C}{P_{50}}$$

Si ambos usuarios pertenecen a grupos demográficos distintos, entonces:

$$f_m = \frac{C}{P_{75}}$$

De esta forma, si un usuario  $u$  tiene igual número de ítems en común con el usuario para el cual se están creando recomendaciones y que también se conoce como usuario activo, la función de castigo dará como resultado un valor menor si el usuario  $u$  no tiene el mismo perfil demográfico que el usuario activo.

### 5.1.6 Imputación demográfica.

Se propone un proceso llamado imputación demográfica mediante el cual, el usuario activo tiene en cuenta para cada ítem el puntaje asignado por su grupo demográfico. El grupo demográfico de un usuario está conformado por todos los usuarios con el mismo perfil demográfico del usuario activo. En este caso se realizó un análisis modal para asignar a cada ítem prospecto de recomendación un valor de predicción que corresponde al puntaje que mayor número de veces se asignó a dicho ítem por parte de los miembros del grupo demográfico del usuario activo. Este parámetro de clasificación no se usa en los cálculos de predicción y por lo tanto tampoco afecta las medidas de error cuadrático medio ni de error medio absoluto.

### 5.1.7 Predicción.

La siguiente es la fórmula matemática con la que se realiza la predicción de la calificación que obtendrá un ítem de parte de un usuario  $a$  que no lo ha calificado. Incorpora los valores de la media y desviación estándar de las calificaciones del usuario activo (Es decir el usuario  $a$ ) y de los otros usuarios, además de la correlación entre cada par de usuarios.

$$p_{a,x} = \bar{r}_a + \sigma_a \frac{\sum_{i=1}^n \left[ \left( \frac{r_{i,x} - \bar{r}_i}{\sigma_i} \right) s_{a,i} \right]}{\sum_{i=1}^n s_{a,i}}$$

Donde  $i$  es cada usuario distinto de  $a$ ,  $n$  es el número de usuarios distintos de  $a$  y  $s_{a,i}$  es la correlación de pearson entre los usuarios  $a$  e  $i$ .

### 5.1.8 Función de fusión.

Esta función propone una forma de combinar los resultados de los esquemas de filtrado por contenido y filtrado colaborativo. Mediante esta función se asignó un peso que permite ordenar mejor los ítems a recomendar, pero que no afecta la predicción de los ítems que se recomiendan al usuario activo. De esta forma se intenta favorecer a aquellos ítems que pertenecen a los géneros preferidos por el usuario activo. En la función de fusión se obtienen los tres géneros preferidos por el usuario de acuerdo con el indicador de preferencia de género según como se describió anteriormente y se potencian sus predicciones de acuerdo con su preferencia de modo que puedan alcanzar niveles más altos en la lista de recomendación. De esta forma para cada ítem  $i$  que pertenece al género  $g$  con una preferencia  $p$  por parte del usuario, y siendo  $p$  uno de los tres valores más altos de preferencia de género del usuario, su valor, que en este caso es llamado valor de ordenamiento  $o$ , se obtiene mediante la fórmula:

$$o_0 = \text{predicción}$$

$$o_i = o_{i-1} * (1 + p); i \in \{1,2,3\}$$

El valor inicial  $o_0$  del valor de ordenamiento del ítem  $i$  es el valor de la predicción obtenida mediante la aplicación del modelo de recomendación.

### 5.1.9 Límite de predicción positiva.

Las recomendaciones para un usuario dado se obtienen mediante la generación de una lista de los mejores- $N$  ítems de acuerdo con la predicción que dichos ítems

obtengan cuando se aplica el modelo de recomendación a los distintos conjuntos de datos. Es evidente que dichas recomendaciones deben ser ítems con una buena predicción. Es decir, que un ítem cuya predicción es 1 en una escala de 1 a 5 no debería incluirse en la lista de recomendación para un usuario y que se deben preferir a aquellos ítems con mayor predicción, es decir que entre más alto sea el límite mínimo, mejor deben ser las recomendaciones. Se debe definir entonces un límite mínimo para los ítems que se tendrán en cuenta para la recomendación. Esto es equivalente a clasificar los ítems con predicción o calificación real por encima del límite de predicción positiva como relevantes y aquellos ítems por debajo de éste como irrelevantes. Si no se usa un límite mínimo se pueden obtener resultados desorientadores.



## 6 EVALUACIÓN DEL MODELO Y RESULTADOS

### 6.1 DISEÑO DEL EXPERIMENTO

El experimento se realizó aplicando el modelo propuesto a tres diferentes entidades que se comportan como usuarios activos de la siguiente forma:

- **Individuos:** Primero se aplicó el modelo a los usuarios del conjunto de datos tal y como aparecen en el mismo. Es decir, que el usuario activo para cada aplicación del modelo es un usuario del conjunto de datos. En este caso el objetivo es determinar si las recomendaciones que el sistema entrega a un individuo cualquiera, pueden mejorarse si se tiene en cuenta el grupo demográfico al cual pertenece.
- **Parejas:** Eligiendo usuarios al azar del conjunto de datos original, se conformaron 1000 parejas cuyos miembros al menos hubieran calificado 50 ítems en común. Luego se asignó a cada pareja un identificador, de forma que a partir de ese momento el grupo es tratado como una única usuario durante la aplicación del modelo. El objetivo era determinar si las recomendaciones que el sistema de recomendación arroja para una pareja de televidentes, puede mejorarse si se tiene en cuenta información de otras parejas que coincidan con el estereotipo demográfico de sus miembros. Para la simulación del grupo, a los ítems en común se le asignó una calificación correspondiente a la media de las calificaciones de sus miembros.
- **Tríos:** Eligiendo usuarios al azar del conjunto de datos original, se conformaron 128 tríos cuyos miembros al menos hubieran calificado 50

ítems en común. Para la simulación del grupo, a los ítems en común se le asignó una calificación correspondiente a la media de las calificaciones de sus miembros. Luego, al igual que en el caso anterior, se asignó a cada trío un identificador, de forma que el identificador de cada trío es tratado como el usuario activo para la aplicación del modelo. El objetivo era determinar si las recomendaciones que el sistema de recomendación arroja para un grupo de tres televidentes, puede mejorarse si se tiene en cuenta información de otros tríos que coincidan con el perfil demográfico de sus miembros.

Luego de la conformación de los grupos, debe tenerse en cuenta que el grupo es tratado como una entidad, por lo cual el sistema se aplica de igual forma que si fuera un individuo, pero la información que se procesa es el resultado del consenso grupal.

### **6.1.1 Conjuntos de datos de entrenamiento y evaluación.**

Para la evaluación del modelo propuesto, se seleccionaron al azar un 20% de las calificaciones del conjunto de datos que se eligió para el estudio y se usó como el conjunto de datos de prueba (Es decir el conjunto de datos de prueba) y el 80% restante (Es decir 80000 calificaciones) se usó como el conjunto de entrenamiento para realizar los cálculos de predicción y clasificación de ítems a recomendar. De esta forma se aplica el modelo presentado en la figura 15 teniendo en cuenta solamente las calificaciones del conjunto de datos de entrenamiento y se evalúan los resultados con el conjunto de datos de prueba.

Además para garantizar que existen los suficientes datos que permitan la aplicación y comparación entre el modelo propuesto y el modelo tradicional, se

toman en cuenta solamente los resultados de las predicciones y recomendaciones de aquellos usuarios que tienen más de 50 calificaciones entre las 20000 calificaciones del conjunto de datos de evaluación.

### **6.1.2 Procedimiento.**

Las recomendaciones del modelo propuesto son obtenidas mediante la aplicación del modelo y el uso exclusivo del conjunto de datos de entrenamiento de la siguiente forma:

- a. Se realizan los cálculos de correlación entre usuarios o grupos usando la fórmula de correlación de Pearson.
- b. Se calculan los datos estadísticos de cada usuario o grupo que serán usados para realizar las predicciones. En este caso se necesitan la media y la desviación estándar de las calificaciones de cada usuario.
- c. Se aplica la función de castigo a las correlaciones entre los usuarios o grupos dependiendo del número de ítems en común de un usuario con todos los demás. En este caso los valores en la matriz de correlación se modifican y la matriz resultante continúa siendo una matriz cuadrada, los valores en la diagonal continúan teniendo el valor 1, pero cesa de ser una matriz simétrica, de forma que  $c_{ij}$  no es necesariamente igual a  $c_{ji}$ .
- d. Se realiza el cálculo de las predicciones usando la fórmula propuesta por Van Setten y presentada en la sección 5.1.7<sup>60</sup>, pero a la se le incorporan los valores de la matriz de correlación con castigo y la media y desviación estándar de las calificaciones del usuario o grupo que está siendo analizado, así como las mismas medidas de los demás usuarios o grupos.

---

<sup>60</sup> van Setten, M. (2005). Supporting people in finding information: hybrid recommender systems and goal-based structuring. (Citada el 11 de Julio de 2011) <[http://doc.utwente.nl/50889/1/thesis\\_van\\_Setten.pdf](http://doc.utwente.nl/50889/1/thesis_van_Setten.pdf)>

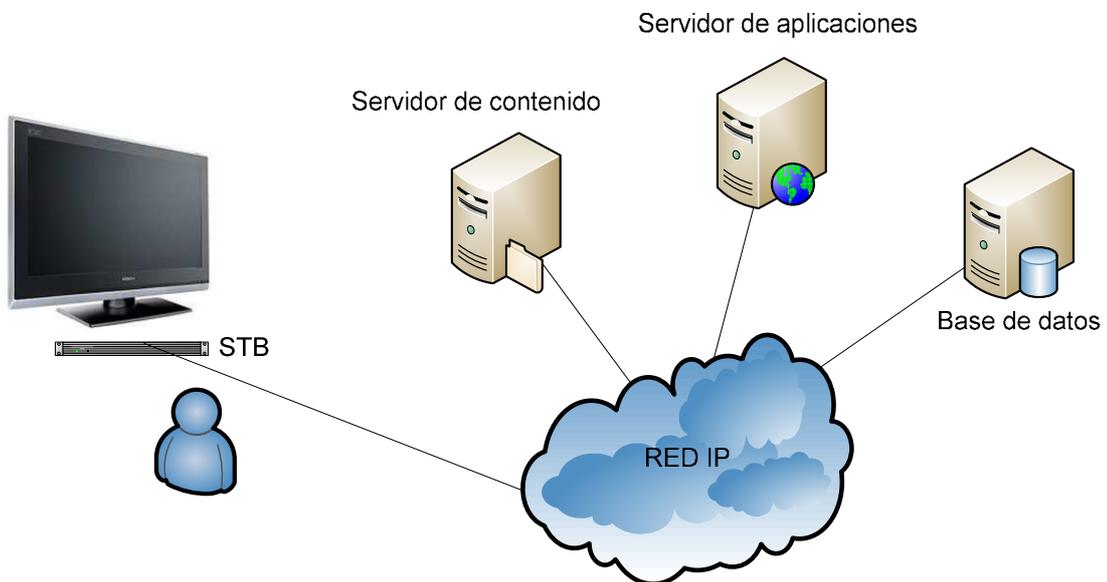
- e. Se realiza una predicción por medio de un análisis de frecuencia modal para cada usuario o grupo teniendo en cuenta las calificaciones asignadas a los ítems por parte de los miembros que tienen sus mismas características y composición demográfica.
- f. Se genera una lista de ítems que serán prospectos de recomendación mediante la realización de la intersección entre las predicciones individuales o grupales y las predicciones imputadas de los grupos demográficos.
- g. Se le da un peso a cada ítem de la lista de posibles ítems a recomendar. Este peso se obtiene a partir del género al que pertenece cada ítem de la lista y a las preferencias de género del usuario o grupo.
- h. Se seleccionan los ítems cuya predicción es mayor a un valor  $I$  y estos se presentan como la lista de recomendación.

## 6.2 ARQUITECTURA TI

Para la evaluación del modelo propuesto se basa en un sistema con una arquitectura cliente-servidor centralizada. Como se muestra en la figura 21 el sistema está conformado por:

- **Servidor de persistencia:** En este servidor se ejecutan los procesos necesarios del sistema de recomendación. Almacena los datos del perfil de usuarios, los datos de los ítems, las calificaciones, las predicciones y las variables de configuración del sistema en una base de datos. Algunos datos de cálculos intermedios (como los resultados de la matriz de correlación) se almacenan en archivos o simplemente en memoria temporal para no afectar el rendimiento del sistema. Los procesos del sistema de recomendación se ejecutan en batch.

- **Servidor de aplicaciones:** En este servidor se expone el sistema de recomendación como un conjunto de servicios web que reciben solicitudes y entregan las recomendaciones para el usuario que las solicitó.
- **Servidor de contenido:** Es el servidor que contiene los videos que serán transmitidos al usuario cuando los solicite.
- **Set-top box:** Es el dispositivo que se encarga de comunicarse con los servidores y el que recibe las órdenes del usuario final. Es el cliente en la arquitectura cliente-servidor del sistema de recomendación.
- **Televisor:** Es el dispositivo que entrega información de manera visual y auditiva al usuario final.
- **Red IP:** Es la red que permite la comunicación entre los diferentes componentes del sistema.



*Figura 21. Arquitectura Cliente/Servidor utilizada*

### 6.3 MÉTRICAS DE EVALUACIÓN

Existen varias métricas para la evaluación de la exactitud de las recomendaciones arrojadas por un sistema de recomendación, las cuales pueden ser clasificadas en tres tipos<sup>61 62</sup>:

- Métricas de exactitud en la predicción: Estas métricas miden qué tan cerca estuvieron las calificaciones que predijo el sistema en comparación con las calificaciones reales que los usuarios dieron a los ítems.
- Métricas de exactitud de clasificación: Se encargan de medir con qué frecuencia un sistema de recomendación acierta al decidir que un ítem le interesa a un usuario.
- Métricas de exactitud en el ordenamiento o ranking: Estas métricas miden la capacidad que tiene un sistema de recomendación para ordenar los ítems que recomienda a los usuarios en el orden en que el usuario los hubiera ordenado.

Dos métricas de exactitud en la predicción muy usadas para evaluar sistemas de recomendación son el error cuadrático medio (Root Mean Squared Error - RMSE) y el error medio absoluto (Mean Absolute Error - MAE). El MAE y el RMSE son medidas similares que intentan representar la diferencia entre el valor predicho y el valor real de la calificación que un usuario asigna a un ítem. El RMSE y el MAE son indicadores de la exactitud de la predicción, pero no son indicadores de la exactitud de la recomendación. Se definen de la siguiente forma, siendo  $r_i$  el valor de predicción y  $r_o$  el valor real (Es decir el valor observado) de la calificación:

---

<sup>61</sup> Herlocker, J. Konstan, J. Terveen, L. Riedl, J. (2004). Evaluating collaborative filtering recommender systems. *ACM Trans. Inf. Syst.* 22, 1 (January 2004), 5-53.

<sup>62</sup> Shani, G. Gunawardana, A. (2011). Evaluating Recommendation Systems. In *Recommender Systems Handbook*. pp. 257-297.

$$RMSE = \sqrt{\sum_{i=1}^N \frac{(r_i - r_0)^2}{N}}$$

$$MAE = \frac{\sum_{i=1}^N |r_i - r_0|}{N}$$

Dado que en los sistemas de recomendación reales la buena o mala experiencia de sus usuarios depende de la exactitud de las recomendaciones, el RMSE y el MAE pueden no ser las medidas de evaluación preferidas y se deben preferir métricas de exactitud en la clasificación como lo son la precisión y el recuerdo, que intentan calificar el sistema de recomendación con base en los ítems recuperados y los ítems que son relevantes para un usuario<sup>63,64</sup>. La precisión y el recuerdo son probablemente las métricas populares para evaluar sistemas de recuperación de información, fueron propuestas en 1968 por Cleverdon y Keen<sup>65</sup> y son aún las métricas más usadas para evaluar el desempeño de los sistemas de recuperación de información.

En este caso se considera que un ítem es relevante para un usuario si el rating que el usuario dio a dicho ítem se encuentra por encima del límite de predicción positiva. Por otro lado, los ítems recuperados son los ítems cuya predicción de la calificación para dicho usuario están por encima de la predicción positiva. Si

---

<sup>63</sup> Cremonesi, P., Koren, Y., Turrin, R. Performance of recommender algorithms on top-n recommendation tasks, Proceedings of the fourth ACM conference on Recommender systems, September 26-30, 2010, Barcelona, Spain [doi>10.1145/1864708.1864721]

<sup>64</sup> Herlocker, J. Konstan, J. Terveen, L. Riedl, J. (2004). Evaluating collaborative filtering recommender systems. *ACM Trans. Inf. Syst.* 22, 1 (January 2004), 5-53.

<sup>65</sup> Cleverdon, C. Mills, J. Keen, M. (1966). ASLIB Cranfield project, Cranfield.

llamamos  $\{A\}$  al conjunto de ítems recuperados y  $\{B\}$  al conjunto de ítems relevantes, entonces la precisión y el recuerdo se definen de la siguiente forma:

$$\text{Precisión} = \frac{\|\{A \cap B\}\|}{\|\{A\}\|}$$

$$\text{Recuerdo} = \frac{\|\{A \cap B\}\|}{\|\{B\}\|}$$

Como puede verse, para un usuario que recibe una lista de recomendaciones de  $N = \|\{A\}\|$  ítems, la precisión es la proporción entre el número de ítems relevantes que se le recomiendan al usuario y el número  $N$  de ítems que se le recomiendan. El Recuerdo es la proporción entre el número de ítems relevantes que se le recomiendan al usuario y el número de ítems que son relevantes para el usuario. En otras palabras, el Recuerdo representa la capacidad que tiene el sistema de recomendación para obtener todos los ítems que son útiles para el usuario, mientras que la precisión mide la capacidad que tiene el sistema para obtener solamente esos ítems que son útiles para el usuario sin mezclarlos con aquellos que no son útiles. Puede verse de la definición de las dos métricas, que es trivial mejorar una de ellas mientras se empeora la otra, por lo tanto se requiere una métrica como la llamada F1-score que combine el Recuerdo y la Precisión<sup>66</sup>.

Es importante anotar que dada la alta dispersión de los datos de calificaciones en los sistemas de recomendación y particularmente en el conjunto de datos que se usó en este estudio, hay muchos ítems que no han obtenido calificación por parte

---

<sup>66</sup> Geyer-Schulz, A. Hahsler, M. (July 2002) In Fourth WebKDD Workshop: Web Mining for Usage Patterns & User Profiles (July 2002), 100-114.

de los usuarios. En este caso, para mantener la imparcialidad, se decidió considerar que el ítem es irrelevante y cuenta de manera negativa en el cálculo de la precisión dado que se divide por N. El cálculo de la precisión toma en cuenta todos los documentos recuperados, pero también puede evaluarse en un número c de corte en particular. Esta medida es llamada precisión en c o P@c y tiene en cuenta solamente los primeros c ítems recuperados por el sistema.

El F1-score es una medida que intenta combinar la precisión y el recuerdo para dar una idea concisa de la evaluación de las otras dos métricas y se define como:

$$F1\_score = 2 * \frac{Precisión * Recall}{Precisión + Recall}$$

Para la precisión, el recuerdo y el F1-score el valor óptimo es 1 y el peor valor es 0.

#### **6.4 COMPARACIÓN CON EL MODELO DE LÍNEA BASE**

Algunos experimentos de evaluación de sistemas de recomendación carecen de la comparación con un algoritmo base. En este caso se decidió realizar las comparaciones contra el modelo de filtrado colaborativo desarrollado por Mark Van Setten<sup>67</sup>. Se aplicaron ambos modelos, el modelo base y el modelo propuesto, al conjunto de datos de MovieLens para comparar los resultados.

---

<sup>67</sup> van Setten, M. (2005). *Supporting people in finding information: hybrid recommender systems and goal-based structuring*. (Citada el 11 de Julio de 2011) <[http://doc.utwente.nl/50889/1/thesis\\_van\\_Setten.pdf](http://doc.utwente.nl/50889/1/thesis_van_Setten.pdf)>

## 6.5 ANÁLISIS DE RESULTADOS

Para cada métrica de evaluación se presentan a continuación los resultados obtenidos en el modelo base y en el modelo propuesto para las diferentes entidades de estudio (Es decir individuos, parejas y tríos) como se describió en el diseño de los experimentos.

### 6.5.1 Evaluación del modelo en individuos.

Las siguientes figuras y tablas muestran los resultados obtenidos para los experimentos realizados cuando los usuarios del sistema son individuos. Se comparan los resultados de la evaluación para el modelo base y para el modelo propuesto.

Límite	Precisión @20 Modelo Base	Precisión @20 Modelo Propuesto
3,5	0,57721199	0,66759670
3,6	0,53998722	0,66757733
3,7	0,44594669	0,67482002
3,8	0,35209409	0,67834496
3,9	0,31865681	0,67286193
4	0,24086521	0,66164134
4,1	0,10391435	0,41578702
4,2	0,11385542	0,42017210
4,3	0,07056799	0,41361948
4,4	0,04819277	0,40867111

Tabla 4. Comparación de Precisión entre el modelo base y el modelo propuesto

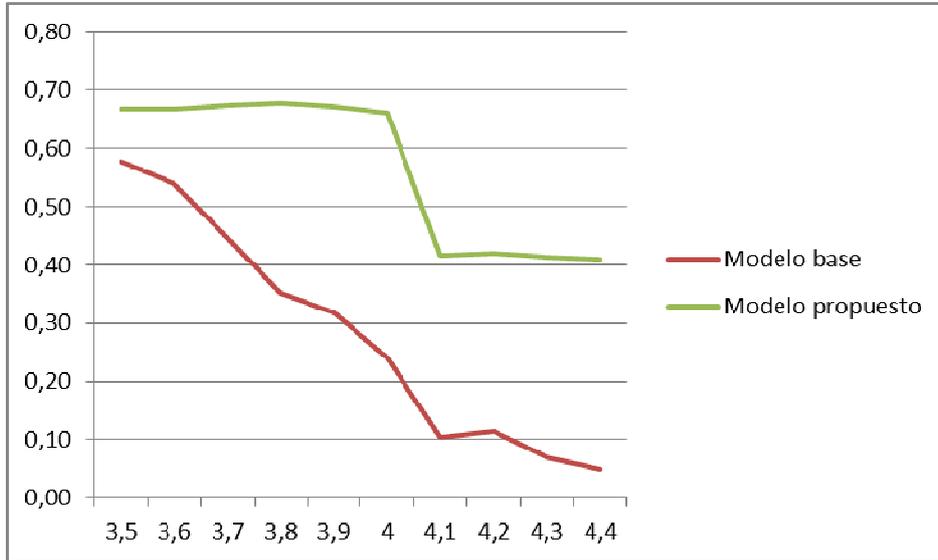


Figura 22. Precisión de modelo base vs modelo propuesto

Límite	Recall @20 SoA	Recall @20 Groups I
3,5	0,21496962	0,39478796
3,6	0,16953308	0,39060045
3,7	0,13513288	0,39240536
3,8	0,10213284	0,39025607
3,9	0,08471984	0,38670298
4	0,05386447	0,37065973
4,1	0,04212750	0,23546010
4,2	0,01979232	0,22871617
4,3	0,00816825	0,22480378
4,4	0,00289597	0,19647040

Tabla 5. Comparación de Recuerdo entre el modelo base y el modelo propuesto.

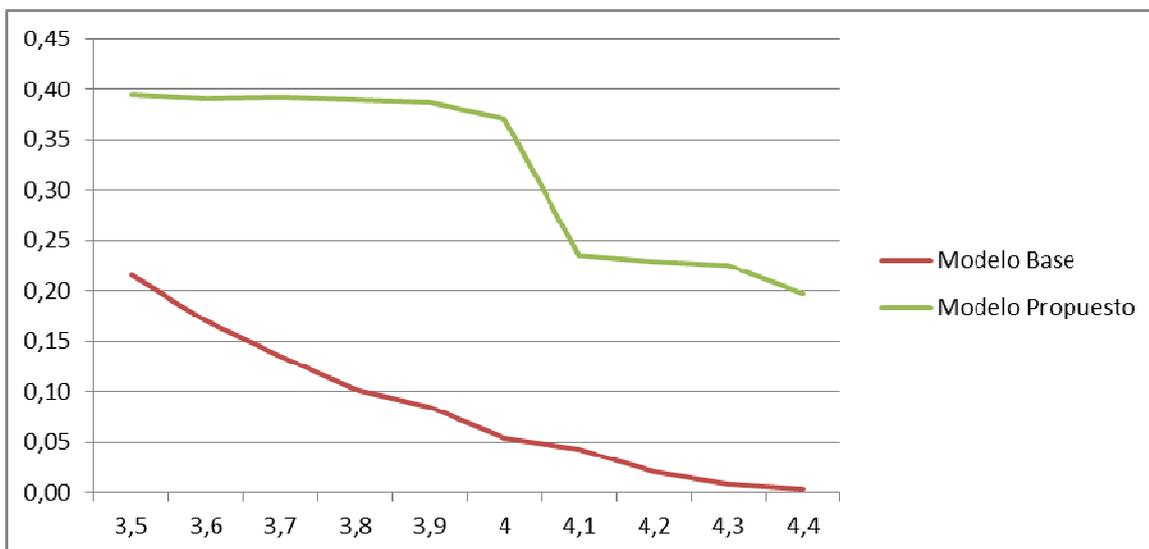


Figura 23. Recuerdo de modelo base vs modelo propuesto

Límite	F1-score @20 SoA	F1-score @20 Groups I
3,5	0,29771549	0,48116361
3,6	0,23813022	0,47978474
3,7	0,19255017	0,48328202
3,8	0,14674692	0,48048000
3,9	0,12195879	0,47991160
4	0,08060807	0,46509664
4,1	0,05268584	0,25752505
4,2	0,02759796	0,25115087
4,3	0,01352006	0,24640313
4,4	0,00543350	0,22667164

Tabla 6. Comparación de F1-Score entre el modelo base y el modelo propuesto

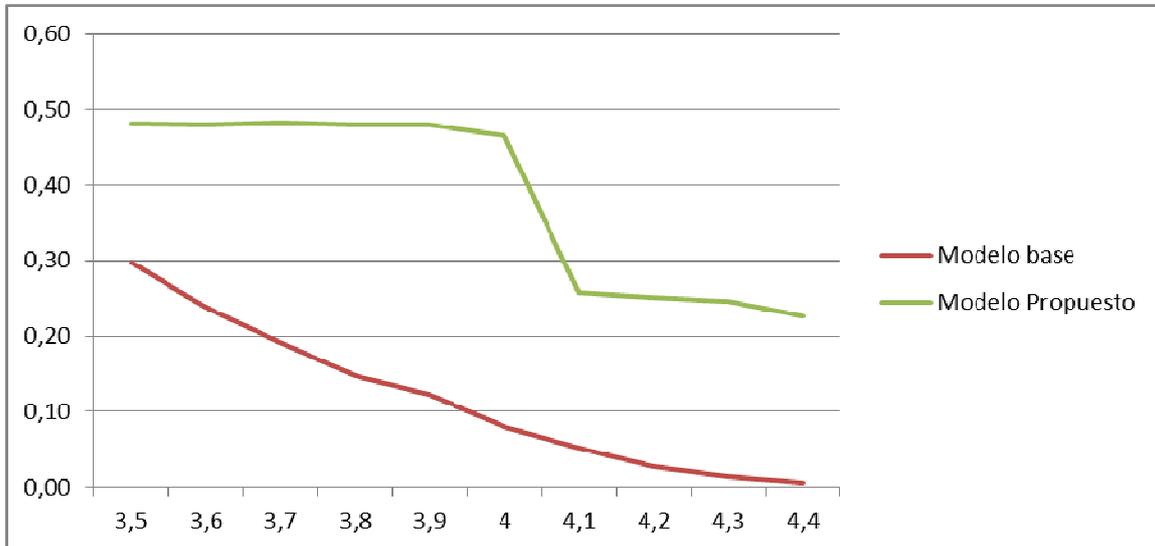


Figura 24. F1-Score de modelo base vs modelo propuesto

Límite	MAE SoA	MAE Groups I
3,5	0,77955282	0,76903647
3,6	0,76256842	0,75806127
3,7	0,75255541	0,74566303
3,8	0,72551478	0,72295680
3,9	0,69330972	0,69194042
4	0,66195673	0,64870785
4,1	0,67464874	0,67653959
4,2	0,70265164	0,68696415
4,3	0,61863371	0,53655226
4,4	0,50690087	0,45496134
4,5	0,31725511	0,39630638

Tabla 7. Comparación de MAE entre el modelo base y el modelo propuesto

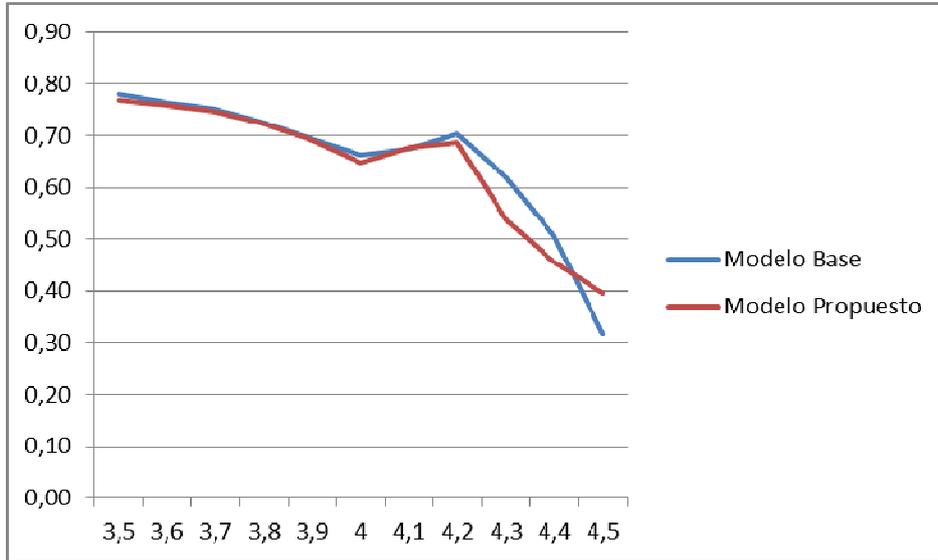


Figura 25. Comparación de MAE entre el modelo base y el modelo propuesto

Límite	RMSE SoA	RMSE Groups I
3,5	0,97298266	0,96320386
3,6	0,96059658	0,95591025
3,7	0,95180434	0,94308653
3,8	0,91963047	0,92125032
3,9	0,89230864	0,88652242
4	0,84516322	0,82427005
4,1	0,81168505	0,80599386
4,2	0,82226999	0,81341846
4,3	0,67655213	0,57025504
4,4	0,51622247	0,46530158
4,5	0,31725511	0,40815292

Tabla 8. Comparación de RMSE entre el modelo base y el modelo propuesto

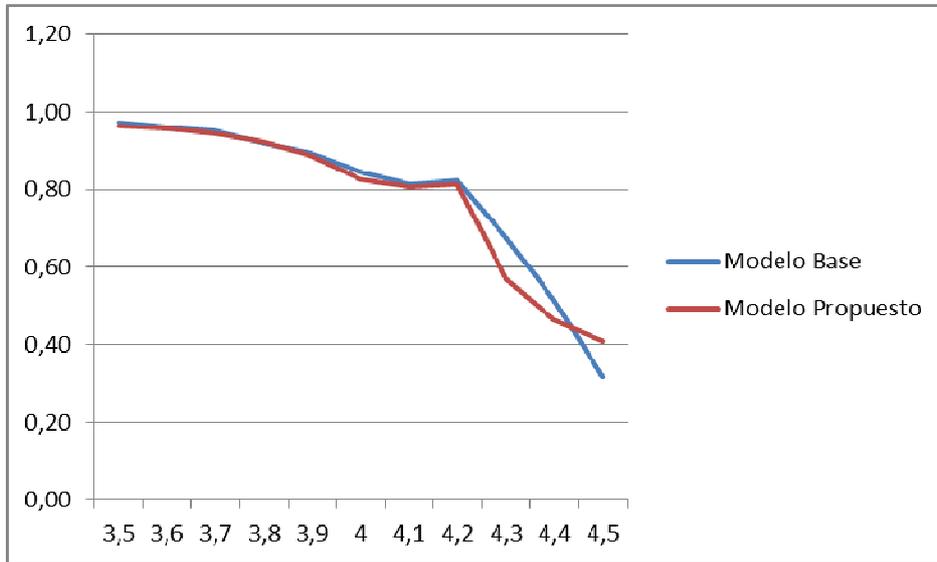


Figura 26. Comparación de RMSE entre el modelo base y el modelo propuesto

Como puede observarse en los resultados anteriormente expuestos, el cálculo de error en las predicciones presenta en la mayoría de los casos variabilidad de alrededor del 1% en el caso del RMSE y del 2% en el caso del MAE. Las métricas de Precisión y Recuerdo se logran mejorar con el modelo propuesto por medio de la recuperación de muchos más elementos relevantes a medida que se aumenta el límite de predicción. Es decir, el modelo propuesto eleva los indicadores de precisión y recuerdo mediante la recuperación de más elementos relevantes, los cuales se obtienen basados en las preferencias de usuarios con el mismo perfil demográfico. Estos elementos no son identificados por el modelo de línea base.

### 6.5.2 Evaluación del modelo en parejas

Las siguientes figuras y tablas muestran los resultados obtenidos cuando se realiza la evaluación para el modelo base en comparación con los resultados obtenidos cuando se aplica el modelo propuesto en parejas identificadas por la columna Groups I.

Límite	Precisión @20 SoA	Precisión @20 Groups I
3,5	0,57721199	0,582198823
3,6	0,539987222	0,53438429
3,7	0,445946694	0,479588868
3,8	0,352094091	0,370015777
3,9	0,318656813	0,327256815
4	0,240865215	0,298661429
4,1	0,103914359	0,13151161
4,2	0,113855422	0,142771084
4,3	0,070567986	0,095481928
4,4	0,048192771	0,076506024

Tabla 9. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a parejas

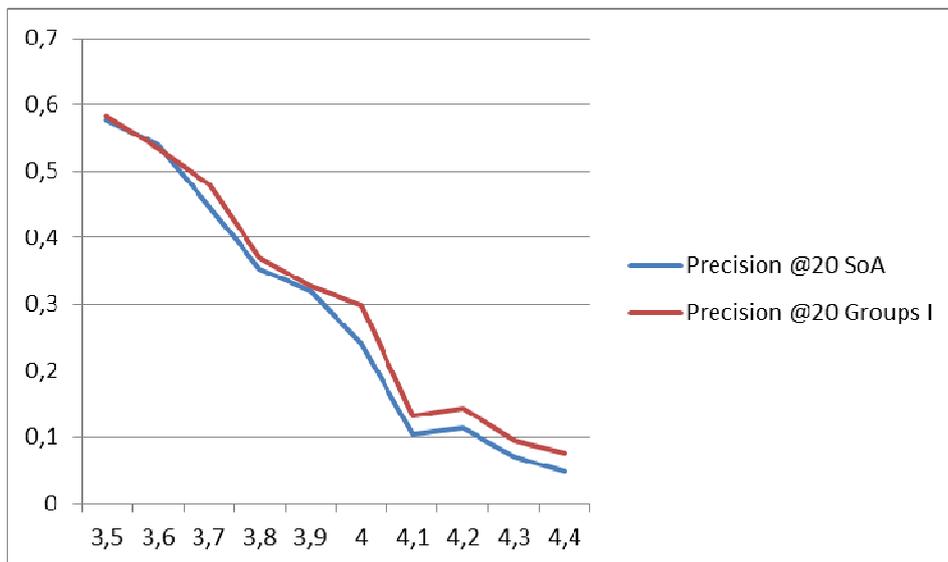


Figura 27. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a parejas

Límite	Recall @20 SoA	Recall @20 Groups I
3,5	0,214969619	0,208732263
3,6	0,169533082	0,176336364
3,7	0,135132877	0,143079157
3,8	0,102132839	0,109945291
3,9	0,084719839	0,089390276
4	0,05386447	0,059588608
4,1	0,0421275	0,049717664
4,2	0,019792316	0,027861366
4,3	0,008168248	0,013418185
4,4	0,002895971	0,005602163

Tabla 10. Comparación de Recuerdo entre el modelo base y el modelo propuesto aplicado a parejas

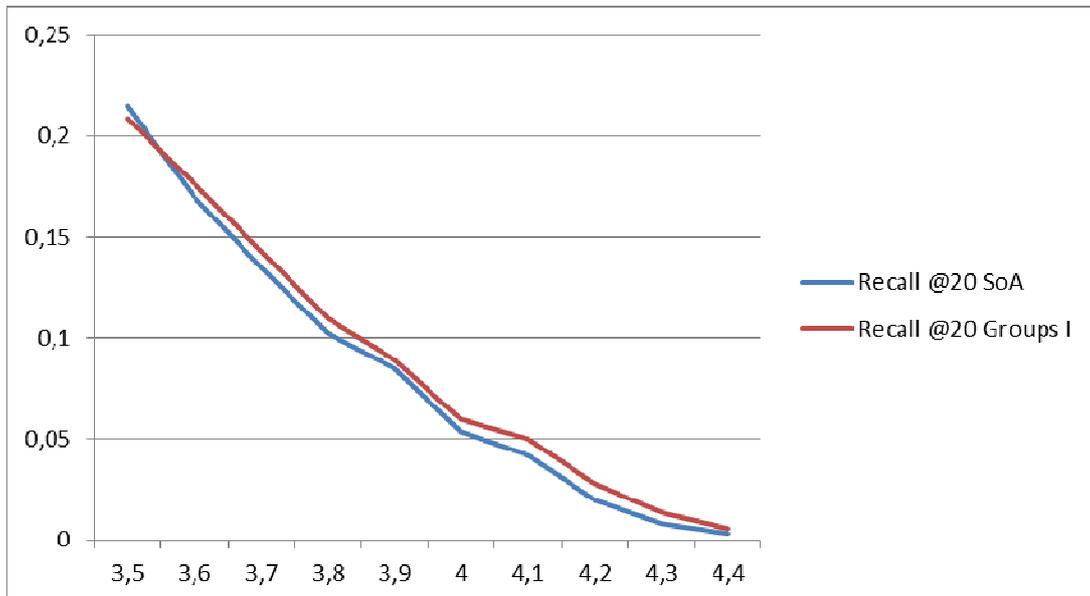


Figura 28. Recuerdo de modelo base vs modelo propuesto

Límite	F1 Score @20 SoA	F1 Score @20 Groups I
3,5	0,297715492	0,288881354
3,6	0,238130223	0,247126259
3,7	0,192550173	0,202957136
3,8	0,146746922	0,157829201
3,9	0,121958792	0,130587429
4	0,080608068	0,089834964
4,1	0,052685843	0,065099141
4,2	0,027597969	0,040716638
4,3	0,013520056	0,021517382
4,4	0,005433499	0,010123701

Tabla 11. Comparación del F1-Score entre el modelo base y el modelo propuesto aplicado a parejas

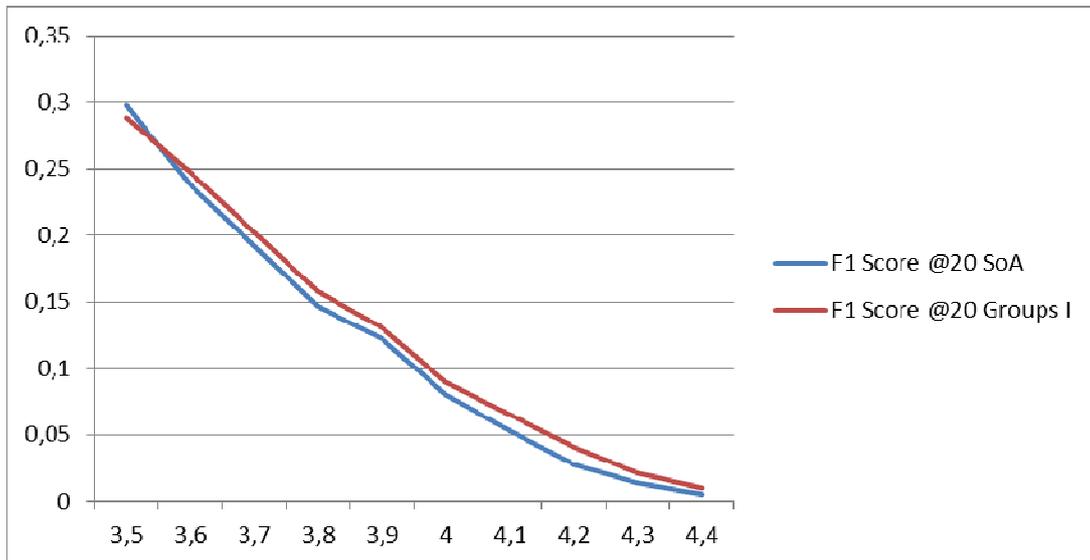


Figura 29. Comparación del F1-Score entre el modelo base y el modelo propuesto aplicado a parejas.

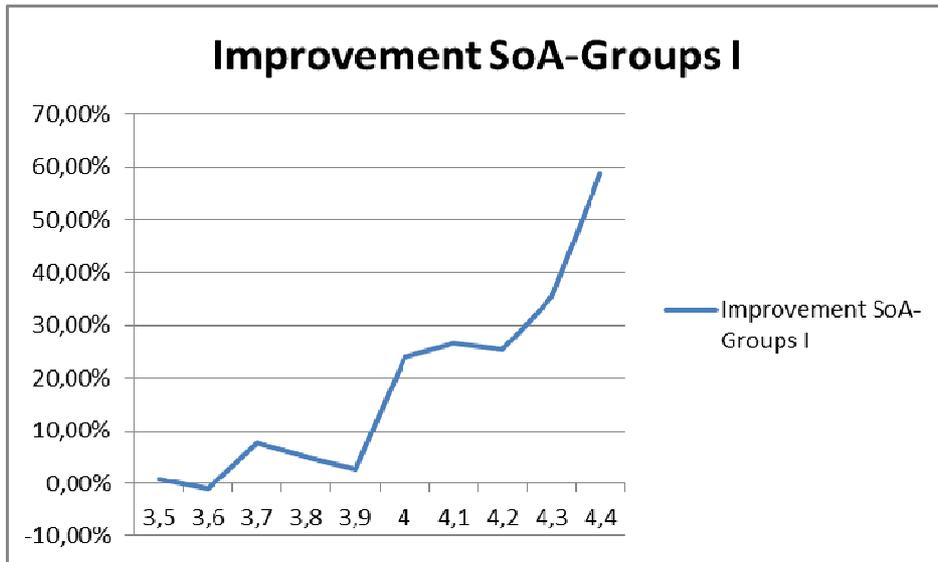


Figura 30. Mejora de la precisión entre el modelo base y el modelo propuesto cuando es aplicado a parejas.

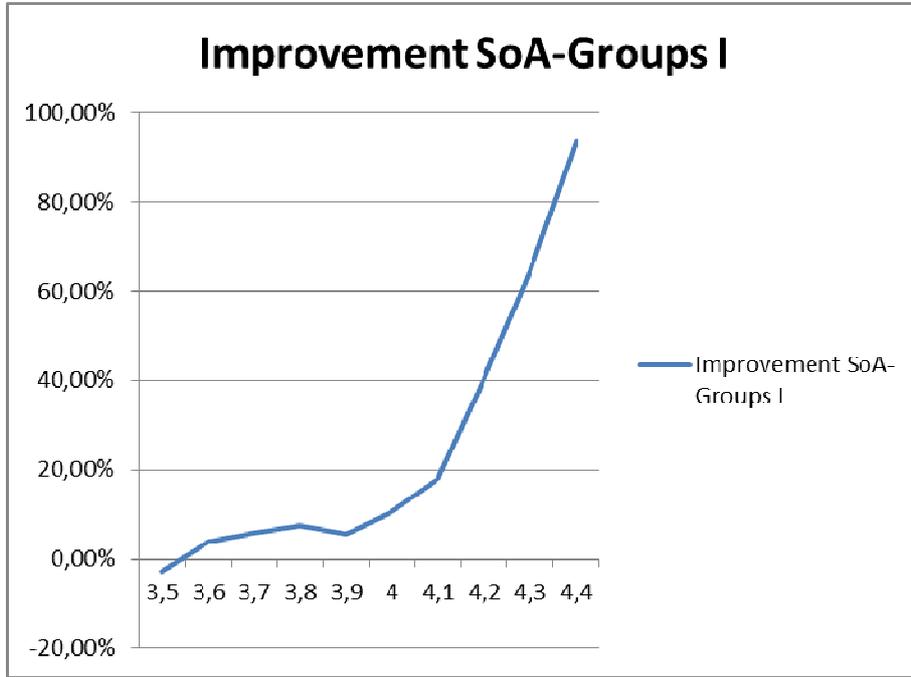


Figura 31. Mejora del recuerdo entre el modelo base y el modelo propuesto cuando es aplicado a parejas.

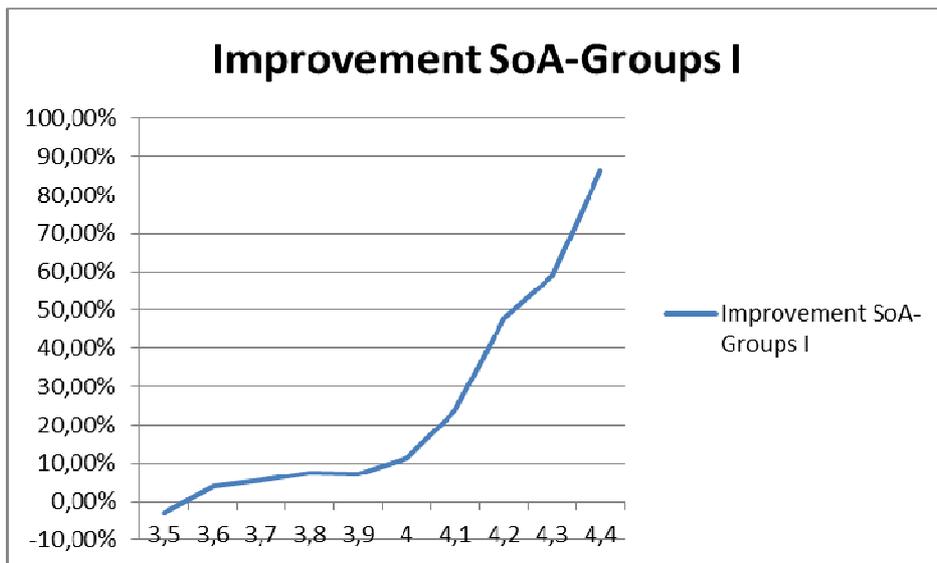


Figura 32. Mejora del F1-score entre el modelo base y el modelo propuesto cuando es aplicado parejas.

### 6.5.3 Evaluación del modelo en tríos

Las siguientes figuras y tablas muestran los resultados obtenidos cuando se realiza la evaluación para el modelo base en comparación con los resultados obtenidos cuando se aplica el modelo propuesto en tríos identificados por la columna Groups II.

Límite	Precisión @20 SoA	Precisión @20 Groups II
3,5	0,632789192	0,753651108
3,6	0,587732275	0,756384958
3,7	0,446710845	0,642257764
3,8	0,412303578	0,639913315
3,9	0,337802177	0,63685321
4	0,280691951	0,643678028
4,1	0,198906267	0,542080745
4,2	0,121307798	0,536151892
4,3	0,09075538	0,54148786
4,4	0,039278656	0,222990777

Tabla 12. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a tríos

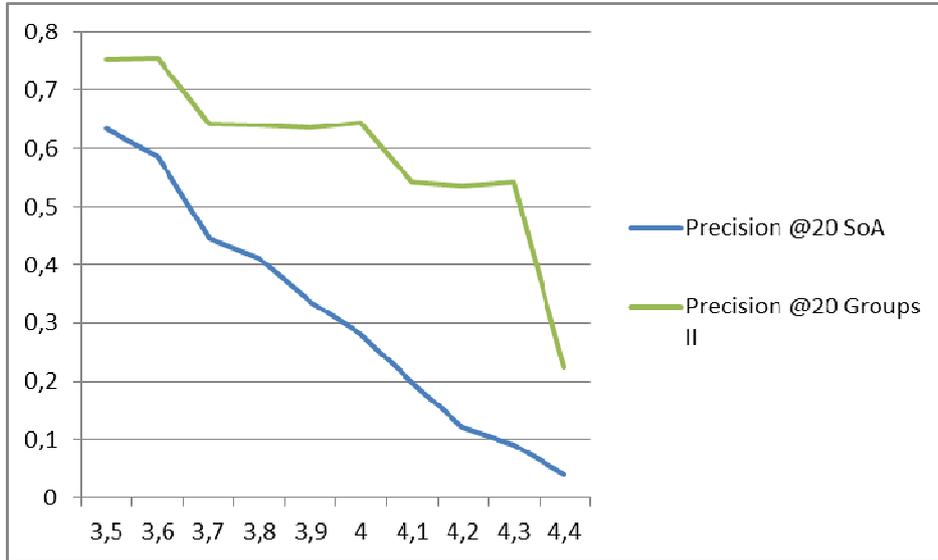


Figura 33. Comparación de precisión entre el modelo base y el modelo propuesto aplicado a tríos

	Recall @20 SoA	Recall @20 Groups II
3,5	0,812978017	0,734274393
3,6	0,705274785	0,717389949
3,7	0,633758249	0,591343966
3,8	0,480807039	0,571905367
3,9	0,346354524	0,54559255
4	0,233187947	0,527089051
4,1	0,160842901	0,381876216
4,2	0,072299078	0,360064935
4,3	0,03532844	0,35610766
4,4	0,015885564	0,120007529

Tabla 13. Comparación de Recuerdo entre el modelo base y el modelo propuesto aplicado a tríos

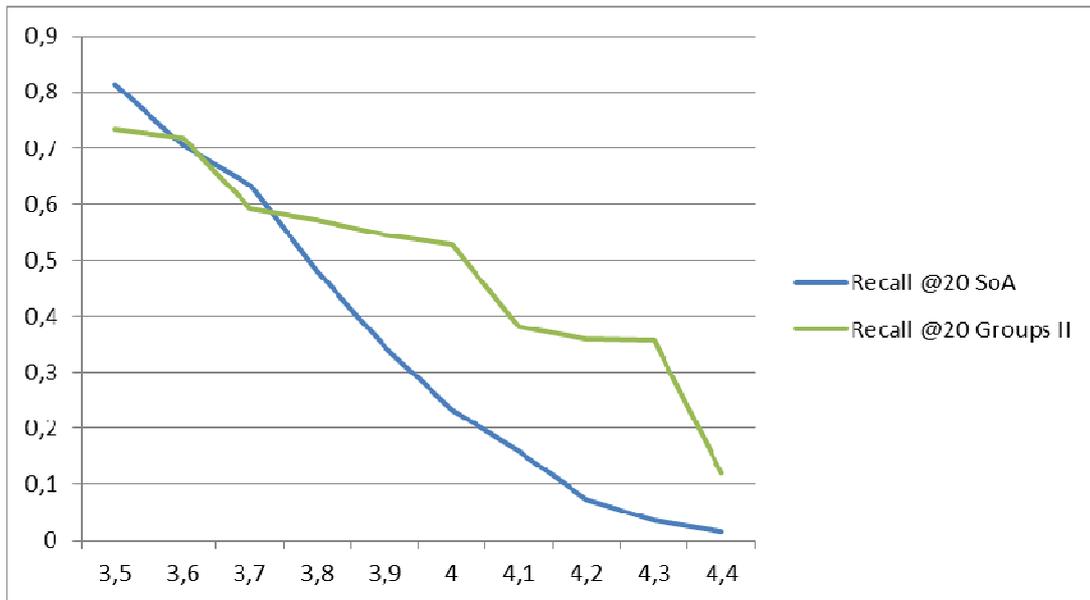


Figura 34. Comparación de recuerdo entre el modelo base y el modelo propuesto aplicado a tríos

	F1 Score @20 SoA	F1 Score @20 Groups II
3,5	0,684298313	0,72376839
3,6	0,619476595	0,715925347
3,7	0,488678016	0,584541577
3,8	0,401580855	0,572257724
3,9	0,305970049	0,555412824
4	0,219713359	0,545645939
4,1	0,143438301	0,406247145
4,2	0,077177149	0,389555482
4,3	0,0448176	0,388416327
4,4	0,019652916	0,142289353

Tabla 14. Comparación del F1-Score entre el modelo base y el modelo propuesto aplicado a tríos.

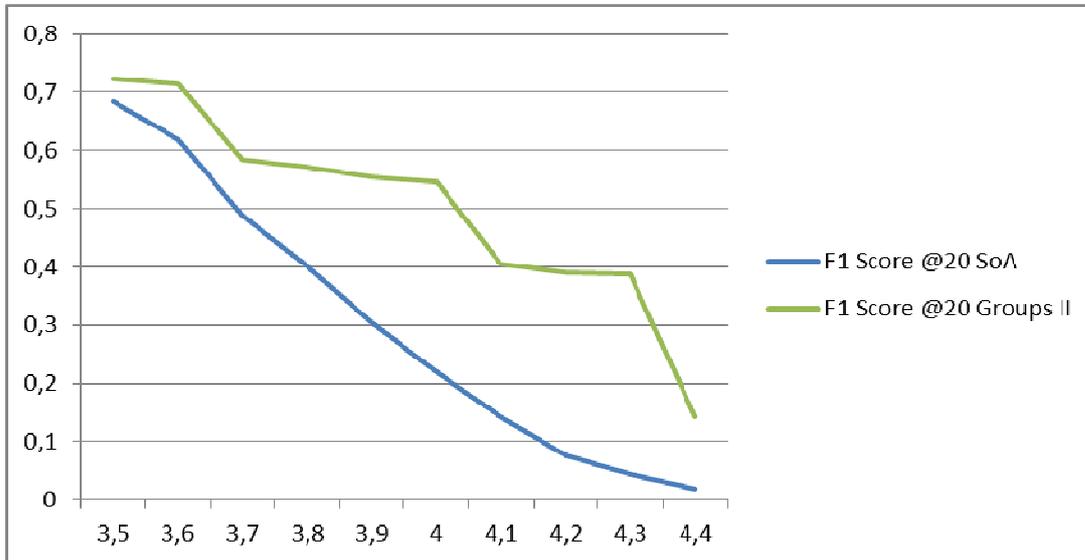


Figura 35. F1-Score de modelo base vs modelo propuesto.

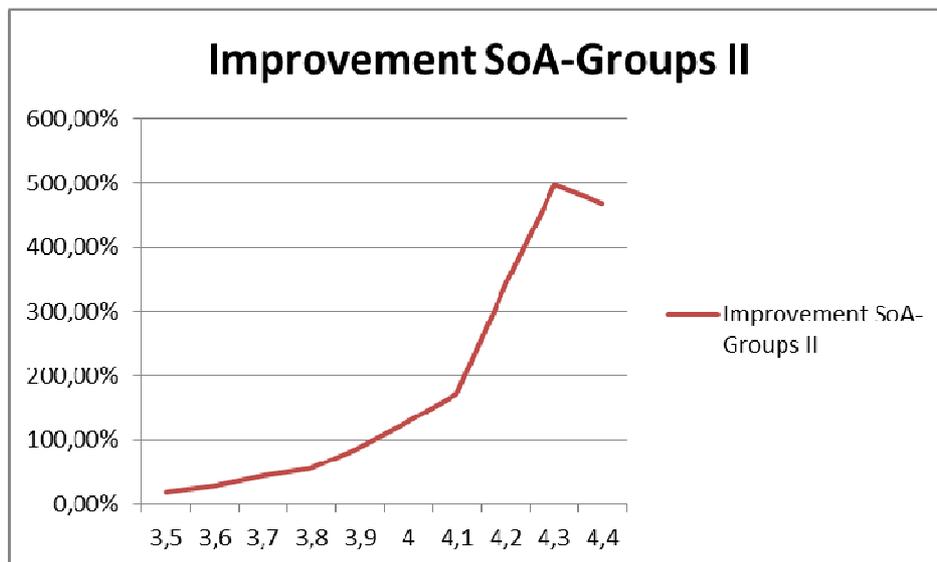


Figura 36. Mejora de la precisión entre el modelo base y el modelo propuesto cuando es aplicado a tríos.

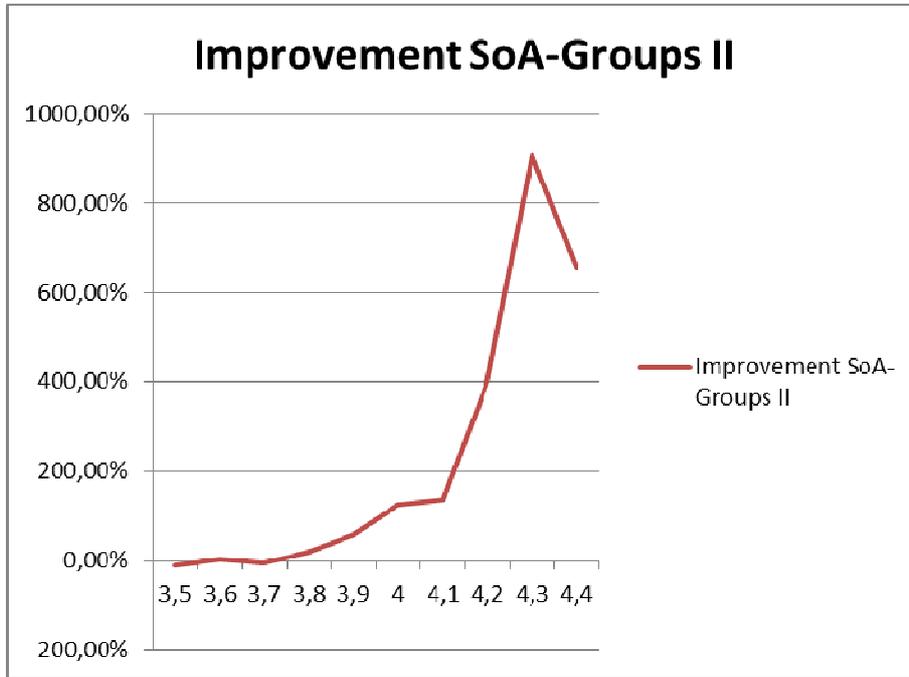


Figura 37. Mejora del recuerdo entre el modelo base y el modelo propuesto cuando es aplicado a tríos.



Figura 38. Mejora del F1-score entre el modelo base y el modelo propuesto cuando es aplicado tríos.

Las mejoras logradas cuando el modelo propuesto se aplica a grupos de tres personas se hacen cada vez más grande a medida que se aumenta el límite de predicción. Durante la evaluación del modelo se detectó que el modelo de línea base identifica pocos ítems para ser recomendados al usuario, lo cual hace que los cálculos precisión y recuerdo sean muy bajos en comparación con el modelo propuesto. Como se explicó anteriormente, el modelo propuesto tiene la capacidad de identificar más elementos mediante la asociación de individuos y grupos que comparten el mismo perfil demográfico. La mejor correspondencia entre ítems recomendados por el modelo de línea base y el modelo propuesto se presenta cuando el límite de predicción de encuentra entre 4.0 y 4.1. El mismo fenómeno ocurre para grupos de dos personas. Además, dadas las características del conjunto de datos, a medida que el número de miembros de un grupo se incrementa, también se hace más difícil encontrar ítems en común, lo cual reduce la cantidad de ítems de entrenamiento y evaluación.

#### 6.5.4 Evaluación de métricas de error

Las siguientes figuras y tablas muestran los resultados obtenidos para las métricas de error definidas en la sección 8.3. Se realiza la evaluación para el modelo base en comparación con los resultados obtenidos cuando se aplica el modelo propuesto en parejas y tríos identificados por la columna Groups I y Groups II respectivamente.

	MAE SoA	MAE Groups I	MAE Groups II	SoA - Groups I	SoA - Groups II
3,5	0,774017712	0,778427665	0,6912198	-0,57%	10,70%
3,6	0,760893505	0,765552824	0,676430518	-0,61%	11,10%
3,7	0,744770809	0,749905614	0,661157025	-0,69%	11,23%
3,8	0,722205479	0,728522671	0,648873072	-0,87%	10,15%
3,9	0,706344908	0,712561848	0,626689189	-0,88%	11,28%
4	0,693151367	0,696532933	0,568	-0,49%	18,06%
4,1	0,682140035	0,686148832	0,342465753	-0,59%	49,80%
4,2	0,686783471	0,685859739	0,36	0,13%	47,58%
4,3	0,650027087	0,647430203	0,2	0,40%	69,23%
4,4	0,608755451	0,597230557	0,25	1,89%	58,93%
4,5	0,548223452	0,544188067	0,125	0,74%	77,20%

Tabla 15. Comparación del MAE entre el modelo base y el modelo propuesto

	RMSE SoA	RMSE Groups I	RMSE Groups II	SoA - Groups I	SoA - Groups II
3,5	0,973101555	0,977964394	0,991121458	-0,50%	-1,85%
3,6	0,964232145	0,968488364	0,972720559	-0,44%	-0,88%
3,7	0,953125777	0,957554359	0,934002122	-0,46%	2,01%
3,8	0,931193169	0,939228093	0,920956746	-0,86%	1,10%
3,9	0,916997602	0,924000314	0,888173041	-0,76%	3,14%
4	0,888781664	0,894714748	0,827848617	-0,67%	6,86%
4,1	0,853344328	0,860678729	0,73092173	-0,86%	14,35%
4,2	0,855496645	0,853709721	0,748331477	0,21%	12,53%
4,3	0,801456164	0,797840878	0,447213595	0,45%	44,20%
4,4	0,778090841	0,765739237	0,5	1,59%	35,74%
4,5	0,747447561	0,732068354	0,353553391	2,06%	52,70%

Tabla 16. Comparación del RMSE entre el modelo base y el modelo propuesto

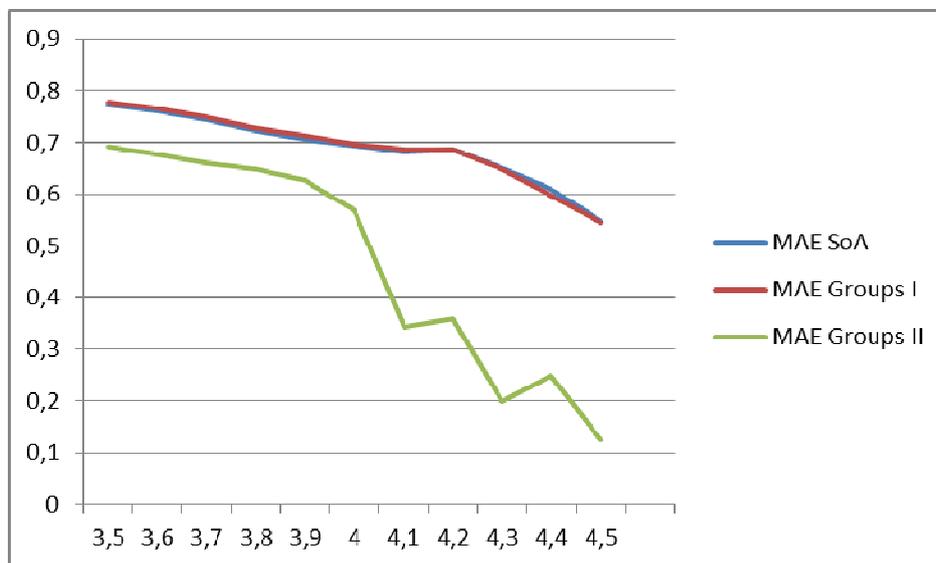


Figura 39. Comparación del MAE entre el modelo base y el modelo propuesto

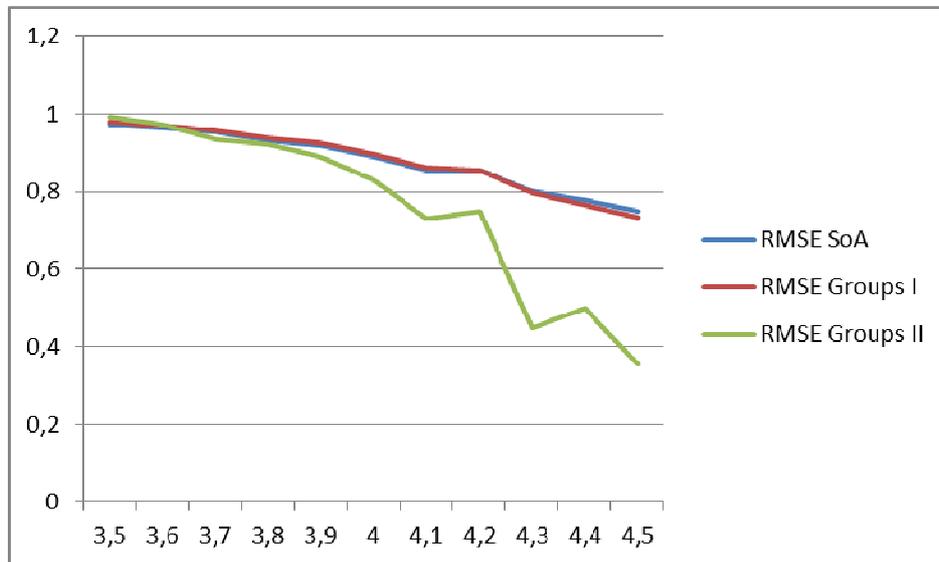


Figura 40. Comparación del RMSE entre el modelo base y el modelo propuesto

Las valores de error para parejas son muy parecidas a los errores para el modelo de línea base. El modelo propuesto no intenta mejorar estas métricas, pues como se explicó en la sección 8.3, estas medidas no son significativas para el usuario.

## 7 CONCLUSIONES Y RECOMENDACIONES

Los sistemas de recomendación son especialmente útiles cuando la sobrecarga de opciones de contenido a la que se ve expuesto un usuario puede resultar en que a los usuarios se les dificulte encontrar la información que les pueda resultar interesante. Para ello, la aplicación de una combinación de técnicas de filtrado por contenido y filtrado colaborativo elegidas y aplicadas de manera cuidadosa y sistemática pueden llevar a obtener muy buenos resultados de recomendación. Es decir, que la lista de ítems de contenido que finalmente el sistema le recomienda a un usuario, cuenta con muy pocos o ningún ítem que no le resulte relevante al usuario.

Las técnicas de filtrado colaborativo son particularmente susceptibles a la realimentación que los usuarios provean al sistema, lo cual se realiza usualmente de manera explícita mediante una calificación positiva o negativa que un usuario da a un cierto contenido dependiendo de la relevancia que tuvo para él. Estos datos de realimentación son usados para identificar a otros usuarios del sistema que tengan gustos parecidos a los de dicho usuario y con los cuales se compartirá información sobre otros ítems que no hayan sido vistos por él. Además, dicha realimentación puede usarse como parte del filtrado por contenido, pues ayuda a determinar los gustos de los usuarios y a relacionarlos con los ítems que aún no han visto y que tienen características que el sistema ha identificado como preferencias del usuario.

Mediante la creación y utilización de variables que refuercen o debiliten las relaciones entre usuarios e ítems de acuerdo con sus respectivos gustos y características, pueden obtenerse mejoras en las recomendaciones para grupos e

individuos televidentes. De lo anteriormente expuesto se desprende que el conocimiento del usuario en cuanto a sus preferencias se refiere forma parte fundamental de la capacidad de mejorar las recomendaciones en un sistema como el que se propone en este documento. Estas mejoras se producen tanto para individuos televidentes como para grupos de televidentes y son producto de la capacidad que tiene el modelo propuesto de detectar preferencias de usuarios y grupos con el mismo perfil demográfico.

Para finalizar, aunque se encuentra fuera del alcance de este proyecto, la construcción de un conjunto de datos que contenga de manera explícita los gustos de un grupo de televidentes es de vital importancia para producir mejoras en las recomendaciones que se presentan a un grupo de televidentes sentados en frente de un mismo televisor. La mayor dificultad en este sentido se presenta porque dadas las características del conjunto de datos de Movielens, a medida que el número de miembros de un grupo se incrementa, también se hace más difícil encontrar ítems en común, lo cual reduce la cantidad de ítems de entrenamiento y evaluación. Además, para individuos y grupos resultaría interesante correlacionar sus preferencias con datos de su contexto (por ejemplo horarios, estados de ánimo o días de la semana entre otros). La modificación de los valores de las variables que se encargan del reforzamiento o el debilitamiento de la relación usuario/grupo – ítem puede ser modificada mediante la aplicación de un modelo de red neuronal que actualice dichos valores de forma automática. También podrían evaluarse las mejoras que podría producir tener la posibilidad de contar con valores de estas variable para cada individuo o grupo en comparación con la carga de procesamiento y almacenamiento que ello requiere.

## BIBLIOGRAFÍA

AKKERMANS, Paul, AROYO, Lora y BELLEKENS, Pieter. ifanzy: Personalised filtering using semantically enriched tv-anytime content [Online]. Eindhoven: Eindhoven University of Technology, 2005. (Citada: 19 mayo 2009) <<http://kmi.open.ac.uk/events/eswc06/demo-papers/FD36-Lora.pdf>>

ATARASHI, Ray, KISHIGAMI, Junichi y SUGIMOTO, Shigeo. Metadata and new challenges. En: 2003 SYMPOSIUM ON APPLICATIONS AND THE INTERNET WORKSHOPS (1:2003:). Proceedings of the 2003 Symposium on Applications and the Internet Workshops SAINT'03 Workshops. Washington: IEEE Computer Society, p. 395-398.

BELLEKENS, Pieter et al. Sensee framework for personalized access to TV content [Online]. Amsterdam: Departamento de Ciencias de la Computación Universidad de Amsterdam, 2007. (Citada: 17 mayo 2009) <<http://www.cs.vu.nl/~pmika/swc-2007/SenSee.pdf>>

BERNHaupt, Regina et al. An Ethnographic Study on Recommendations in the Living Room. Implications for the Design of iTV Recommender Systems. En: Lectures notes in Computer Science. Julio, 2008. Vol. 5066.

BHAIDANI, Sameer. Recommender Systems Algorithms. Toronto, 2008, 47 p. Trabajo de grado (Bachelor of Applied Science), University of Toronto. Department of Mechanical and Industrial Engineering.

BIEZUNSKI, Michel. A matter of perspectives. Talking about talking about topic maps [Online]. Montreal: Extreme Markup Languages, 2005. (Citada: 10 mar 2009). <<http://antonieta.philo.unibo.it/IUcorso2007-08/materiali/EML2005Biezunski01.pdf>>

BURKE, Robin. Hybrid Recommender Systems: Survey and Experiments. En: User Modeling and User Adapted Interaction. Noviembre, 2002. Vol. 12, no 4, p. 331-370.

CESAR, Pablo y CHPORIANOPULOS, Konstantinos. The Evolution of TV Systems, Content, and Users Toward Interactivity. En: Foundations and Trends in Human-Computer Interaction. Marzo, 2009. Vol. 2, no 4, p. 279-374.

CLEVERDON, C. MILLS, J. KEEN, M. (1966). ASLIB Cranfield project, Cranfield.

COMISIÓN NACIONAL DE TELEVISIÓN (2008). La Gran Encuesta de la Televisión en Colombia. (Citada 07 de julio de 2011) <[http://www.cntv.org.co/cntv\\_bop/noticias/2008/abril/gran\\_encuesta.pdf](http://www.cntv.org.co/cntv_bop/noticias/2008/abril/gran_encuesta.pdf)>

CREMONESI , P., KOREN, Y., TURRIN, R. Performance of recommender algorithms on top-n recommendation tasks, Proceedings of the fourth ACM conference on Recommender systems, September 26-30, 2010, Barcelona, Spain [doi>10.1145/1864708.1864721]

DAS, D. and TER HORST H.: 1998, 'Recommender Systems for TV'. Technical Report WS-98-08 Recommender System, Papers from the 1998 Workshop, Madison, WI. Menlo Park,CA: AAAI Press, pp. 35-36.

DE PESSEMIER, Toon y MARTENS, Luc. A profile based recommendation system for TV-anytime annotated content. En: FirW PhD Symposium (8:2008:Gent). Proceedings of the, 8th FirW PhD Symposium. Gent: University of Gent, 4p.

ESTADOS UNIDOS. Academy of Television Arts and Sciences. Interactive Television Emmy to be Voted Online [Online]. (Citada: 28 feb. 2009).< <http://www.emmys.tv/news/2004/interactive-television-emmy-be-voted-online>>

ESTADOS UNIDOS. ITA Interactive Television Alliance. Interactive television: a short history [Online]. (Citada: 13 mar. 2009).< <http://www.itvalliance.org/>>

FREED, Ken. When cable went qubist. The Qube network in the Seventies set the mark for interactive TV, but the business case was a bust [Online]. (Citada: 22 mar. 2009).< <http://www.media-visions.com/itv-qube.html>>

GAWLINSKI, Mark. Interactive Television Production. Oxford: Focal Press, 2003. p.273. ISBN 0240516796.

GEYER-SCHULZ, A., HAHLER, M. (July 2002) In Fourth WebKDD Workshop: Web Mining for Usage Patterns & User Profiles (July 2002), 100-114.

GUTTA, Srinivas. .. Tv content recommender system. En: National Conference on Artificial Intelligence y Twelfth Conference on Innovative Applications of Artificial Intelligence (7:2000:Austin). Proceedings of the Seventeenth National Conference on Artificial Intelligence y Twelfth Conference on Innovative Applications of Artificial Intelligence. Boston: The MIT Press, p.1121-1122.

HALLE, T. (2003). Standards for interactive television: A brief state of the union. (Citada 8 de abril de 2009) <<http://etvcookbook.org/reference/standards.html>>

HERLOCKER, J. KONSTAN, J. TERVEEN, L. RIEDL, J. (2004). Evaluating collaborative filtering recommender systems. ACM Trans. Inf. Syst. 22, 1 (January 2004), 5-53.

HSU, Shang et al. AIMED- A Personalized TV Recommendation System. En: Lecture Notes in Computer Sciences. Junio, 2007. Vol. 4471.

KIM, Taehwan, JEON, Hochul y CHOI, Joongmin. Personalized Information Retrieval Using the User History. En: International Conference on Multimedia and Ubiquitous Engineering (MUE2008) (2:2008:Busan). Proceedings of the 2<sup>nd</sup> International Conference on Multimedia and Ubiquitous Engineering (MUE2008). Washington: IEEE Computer Society, p. 229-232.

KOWALSKI, Gerald y MAYBURY, Mark. Information Storage and Retrieval Systems-Theory and Implementation. 2 ed. S.L: Kluwer Academic Publishers, 2000.p.2..

LI, Wei y SUN, Maosong. Incorporating Prior knowledge into multi-label boosting for cross-modal image annotation and retrieval. En: Lecture notes in Computer Science. Octubre, 2006, Vol. 4182. ISSN 0302-9743.

LIANG, Ting-Peng, LAI, Hung-Jen y KU, Yi-Cheng. Personalized Content Recommendation and User Satisfaction. Theoretical Synthesis and Empirical Findings. En: Journal of Management on Information Systems. Enero, 2007. Vol. 23, no. 3, p. 45-70.

LIM, Joo-Hwee y JIN, Jesse. A structured learning framework for content-based image indexing and visual query. En: Multimedia Systems. Abril, 2005, Vol. 10, no. 4. ISSN 0942-4962.

LU, Karyn Y. Interaction design principles for interactive television. Atlanta, 2005, p.219. Trabajo de grado (Master of Science in Information Design and Technology). Georgia Institute of Technology. School of Literature Communication and Culture.

LUETTEKE, George. Multimedia Home Platform. En: DIGITAL VIDEO BROADCASTING SEMINAR (1:2001:Taipei) Presentación DVB Seminar. Taipei, 2001. p.59.

MATHES, Adam. El Cooperative Classification and Communication Through Shared Metadata [Online]. Urbana: University of Illinois at Urbana-Champaign, 2004. (Citada: 08 julio 2009) <<http://www.adammathes.com/academic/computer-mediated-communication/folksonomies.html>>

MELVILLE, Prem y SINDHWANI, Vikas. Recommender Systems [Online]. New York: IBM T.J. Watson Research Center, 2010. (Citada 8 septiembre de 2009) <<http://people.cs.uchicago.edu/~vikass/recommender.pdf>>

MÉNDEZ, Eva. Metadatos y recuperación de información. Estándares, problemas y aplicabilidad en bibliotecas digitales. S.l: Ediciones Trea, 2002. 429 p.

MORRIS, Steven y SMITH-CHAIGNEAU, Anthony. Interactive TV Standards. A Guide to MHP, OCAP, and JavaTV. Oxford: Focal Press, 2005. p.1. ISBN 0240806662.

MORTENSEN, Magnus. Design and Evaluation of a Recommender System. Tromso, 2007, 109 p. Trabajo de grado (Master in Computer Science), University of Tromso. Department of Computer Science.

O'DONNOVAN, John y SMYTH, Barry. Trust in Recommender Systems. En: International Conference on Intelligent User Interface (10:2005:San Diego). Proceedings of the 10th International Conference on Intelligent User Interface. New York: ACM Press, p. 167-174.

SAYKOL, Ediz, GUDUKBAY, Ugur y OLUZOY, Osgur. A semiautomatic object extraction tool for querying in multimedia database [Online]. Ankara: Bilkent University, 2001. (Citada: 07 abr 2009). <<http://www.cs.bilkent.edu.tr/~bilmdg/papers/mis01.pdf>>

SHANI, G. GUNAWARDANA, A. (2011). Evaluating Recommendation Systems. In Recommender Systems Handbook. pp. 257-297.

SILVA, Fabio, ALVES, Luiz, BRESSAN, Graca. Personal TVware: A Proposal of Architecture to Support the Context-aware Personalized Recommendation of TV Programs [Online]. Leuven: Catholic University of Leuven, 2009. (Citada: 20 noviembre 2009) <  
[http://soc.kuleuven.be/com/mediac/euroitv2009/docs/adjunct\\_proceedings/posters/SANTOS,%20FABIO,%20et%20al.%20-%20Posters.pdf](http://soc.kuleuven.be/com/mediac/euroitv2009/docs/adjunct_proceedings/posters/SANTOS,%20FABIO,%20et%20al.%20-%20Posters.pdf) >

SULLIVAN, D., SMYTH, B., MCDONALD, K., SMEATON, A. Interactive Television Personalization: from guides to programs en Personalized Digital Television. Netherland, 2004, 73-91.

TIAN, Qi. Multimedia Information Retrieval [Online]. San Antonio: University of Texas at San Antonio, 2007. (Citada: 14 mayo 2009) <http://lyle.smu.edu/~mhd/8337sp09/mir.pdf>

UCHYIGIT, Gulden y CLARK, Keith. Agents that Learn to give Personalized TV Program recommendations [Online]. Londres: Department of Computing Imperial College of Science, Technology and Medicine, 2002. (Citada: 20 septiembre 2009) <  
<http://www.aaai.org/Papers/Symposia/Fall/2002/FS-02-04/FS02-04-009.pdf>>

VAN SETTEN, M. (2005). Supporting people in finding information: hybrid recommender systems and goal-based structuring. (Citada el 11 de Julio de 2011) <  
[http://doc.utwente.nl/50889/1/thesis\\_van\\_Setten.pdf](http://doc.utwente.nl/50889/1/thesis_van_Setten.pdf)>

VIVANCOS, Pedro. Descripción de contenidos multimedia: introducción al estándar MPEG-7 [Online]. Murcia: Ilustre Colegio de Ingenieros en Informática en la región de Murcia, 2004. (Citada: 13 mayo 2009) <  
[http://www.cii-murcia.es/informas/jul05/articulos/EI\\_estandar\\_MPEG-7.php](http://www.cii-murcia.es/informas/jul05/articulos/EI_estandar_MPEG-7.php)>

WEI, Chia-Hung y LI, Chang-Tsun. Content-Based Multimedia Retrieval. Introduction, Applications, Design of content-based retrieval systems, Feature extraction and representation, Low-level features, High-level features [Online]. United Kindong: University of Warwick, 2006. (Citada: 10 jun 2009). <  
<http://encyclopedia.jrank.org/articles/pages/6567/Content-Based-Multimedia-Retrieval.html> >