

UNIVERSIDAD DE CUENCA



FACULTAD DE INGENIERÍA

ESCUELA DE INGENIERÍA DE SISTEMAS

“Sistema de Recomendación de Contenidos Audiovisuales basado en Tecnologías Semánticas para Grupos de Usuarios de TV Digital”

UNIVERSIDAD DE CUENCA
desde 1867

Tesis previa a la obtención del
título de Ingeniero de Sistemas

Autores:

Wilson Vinicio Monge Llivisaca.
Martha Angélica Sapatanga Guartasaca.

Director:

Ing. Kenneth Samuel Palacio Baus, MSc.

Co-Director:

Ing. Jorge Mauricio Espinoza Mejía, Ph.D.

Cuenca - Ecuador
2015

Resumen

Palabras clave: Sistema de Recomendación de Grupos, Reconocimiento Facial, Grupos Homogéneos, Grupos Heterogéneos, Ontologías, Tecnologías Semánticas.

En el mundo de hoy, la cantidad de información generada por las personas en diversos contextos se incrementa de manera acelerada, debido mayormente a la facilidad de acceso a medios de consulta electrónicos y a la rápida evolución de la tecnología. Es así que una actividad simple como una búsqueda de contenidos puede convertirse en una tarea compleja como consecuencia de la *Sobrecarga de Información* que un usuario enfrenta tras descubrir una abrumadora cantidad de fuentes sobre las cuales elegir. En el ámbito del entretenimiento audiovisual, se han propuesto diferentes enfoques que buscan mejorar la experiencia del usuario a través de facilitar la selección de contenidos mediante el uso de *Sistemas de Recomendación - SR*, que reducen la cantidad de opciones de entretenimiento disponibles en función de sus preferencias, descartando aquellas que considera fuera del marco de sus intereses. La aplicación de SR se ha extendido a diversos dominios, destacándose su efectividad en la mayoría de actividades cotidianas tales como: viajes vacacionales, visitas a museos, programación de televisiva, compras, etc. Sin embargo, es importante mencionar que los SR se ha utilizado principalmente pensando en usuarios individuales, sin considerar que la mayoría de las actividades mencionadas suelen realizarse de forma grupal, por lo que se estima necesario extender su uso para grupos de usuarios.

Para este trabajo, se considera el dominio de la recomendación de contenidos audiovisuales para grupos de usuarios de Televisión Digital Terrestre - TDT, actividad de entretenimiento cotidiana que al igual que muchas otras suele desarrollarse en grupo, tal como es el caso de una familia disfrutando de una película o el de un grupo de amigos mirando fútbol un domingo por la tarde. Con este objetivo, se ha propuesto un sistema que extiende el trabajo desarrollado para un sistema de recomendación de usuarios individual mediante el uso de tecnologías semánticas. Las recomendaciones se generan a partir de la inferencia de conocimiento realizada a partir de la información de un perfil ontológico, construido a partir del historial de programación televisiva evaluada por el usuario.

Puesto que el sistema se enfoca en grupos de usuarios, este trabajo propone una etapa de identificación de los televidentes mediante técnicas de reconocimiento facial aplicado a las imágenes capturadas por un video cámara integrada



al televisor, o en su defecto al dispositivo receptor de señal digital conocido como *set-top-box*, facilitando así los procedimientos de autenticación. La correcta identificación de los miembros de un grupo de televidentes posibilita entonces la aplicación de técnicas de recomendación grupal en función de la creación de perfiles ontológicos que asocian las preferencias de todos sus miembros y también, en función de un procesamiento de agregación de las recomendaciones generadas para cada miembro. La aplicación de un enfoque determinado depende de la naturaleza del grupo identificado, puesto que en general sus miembros pueden tener mucha afinidad en sus gustos y preferencias televisivas o ser totalmente diferentes, lo que la literatura denomina grupos *homogéneos* y *heterogéneos* respectivamente. Bajo esta consideración, el sistema propuesto incluye un componente que permite discriminar la naturaleza de un grupo y con ello evaluar diferentes algoritmos de recomendación grupal.

El sistema desarrollado ha sido evaluado mediante el establecimiento de grupos de diferentes tamaños, considerando que éstos pueden conformarse a partir de una familia tipo de cinco miembros y contemplando todas sus posibles combinaciones, para las cuales se incluye diferentes rangos de edad y la presencia de niños.

Wilson Vinicio Monge Llivisaca
Martha Angélica Sapatanga Guartasaca

UNIVERSIDAD DE CUENCA
desde 1867

Abstract

Keywords: Recommender Systems for Groups of Users, Face Recognition, Homogeneous Groups, Heterogeneous Groups, Ontology, Semantic Technology.

Nowadays, the increasing amount of data generated by people in several domains has turned very simple tasks such as content searching, into an overwhelming activity exacerbated by the information overload that users experience. In the context of audiovisual entertainment, several approaches have been proposed aimed to improve the content selection process. Specifically, the use of Recommender Systems (RS) focuses on reducing the amount of available options to choose from, by narrowing searches making use of user's preferences information.

Recommender Systems have been successfully applied to several domains and daily activities including traveling, shopping, TV programs, etc. However, most of these approaches focus on individual users in spite of the fact that such activities are normally performed with others. Therefore, we identified the need for RS for groups of users, in particular, we consider the domain of audiovisual content recommendation for Digital Terrestrial Television (DTT) broadcasting, since it stands as a very common group activity for families and friends.

This work proposes a system that extends the work developed for an individual users recommender systems using semantic technology, in which recommendations are produced from a knowledge inference process performed by creating ontological profiles built up from the user television program watching history. Since the system focuses on groups of users, we also present an automatic user identification component based on face recognition techniques, by introducing the incorporation of a video camera in the TV set, or into the set-top-box receiver. A correct user authentication process makes it possible to generate group recommendations once every user located in front of the TV is identified by either, using a common ontological profile or performing an individual recommendation aggregation procedure. The use of a given group recommendation technique relies on an additional process that discriminates homogeneous groups from heterogeneous groups. The former corresponds to those whose member's preferences are very similar and the latter corresponds to the opposite. Under this consideration it has been possible to analyze different group recommendation algorithms.



The developed system has been evaluated by producing recommendations for several groups of users, which have been established by considering all the available combinations from a five members set, including in some cases the presence of children.

Wilson Vinicio Monge Llivisaca
Martha Angélica Sapatanga Guartasaca



Índice general

Resumen	2
Abstract	4
Índice general	6
Índice de figuras.	9
Índice de tablas.	12
1. INTRODUCCIÓN	20
1.1. Planteamiento del Problema.	20
1.2. Antecedentes.	21
1.3. Objetivos.	22
1.3.1. Objetivo General	22
1.3.2. Objetivos Específicos	22
1.4. Justificación	23
1.5. Alcance	24
1.6. Organización de la Tesis	24
2. SISTEMAS DE RECOMENDACIÓN SEMÁNTICOS Y GRUPOS DE USUARIOS	26
2.1. Introducción	26
2.2. Ontologías y Web Semántica	27
2.2.1. Definición de Web Semántica	27
2.2.2. Componentes de la Web Semántica	27
2.2.3. Funcionamiento de la Web Semántica	29
2.2.4. Ontologías	29
2.2.5. OWL	31
2.3. Sistemas de Recomendación	32
2.3.1. Sistemas de Recomendación no Semánticos	33
2.3.2. Sistemas de Recomendación Semánticos	34
2.4. Sistemas de Recomendación para Grupos de Usuarios.	36
2.4.1. Lineamientos Generales para la Recomendación de Grupos de Usuarios	36
2.4.2. Modelado de un Grupo de Usuarios	38
2.4.3. Sistemas Recomendadores sin Enfoque Semántico	39
2.4.4. El Sistema de Recomendación Semántico AVATAR	41
2.5. Identificación de los Miembros de un Grupo	46
2.5.1. Identificación de Usuarios: Técnicas de Reconocimiento Facial	46



2.5.2.	Etapas Generales en un Proceso de Reconocimiento de Ros-tros	46
3.	DESARROLLO E IMPLEMENTACIÓN DEL SISTEMA	57
3.1.	Introducción	57
3.2.	Descripción del Sistema	57
3.2.1.	Antecedentes	57
3.2.2.	Herramientas de Software Utilizadas	58
3.2.3.	Base de Conocimiento	59
3.2.4.	Parámetros Ontológicos	61
3.2.5.	Arquitectura del Sistema	63
3.2.6.	Arquitectura de la Implementación del Sistema	64
3.2.7.	Algoritmo de Inferencia Semántica	66
3.3.	Identificación de Integrantes de Grupos de Usuarios	70
3.3.1.	Proceso de Captura de Imágenes y Detección	71
3.3.2.	Proceso de Entrenamiento	71
3.3.3.	Proceso de Reconocimiento	72
3.3.4.	Proceso de Optimización	73
3.4.	Procedimiento de Clasificación de Grupos	74
3.4.1.	Grupos Homogéneos y Heterogéneos	74
3.4.2.	Enfoque de Votación	75
3.4.3.	Enfoque de Promedios	83
3.4.4.	Clasificación de Grupo Promediando los Enfoques	85
3.5.	Algoritmo de Recomendación para Grupos Homogéneos	87
3.5.1.	Modelado de Grupo	87
3.5.2.	Técnica de Recomendación	87
3.6.	Algoritmo de Recomendación para Grupos Heterogéneos	89
3.6.1.	Generación de Recomendación Individual	90
3.6.2.	Cálculo de DOI	90
3.6.3.	Reducción de la Miseria(<i>miseriaAdjustment</i>)	91
3.6.4.	Función Control Parental	93
3.7.	Limitación del Sistema	94
3.7.1.	Problema de Arranque en Frío	94
4.	EVALUACIÓN DEL SISTEMA	96
4.1.	Introducción	96
4.2.	Procedimiento de Evaluación para el Sistemas de Recomendación de Grupos de Usuarios	96
4.2.1.	Análisis de los Datos	96
4.2.2.	Conformación de Grupos Pseudoaleatorios	97
4.2.3.	Conjunto de datos de entrenamiento y pruebas	100
4.2.4.	Métricas de Evaluación	102
4.2.5.	Procedimiento de Evaluación	103
4.3.	Evaluación del Sistema	104
4.3.1.	Algoritmos de identificación de usuarios	105
4.3.2.	Algoritmos de clasificación de grupos	106



4.3.3. Técnicas de recomendación para grupos homogéneos y heterogéneos	108
4.3.4. Técnicas de recomendación según el número de miembros	111
4.3.5. Técnicas de recomendación según el tipo de grupo	113
4.4. Análisis de Resultados	114
5. CONCLUSIONES Y TRABAJO A FUTURO	116
5.1. Conclusiones	116
5.2. Trabajo Futuro	118
Anexos	119
A. Tablas de Resultados	120
A.1. Módulo de Recomendación	120
A.1.1. Fusión de Perfiles vs Fusión de Recomendaciones para grupos homogéneos	120
A.1.2. Fusión de Perfiles vs Fusión de Recomendaciones para grupos heterogéneos	123
A.1.3. Fusión de Perfiles vs Fusión de Recomendaciones según tamaño de grupo	125
A.1.4. Fusión de Perfiles vs Fusión de Recomendaciones según tipo de grupo	125
A.2. Módulo de Reconocimiento	125
A.2.1. Resultados por técnicas: Eigenfaces, Fisherfaces y LBPH	125
A.2.2. Resultados según tamaño de grupo	126
A.2.3. Evidencias	127
B. Manual de Usuario	128
Bibliografía.	133

Índice de figuras.

1.1. Arquitectura del Sistema de Recomendación desarrollado en [9], [8]	22
1.2. Desarrollo de la DTV en el periodo 2008-2012 [1]	23
2.1. Capas de la web semántica.	28
2.2. Conceptualización humana de la película Piratas del Caribe.	30
2.3. Conceptualización de datos para una máquina.	30
2.4. Representación en lenguaje OWL.	31
2.5. Representación Ontológica del Sistema Avatar [12].	35
2.6. Generación de recomendación para grupos de usuarios	38
2.7. Estructura de fusión de perfiles [13].	39
2.8. Estructura de fusión de recomendaciones [13].	40
2.9. Representación Ontológica del Sistema Avatar basada en la norma TV-Anytime [56].	42
2.10. Vectores de las cuatro jerarquías para el usuario u_j [56]	43
2.11. Correlación del vector Intent para los usuarios u_j y u_k [56]	43
2.12. Correlación entre los usuarios u_j y u_k para los cuatro vectores de clasificación [56]	43
2.13. Proceso de recomendación para grupos homogéneos [56]	44
2.14. Proceso de recomendación para grupos heterogéneos [56]	45
2.15. Funcionamiento básico de una cámara web	48
2.16. Características Haar. [47]	48
2.17. Características Haar.	48
2.18. Uso del HaarCascade en una cara [47].	49
2.19. Técnica de la imagen integral [47]	49
2.20. Caras de entrenamiento. [47]	51
2.21. Eigenfaces. [47]	51
2.22. Conjunto de Eigenfaces con la imagen predominante en primer lugar. [47]	52
2.23. Representación Eigenfaces. [45]	53
2.24. Creación de Eigenfaces. [19]	53
2.25. Resumen de algoritmo Eigenfaces. [19]	54
2.26. LBPH Matriz. [58]	55
2.27. Codificación. [58]	56
2.28. Regiones para los descriptores. [58]	56
3.1. Descripción de una película en IMDB	60



3.2. Películas calificadas por los usuarios seleccionados	61
3.3. Ontología de las películas	62
3.4. Arquitectura del SRGU	63
3.5. Arquitectura de la implementación del sistema SRGU	65
3.6. Modelo ontológico de la película <i>Piratas del Caribe</i> [9]	67
3.7. Relación del recurso Johnny Deep con otros contenidos [9]	67
3.8. Secuencias uno y dos de la película “Piratas del Caribe” [9]	68
3.9. Conjunto de secuencias de propiedades [9]	68
3.10. Descomposición individual de la secuencias de propiedades [9]	69
3.11. Relaciones rho-path [9]	70
3.12. Estructura para la identificación de usuarios	71
3.13. (izq.) Grupo heterogéneo, (der.) Grupo homogéneo	75
3.14. Pseudocódigo para encontrar el número coincidencias de la propiedad ρ	79
3.15. Procedimiento de Recomendación para grupos homogéneos	87
3.16. Pseudocódigo del algoritmo de recomendación de inferencia semántica	89
3.17. Descripción gráfica de la técnica de recomendación de grupos heterogéneos	89
3.18. Conjunto de recomendaciones de los miembros del grupo G_i	90
3.19. Escala de Representación del valor DOI	91
3.20. Relación de la película i con otros contenidos	92
4.1. Promedio de Ratings	97
4.2. Representación de un familia	99
4.3. Conformación de subgrupos dentro de una familia	99
4.4. Grupo a evaluar en el de reconocimiento facial	100
4.5. Número de películas para el grupo G_i	101
4.6. Conjunto de contenidos para el entorno de pruebas	101
4.7. Conjunto de contenidos para el entorno de entrenamiento	102
4.8. Gráfica de la eficiencia de las técnicas de reconocimiento.	105
4.9. Umbral-MAPE, Enfoque de Votación vs Promedios	107
4.10. Resultado de clasificación de subgrupo de cada enfoque	107
4.11. Determinación del umbral adecuado para la clasificación	108
4.12. Grupos-MAPE: Recomendación para grupos homogéneos	109
4.13. Grupos-MAPE: Recomendación para grupos heterogéneos	109
4.14. Grupos-NDCG: Recomendación para grupos homogéneos	110
4.15. Grupos-NDCG: Recomendación para grupos heterogéneos	110
4.16. Tamaño_Grupos-MAPE: Recomendación para grupos homogéneos	111
4.17. Tamaño_Grupos-MAPE: Recomendación para grupos heterogéneos	112
4.18. Tamaño_Grupos-NDCG: Recomendación para grupos homogéneos	112
4.19. Tamaño_Grupos-NDCG: Recomendación para grupos heterogéneos	113
4.20. Promedios de las recomendación de grupos	114
A.1. Reconocimiento de Integrantes	127
B.1. Inicio del sistema recomendador	128



B.2. Identificación del usuario: MarthaS	129
B.3. Carga de datos del usuario registrado	130
B.4. Registro de grupo	130
B.5. Identificación del grupo: MarthaS, RuthS y Mirilu	131
B.6. Identificación del grupo: Mirilu y RuthS	132
B.7. Identificación del grupo: MarthaS y RuthS	132



UNIVERSIDAD DE CUENCA
desde 1867

Índice de tablas.

2.1. Aspectos para la Recomendación grupal	36
2.2. Sistemas recomendación no semánticos	40
3.1. Clasificación de usuarios para la creación de grupos	60
3.2. Lista de películas de u_1 y u_2	77
3.3. Propiedades semánticas de u_1 y u_2	77
3.4. Número de propiedades semánticas por propiedad, para u_1 y u_2 .	78
3.5. Umbral de las propiedades	79
3.6. Número de similitudes de las propiedades	80
3.7. Votación para cada propiedad	80
3.8. Asignación de pesos por propiedad	81
3.9. Clasificación del subgrupo - Enfoque Votación	82
3.10. Promedio de las propiedades	84
3.11. Clasificación del subgrupo - Enfoque Promedios	85
3.12. Clasificación de grupo - Promediando los Enfoques de Votación y Promedios	86
3.13. Listado de películas de los integrantes de G_i	88
3.14. Listado de películas del grupo G_i	88
3.15. Clasificación de Usuarios	94
4.1. Conformación de grupos	98
4.2. Grupo para evaluación del módulo de reconocimiento facial	100
4.3. Conjunto de grupos para la evaluación en el módulo recomendador	104
4.4. Resultados promedio totales de la evaluación	105
A.1. Técnicas de recomendación para grupos homogéneos	122
A.2. Técnicas de recomendación para grupos heterogéneos	124
A.3. Técnicas de recomendación - tamaño de grupos homogéneos . . .	125
A.4. Técnicas de recomendación - tamaño de grupos heterogéneos . . .	125
A.5. Técnicas de recomendación - según tipo de grupo	125
A.6. Promedio de los resultados por técnica	125
A.7. Promedio de los resultados según tamaño de grupo	126



Yo, *Wilson Vinicio Monge Llivisaca*, autor de la tesis *Sistema de Recomendación de Contenidos Audiovisuales basado en Tecnologías Semánticas para Grupos de Usuarios de TV Digital*, certifico que todas las ideas, opiniones, y contenidos expuestos en la presente investigación, son de exclusiva responsabilidad de sus autores.

Cuenca, 30 de Octubre de 2015.

A handwritten signature in blue ink, enclosed in a blue oval. The signature appears to be 'Wilson Vinicio Monge Llivisaca'.

Wilson Vinicio Monge Llivisaca.
C.I. 0104112347



Yo, *Martha Angélica Sapatanga Guartasaca*, autor de la tesis *Sistema de Recomendación de Contenidos Audiovisuales basado en Tecnologías Semánticas para Grupos de Usuarios de TV Digital*, certifico que todas las ideas, opiniones, y contenidos expuestos en la presente investigación, son de exclusiva responsabilidad de sus autores.

Cuenca, 30 de Octubre de 2015.

A handwritten signature in black ink, which appears to read 'Martha Angélica Sapatanga Guartasaca'. The signature is written in a cursive style with a long horizontal stroke at the end.

Martha Angélica Sapatanga Guartasaca.
C.I. 0925634891



Yo, *Wilson Vinicio Monge Llivisaca*, autor de la tesis *Sistema de Recomendación de Contenidos Audiovisuales basado en Tecnologías Semánticas para Grupos de Usuarios de TV Digital*, reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de *Ingeniero de Sistemas*. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor.

Cuenca, 30 de Octubre de 2015.

Wilson Vinicio Monge Llivisaca.
C.I. 0104112347



Yo, *Martha Angélica Sapatanga Guartasaca*, autor de la tesis *Sistema de Recomendación de Contenidos Audiovisuales basado en Tecnologías Semánticas para Grupos de Usuarios de TV Digital*, reconozco y acepto el derecho de la Universidad de Cuenca, en base al Art. 5 literal c) de su Reglamento de Propiedad Intelectual, de publicar este trabajo por cualquier medio conocido o por conocer, al ser este requisito para la obtención de mi título de *Ingeniera de Sistemas*. El uso que la Universidad de Cuenca hiciere de este trabajo, no implicará afección alguna de mis derechos morales o patrimoniales como autor.

Cuenca, 30 de Octubre de 2015.

Martha Angélica Sapatanga Guartasaca.
C.I. 0925634891



CERTIFICO

Que el presente proyecto de tesis: “Sistema de Recomendación de Contenidos Audiovisuales basado en Tecnologías Semánticas para Grupos de Usuarios de TV Digital” fue dirigido por mi persona.

A handwritten signature in dark ink, appearing to read "Kenneth Samuel Palacio Baus".

Ing. Kenneth Samuel Palacio Baus, MSc.
Director de Tesis

Agradecimientos

Este trabajo de tesis es la imagen de nuestro esfuerzo y sacrificio invertido durante este tiempo por lo que queremos agradecer:

A Dios por habernos bendecido con el don de la vida y a nuestros padres y familiares, por permitirnos hacer realidad nuestros ideales.

De la misma manera a nuestro director de tesis, el Ing. Kenneth Samuel Palacio Baus, MSc., por su entrega, dedicación, compromiso y el tiempo que en forma desinteresada nos ha brindado, para concluir nuestra labor universitaria, al Ing. Mauricio Espinoza Mejía, Ph.D. nuestro co-director, y a los colaboradores del proyecto *Empleo de Tecnologías Semánticas para el Análisis de Contenido Multimedia Transmitido para Televisión Digital*, financiado por la Dirección de Investigación de la Universidad de Cuenca, quienes han confiado en nosotros para la participación de este componente del proyecto.

Con mucha gratitud a la Universidad de Cuenca, Facultad de Ingeniería y sus profesores que en los años que cursamos supieron ser nuestros guías en nuestra formación profesional.

Así también queremos expresar nuestro agradecimiento a todas las personas que nos apoyaron de una u otra manera a culminar con este trabajo.

Wilson Vinicio Monge Llivisaca.
Martha Angélica Sapatanga Guartasaca.

Dedicatoria

Este trabajo va dedicado a mis padres por ser el pilar fundamental en mi vida, por sus consejos, sus valores, por la motivación constante que me ha permitido ser una persona de bien, pero más que nada, por su amor. A mi hijo, quien se ha convertido en la razón para nunca darme por vencido. A mi esposa por acompañarme en este largo camino. Y finalmente a mis amigos y familiares que me han sabido apoyar de una u otra forma para continuar con este proceso.

Wilson Vinicio Monge Llivisaca.



UNIVERSIDAD DE CUENCA
desde 1867

Este trabajo, lo dedico a mis padres por su apoyo y motivación a esforzarme para poder alcanzar uno de mis sueños. A mi abuelita mi segunda madre, por haberme formado como persona, por sus consejos, principios inculcados y por estar siempre presente en mis logros y en aquellos momentos que más le necesité. A mi abuelito que desde el cielo me cuida, me hubiese gustado que esté presente al concluir mi carrera universitaria. A mis hermanos por ser parte de mi día a día. A mis tías y primos, quienes me han brindado todo su apoyo. A mis amigos que estuvieron presentes y colaboraron con mi tesis.

Martha Angélica Sapatanga Guartasaca.

Capítulo 1

INTRODUCCIÓN

1.1. Planteamiento del Problema.

La constante evolución de los Sistemas de Telecomunicaciones ha posibilitado el desarrollo de la Televisión Digital (DTV) que incorpora al modelo tradicional de transmisión de nuevos servicios, tales como la interactividad con el usuario y la multiprogramación. Actualmente, se desarrolla un proceso de transición paulatina a nivel mundial de la TV Analógica a la Digital. Según estudios realizados por la Unión Internacional de Telecomunicaciones ¹, hasta el 2012 un 80 % de la población mundial posee un televisor en el hogar. Los países en desarrollo como Ecuador representan el 66 % del total, donde el 50 % de los hogares disponen por lo menos de un computador y el 47 % tienen acceso a internet. Estos indicadores demuestran que la televisión se ha consolidado como la tecnología de mayor penetración en los hogares en comparación con otras Tecnologías de la Información y Comunicación – TIC [60].

Dadas sus características técnicas, la Televisión Digital ofrece una extensa variedad de contenido audiovisual, sin embargo, se estima que solamente una pequeña porción de ese contenido es de la preferencia del usuario. Por tal razón, es importante ofrecer a los usuarios información relevante para ellos, con el fin de aprovechar las ventajas que ofrece la DTV tales como la experiencia audiovisual personalizada en la que se enfatiza lo que más se acerca a los gustos de la persona. Más allá de las posibilidades de personalización del contenido ofrecido por los medios, se considera que en un hogar promedio, es la familia quien participa de momentos de esparcimiento frente a la televisión en conjunto, según Masthoff 2004 [36]. Los grupos de personas que se reúnen para mirar la televisión por lo general, son de distintas edades, géneros y gustos. Es difícil que todos los miembros de un grupo estén satisfechos, pues muchas veces el contenido que se visualiza no es de su preferencia. A pesar de ello, se puede mejorar el índice de satisfacción de un grupo si se le presenta un contenido relacionado a las preferencias de sus miembros, por ejemplo, a través de los sistemas de recomendación para grupos de usuarios (SRGU).

En el presente trabajo de tesis, se continúa con la investigación del Sistema de Recomendación de Contenidos para TV Digital basado en Ontologías [9], que se centra en sugerir contenidos audiovisuales a un usuario de acuerdo a sus preferencias. Como en la mayoría de las veces, la televisión no es observada por un solo espectador sino por un grupo de televidentes, el sistema

¹<http://www.itu.int/>



[9] *está limitado para un grupo de usuarios*, debido a que no llenaría las expectativas de sus integrantes.

Existen varios estudios realizados con el enfoque en los sistemas de recomendación para grupos, que se basan en la técnica tradicional de filtrado colaborativo², como: PolyLens [43], Masthoff 2011 [37] y Yu [32]. La tendencia actual es utilizar la tecnología semántica, entre los que se puede mencionar a Rafael Sotelo, quien estudia la recomendación para grupos de usuarios de la televisión digital, clasificándolos en dos tipos específicos de grupos, Homogéneos y Heterogéneos [56]; y, Recomendación para grupos de usuarios de DTV [11], enfatizado en grupos pequeños y generalmente con gustos similares.

Un sistema de recomendación para un grupo se nutre de información de sus integrantes sin importar su número. Para ello, la primera alternativa en considerar es el uso del control remoto, se estima que este método causaría molestias a los televidentes, dado que deberían realizar una identificación manual cada vez que requieran de este servicio. Tratando de minimizar el tiempo y esfuerzo frente a un aparato televisivo, se usa una técnica de reconocimiento facial para la identificación de un grupo de usuarios que facilite su autenticación automática en el sistema. Para este fin, se considera el trabajo documentado en [28], basado en la librería de desarrollo de aplicaciones de visión por computador OpenCV³ (EGMUCV).

1.2. Antecedentes.

Este trabajo de tesis, parte del proyecto denominado: “EMPLEO DE TECNOLOGÍAS SEMÁNTICAS PARA EL ANÁLISIS DE CONTENIDO MULTIMEDIA TRANSMITIDO PARA TELEVISIÓN DIGITAL TERRESTRE”, que está aprobado y financiado por la DIUC (Dirección de Investigación de la Universidad de Cuenca). Su objetivo principal es diseñar un Sistema de Recomendación de Contenidos basado en las preferencias del usuario usando ontologías.

Como paso inicial se ha elaborado un “Sistema de Recomendación de Contenido para TV Digital basado en Ontologías” trabajo que fue realizado por Johnny Ávila y Xavier Riofrío [9], quienes diseñaron el sistema de recomendación para un usuario basado en la siguiente arquitectura 1.1:

²Los sistemas colaborativos recomiendan objetos que son del gusto de otros usuarios de intereses similares, sección 2.3.1

³<http://opencv.org/>

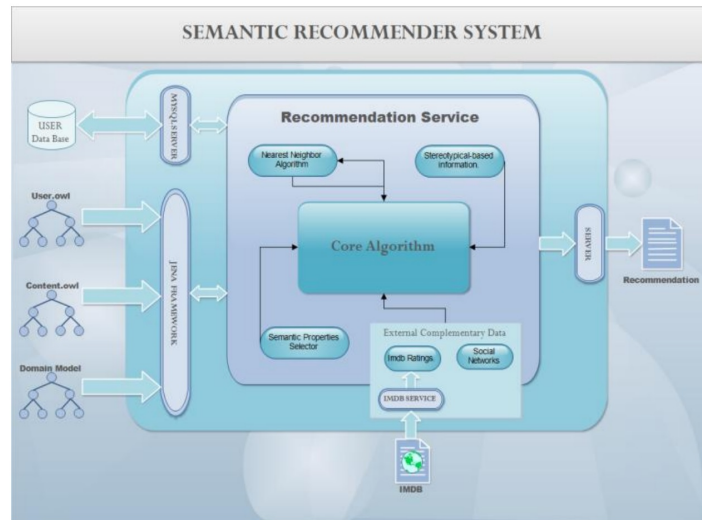


Figura 1.1: Arquitectura del Sistema de Recomendación desarrollado en [9], [8]

El sistema consta de tres funciones básicas: entrada, procesamiento y recomendación. Los parámetros de entrada se componen del perfil ontológico del usuario y el modelado ontológico de los contenidos audiovisuales. El servicio de recomendación, toma la información ingresada y las mismas pasan por diferentes módulos dependiendo del algoritmo utilizado para obtener recomendaciones. Los algoritmos experimentados son: algoritmo semántico por dispersión y con inferencia semántica; además, el servicio de recomendación contiene módulos adicionales como información de estereotipos, selector de propiedades semánticas, algoritmo de vecinos cercanos y el módulo de componentes externos no semánticos. La función de salida es generar una lista de contenidos ordenados dependiendo de la calificación de cada ítem, la primera sugerencia de la lista será aquel contenido con mayor puntuación, inferido por el sistema.

1.3. Objetivos.

1.3.1. Objetivo General

Implementar un Sistema de Recomendación de Contenidos Audiovisuales para Grupos de usuarios de televisión digital, en el contexto del proyecto “EMPLEO DE TECNOLOGÍAS SEMÁNTICAS PARA EL ANÁLISIS DE CONTENIDO MULTIMEDIA TRANSMITIDO PARA TELEVISIÓN DIGITAL TERRESTRE”, de la Universidad de Cuenca.

1.3.2. Objetivos Específicos

1. Desarrollar un procedimiento de identificación de grupos de usuarios mediante técnicas de reconocimiento facial.
2. Desarrollar un procedimiento para la clasificación de grupos homogéneos y heterogéneos de usuarios de TV digital.

3. Extender los alcances del algoritmo de recomendación desarrollado en [9] para recomendar a grupos de usuarios.
4. Desarrollar los procedimientos de evaluación necesarios para el sistema implementado considerando su arquitectura.

1.4. Justificación

La tecnología de DTV está en el proceso de sustitución a la tecnología de televisión analógica, debido a sus ventajas tales como mayor número de canales, transmisión de datos y sobre todo la interactividad con el usuario. En el periodo de 2008 al 2012, en este campo tecnológico ha existido un cambio visible a nivel mundial. Según la figura 1.2, en países desarrollados, para el 2008 el 53 % ya disponía de DTV, sin embargo se ha incrementado en aproximadamente el 30 % hasta el 2012 llegando al 81 % de usuarios con el servicio de DTV. En los países en desarrollo en el 2008 tan solo el 17 % disponía de DTV en comparación al 2012 que llega al 42 %. Estas cifras significan que la Televisión Digital en países desarrollados está implantada en su mayoría desde el 2008 y el avance ha sido similar, dado que para el 2012 se ha incrementado el 28 % y el 25 %, en países desarrollados y en desarrollo respectivamente [60].

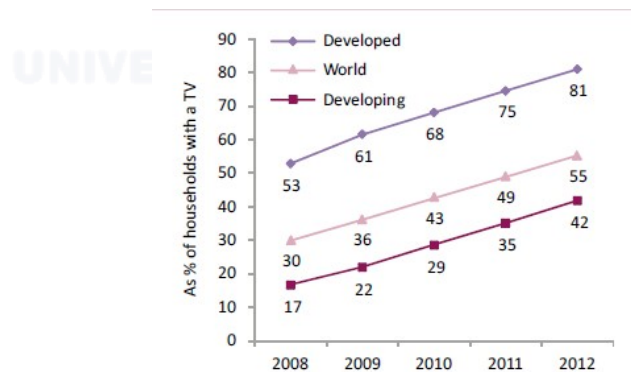


Figura 1.2: Desarrollo de la DTV en el periodo 2008-2012 [1]

Primero, las ventajas de la DTV y la disponibilidad de la información que ofrece esta tecnología, hace que exista un gran número de canales disponibles para el usuario, muchos de los cuales no serán del interés del televidente. Segundo, la televisión es el medio que más se comparte en la familia, la mayoría de las veces se lo realiza de manera grupal más no individual [36]. Tomando en cuenta los dos aspectos mencionados, es necesario contar con un sistema de recomendación para grupos de usuarios, de esta manera se trata de evitar la pérdida de tiempo en revisar los contenidos disponibles y sobre todo que algún miembro del grupo no esté satisfecho con la programación elegida a ser visualizada. Mediante el sistema de recomendación el grupo de usuarios puede recibir una lista de recomendaciones de forma eficiente y eficaz, que a su vez, utilicen el menor número de recursos para disfrutar un contenido televisivo agradable para cada integrante.



Para que los usuarios puedan tener acceso a ciertos servicios es necesario identificarse con nombre de usuario y contraseña. De la misma manera sucede con el servicio de recomendación de contenidos, que deberán ingresar sus datos mediante un control remoto y esto lo tendrán que realizar cada vez que deseen utilizar el sistema. Al ser un grupo de usuarios, que puede estar compuesto de dos o más personas, cada integrante debería autenticarse y esto podría causar malestar en los televidentes. Por tal razón, se ve necesario disponer de un método o técnica que sea automático el reconocimiento de los miembros, prescindiendo de un método manual, la pérdida de tiempo y sobre todo que el usuario se sienta incómodo.

1.5. Alcance

Dentro de las actividades a desarrollarse en este trabajo, se plantea el estudio del estado del arte de los sistemas de recomendación de grupos mediante la aplicación de tecnologías semánticas y, además, de diferentes técnicas de reconocimiento facial que se utilizarán para la identificación de los televidentes y grupos. El sistema deberá nutrirse de una base de conocimiento que contenga información relacionada con usuarios, películas y calificaciones de películas. Dado que los sistemas de recomendación de grupos consideran dos variantes: homogéneos y heterogéneos [56], se estudiará las técnicas de modelado del perfil de usuario grupal siguiendo los lineamientos encontrados en el estado del arte ([13] y [56]). Además, se propone el uso del algoritmo de recomendación implementado en [9] para usuarios individuales, para generar recomendaciones de contenido tanto para grupos homogéneos como heterogéneos, a través de modificaciones que permitan extender dicho trabajo. Dado que se explora el problema de la identificación de los grupos de usuarios, se implementará un módulo de reconocimiento facial a manera de prototipo de identificación del grupo. El desarrollo exitoso de estas actividades permitirá implementar procedimientos de evaluación que permitan corroborar las hipótesis planteadas para este proyecto de investigación.

1.6. Organización de la Tesis

El presente proyecto de tesis constará de la siguiente organización:

CAPÍTULO 1: INTRODUCCIÓN, se describe la identificación del problema, antecedentes, el objetivo general y sus respectivos objetivos específicos, con los cuales se pretende resolver el problema encontrado. También se menciona la justificación para el trabajo a realizarse y el alcance que tendrá.

CAPÍTULO 2: SISTEMAS DE RECOMENDACIÓN SEMÁNTICOS Y GRUPOS DE USUARIOS, en este apartado se menciona la parte conceptual de web semántica, el estado del arte de sistemas de recomendación para grupos de usuarios y las técnicas de reconocimiento facial.

CAPÍTULO 3: DESARROLLO E IMPLEMENTACION DEL SISTEMA, constituye las propuestas planteadas para: detección de usuarios presentes que facilitan la formación de un



grupo; clasificación del mismo en sus dos variantes: homogéneo y heterogéneo; y, las técnicas de recomendación de contenidos audiovisuales.

CAPÍTULO 4: EVALUACIÓN DEL SISTEMA, contiene los resultados determinados de los diferentes algoritmos desarrollados, estos se presentan de manera cuantitativa.

CAPÍTULO 5: CONCLUSIONES Y TRABAJO FUTURO, describe las conclusiones a las cuales se ha llegado al concluir el desarrollo del sistema y el estudio del estado del arte. Además, se plantea posibles temas de investigación.

ANEXOS: Compuesta de tablas de resultados y manual de usuario del prototipo desarrollado.

BIBLIOGRAFÍA: Listado de fuentes o referencias utilizados para el desarrollo de la presente tesis.


UNIVERSIDAD DE CUENCA
desde 1867

Capítulo 2

SISTEMAS DE RECOMENDACIÓN SEMÁNTICOS Y GRUPOS DE USUARIOS

2.1. Introducción

Hoy en día la cantidad de información disponible crece constantemente en diferentes dominios, lo que ha ocasionado que muchas veces las búsquedas se tornen cada vez más complejas. Por otra parte, es importante que las aplicaciones y servicios experimenten cambios considerables para adaptarse a las necesidades de los usuarios y en ese contexto han surgido aplicaciones y sistemas que asisten al usuario ante esta sobrecarga de información. En el ámbito del entretenimiento por ejemplo, se dispone de lo que se conoce como *Sistemas Recomendadores (SR)* que proveen facilidades para elegir contenido personalizado de entre una gran cantidad de alternativas. Estos sistemas se enfocan en mejorar la velocidad y precisión de una búsqueda, así como en simplificar la localización de elementos preferidos de contenido en muchos contextos: desde un simple dominio de compras, hasta la compleja tarea de encontrar canciones o programas televisivos que estén acorde a los intereses y necesidades del consumidor. Los SR se han posicionado de manera relevante en diversos ámbitos de investigación que pretenden encontrar métodos óptimos para generar las recomendaciones utilizando diferentes tecnologías.

En la actualidad es importante notar que la mayoría de SR existentes están enfocados en el individuo a pesar que en la mayoría de las ocasiones los usuarios interactúan entre sí. Para nombrar algunos ejemplos de estas interacciones sociales, se tiene entre otros: el caso de un viaje que se realiza con amigos o la familia, ir al cine, visitar un museo, observar un programa televisivo, etc. Por esta razón, el estudio de técnicas de generación de recomendaciones para grupos de usuarios es primordial y al mismo tiempo sumamente compleja pues se tiene que considerar a todos sus integrantes. En el contexto de este proyecto el caso particular de la televisión empieza por identificar a los espectadores presentes delante del televisor y con ello la determinación de los grupos de usuarios que pueden formarse, por ejemplo, en el caso de una familia lo cual puede conseguirse a partir del uso de técnicas de reconocimiento facial.

Con el objetivo de generar recomendaciones para grupos de usuarios, se han estudiado diferentes metodologías propuestas por diferentes autores y haciendo uso de enfoques diversos. Las técnicas más utilizadas se basan en enfoques de filtrado colaborativo, enfoques basados en



el contenido y enfoques híbridos. Las técnicas de filtrado colaborativo sugieren ítems basados en otros usuarios con gustos similares, mientras que las basadas en contenido, recomiendan ítems en función de la información de los mismos. Aquellas basadas en contenido dieron surgimiento a los SR semánticos que utilizan una base de conocimiento creada a partir de las preferencias de los usuarios.

Es así que las tecnologías semánticas han sido ampliamente aprovechadas para el desarrollo de SR, por lo que las siguientes secciones se enfocan en describir principios fundamentales y presentar su uso en el dominio de los SR.

2.2. Ontologías y Web Semántica

2.2.1. Definición de Web Semántica

La web semántica es una tecnología que forma parte de la Web 3.0 o Web Semántica¹. La evolución de la Web 2.0 actual cuyo objetivo principal es hacer que las máquinas, término usado por esta tecnología para referirse a las aplicaciones informáticas, puedan interpretar la información de una manera similar a la que lo hacen los seres humanos. Su funcionamiento se apoya en metadatos (datos sobre datos) que se suponen, son entendibles para las máquinas ampliando así su capacidad de interoperabilidad como se resalta en [52]. Los metadatos normalmente se integran como una parte de una página web, de tal modo que incorporan información detallada y relevante de manera estructurada, no solo describiendo simples datos sino también características como contenido, calidad, condición, etc. La web semántica posibilita que las aplicaciones informáticas puedan buscar, entender y presentar información sobresaliente.

2.2.2. Componentes de la Web Semántica

En esta sección se describe los componentes principales de la web semántica, cuya arquitectura se caracteriza por una organización en capas que se muestra en la Figura 2.1. La descripción de sus componentes se presenta a continuación:

- **XML:** Lenguaje de Marcas Extensible, permite definir etiquetas para describir y organizar datos, de esta manera facilita el intercambio de datos en la web.
- **XML Schema:** Define la estructura, contenido y las restricciones sobre los documentos XML.
- **RDF:** El Marco de Descripción de Recursos, describe conceptualmente la información contenida por los recursos web. Cada expresión dentro de RDF tiene un significado, dado que consta de sujeto, objeto y predicado. Está diseñado para el tratamiento de conocimiento en lugar de tratar sólo información.
- **RDF Schema:** Corresponde al lenguaje de ontologías derivado de RDF. Describe el significado, características y relaciones de recursos basados en RDF, semanticamente para generalizar jerarquías de las propiedades y clases.

¹<http://www.w3.org/standards/semanticweb/>

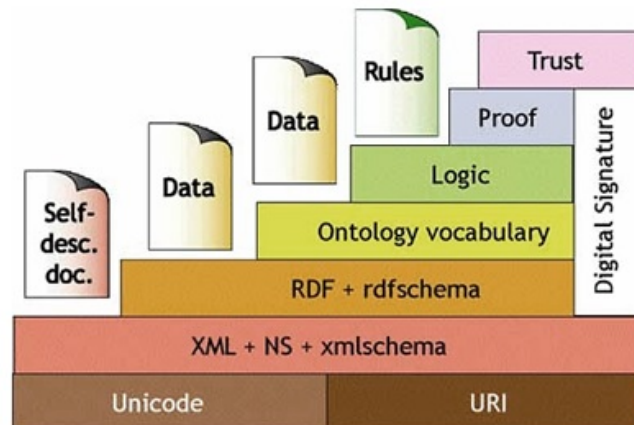


Figura 2.1: Capas de la web semántica.^a

^aFuente: www.maestrosdelweb.com/web-semantica-y-sus-principales-caracteristicas

- **OWL:** El lenguaje de ontologías Web, Es el lenguaje de marcado que sirve para compartir datos a través del uso de ontologías.
- **Unicode:** Estándar cuyo objetivo es identificar de manera única cada caracter o símbolo proporcionando el medio por el cual un texto en cualquier forma e idioma pueda ser codificado para el uso informático.
- **URI:** Identificador de Recursos Uniforme, son cadenas que permiten acceder a cualquier recurso de la Web. En la Web Semántica las URIs identifican recursos de manera única.
- **XML+NS+xmlschema:** XML provee un formato común para el intercambio de documentos, Namespaces (NS) sirve para organizar clases dentro de un entorno, asociándolas con espacios de nombre identificados por referencias URIs y XML Schema describe la estructura y restringe el contenido de los documentos XML.
- **RDF+rdfschema:** Define un modelo de datos para describir recursos mediante tripletas sujeto-predicado-objeto. Los dos primeros serán URIs y el tercero puede ser URI o un valor literal. RDF Schema por otro lado, ya no describe solo datos sino que también les da significado.
- **Ontology:** Sirve para representar el conocimiento, proporcionando una descripción más lógica y formal de sus conceptos y relaciones.
- **Logic:** También se necesitan reglas de inferencia (aplicación de reglas lógicas) sobre los datos.
- **Proof:** Se refiere a comprobar la fiabilidad de los razonamientos a través de demostraciones.
- **Trust:** Sirve para otorgar confianza en las transacciones comprobado de forma exhaustiva las fuentes de información.
- **Digital Signature:** Es un mecanismo de criptografía utilizado por los ordenadores para verificar que la información venga de una fuente de confianza.



2.2.3. Funcionamiento de la Web Semántica

Ya se había mencionado en un apartado anterior la importancia de los metadatos para la Web Semántica, sin embargo, también se necesita de un lenguaje de codificación de páginas. XML es un metalenguaje de codificación de páginas que permite diseñar etiquetas estructuradas y explícitas en las cuales se dejan a un lado las etiquetas tradicionales de HTML como `` o `<i>` por etiquetas personalizadas, por ejemplo: `<titulo>`, `<actor>`, `<director>`, etc. [15].

Existe un problema con los metadatos actuales dado que no cuentan aún con semántica, ni sintaxis y tampoco están unificados bajo alguna norma común. Para dotar a los metadatos de estas tres características se ha desarrollado la norma conocida como RDF o marco de descripción de recursos. RDF especifica una gramática lógica para que se puedan describir propiedades semánticas dentro de cualquier documento web utilizando el procedimiento de etiquetado XML [15].

RDF parte de tres entidades lógicas como son los recursos, las propiedades y los valores. Estas tres entidades están en correspondencia con los tres elementos de la lingüística que son sujeto, predicado y objeto. Con estos tres elementos se puede formular declaraciones sobre algún recurso de la siguiente manera: el recurso X tiene la propiedad Y con el valor P . Los recursos pueden ser sitios, páginas web, personas o cualquier objeto del mundo real o conceptual [18].

Para resumir se puede decir que el lenguaje XML hace de los documentos más explícitos. Los metadatos hacen que los documentos sean más fáciles de representar, indexar y buscar. Y por último los métodos de representación del conocimiento sirven para explotar las dos características anteriores [44]. Pero ¿cómo convertir la información en conocimiento? La información debe estar representada de manera que sea legible por los ordenadores, estar consensuada y ser reutilizable, para ello se introduce un término conocido como ontología.

2.2.4. Ontologías

Una ontología es un esquema conceptual abstracto dentro de un determinado entorno que facilita la comunicación y el intercambio de contenidos entre las aplicaciones informáticas, dado que detalla el contenido, le da significado y especifica la relación de los datos. A su vez, estas características permiten a las máquinas interpretar información de manera similar a como lo realizan los seres humanos. Para entender el concepto de una manera más clara se plantea el siguiente ejemplo:

El siguiente texto “ La película *Piratas del Caribe la Maldición del Perla Negra*, sus géneros son acción, aventura y fantasía; la duración es de 143 minutos, se estreno en el 28 de junio de 2003 en Estados Unidos. El director es Gore Verbinski, el escritor es Ted Elliott, sus personajes principales son: Johnny Depp, Orlando Bloom y Keira Knightley ”. Un humano lo define de la siguiente manera:

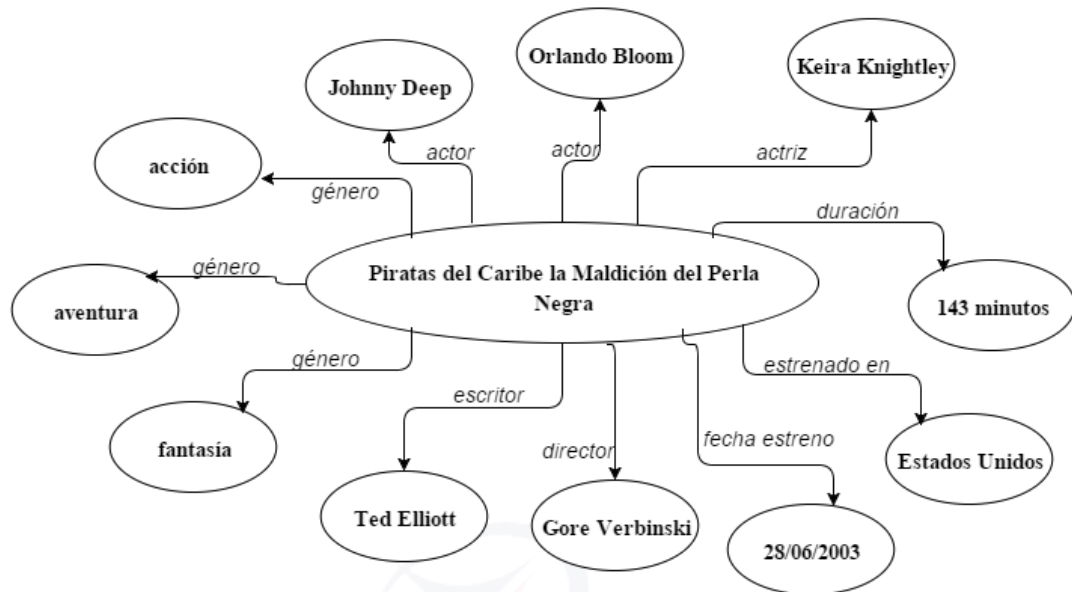


Figura 2.2: Conceptualización humana de la película Piratas del Caribe.

Para que una máquina pueda modelar el conocimiento que los humanos interpretan, los datos del ejemplo deben estar representados de la siguiente manera:

```

<Película ID="Piratas del Caribe la Maldición del Perla Negra">
  <título>Piratas del Caribe la Maldición del Perla Negra</título>
  <actor número="1" nombre="Johnny Deep" />
  <actor número="2" nombre="Orlando Bloom" />
  <actor número="3" nombre="Keira Knightley" />
  <fecha_estreno>28/06/2003</fecha_estreno>
  <lugar_estreno>Estados Unidos</lugar_estreno>
  <género id="aventura" />
  <género id="fantasía" />
  <género id="acción" />
  <duración>143 minutos</duración>
  <escritor>Ted Elliott</escritor>
  <director>Gore Verbinski</director>
</Película>

```

Figura 2.3: Conceptualización de datos para una máquina.

La ontología tiene una estructura jerárquica que posibilidad detallar claramente los contenidos, en ésta, constan los siguientes elementos:

Clases: describe conceptos, tomando el ejemplo de la Figura 2.3, las clases serían actor, director, escritor y año.

Propiedades: es la relación que existe entre las clases, según la Figura 2.3, Johnny Deep es actor de la película “Piratas del Caribe la Maldición del Perla Negra”.

Instancias: es una entidad o prototipo que concreta a la clase, de la clase actor su instancia es Johnny Deep.

Se ha analizado como deben estructurarse los datos para que las máquinas los puedan procesar, para esto, la ontología debe estar representada en un lenguaje entendible por el mismo. Con este fin fue desarrollado OWL.

2.2.5. OWL

OWL es el lenguaje estándar de la web semántica para expresar y codificar ontologías. Esto se logra a través de RDF, que añade elemento a elemento facilitando la descripción de clases, propiedades e instancias [18]. En el ejemplo anterior de la película, la codificación en lenguaje OWL mediante RDF quedaría de la siguiente manera:

```
<rdf:Description rdf:about="file:///home/OntologyIMDB.owl#tt0325980">
  <hasTitle rdf:datatype="http://www.w3.org/2001/XMLSchema#string">Piratas del Caribe.
  La maldición de la Perla Negra (2003)</hasTitle>
  <hasActor rdf:resource="file:///home/OntologyIMDB.owl#OrlandoBloom"/>
  <hasRanking rdf:datatype="http://www.w3.org/2001/XMLSchema#string">8.1</hasRanking>
  <hasActor rdf:resource="file:///home/OntologyIMDB.owl#KeiraKnightley"/>
  <hasActor rdf:resource="file:///home/OntologyIMDB.owl#GeoffreyRush"/>
  <hasID rdf:datatype="http://www.w3.org/2001/XMLSchema#string">tt0325980</hasID>
  <hasDirector rdf:resource="file:///home/OntologyIMDB.owl#GoreVerbinski"/>
  <hasWriter rdf:resource="file:///home/OntologyIMDB.owl#StuartBeattie(screenstory)"/>
  <rdf:type rdf:resource="file:///home/OntologyIMDB.owl#FANTASY"/>
  <hasWriter rdf:resource="file:///home/OntologyIMDB.owl#TerryRossio(screenstory)"/>
  <rdf:type rdf:resource="file:///home/OntologyIMDB.owl#ACTION"/>
  <hasVotes rdf:datatype="http://www.w3.org/2001/XMLSchema#string">706823</hasVotes>
  <hasWriter rdf:resource="file:///home/OntologyIMDB.owl#TedElliott(screenstory)"/>
  <hasDOI rdf:datatype="http://www.w3.org/2001/XMLSchema#double">4.5</hasDOI>
  <rdf:type rdf:resource="file:///home/OntologyIMDB.owl#ADVENTURE"/>
  <hasYear rdf:resource="file:///home/OntologyIMDB.owl#_2003"/>
  <hasActor rdf:resource="file:///home/OntologyIMDB.owl#JohnnyDepp"/>
</rdf:Description>
```

Figura 2.4: Representación en lenguaje OWL.

La representación de la Figura 2.4, es un ejemplo de como se definen los contenidos en un perfil de usuario, que está detallado en la Sección 3.2.4.



2.3. Sistemas de Recomendación

Un sistema de recomendación, constituye un conjunto de técnicas que permiten esencialmente disminuir el número de opciones elegibles para un usuario de entre todas aquellas que están disponibles. Su aplicación en diversos contextos ha facilitado que los usuarios puedan disponer de opciones más cercanas a sus intereses, con lo que pueden aprovechar de mejor manera su tiempo sin tener que analizar cientos de alternativas alejadas de sus preferencias. Diversos estudios [51] han demostrado que los usuarios se sienten más satisfechos cuando tienen menos opciones para elegir. Se dice que cada individuo en su subconsciente siempre tiende a imaginar lo que perdió al no haber considerado el resto de opciones no tomadas. Este fenómeno se acentúa cuando el número de opciones es considerable lo que origina una sobrecarga de información en los usuarios.

En el contexto del desarrollo informático contemporáneo, la cantidad de información que existe en Internet se ha convertido en un inconveniente no sólo para las grandes empresas, sino también para el usuario común, sobre todo considerando que la mayor parte de dicha información le es irrelevante. En respuesta a este problema, surge una alternativa denominada Sistemas de Recomendación, que se presentan como programas informáticos y técnicas encargadas de proporcionar sugerencias a los usuarios de acuerdo a sus preferencias [48],[49] en un determinado ámbito, como lo son: viajes, selección de restaurantes, música, películas, etc.

Hoy en día, millones de personas usan este tipo de sistemas sin saberlo. Por ejemplo, dos de las más populares páginas de Internet que los utilizan y los aprovechan corresponden a *Amazon*² y *YouTube*³. Amazon, cuenta con un algoritmo personalizado de recomendación de filtrado colaborativo de ítem a ítem. Este algoritmo asocia cada producto comprado por un usuario con una lista de productos similares que se obtiene en función de los elementos que hayan sido adquiridos en un mismo pedido, añadidos a un carrito de compra, o almacenados en una lista de deseos [38]. También, se hace uso de la información de compras de otros usuarios que han adquirido los mismos ítems sobre lo que un usuario muestra interés a través de su historial de navegación en la página. Por otro lado, YouTube utiliza un sistema de recomendación basado en contenido para obtener recomendaciones personalizadas mediante la combinación de las reglas de asociación vídeos relacionados con la actividad personal del usuario en el sitio. Esto incluye varios factores, como los videos que fueron vistos en conjunto a un cierto umbral de tiempo, la fecha en que fue visto el video, cuántas veces fue visto, etc. Además, YouTube utiliza factores con énfasis en los videos que fueron calificados con un “me gusta”, agregados a una lista de favoritos, o que se añaden a una lista de reproducción. La unión de estas características es conocida como la muestra semilla. De esta manera, para calcular las recomendaciones candidatas para la muestra semilla, YouTube expande su búsqueda hacia vídeos relacionados, como se describe con más detalle en [26].

En este sentido, y considerando la importancia de las tecnologías semánticas dentro de su aplicación en el desarrollo de sistemas de recomendación, a continuación se presenta una descripción general de los mismos en función del uso de la web semántica.

²www.amazon.com

³www.youtube.com



2.3.1. Sistemas de Recomendación no Semánticos

Estos sistemas corresponden a todos aquellos enfoques que no utilizan los principios de la web semántica, y que fundamentalmente no aplican técnicas de inferencia de conocimiento a partir de la descripción semántica de los usuarios o los ítems a ser recomendados.

Sistemas de recomendación de filtrado demográfico

Utilizan características demográficas de las personas como edad, sexo, profesión, domicilio para crear estereotipos de usuarios. Además de ser sistemas de recomendación poco confiables, son difíciles de implementar, muchas veces debido a la restricción creada dado el tipo de información que en muchas ocasiones, es de difícil acceso por motivos de privacidad, según se indica en [20].

Sistemas de recomendación basados en contenido

Este tipo de sistemas permiten sugerir al usuario un determinado ítem en función de su similitud con respecto a otros ítems que él mismo calificó previamente. Los ítems deben contar con una descripción de sus características, las mismas que serán puntuadas con un valor concreto que defina su importancia. Se necesita que el usuario evalúe una cantidad suficiente de productos para poder recoger sus gustos y necesidades. Los sistemas de recomendación basados en contenido utilizan varias técnicas para el cálculo de recomendaciones, entre las cuales se destacan las siguientes según [20]:

- **Modelado en Espacios Vectoriales.** Se calcula un vector asociado a un usuario y se obtiene la similitud con los vectores asociados a los productos que este no haya valorado. Finalmente se recomiendan los N productos cuya similitud con el perfil del usuario sea mayor.
- **Redes Bayesianas.** Se realizan inferencias para calcular la probabilidad de una variable condicionada al valor de las variables de las que depende. La red bayesiana contiene nodos por valor, característica y producto. Utilizando las valoraciones que otros usuarios dan a productos similares, se calcula una puntuación para el producto. Se recomiendan los K productos con mayor puntuación.

Sistemas de recomendación de filtrado colaborativo

Los sistemas colaborativos basan su funcionamiento en la similitud entre los usuarios a diferencia de los sistemas basado en contenido, que se fundamentan en la afinidad de los ítems. Las recomendaciones para un usuario se obtienen de ítems preferidos por otros usuarios con gustos similares [35]. Los recomendadores colaborativos se dividen en tres fases [61]: En la primera fase se guardan los perfiles de cada usuario con las respectivas evaluaciones de los ítems. En la segunda fase se mide el grado de similitud entre los diferentes usuarios en base a sus perfiles y se crean grupos con características afines. Y por último en la tercera fase se realiza la recomendación de ítems que el usuario no ha evaluado previamente pero que obtuvieron una calificación adecuada por parte de su grupo.



Existen dos técnicas importantes dentro del filtrado colaborativo [20]:

- **Vecinos Cercanos.** Este algoritmo busca los k usuarios más parecidos al que se va a recomendar, es decir, se conforma un vecindario. Luego procede a realizar la recomendación basándose en las preferencias de sus vecinos.
- **Clustering.** Clasifica a los usuarios en grupos de manera que aquellos de un mismo grupo sean lo más parecidos y si están en dos grupos separados que sean disímiles.

Para que el filtrado colaborativo tenga éxito es necesario contar con una gran cantidad de información. Además, existe un inconveniente en este tipo de sistemas de recomendación conocido como el arranque en frío, que se refiere tanto a nuevos usuarios como a nuevos ítems, pues estos no cuentan con información suficiente para poder sugerir contenidos adecuados.

Sistemas de recomendación híbridos

Estos sistemas de recomendación realizan una combinación de los recomendadores demográficos, basados en contenido y el colaborativo, con el fin de minimizar los problemas que puedan presentar cada una de las técnicas por separado. Por ejemplo los sistemas híbridos que combinan los basados en contenido con los colaborativos guardan las preferencias de un usuario y las combinan con los ítems más relevantes para obtener una recomendación precisa [25].

2.3.2. Sistemas de Recomendación Semánticos

Los sistemas de recomendación semánticos se caracterizan por la utilización de una base de conocimiento de información ampliamente detallada y representada en una estructura llamada ontología (Sección 2.2.4) mediante la cual puede inferirse conocimiento. El uso de técnicas de la Web Semántica, posibilita que mediante metadatos y ontologías se pueda describir contenidos, darles significado y su vez la facilidad de relacionarlos y por ende, descubrir nuevo conocimiento.

A diferencia de los métodos como el filtrado colaborativo, filtrado basado en contenido, etc. que se basan en técnicas sintácticas. Los SR han demostrado tener un rendimiento superior al hacer uso de técnicas semánticas [57]. Mediante la explotación de la información representada a través de una ontología, que se codifica mediante el lenguaje OWL usando RDF, se puede además proporcionar interoperabilidad, reutilización y extensibilidad al sistema [63].

En el ámbito de la programación televisiva la información de los usuarios y la de los contenidos televisivos suele modelarse usando ontologías. La información sobre el usuario incluye sus preferencias, por lo general se almacenan en una estructura de datos personal conocida como perfil de usuario [4]. Este perfil puede ser construido teniendo en cuenta evaluaciones directas del usuario, ya sea en forma explícita o implícita. En el caso de la forma explícita, el usuario debe manifestar voluntariamente sus preferencias, lo que normalmente es difícil de obtener dado que el interés del usuario se actualiza con frecuencia y, por ello él tendría que informar sus nuevas preferencias con la misma frecuencia [21], por ejemplo, a través de un cuestionario. Por otro lado, el sistema puede extraer información implícita observando el comportamiento del usuario y utilizando sus interacciones con el sistema para inferir sus intereses.

El Sistema Recomendador AVATAR

AVATAR es un SR basado en tecnología semántica ampliamente conocido cuyo algoritmo principal se basa en un proceso de inferencia semántica que se presenta en [12]. Este sistema descubre nuevo conocimiento de los perfiles de usuario que están representados en una ontología descrito mediante el lenguaje OWL (Ontology Web Language), el cual ilustra una jerarquía que especifica superclases, clases, instancias y propiedades. Además, una de las características dentro de la ontología empleada es la integración de un valor llamado Nivel de Interés o DOI (Degree of Interest), que corresponde a un valor numérico en el rango de 1-5, que se utiliza para determinar la importancia de cada una de las propiedades de los ítems a ser recomendados. La representación de la ontología de AVATAR se muestra en la Figura 2.5.

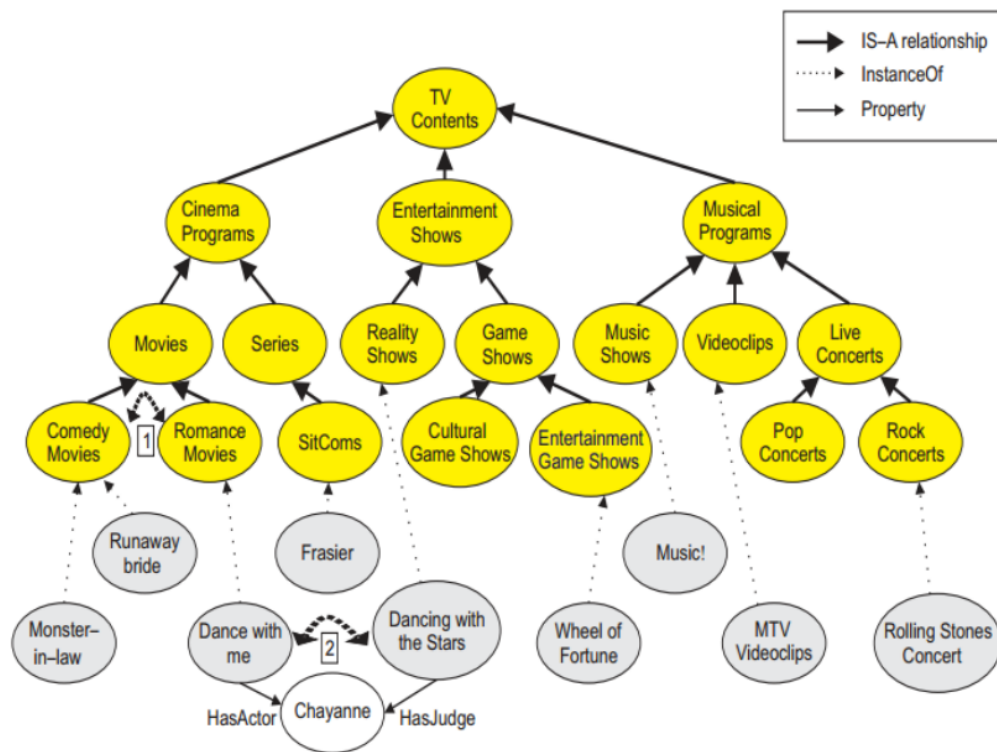


Figura 2.5: Representación Ontológica del Sistema Avatar [12].

Para generar una recomendación, el sistema Avatar, utiliza la técnica híbrida. Técnica que utiliza el filtrado basado en contenido para buscar contenidos relacionados mediante el razonamiento semántico y su historial de programación televisiva. Además, incorpora el uso de filtrado colaborativo en caso de que el contenido no fue seleccionado en la metodología basado en contenido y si éste está relacionado con las preferencias de los usuarios similares. Adicionalmente, Avatar también propone una estrategia para el problema del arranque en frío y el de nuevos usuarios.

Este proyecto de investigación, utiliza parte de los resultados obtenidos por parte de Marcos Juayek Ferreira Pinto y Alejandra Scuoteguazza de la Universidad de Montevideo [55], quienes desarrollaron un algoritmo basado en los principios del Sistema Avatar. Algoritmo que fue el resultado de comparar el enfoque filtrado colaborativo con el de inferencia semántica. Su



análisis concluyó en el desarrollo de dos enfoques de recomendación, conocidos como *algoritmo por dispersión del DOI*, documentado en [55], y el *algoritmo de recomendación por inferencia semántica*, documentado en [55], [33] y [12]. Estos enfoques se utilizaron en [9] para generar un sistema de recomendación de usuarios individuales enfocado al ámbito de la Televisión Digital, del cual se concluyó que el algoritmo de inferencia semántica es el más apropiado, puesto que produce recomendaciones más precisas. En la etapa evaluativa de los experimentos realizados se usó la métrica del MAE (Error Medio Absoluto) para calcular el error de recomendación, y así, contrastar los resultados.

2.4. Sistemas de Recomendación para Grupos de Usuarios.

Dado que los SR responden a la necesidad de contar con herramientas de asistencia al usuario para facilitarle la búsqueda de contenido, es importante considerar que el accionar de la sociedad en general no se produce de forma individual, sino que en la mayoría de las veces lo hace en grupo. Actividades como viajar, mirar una película, disfrutar de una lista de reproducción de canciones o jugar video juegos se realizan en reiteradas ocasiones en grupos de amigos o dentro del núcleo familiar. En este contexto, la generación de recomendaciones enfocada en grupos de usuarios requiere de varios procesos de análisis que incluyen como uno de los principales, el correcto modelado del grupo puesto que de ello dependerá la precisión de las sugerencias finales del sistema [30]. Entre las técnicas más utilizadas y populares para modelar el perfil de un grupo de personas se tiene: la fusión de perfiles, la fusión de recomendaciones personalizadas y la creación de un usuario virtual que represente a todos los miembros.

2.4.1. Lineamientos Generales para la Recomendación de Grupos de Usuarios

Para realizar recomendaciones a grupos de usuarios, surgen diferentes condiciones que se deben tomar en cuenta y ser estudiadas a detalle que influirán en el resultado de un sistema enfocado en las preferencias de múltiples individuos, según se documenta en [27], [37], y [30].

Tarea	Retos	Alternativas
Identificación de los integrantes	¿Cómo determinar a los usuarios presentes?	Técnica manual o automática
Adquisición de la Información	¿De qué manera adquirir la información de cada integrante?	De forma explícita o implícita
Generación de las recomendaciones	¿De qué forma generar recomendaciones adecuadas?	Técnica tradicional o semántica
Presentación de las recomendaciones	¿Cuál sería la mejor manera de presentar la lista de sugerencias?	Explicar la lista sugerida o presentación simple
Decisión Grupal	¿Cómo ayudar a tomar la mejor decisión?	Uso de correo electrónico o mensajes de texto

Tabla 2.1: Aspectos para la Recomendación grupal



Identificación de los Integrantes de un Grupo

Los usuarios pertenecientes a un grupo determinado tienen que ser identificados de tal forma que el SR pueda determinar las preferencias de sus miembros y generar recomendaciones a partir de ellos. Esta tarea puede realizarse de forma manual, por ejemplo, ingresando los datos de cada usuario de manera similar a cuando un usuario se autentifica y provee información en una Red Social como Facebook⁴. En el caso de un SR desarrollado en el dominio de la TV Digital se puede usar un control remoto como herramienta para el ingreso de información. En una aplicación que se ejecuta en el mismo televisor o en un aparato decodificador *set-top-box*, como el documentado en [40], es importante que cada integrante pueda notificarle su presencia al sistema y así determinar quienes son los integrantes del grupo. En un enfoque de identificación de usuarios de forma automática, los usuarios no intervienen en el proceso con mayor esfuerzo, por ejemplo, haciendo uso de técnicas de reconocimiento facial, lo que permite identificar a cada individuo mediante cámaras y el simple hecho de prestar atención a la pantalla por un instante, con lo que se minimizaría la necesidad de increpar al usuario.

Adquisición de la Información

Existen varios medios que posibilitan la extracción de información de los usuarios relacionada a sus preferencias, considerando dos aspectos importantes:

- Información para inicializar el modelo de grupo (nuevo usuario)
- Información para realizar el mantenimiento o enriquecimiento de un usuario existente.

Las técnicas más comunes para obtener información de un usuario contemplan una forma explícita y otra implícita, las cuales deben mantener la privacidad de sus preferencias, pero al mismo tiempo posibilitar que el resto de miembros conozcan los gustos de los demás. A continuación se analiza cada uno de estos dos enfoques:

Obtención Explícita de Información: donde el usuario puede expresar sus preferencias de manera directa, usando cuestionarios o calificaciones a un determinado ítem en un rango, por ejemplo de 1-5. Sistemas en el dominio de TV utilizan el control remoto para obtener información del usuario. En el caso de una calificación grupal y considerando un modelo ideal de alimentación del sistema, las calificaciones otorgadas a un ítem por parte de un grupo, suele otorgarse a partir de llegar a un consenso de grupo, lo que podría tornarse un problema al considerar el tiempo que involucraría este proceso. En los sistemas PolyLens [43] y Avatar[12], cada usuario emite sus preferencias dando una valoración a las películas que ha visto mediante un esquema de calificación de 1 a 5, mediante un interfaz gráfico que vincula una estrella por cada punto. A partir de la calificación de los ítems el sistema infiere los intereses del usuario.

Obtención Implícita de Información: donde la información se extrae a partir del comportamiento del usuario, por ejemplo, capturando el tiempo de permanencia mientras se observa un programa de TV. Además, se han planteado enfoques que infieren información a partir de las redes sociales, como aquel documentado en [17], en las que generalmente el usuario manifiesta sus preferencias, como por ejemplo mediante un *me gusta* en Facebook. Partiendo de esa

⁴Red social Facebook: www.facebook.com

información y con el uso de tecnologías semánticas se puede descubrir nuevo conocimiento.

Compartir Preferencias de Usuario: El compartir preferencias permite que el resto de miembros del grupo conozcan los gustos de sus pares y así facilitar el proceso de llegar a un consenso grupal. Sin embargo, este proceso debería darse de manera natural, puesto que las actividades de mirar la televisión en grupo, por lo general envuelve personas con gustos afines, por ejemplo, no es difícil imaginar un grupo de amigos disfrutando de un partido de fútbol en una tarde de domingo, donde por su puesto, todos comparten la afición por dicho deporte.

Generación de las Recomendaciones para un Grupo de Usuarios

Existen diferentes técnicas para generar recomendaciones destinadas a más de un individuo, La Figura 2.6 ilustra una de las maneras para lograrlo, considerando las técnicas de modelado del grupo de usuario a través de sus preferencias, y la falta de afinidad con las mismas entre sus miembros con respecto al ítem a recomendar (miseria) [37].

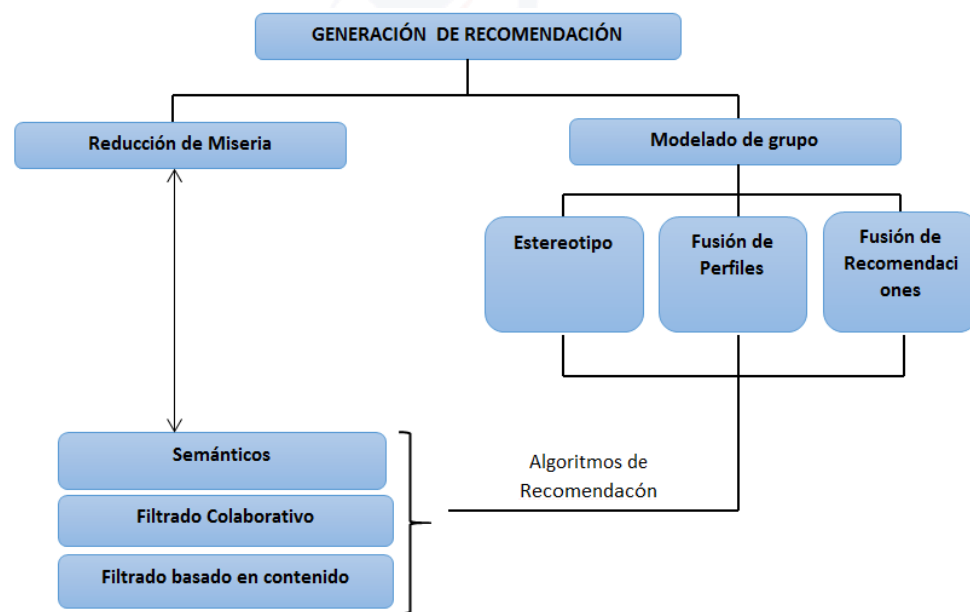


Figura 2.6: Generación de recomendación para grupos de usuarios

2.4.2. Modelado de un Grupo de Usuarios

El correcto modelado de un grupo juega un papel muy importante en la tarea de generar recomendaciones acorde a las preferencias de sus miembros o que en el mejor de los casos, llenen las expectativas de la mayoría de ellos. Con este fin, se han desarrollado diferentes técnicas que se detallan a continuación.

Fusión de Perfiles: También denominado método de combinación de perfiles; este procedimiento enlaza los perfiles de cada usuario de manera que se genera un perfil colectivo. La recomendación final se realiza en base al perfil grupal. Según Cantador [13], la estructura general se puede visualizar en la Figura 2.7.

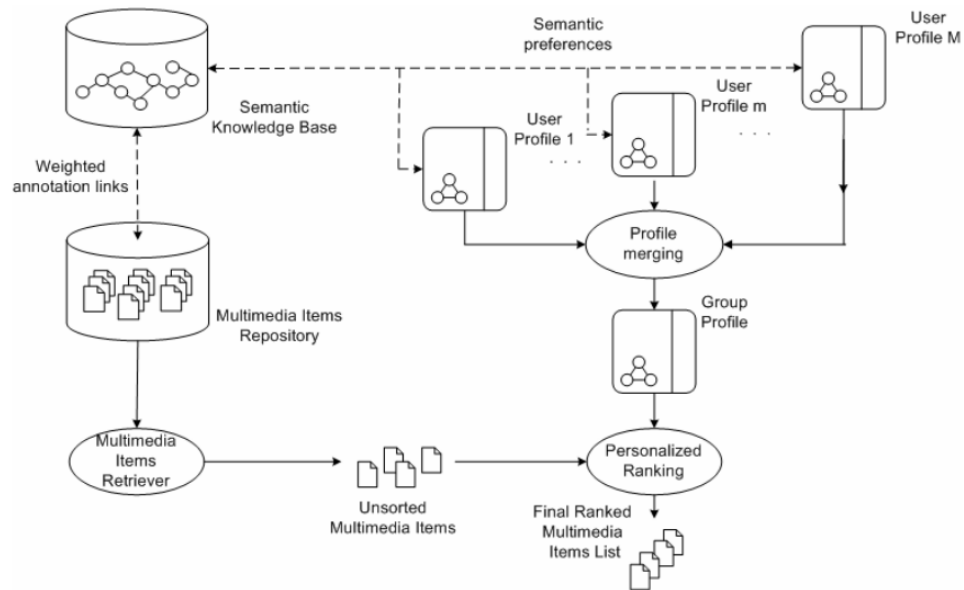


Figura 2.7: Estructura de fusión de perfiles [13].

Fusión de Recomendaciones: este enfoque emplea la lista de sugerencias individuales, es decir aquellas generadas para cada usuario. Cada recomendación se agrega a una lista común, de tal forma que el sistema posea una más opciones para analizar y poder efectuar la propuesta de ítems finales a ser recomendados al grupo. La estructura se muestra en la Figura 2.8.

2.4.3. Sistemas Recomendadores sin Enfoque Semántico

Hasta el momento se han desarrollado sistemas enfocados en varios dominios y aplicando diferentes metodologías o técnicas. En la mayoría de las investigaciones realizadas se utiliza la estrategia de agregación de perfiles y recomendaciones, las cuales se resumen en la Tabla 2.2.

A continuación se detalla cada uno de los sistemas. **MusicFX** [39], este sistema permite generar sugerencias de canciones dentro de un gimnasio de tal modo que la lista de reproducción no sea generada por una sola persona. Para este objetivo, se dispone de la base de datos de los usuarios y géneros musicales, que se ha formado a partir de calificaciones en el rango de 1–5 otorgadas por cada usuario. El resultado del mecanismo de identificación de los usuarios presentes en el gimnasio corresponde a la entrada al algoritmo de recomendación, el cual no realiza un análisis del grupo, y solo considera los géneros de las canciones.

PolyLens [43], corresponde a un sistema que sugiere películas a grupos pequeños de usuarios, utiliza la estrategia de *menor miseria* propuesta en [37]. Está basado en el desarrollo de MovieLens [42], que permite realizar recomendaciones personalizadas, usando las calificaciones de las películas y la técnica de filtrado colaborativo y la fusión de recomendaciones.

Intrigue [6], cuyo nombre surge de la extracción de ciertas letras de la frase: INteractive TouRist Information GUIde. Corresponde a un sistema desarrollado para el ámbito turístico, el cual asiste a un grupo de personas a elegir lo más adecuado para una actividad turística de forma grupal. Su función es crear subgrupos homogéneos, con usuarios de gustos similares dentro de

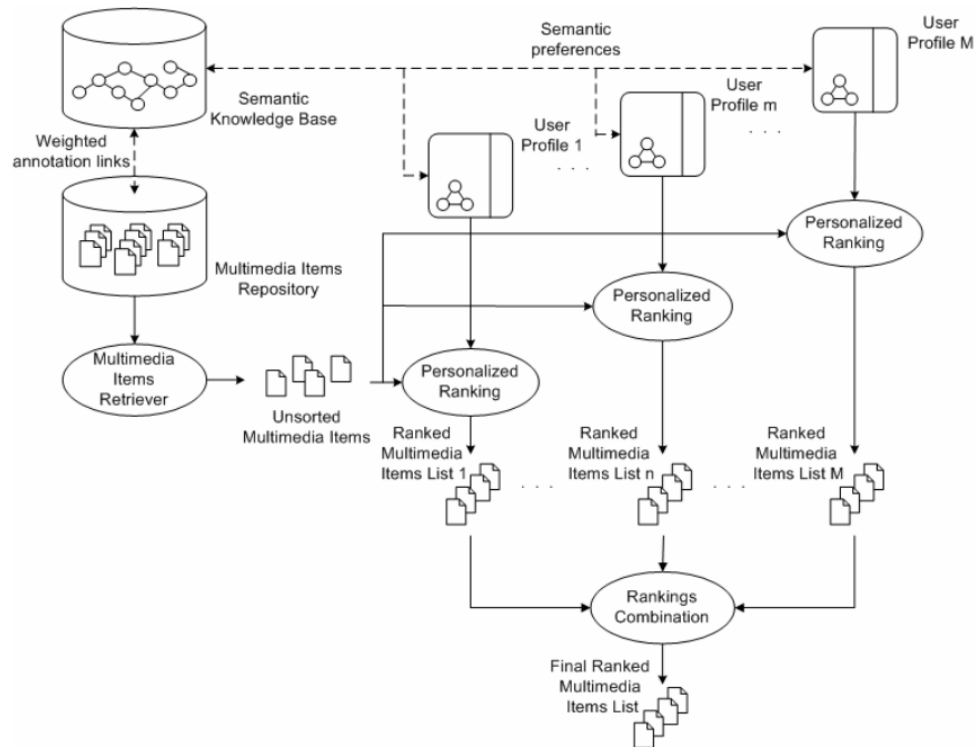


Figura 2.8: Estructura de fusión de recomendaciones [13].

Sistema	Dominio	Grupo	Recomendaciones	Modelado Grupal
Music FX-1998	Música	Usuarios de un gimnasio	Lista de canciones	Perfiles
PolyLens-2001	Películas	Amigos planeando salir al cine	Lista de Películas	Perfiles
Intrigue-2003	Turismo	Turistas	Actividades turísticas	Perfiles
FIT Family-2004	Televisión	Miembros de una familia	Programas de TV	Perfiles
Group Modeler-2005	Museos	Personas visitando un museo	Lista de zonas	Perfiles
TV Recommender-2005	Televisión	Programas de TV	Lista de contenidos de TV	Perfiles
Happy Movie-2011 y gRecs-2012	Películas	Grupo de amigos	Lista de películas	Recomendaciones
HbbTV -2013	Televisión	Grupo de amigos	Programas de TV	Perfiles

Tabla 2.2: Sistemas recomendación no semánticos

un grupo heterogéneo (con gustos disímiles). Luego, el algoritmo asigna pesos o relevancias a cada subgrupo considerando factores como, qué lugares debe visitar, actividades que se pueden realizar, de acuerdo a los integrantes del grupo, en los cuales pueden estar incluidos niños o personas con capacidades especiales. Previamente cada integrante otorga una calificación a las actividades y lugares turísticos. El sistema también proporciona una breve explicación de la



lista de sugerencias.

FIT Family [23], o Sistema Interactivo de TV, se enfoca en sugerir programas de televisión a un grupo familiar. Su función básica es la predicción de usuarios presentes mediante probabilidad, quienes tienen que proporcionar datos personales, ocupación y el tiempo que observan la TV. Para la recomendación grupal, el algoritmo analiza los géneros de los contenidos televisivos, género, edad y las relaciones del perfil ocupacional de cada integrante.

YU'S TV RECOMMENDER [32], está dirigido a sugerir contenidos televisivos a un grupo de usuarios, empleando la fusión de perfiles. Utiliza las características de los contenidos como: actores, género y palabras clave.

El sistema **Group Modeler** [29], se encarga de generar recomendaciones de actividades a los visitantes de un museo; los modelos individuales se agrupa mediante la fusión de perfiles, sobre este se realiza la recomendación final. Por otro lado, los sistemas **Happy Movie** [53] y **HbbTV** [16], se encargan de generar recomendaciones de contenidos televisivos a un grupo de usuarios. Happy Movie, extrae la información de los integrantes de la red social Facebook. HbbTV, implementa la detección de usuarios mediante códigos QR⁵, y reconocimiento de voz; las preferencias de usuarios se enriquece usando metadatos.

2.4.4. El Sistema de Recomendación Semántico AVATAR

El sistema Avatar [34] desarrollado inicialmente para recomendar usuarios individuales evolucionó a un sistema recomendador de grupos de usuarios a partir del enfoque presentado en el trabajo de Rafael Sotelo, denominado “Recomendación de contenidos audiovisuales para familias y grupos de amigos, basado en clasificaciones TV-anytime multidimensionales” [56]. El algoritmo implementado en dicho trabajo utiliza como entrada información de los programas televisivos y de los perfiles de usuario, seguidamente procede a clasificar al grupo de espectadores, dependiendo de su naturaleza y afinidad en las preferencias de sus miembros, lo que posibilita realizar la recomendación final utilizando una técnica diferente de acuerdo al tipo de grupo que se presenta al sistema. Este proceso se logra a través de una serie de pasos que se detallan a continuación:

Información de los programas televisivos

Los contenidos televisivos están representados en la ontología multidimensional *TV-Anytime-compliant*, el cual utiliza TV-Anytime⁶, para describir los ítems y clasificarlos en cuatro categorías tales como: *i) Intention*, corresponde a determinar cuál es el objetivo del programa, por ejemplo, informar y educar; *ii) Format*, es el tipo de contenido, como pueden ser musicales y documentales; *iii) Content*, define la estructura narrativa, por ejemplo, teatro y cine; y *iv) Intended Audience*, determina para quiénes está dirigido el programa, como adultos, niños, etc. Con este esquema de categorización se puede realizar comparaciones de propiedades a nivel multidimensional con el fin de obtener similitudes entre los contenidos televisivos. La representación ontológica de este enfoque se muestra en la Figura 2.9.

⁵<http://www.qrcode.es/es/generador-qr-code/>

⁶<http://www.tv-anytime.org/>, corresponde a un conjunto de especificaciones para la transmisión de contenido multimedia a los usuarios.

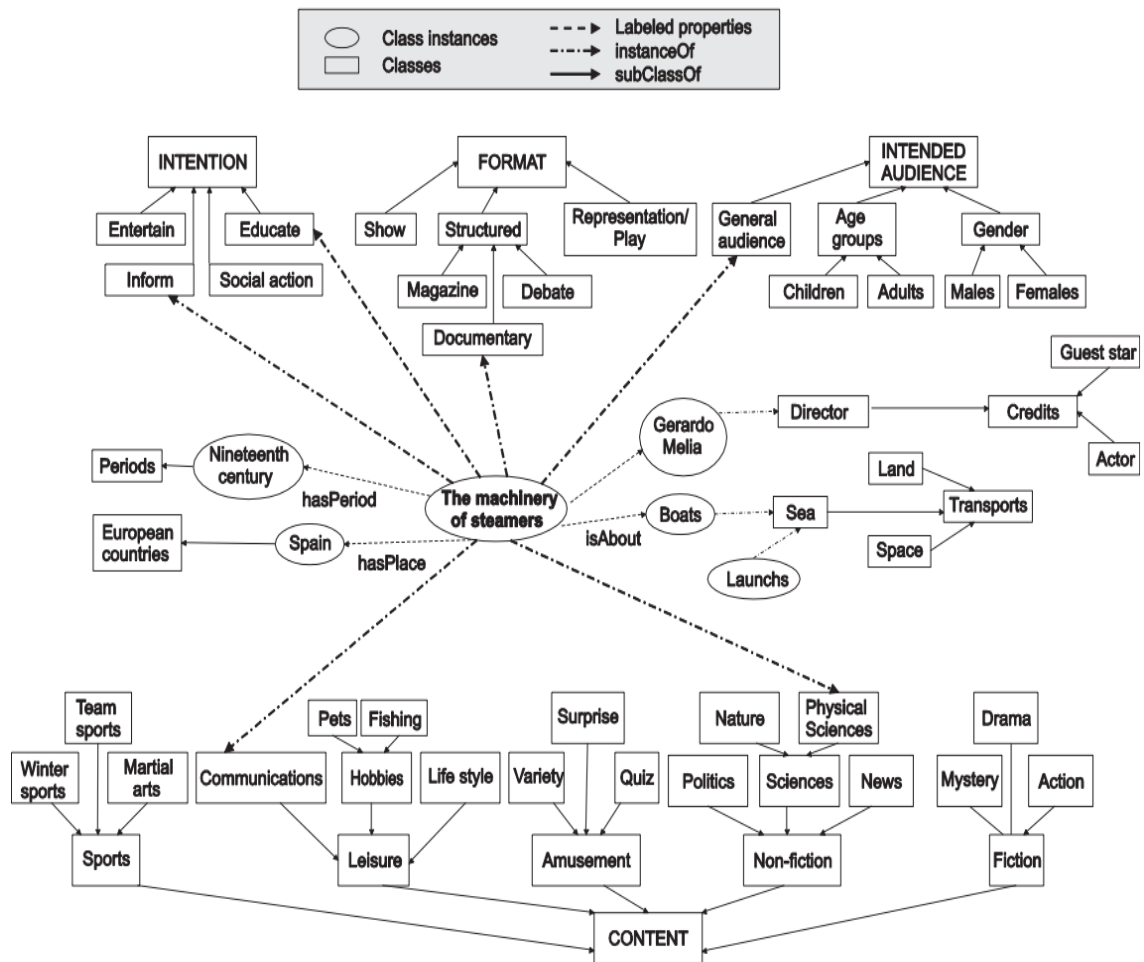


Figura 2.9: Representación Ontológica del Sistema Avatar basada en la norma TV-Anytime [56].

Modelado Ontológico del Perfil del Televidente

Esta etapa especifica las preferencias del espectador, además, haciendo uso de la estructura de la ontología televisiva se agrega ítem a ítem considerando todos los contenidos que fueron valorados con el DOI. Así, cada propiedad tiene una puntuación, por ejemplo, si un determinado usuario prefiere las películas del actor *Jonny Deep*, probablemente el DOI asignado para ese actor será óptimo.

Tipos de Grupo

Es importante analizar las preferencias de cada integrante de un grupo para poder proporcionar una lista de películas adecuadas para el grupo. El objetivo es determinar si el conjunto de miembros como tal es *homogéneo*, lo que implica usuarios con preferencias similares; o en su defecto de tipo *heterogéneo*, aquellos que tienen gustos disímiles. Por ejemplo, si el grupo de espectadores esta definido por tres usuarios denotados por u_j , u_k e u_i , entonces el grupo se

denota como:

$$G_n = \{u_j, u_k, u_i\}$$

Entonces,

1. Se genera cuatro vectores de clasificación para u_j , u_i y u_k del grupo G_n que se forman a partir de las propiedades mas relevantes, inferidas de manera implícita con sus respectivas calificaciones (DOI), basados en las categorías de la ontología televisiva, las cuales son Format (F), Intention (I), Intended Audience (IA) y Content (C).
2. La dimensión n de cada uno de los vectores está dada por n^F , n^I , n^{IA} y n^C respectivamente.
3. Para el usuario u_j el vector queda conformado de la siguiente manera:

$$U_j = \begin{cases} (v^I_j[1], \dots, v^I_j[n^I]) & \text{Intention} \\ (v^F_j[1], \dots, v^F_j[n^F]) & \text{Format} \\ (v^{IA}_j[1], \dots, v^{IA}_j[n^{IA}]) & \text{Intended Audience} \\ (v^C_j[1], \dots, v^C_j[n^C]) & \text{Content} \end{cases}$$

Figura 2.10: Vectores de las cuatro jerarquías para el usuario u_j [56]

4. Calcular la correlación entre los dos usuarios para cada vector, dada por la fórmula.

$$\text{corr}^I(U_j, U_k) = \frac{\sum_r (v^I_j[r] - \bar{v}^I_j) \cdot (v^I_k[r] - \bar{v}^I_k)}{\sqrt{\sum_r (v^I_j[r] - \bar{v}^I_j)^2 \cdot \sum_r (v^I_k[r] - \bar{v}^I_k)^2}}$$

Figura 2.11: Correlación del vector Intent para los usuarios u_j y u_k [56]

5. El siguiente paso es promediar los cuatro valores obtenidos de la correlación anterior, este valor se multiplica por un peso dependiendo la importancia de cada vector.

$$\begin{aligned} \text{corr}(U_j, U_k) &= w_I \text{corr}^I(U_j, U_k) + w_F \text{corr}^F(U_j, U_k) + w_{IA} \text{corr}^{IA}(U_j, U_k) \\ &+ w_C \text{corr}^C(U_j, U_k) \end{aligned}$$

Figura 2.12: Correlación entre los usuarios u_j y u_k para los cuatro vectores de clasificación [56]

6. Finalmente se categoriza al grupo de acuerdo a la correlación de cada par de usuarios, si este supera un umbral fijado el grupo G_n es homogéneo, caso contrario será heterogéneo.

Técnicas de Recomendación

De acuerdo al tipo de grupo ya sea este homogéneo o heterogéneo, se utiliza una técnica diferente para realizar la recomendación final. Al tratarse de un conjunto de miembros con gustos similares el proceso para la recomendación final se muestra en la Figura 2.13:

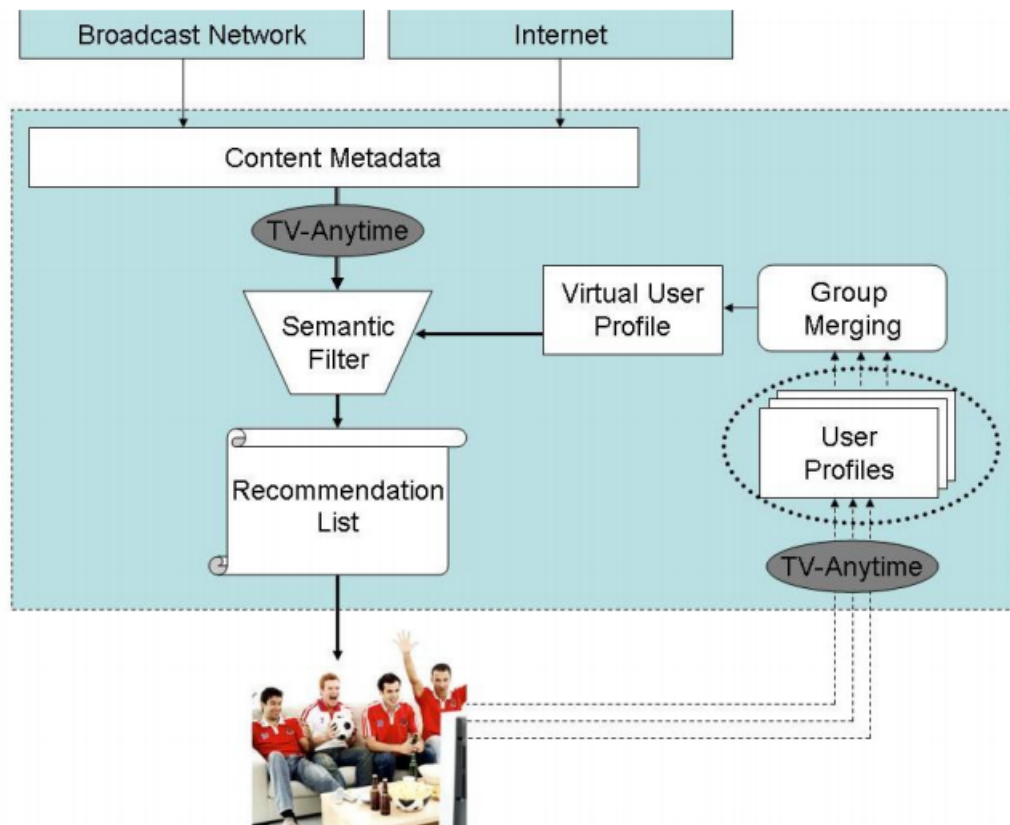


Figura 2.13: Proceso de recomendación para grupos homogéneos [56]

El perfil individual de cada miembro es agrupa en un solo perfil al cual se denomina *usuario virtual*, a este perfil se agrega las preferencias de los miembros, muchas de las cuales serán similares entre sí. El valor del DOI para las diferentes propiedades se promedia con el objetivo de obtener un DOI grupal. El nuevo perfil refleja al grupo como un usuario único. Para generar la lista de sugerencias se emplea el algoritmo de *filtrado basado en contenido*, que utiliza Avatar enfocado en un solo usuario.

La estrategia de recomendación para los grupos heterogéneos es la de utilizar la técnica de filtrado colaborativo como ilustra la Figura 2.14.

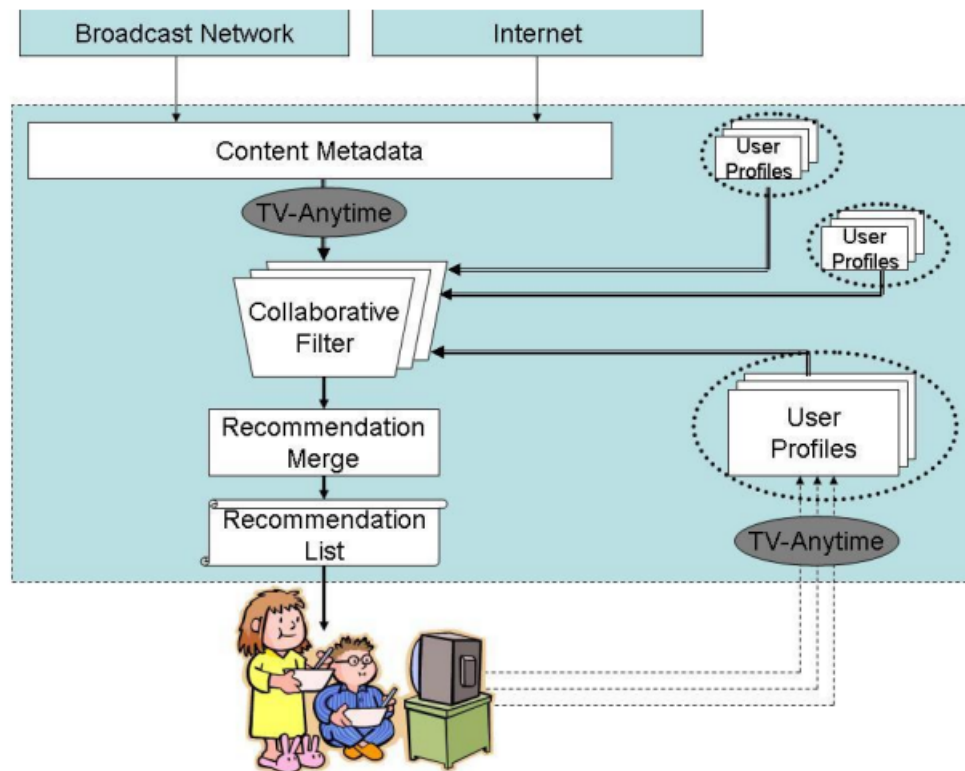


Figura 2.14: Proceso de recomendación para grupos heterogéneos [56]

El proceso es el siguiente:

1. Se encuentra el vecindario N_j de cada miembro U_j de un grupo G en particular. N_j incluirá a todos los usuarios U_k tal que la medida de la correlación C_{jk} esté por encima de un umbral establecido.
2. Se determina los grupos conocidos G_m en el sistema, cuyos miembros V_{mn} están incluidos en uno de esos vecindarios. Lo que implica que existirá un i tal que para todo n y V_n pertenecerá a N_i , resultando que G y G_m son intereses individuales similares.
3. Entonces, el conjunto G_m será considerado el vecindario de G .
4. Si se quiere recomendar un nuevo programa TP se debe primero encontrar los grupos que puedan estar interesados en él. Lo que se hace es calcular la adecuación de TP para cada miembro de V_m de todos los grupos de G_m .
5. En el caso de que un usuario haya visto ya el programa se utilizará su índice DOI, caso contrario, el nivel de preferencia se calculara por razonamiento semántico.
6. Se calculan los niveles de similitud entre el miembro V_m y el programa TP a través del filtrado basado en contenido (Cuantificar el valor de coincidencia de un programa TP y un usuario mediante la medición de la semejanza entre TP y los contenidos incluidos en el perfil del usuario).



7. Posteriormente se calcula la correspondencia entre cada G_m y TP con la estrategia Promedio Sin Miseria (las puntuaciones para recomendar programas a un grupo de usuarios se obtienen realizando un nuevo promedio de las calificaciones individuales, pero sin tener en cuenta los valores inferiores a un umbral determinado.) aplicada a todos los miembros del grupo G_m .
8. Por último se promedia todos los *matchings* o emparejamientos de los grupos de vecinos y se obtiene el interés previsto de G para el contenido de TP .

2.5. Identificación de los Miembros de un Grupo

Esta sección presenta una breve descripción de la necesidad de utilizar sistemas de identificación de usuarios no invasivos y que impliquen una mínima intervención del usuario o de los miembros de un grupo. Al utilizar estas técnicas, los grupos de usuarios pueden fácilmente ser identificados, y a partir de ello, las recomendaciones del sistema pueden generarse en función de los espectadores considerados como un grupo.

2.5.1. Identificación de Usuarios: Técnicas de Reconocimiento Facial

La identificación de las personas corresponde a un tópico de profundo interés sobre el cual se han desarrollado diferentes enfoques y técnicas asociadas a caracterizar a un individuo mediante un identificador que lo diferencie de otras personas en un contexto determinado. Entre estas técnicas se puede mencionar aquellas de reconocimiento facial, que suelen ser utilizadas para complementar el uso de contraseñas como medida de seguridad en determinados accesos. El objetivo de un sistema de reconocimiento facial es identificar una imagen de una cara desconocida que se ingresa como entrada del sistema entre un conjunto de imágenes conocidas, lo que se conoce como un conjunto de entrenamiento, y así reconocer a un usuario determinado.

Los sistemas de reconocimiento facial empezaron a desarrollarse desde la década de los sesenta. Los primeros sistemas de reconocimiento facial localizaban distintos rasgos a partir de una imagen en dos dimensiones, rasgos obtenidos a partir de los elementos faciales más representativos como la nariz, la boca, los ojos y las orejas mediante el cálculo de distancias y puntos de referencia, para después enfrentarlos contra una base de datos previamente preparada buscando coincidencias. En los años setenta Goldstein, Harmon, & Lesk [1], utilizaron 21 marcadores subjetivos como el color del cabello y grosor de labios para automatizar el proceso de reconocimiento facial. Para la década de los ochenta, Kirby & Sirobich [31] aplicaron la técnica del análisis de componentes principales (PCA - Principal Component Analysis), una técnica estándar del álgebra lineal, al problema del reconocimiento facial. Para los noventa, Turk & Pentland [2] desarrollaron la técnica de las *Eigenfaces*, relacionado al procedimiento de encontrar los Eigen valores y Eigen Vectores de una matriz, utilizando el error residual para detectar caras en las imágenes.

2.5.2. Etapas Generales en un Proceso de Reconocimiento de Rostros

Los métodos de reconocimiento facial, se fundamentan en principios matemáticos básicos derivados de áreas como el álgebra y la estadística. Las fases en las que generalmente trabajan



los métodos de reconocimiento facial, según se indica en [24] son:

- **Adquisición:** Captura de la imagen digital mediante una video cámara.
- **Detección:** El sistema detecta que en la imagen existe una cara; en el caso de un vídeo es capaz de realizar un seguimiento hasta obtener datos precisos de su localización espacio-temporal. Así, se normaliza y alinea rasgos de interés de la cara respecto a un patrón geométrico establecido y un formato de obtención de información determinado.
- **Características:** el proceso de extracción de características permite encontrar parámetros en espacios multidimensionales que permiten caracterizar a cada sujeto en dicho espacio para posteriormente utilizar diferentes enfoques de clasificación.
- **Identificación:** Compara el vector de características obtenido con otros vectores disponibles mediante diferentes técnicas de reconocimiento de patrones. Se persigue encontrar mediante medidas de similitud la identidad del rostro asociado a dicho vector de características.

Estas fases se detallan a continuación:

Adquisición

La adquisición de las imágenes a ser analizadas se realiza comúnmente a través de una cámara digital.

Las cámaras constan de varios componentes, entre los cuales se destaca es el dispositivo de imagen, donde se convierte la imagen óptica en señales eléctricas a través de dos sub-componentes, el prisma y el detector CCD (Charge-Coupled Device) o dispositivo de transferencia de carga. El prisma se compone de varios filtros permitiendo separar la luz blanca en los tres colores principales: rojo, verde y azul, para posteriormente enviar al CCD. Este corresponde a un chip reticular formado por un conjunto de píxeles, los cuales están constituidos por filas horizontales y verticales, que son sensibles a la variación de la luz que recibirá del prisma, de esta manera se reconstruye una imagen a modo de mosaico con información de crominancia y luminancia. Cada píxel transforma dicha información en una carga eléctrica determinada, que se transferirá desde el área fotosensible de los píxeles al área de almacenamiento transformándose en una señal de vídeo con los tres colores primarios [22]. Esta información finalmente se convierte códigos binarios que pueden ser procesados en un computador.

Detección

En esta fase, se hará referencia al trabajo publicado por Paul Viola y Michael Jones⁷ [65]. Las funciones que utilizan Viola y Jones se basan en conjuntos de bloques para reconocer formas, las cuales se denominan características *Haar*, que consisten en considerar regiones rectangulares adyacentes en una ventana de detección, y sumar la intensidad de los píxeles en cada región para calcular la diferencia entre estas sumas que permitirá clasificar distintas secciones de la imagen. Estas características se muestran en la Figura 2.16.

⁷El framework de detección de objetos de Viola-Jones es el primer framework que proporcionó detección de objetos en tiempo real propuesto en 2001.




Figura 2.15: Funcionamiento básico de una cámara web^a

^aFuente: http://www.informaticamoderna.com/Camara_web.htm




Figura 2.16: Características Haar. [47]

Por ejemplo, si se trata de detectar dónde están los ojos en una cara, una característica es que los ojos son más oscuros que las mejillas. Se aplica entonces una región rectangular para detectar los ojos, así, una característica de Haar común para la detección de caras es un conjunto de dos rectángulos adyacentes, uno debajo de otro, que coincidirán con la región de los ojos y las mejillas. Lo que permitirá que se definan una serie de características que permitirán detectar una cara con gran probabilidad de acierto, según se describe en la documentación de OpenCV⁸.



Figura 2.17: Características Haar.^a

^aFuente: http://ocw.unia.es/.../deteccion_de_caras.htm

⁸OpenCV, corresponde a un conjunto de librerías abiertas que permiten la evaluación de diferentes algoritmos relacionados con visión por computador. El proyecto OpenCV está disponible en: www.opencv.org

El algoritmo de detección debe atravesar en primer lugar a una fase de entrenamiento, en la que una serie de filtros en cascada son ejecutados con patrones positivos que coinciden con el objeto buscado y también con patrones negativos que no tienen el objeto buscado, de tal forma que el sistema aprenda y se forme un modelo de las características de Haar del objeto a detectar. La presencia de una característica Haar se determina restando el valor promedio de píxeles de la región oscura del valor promedio de píxeles de la región clara. Si la diferencia es superior a un umbral (establecido durante el aprendizaje), se dice que esa característica está presente.



Figura 2.18: Uso del HaarCascade en una cara [47].

Para determinar la presencia o ausencia de ciertas características Haar en cada ubicación de la imagen y en varias escalas, Viola y Jones utilizaron una técnica llamada de una *Imagen Integral*. En general, la integración significa agregar pequeñas unidades juntas. En este caso, las pequeñas unidades son los valores de los píxeles. El valor de la integral para cada píxel es la suma de todos los píxeles por encima de ella y a su izquierda. Comenzando en la parte superior izquierda y dirigiéndose hacia la derecha y hacia abajo, toda la imagen puede ser integrada con unas pocas operaciones de enteros por píxel, después de la integración, el valor en cada ubicación de píxel, (x, y) , contiene la suma de todos los valores de los píxeles dentro de una región rectangular que tiene una esquina en la parte superior izquierda de la imagen y el otro en la posición (x, y) . Para encontrar valor promedio de píxeles en este rectángulo, sólo había necesidad de dividir el valor en (x, y) para el área del rectángulo [47].

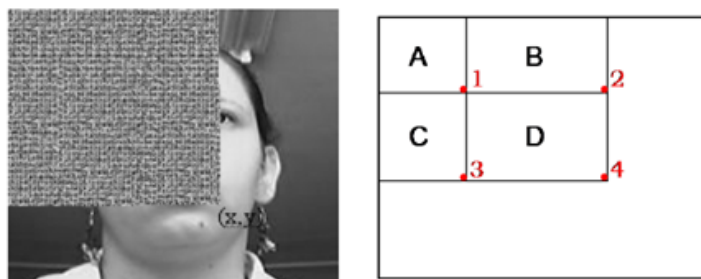


Figura 2.19: Técnica de la imagen integral [47]



Por ejemplo el valor para el rectángulo D en la Figura 2.19, es $D = A + B + C + D - (A + B) - (A + C) + A$. Convenientemente, $A + B + C + D$ es el valor de la Imagen Integral en el punto 4, $A + B$ es el valor en la posición 2, $A + C$ es el valor en la posición 3, y A es el valor del punto 1. Por lo tanto, con una Imagen Integral, se puede encontrar la suma de los valores de píxeles de cualquier rectángulo en la imagen original con sólo tres operaciones con enteros: $(x_4, y_4) - (x_2, y_2) - (x_3, y_3) + (x_1, y_1)$.

Para seleccionar una característica Haar específica a usar, y establecer los niveles de umbral, Viola y Jones utilizan un método de aprendizaje de máquinas llamada *AdaBoost* [64]. *AdaBoost* combina muchos clasificadores débiles para crear un clasificador fuerte. Un clasificador débil es cada característica Haar por separado, es decir, no son suficientes para determinar si la imagen presentada corresponde o no con el objeto buscado. Pero una cascada de todas las características que debe cumplir el objeto por ejemplo indicios de detección de ojos, indicios de detección de boca, indicios de detección de nariz, serán suficientes para poder determinar si la imagen corresponde o no con el objeto buscado, en este caso un rostro humano.

Características e Identificación.

Entre los principales enfoques de reconocimiento facial, que se presentan en la documentación de la librería OpenCV, utilizada en este proyecto, se encuentran:

1. Método de Eigenfaces. 2. Método de Fisherfaces. 3. Método de los Histogramas de patrones binarios locales o *Local Binary Patterns Histograms*.

1. Eigenfaces

Eigenfaces fue una técnica para reconocimiento facial propuesta inicialmente por Karl Pearson en 1901 y luego por Harold Hotelling en 1933. Eigenfaces es una derivación de la técnica PCA (Análisis de componentes principales). PCA realiza una transformación ortogonal a una serie de imágenes separandolas en X variables sin correlación que toman el nombre de eigenfaces. Estos eigenfaces forman una base de vectores capaces de representar el rostro de algun sujeto particular. Esto es posible gracias a que los eigenfaces son representaciones de las características más significativas de un rostro humano, en otras palabras, con tan sólo unas pocas dimensiones vectoriales pueden representan la mayor parte de la información sobre algun individuo. [47].

Para poder analizar a un individuo se necesita previamente contar con un conjunto (set) de entrenamiento. Este conjunto constará de varias imágenes en escala de grises (escala en la que el valor de cada píxel posee un valor equivalente a una graduación de gris). Luego PCA transforma cada imagen original de un conjunto de entrenamiento en su eigenface correspondiente. Sumando cada uno de estos eigenfaces en la proporción adecuada se hace la reconstrucción deseada. Cada eigenface representa sólo ciertos rasgos de la cara, que pueden o no estar presentes en la imagen original. Si la característica está presente en la imagen original en un grado superior, la proporción de la eigenface correspondiente en la suma de las eigenfaces debería ser mayor. Si, al contrario, la característica particular tiene

un grado muy bajo o no está presente en la imagen original, entonces el correspondiente eigenface debe contribuir muy poco o nada en la suma de eigenfaces.[47]. Para reconstruir una imagen no es necesario utilizar todos los eigenfaces, sino solo una parte, con lo que se obtiene una imagen aproximada de la real, y el error se puede minimizar si se eligen los eigenfaces de mayor grado. Si se extraen los pesos de todas las imágenes disponibles, las imágenes podrían agruparse, es decir, todas las imágenes que tengan pesos similares tienden a ser caras similares [47].

La condición inicial para utilizar el método *PCA* es que el conjunto de entrenamiento y la cara conocida tengan el mismo tamaño. *PCA* convierte cada una de estas imágenes en una matriz para trabajar con ellas.



Figura 2.20: Caras de entrenamiento. [47]



Figura 2.21: Eigenfaces. [47]

PCA es usado para generar K Eigenfaces para un conjunto de entrenamiento de tamaño M , en donde $K < M$ reduciendo así el número de valores de M a K , necesarios para identificar un rostro desconocido. Donde el primer componente principal es el más dominante y así sucesivamente le siguen el resto.

Las imágenes del conjunto de entrenamiento están representadas por K número de Eigenfaces:

PCA sigue los siguientes pasos [19]:

- Cada imagen I es dividida en varios cuadrantes con valores de alto y de ancho (x, y) , es decir, cada imagen tiene una dimensión de $N \times N$.

Luego, cada imagen I_1, I_2, \dots, I_M es reorganizada como un vector de dimensión N^2 construido al concatenar cada una de las filas de la imagen. Para que al final el conjunto de M imágenes se convierta en una matriz de dimensión $N^2 \times M$.

- Matriz de covarianza. El rostro promedio viene dado por la fórmula:

$$\gamma = \frac{1}{M} \sum_{n=1}^M I_n$$




Figura 2.22: Conjunto de Eigenfaces con la imagen predominante en primer lugar. [47]

El rostro promedio es restado de cada una de las imágenes del conjunto:

$$\theta_1 = I_1 - \gamma, \theta_2 = I_2 - \gamma, \dots, \theta_M = I_M - \gamma$$

Con lo que se obtiene la matriz de $N^2 \times M$:

$$A = [\theta_1, \theta_2, \dots, \theta_M]$$

Y su matriz de covarianza viene dada por:

$$C = \frac{1}{N^2} AA^T$$

- **Eigenectores.** Los eigenectores de la matriz de covarianza de A son vectores ortogonales que tienen dimensión $N^2 \times N^2$, que hace muy lento el procesamiento por computador, lo cual se soluciona obteniendo la matriz de covarianza reducida de A dimensión $M \times M$:

$$R = \frac{1}{M} AA^T$$

Luego, se obtienen los eigenectores (e) de R , que ordenados de mayor a menor según sus eigenvalores, conforman la matriz B . Se aproximan los eigenectores C

$$e = AB$$

- **Patrón.** Se obtiene el patrón:

$$\Omega_i^T = [\omega_1, \omega_2, \dots, \omega_M]$$

$$\omega_i = e_i^T \theta_i$$

Este patrón es utilizado para encontrar la distancia mínima, si esta distancia mínima supera un umbral predefinido indicara cuál de las imágenes del conjunto de entrena-




Figura 2.23: Representación Eigenfaces. [45]




Figura 2.24: Creación de Eigenfaces. [19]

miento tiene mayor grado de coincidencia con una imagen dada así:

$$\min(|\Omega - \Omega_i|^2)$$

- Diagrama de resumen.

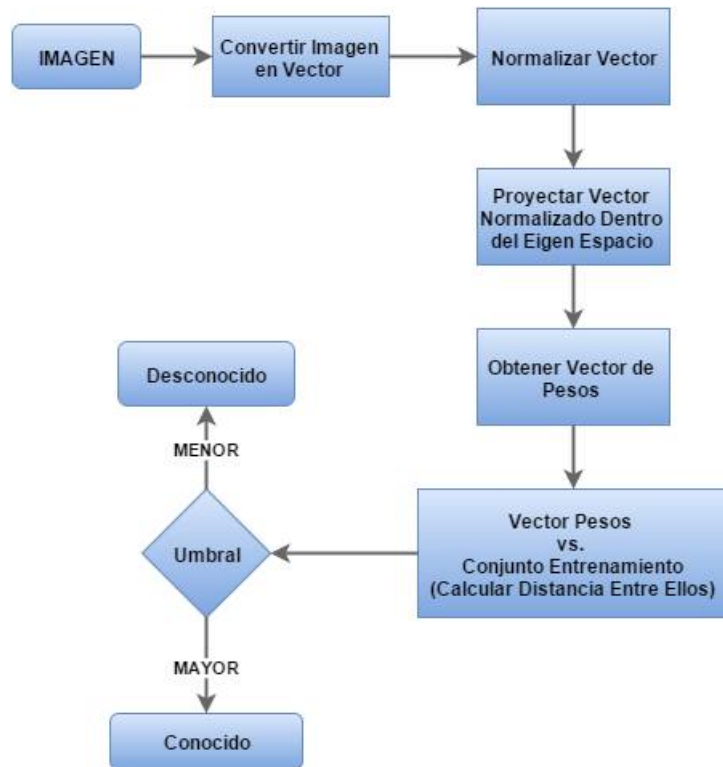


Figura 2.25: Resumen de algoritmo Eigenfaces. [19]

2. Fisherfaces

Fisherfaces es una técnica cuyo principal objetivo es suavizar el problema de los cambios de posturas de los rostros a ser analizados, las deformaciones de las cara, o el cambio de la luz. Esta técnica a diferencia de Eigenfaces utiliza LDA (Análisis Discriminante Lineal) que tiene como objetivo obtener una proyección de los datos en un espacio de menor dimensión que los datos entrantes, con esto se puede lograr que la separabilidad de las clases sea la mayor posible. Con LDA la imagen se proyecta al espacio formado por las imágenes de entrenamiento y así se puede buscar la imagen más semejante a través de la distancia euclidea. [62].

Para el cálculo del espacio vectorial se buscan dos matrices de covarianza, una de distribución entre clases:

$$S_B = \sum_{i=1}^c N_i (u_i - u)(u_i - u)^T$$

Y una matriz de distribución intra-clases:

$$S_W = \sum_{i=1}^c \sum_{x_k \in X} N_i (x_k - u_i)(x_k - u_i)^T$$

Luego se obtiene una matriz orto normal que maximizara la relación de la matriz de distribución entre clases de imágenes proyectadas y las futuras proyecciones que existirán dentro de este determinante:

$$W_{otp} = \underset{w}{\operatorname{argmax}} \frac{|W^T S_B W|}{|W^T S_W W|}$$

Para el reconocimiento de rostros la matriz S_W es de dimensión $N - c$ (N es el número de imágenes de entrenamiento y c es el número de clases o personas). Entonces, se puede escoger una matriz W en la que la distribución intra-clases de las imágenes proyectadas pueda ser cero. Utilizando el método PCA se puede reducir la dimensión del espacio de características a $N - c$. Luego aplicando la técnica *FLD* se reduce la dimensión a $c - 1$.

$$W_{pca}^T = W_{fld}^T W_{pca}^T$$

$$W_{pca}^T = \underset{w}{\operatorname{argmax}} |W^T S_T W|$$

$$W_{fld} = \underset{w}{\operatorname{argmax}} \frac{|W^T W_{pca}^T S_B W_{pca} W|}{|W^T W_{pca}^T S_W W_{pca} W|}$$

3. Local Binary Patterns Histograms

La textura igual que el color es una propiedad fundamental de una imagen para que pueda ser diferenciada de otras. *LBP* es un descriptor de texturas, lo que hace básicamente es etiquetar los pixeles de una imagen tomando como referencia un umbral dado, en una vecindad de 3×3 respecto al valor del pixel central y haciendo que el resultado sea binario [58].




Figura 2.26: LBP Matrix. [58]

Los ocho pixeles que están alrededor del central se van a examinar de la siguiente manera, si el valor de la intensidad de uno de estos pixeles es mayor que la intensidad del pixel central, entonces se le asigna un 1, caso contrario se le asigna un 0. Luego se codificara una cadena binaria por píxel, conteniendo un total de 8 bits que indicaran la intensidad de su alrededor. Se cuenta con un total 2^8 posibles valores, de manera que se puede calcular la distribución de textura con el método de histogramas en escalas de grises (representación gráfica de las frecuencias relativas con las que aparecen los distintos colores en una determinada imagen).




Figura 2.27: Codificación. [58]

El histograma normalizado será:

$$h_i LBP = \frac{n_i}{N} i = 0, 1, \dots, 255$$

Con n_i el número de píxeles de la imagen que poseen el parámetro LBP de valor i y N total de píxeles en la imagen. Para el reconocimiento facial lo que se hace es construir varias descripciones locales de la cara y combinarlas en una descripción global.




Figura 2.28: Regiones para los descriptores. [58]

Las imágenes son divididas en regiones como muestra la Figura 2.28, luego de cada región se extraerá los descriptores de textura independientemente. Para finalmente concatenarlos y tener una perspectiva de toda la cara en conjunto.

Capítulo 3

DESARROLLO E IMPLEMENTACIÓN DEL SISTEMA

3.1. Introducción

El sistema Sistema de Recomendación de Grupos de Usuarios (SRGU) se divide en dos etapas principales: la primera que consiste en la identificación de los usuarios frente al televisor mediante técnicas de reconocimiento facial; y la segunda etapa, que consiste en la generación de recomendaciones de contenidos audiovisuales para el grupo de usuarios identificado. Este trabajo ha tomado como base un sistema de recomendación para usuarios individuales denominado *Sistema de Recomendación de Contenido para TV Digital basado en Ontologías*, documentado en [9]. En el presente capítulo se describe los componentes que se han agregado a dicho sistema a partir del análisis de los parámetros de entrada, su procesamiento y las salidas correspondientes, con el fin de obtener los resultados esperados en el contexto de este proyecto.

El sistema desarrollado parte del proceso de identificación del grupo de usuarios mediante reconocimiento facial, que posibilitan la creación de un perfil del usuario identificado. A continuación se procesa la información obtenida del grupo de usuarios identificado para determinar a cuál de sus dos variantes pertenece: i) grupos homogéneos, que se determinan cuando existe un nivel de similaridad de las preferencias entre los integrantes; y, ii) heterogéneos, que determinan un grupo con preferencias muy distintas. Dependiendo del tipo de grupo, se emplea técnicas de recomendación diferentes, que posibiliten la generación de recomendaciones adecuadas para cada uno.

3.2. Descripción del Sistema

Esta sección presenta una descripción operativa y funcional del sistema, incluyendo los elementos de software y tecnologías utilizadas para su desarrollo.

3.2.1. Antecedentes

Este trabajo incorpora los resultados de diversos proyectos desarrollados en el dominio de la generación de recomendaciones para grupos de usuarios. Con este fin se ha considerado el sistema de reconocimiento de contenidos audiovisuales desarrollado por parte de Marcos Juayek Ferreira Pinto y Alejandra Scuoteguazza de la Universidad de Montevideo [55], quienes



comparan un algoritmo de filtrado colaborativo frente a uno de inferencia semántica. Por otra parte, Ávila y Ríofrio [9], hacen uso de dos algoritmos de recomendación semánticos: uno por dispersión [55] del nivel de interés de un usuario por un ítem DOI (Degree of Interest); y otro que genera una recomendación mediante técnicas de inferencia semántica, documentado en [55], [33] y [12]. Los dos estudios se basaron en el desarrollo del famoso sistema AVATAR [12], y se enfocan en la generación de recomendaciones personalizadas. En este contexto, este proyecto extiende el trabajo presentado en [9], con el objetivo de generar recomendaciones a un grupo de televidentes.

3.2.2. Herramientas de Software Utilizadas

Se describe brevemente las principales herramientas de software utilizadas para la implementación del sistema.

- **MySQL**¹.- Gestor de base de datos relacional, desarrollado en formato de software libre. Utilizado para almacenar datos de usuarios, puntuación otorgada por los usuarios (ratings) y contenidos televisivos.
- **Netbeans**².- Corresponde a un IDE (Entorno de Desarrollo Integrado), especializado para el lenguaje de programación Java, que además se caracteriza por ser un software libre.
- **Java**³.- Constituye un lenguaje de programación orientado a objetos y multiplataforma, donde las aplicaciones desarrolladas en este lenguaje pueden ejecutarse en cualquier Sistema Operativo. Este lenguaje se emplea para la implementación del módulo de clasificación de grupos y el servicio de recomendación.
- **Apache Jena**⁴.- Esta herramienta permite el desarrollo de aplicaciones basadas en ontologías. Contiene una API (Interfaz de Programación de Aplicaciones) que posibilita leer, procesar y escribir ontologías. Además, posee un motor de inferencia capaz de razonar sobre OWL. Su uso está destinado para el algoritmo de inferencia semántica.
- **IMDB**⁵.- Base de Datos de Películas en Internet, utilizado para formar la base de conocimiento sobre programación televisiva.
- **OMDB**⁶.- Servicio web de contenidos audiovisuales, que describe los atributos de un contenido específico, detallando los actores, géneros, directores, etc. Empleado para crear el perfil ontológico del usuario.
- **CSharp**⁷.- Es un Lenguaje de Programación orientado a objetos, basado en .NET⁸, desarrollado por Microsoft como un lenguaje multiplataforma. Empleado para la implementación de identificación de miembros del grupo.

¹<https://www.mysql.com/>

²<https://netbeans.org/>

³<https://www.java.com/es/>

⁴<https://jena.apache.org/>

⁵<http://www.imdb.com/>

⁶www.themoviedb.org

⁷<http://www.microsoft.com/net>

⁸<http://www.microsoft.com/net>



- **OpenCV**⁹.- Corresponde a un conjunto de librerías de código abierto especializadas en el campo de visión por computador, en las que se incluye algoritmos para el reconocimiento biométrico. Este, facilita el desarrollo de las técnicas de reconocimiento facial.
- **Haar Cascades**¹⁰.- Son clasificadores entrenados de OpenCV, que permiten detectar objetos de un tipo específico, por ejemplos rostros de personas (frontal, de perfil), en función de una base de imágenes o características especificadas en formato XML.

3.2.3. Base de Conocimiento

En el Sistema de Recomendación para usuarios individuales desarrollado en [9], se utilizó la base de datos libre de GroupLens¹¹ que recopila información de ratings o calificaciones emitidas por usuarios en la página web de MovieLens¹². A este conjunto de datos se le agrega información de contenidos audiovisuales, usuarios y ratings, según se describe a continuación:

Contenido Audiovisual

La información extraída de IMDB se utiliza con el fin de enriquecer las bases de conocimiento del sistema y también para evaluarlo. Esta base de datos disponible en la web presenta una amplia diversidad de alternativas de contenido televisivo y cinematográfico, incluyendo: series, miniserias, películas, documentales entre otros. Para cada programa se incluye sus características principales como: su género, los protagonistas, el año de producción, director, rating, una breve descripción de la trama, etc., siendo estos aspectos los principales para darle una preferencia según los gustos y conocimientos de los usuarios. De este gran listado se seleccionó un conjunto de alternativas que podrían llenar las expectativas de la mayoría de personas que fueron consultadas en la etapa de evaluación del sistema en base a las calificaciones otorgadas por ellos, lo que será presentado en el capítulo 4.

En la Figura 3.1 se muestra una imagen de la página IMDB, donde la película *Piratas del Caribe: La Maldición de la Perla Negra* es descrita para que el usuario conozca algunos detalles esenciales de la película en cuestión:

Usuarios

En este proyecto a los 6040 usuarios definido en [9] de la base de datos original de *MovieLens* se le agregaron 100 usuarios, de los cuales se obtiene sus datos personales y categoriza según se indica la Tabla 3.1.

Esta categorización es importante dado que permite conformar grupos de usuarios. Para este proyecto, se ha definido que el grupo objetivo será una familia, en la que conste un hombre, una mujer, uno o varios niños; se parte de este enfoque considerando que muy posiblemente representará el escenario principal de espectadores de TV. Además es necesario conformar grupos de amigos basándose en la edad y género, para obtener todos los escenarios posibles de un conjunto de usuarios.

⁹<http://opencv.org/>

¹⁰<http://alereimondo.no-ip.org/OpenCV/34>

¹¹<http://grouplens.org/datasets/movielens/>

¹²<https://movielens.org/>



Figura 3.1: Descripción de una película en IMDB.^a

^aFuente: <http://www.imdb.com/title/tt0325980/>

<i>Clasificación de Usuarios</i>		
Usuarios	Rango de Edad	Cantidad
Niños	5-12	28
Adolescentes	13-18	10
Adultos Hombres	19-65	31
Adultos Mujeres	19-65	30
Tercera Edad	65 en adelante	1
	Total	100

Tabla 3.1: Clasificación de usuarios para la creación de grupos

Ratings

Esta característica corresponde al listado de calificaciones otorgadas a cada contenido audiovisual por parte de los usuarios. En general, se dispone de miles de registros debido a que cada usuario califica aproximadamente 400 películas. El rango de calificación para los programas corresponde a valores en el intervalo: $[1, 5]$, como se muestra en la Figura 3.2.

ID	Pelicula	Genero	Mala	Regular	Buena	Muy Buena	Excelente	Valor
3953	King Kong (2005)	Action Adventure Drama	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="radio"/>	4
3954	El señor de los anillos: La comunidad del anillo (2001)	Adventure Fantasy	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	5
3955	El Hobbit: Un viaje inesperado (2012)	Adventure Fantasy	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	5
3956	El Hobbit: La desolacion de Smaug (2013)	Adventure Fantasy	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	5
3957	El caballero oscuro (2008)	Action Crime Drama	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	3
3958	Piratas del Caribe. La maldicion de la Perla Negra (2003)	Adventure Fantasy	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	5
3959	Piratas del Caribe. El cofre del hombre muerto (2006)	Action Adventure Fantasy	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	5
3960	Piratas del Caribe. En el fin del mundo (2007)	Action Adventure Fantasy	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	5

Figura 3.2: Películas calificadas por los usuarios seleccionados.

A los valores dentro del rango posible de calificación se los asocia con una descripción cualitativa según el siguiente esquema:

- 1: Mala
- 2: Regular
- 3: Buena
- 4: Muy Buena
- 5: Excelente

Con la información obtenida de los usuarios sus datos personales, el listado seleccionado de IMDB y la calificación que cada uno de ellos otorgó a cada ítem del mismo, se formaliza el tratamiento de datos respectivos (modelado ontológico de usuarios y programas televisivos).

3.2.4. Parámetros Ontológicos

El sistema SRGU parte de recibir dos entradas: el modelo ontológico de los contenidos audiovisuales; y el modelo ontológico del usuario. El uso ontologías (cuya implementación es posible utilizando el lenguaje OWL) permite realizar el razonamiento semántico del contenido y con ello, posibilita determinar o predecir las preferencias del usuario a partir del conocimiento inferido a partir de su historial de programación televisiva y también desde otras fuentes, como se propone en [41]. Con este enfoque se dispone de información detallada y completa, descrita mediante las clases de una ontología en la que figuran conceptos que a su vez facilitan la descripción exhaustiva de cada contenido, con lo que es posible encontrar relaciones entre clases y de esta manera se infiere información oculta que no está descrita de forma explícita.

Contenidos Audiovisuales

El modelado de los contenidos audiovisuales mediante ontologías permite representar información relevante de la película, mediante una estructura jerárquica, como se presenta en la Figura 3.3. Para cada película se crea una instancia de la clase “Thing”, la clase “Credits” a su vez contiene las clases Actor, Writer (Escritor), Director. “Contents” hace referencia a los géneros de la película. El modelado se documenta ampliamente en [12]. Tratando de enriquecer la información de programación televisiva se han propuesto diferentes enfoques, como aquel que se describe en [50]. En la implementación del modelado de los contenidos audiovisuales se utilizó el software Protegé¹³.

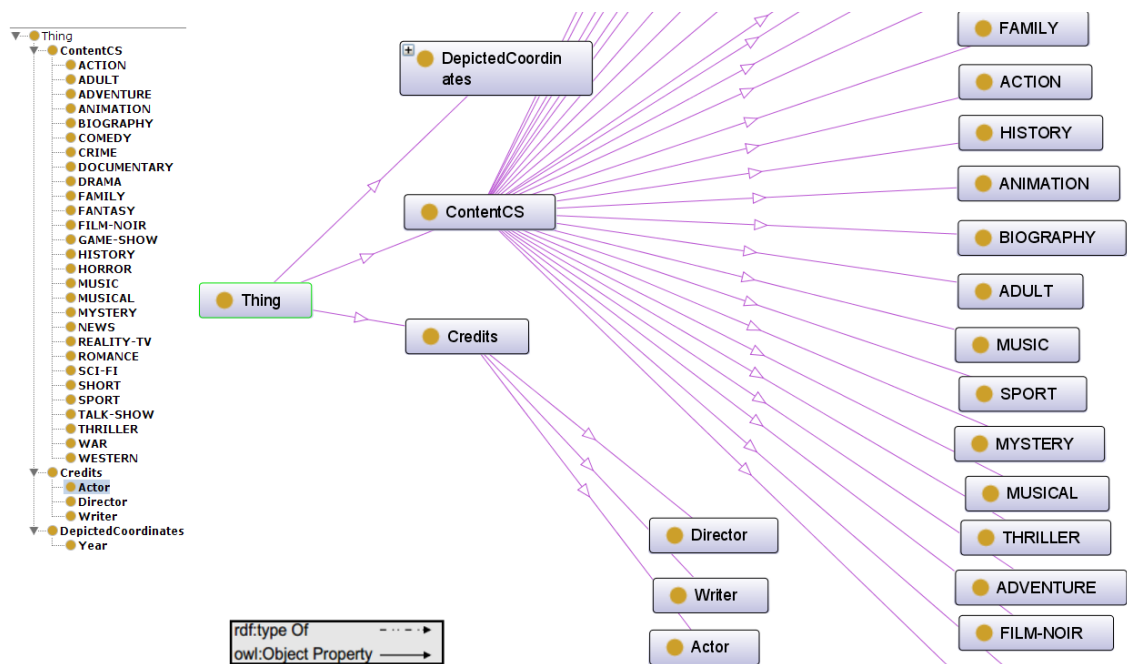


Figura 3.3: Ontología de las películas

Modelado Ontológico de Usuarios

Un perfil ontológico de usuario u_i contiene información acerca de sus preferencias personales en el dominio de los programas televisivos o cinematográficos. Dicho modelo está estructurado por clases, propiedades, e instancias concretas, basado en la estructura ontológica de contenidos de TV. Al agregar una película p_j al perfil ontológico de u_i , se crea una instancia de p_j . Esta instancia se asigna a la clase a la que pertenece y a la jerarquía de superclases, además se adiciona propiedades relevantes como: título de la películas, actores, género, etc. Este modelo permite descubrir nuevo conocimiento, según se ha demostrado en el desarrollo del sistema AVATAR [12] y [34].

El procedimiento de creación del perfil ontológico es el siguiente:

¹³<http://protege.stanford.edu/>

1. Obtener la lista de calificaciones o *ratings* de cada usuario definido en la Base de Conocimiento.
2. Para cada película, el título permite obtener un identificador (ID) en la base de datos IMDB.
3. Este ID se utiliza como un parámetro identificado de la película que posibilita utilizar el servicio de OMDB¹⁴ (Open Movie Data Base), para obtener los atributos importantes de una película tales como: título, actores, géneros, escritores, directores, control parental, año, etc. Estos valores están especificados en formato XML (Sección 2.2.2) o JSON¹⁵.
4. Las propiedades relevantes se utilizan para poblar la ontología.
5. Finalmente, se propaga el valor del DOI (calificación de la película) por todas las propiedades relacionadas, de tal manera, que todos los atributos tendrán una puntuación proporcional a la valoración general del programa o película.

3.2.5. Arquitectura del Sistema

La Figura 3.4 visualiza la arquitectura general del SRGU. Se puede notar que la entrada está constituida por un conjunto de usuarios de un grupo, quienes son los destinatarios de la recomendación de contenidos. Inicialmente, el sistema busca identificar a los usuarios presentes usando técnicas de reconocimiento facial, para posteriormente buscar el perfil ontológico del grupo en la base de datos, y en caso de no existir, se lo crea. La información contenida en el modelo ontológico de los usuarios posibilita que los algoritmos de clasificación de grupos, determinen el tipo de grupo presente, mismo que puede ser del tipo homogéneo o heterogéneo según se describe en la Sección 2.4.2. Seguidamente se realiza la generación de recomendaciones de acuerdo a un método adecuado según el conjunto de integrantes.

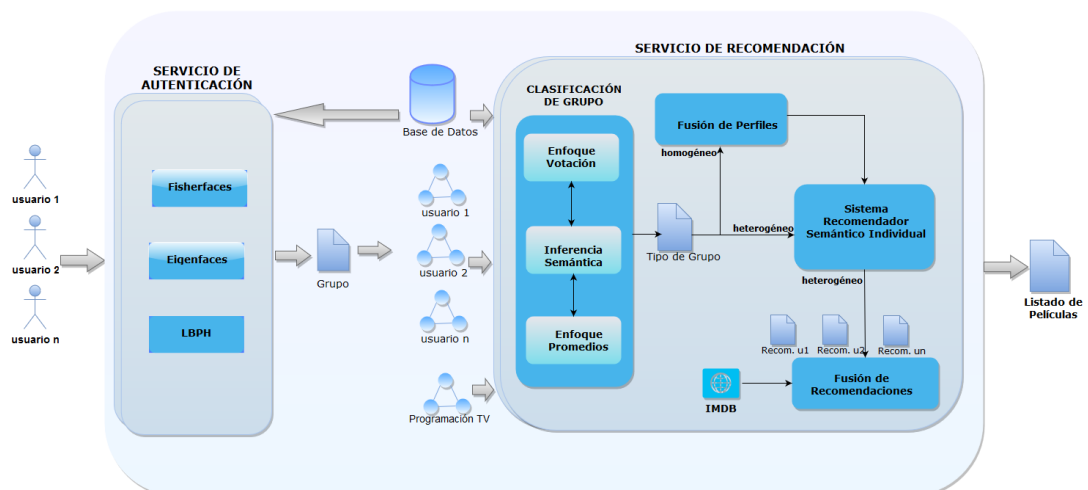


Figura 3.4: Arquitectura del SRGU

¹⁴<http://omdbapi.com/>

¹⁵<http://www.json.org/json-es.html>



Como ilustra la Figura 3.4, el sistema está formado de dos partes principales o servicios, que se describen a continuación:

Servicio de Autenticación

Este componente del sistema contiene al *módulo de identificación de usuarios*, que tiene la tarea de identificar a los usuarios presentes frente al televisor mediante la técnica de reconocimiento facial, lo que facilita la conformación de un grupo dentro del sistema y por tanto su asociación a un perfil ontológico del cual se puede inferir conocimiento. Para la conformación de dicho módulo, se cuenta con tres algoritmos de reconocimiento facial implementados, según se describe en la Sección 2.5.1, y sobre los cuales se puede evaluar su rendimiento:

- Algoritmo Fisherfaces
- Algoritmo Eigenfaces
- Algoritmo LBPH

Servicio de Recomendación

La principal función de este componente es la de generar las recomendaciones para el grupo de usuarios identificado. Dependiendo el tipo de grupo que se ingresa a este bloque, se procede con un enfoque determinado para generar un listado de recomendaciones acorde a las preferencias del grupo de usuarios. El servicio de recomendación se compone de varios módulos que se presentan detalladamente en las siguientes secciones, se describen brevemente a continuación:

Módulo de clasificación de grupos.- Es el encargado de discriminar al grupo de usuarios identificado en sus dos posibles variantes: como un grupo homogéneo o como uno heterogéneo. En este módulo se han implementado dos diferentes enfoques para determinar el tipo de grupo:

- Enfoque de Votación
- Enfoque de Promedios

Módulo de fusión de perfiles.- realiza la recomendación de contenidos a grupos homogéneos mediante el algoritmo de fusión de perfiles.

Módulo de fusión de recomendaciones.- realiza la recomendación de contenidos a grupos heterogéneos usando el algoritmo de fusión de recomendaciones.

Recomendador Individual.- realiza la recomendación de contenidos a un solo usuario.

3.2.6. Arquitectura de la Implementación del Sistema

La implementación del sistema de recomendación de contenidos audiovisuales para grupos de usuarios, se ha concebido en base a una arquitectura modular que posibilita que el código pueda ser agrupado por cada función específica. Los módulos del sistema SRGU son:

1. Módulo de Recomendación Individual (Sistema Base).
2. Módulo de Reconocimiento de Usuarios.

3. Módulo de Clasificación de Grupos.
4. Módulo de Recomendación por Fusión de Perfiles (grupos homogéneos).
5. Módulo de Recomendación por Fusión de Recomendaciones (grupos heterogéneos).

En la Figura 3.5 se muestra la arquitectura del sistema de recomendación para grupos desde la perspectiva de su implementación:

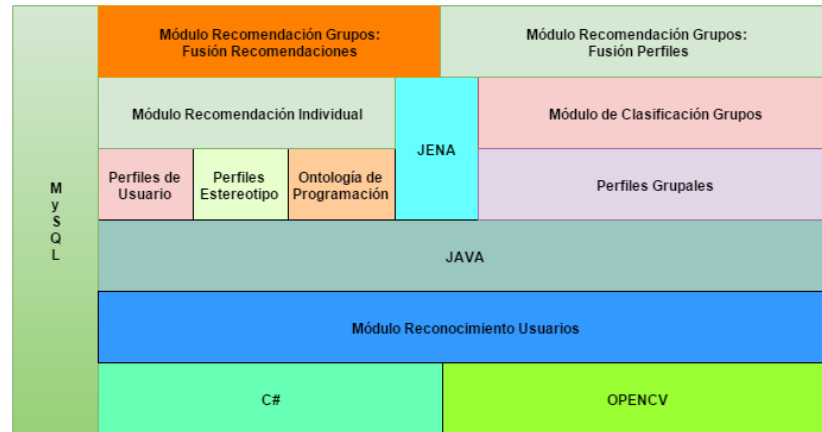


Figura 3.5: Arquitectura de la implementación del sistema SRGU

A continuación se presenta una breve descripción de cada uno de los módulos y tecnologías utilizadas para su implementación:

1. MySQL. Almacena información de *ratings*, usuarios, contenidos televisivos y los resultados generados en el módulo de recomendaciones mediante la técnica de fusión de recomendaciones.
2. Perfiles Grupales/Perfiles Individuales. Con la información de usuarios y sus *ratings* se realiza la creación y enriquecimiento de la ontología de los usuarios individuales. Los perfiles grupales se crean cuando un grupo es categorizado como homogéneo puesto que todos los usuarios del grupo se fusionan en un solo perfil, y a partir de ello se genere las recomendaciones grupales.
3. Módulo de Reconocimiento de Usuarios. Desarrollado en el lenguaje de programación C# e implementado en el IDE Visual Studio¹⁶. Utiliza una biblioteca de código abierto llamada OPENCV¹⁷, dentro de la cual se encuentra EGMUCV¹⁷, un envoltorio para .NET dedicado especialmente para el procesamiento de imágenes. En la operación de este módulo básicamente se captura imágenes a través de una cámara digital, se las procesa, almacena, entrena y utiliza para realizar el reconocimiento de rostros. Para esto se han dispuesto de tres técnicas principales: Eigenfaces, Fisherfaces y LBPH. Finalmente los resultados del reconocimiento son enviados al módulo de clasificación de grupos.

¹⁶<https://www.visualstudio.com/>

¹⁷www.emgu.com/



4. Módulo de Clasificación de Grupos. Desarrollado en el lenguaje de programación *java* utilizando el IDE Netbeans. Este módulo recibe como entrada los identificadores de los usuarios que se han reconocido en un determinado periodo de tiempo y que fueron enviados desde el módulo de reconocimiento de rostros (*C#*). Las preferencias de dichos usuarios son procesadas para su respectiva clasificación de grupo: en homogéneo o heterogéneo, usando la información de los perfiles ontológicos.
5. Módulo de Recomendación Individual (*Java*). Es un módulo que genera recomendaciones para un usuario individual en base a su perfil ontológico y una ontología que describe la programación televisiva, y que fue desarrollado en [9]. Dependiendo de los resultados del módulo de clasificación de usuarios, será utilizado antes o después del procesamiento, correspondientemente en los módulos de fusión de perfiles o de recomendaciones. El módulo es utilizado también para realizar recomendaciones en el caso de que el sistema identifique a un solo usuario frente al televisor.
6. Módulo de Recomendación de Grupos por Fusión de Perfiles (*Java*). Dentro de este módulo los perfiles de los usuarios identificados se fusionan en un solo perfil común. Luego, este perfil único se envía al sistema de recomendación individual como si se tratara de un solo usuario, a manera de un estereotipo como el enfoque descrito en [7].
7. Módulo de Recomendación de Grupos por fusión de recomendaciones (*Java*). Recibe como entrada las recomendaciones individuales (ítem – calificación) para cada usuario identificado en el grupo, y que se obtienen después del procesamiento en el módulo de recomendación individual. Con estos datos se realizan varios procesos entre los cuales están: promedio de resultados, reducción de la miseria y ordenamiento por el control parental, los mismos que se explican con detalle en la Sección 3.6.

3.2.7. Algoritmo de Inferencia Semántica

Este algoritmo se utiliza como componente núcleo del Servicio de Recomendación, puesto que es utilizado para generar recomendaciones a partir de un perfil de usuario y la programación de televisión disponible, ambos descritos a través de ontologías. El algoritmo utilizado en este trabajo es íntegramente el que se desarrolló en [9], se puede encontrar información más detallada en [11] y [12], y para el cual se han agregado funcionalidades adicionales que posibilita su uso en el contexto de su aplicación a un grupo de usuarios. El algoritmo está encargado de formar asociaciones o relaciones semánticas a través de la extracción de conocimiento implícito entre recursos que comparten propiedades similares de una ontología. De esta manera, se forma una secuencia de propiedades (o también llamada cadena de recursos) [5] o caminos dirigidos del ítem (película o programa de TV) analizado, posibilitando obtener una calificación para dicho ítem. El funcionamiento del algoritmo de inferencia semántica puede describirse como una serie de pasos que se detallan a continuación [9]:

1. Formar Secuencias de Propiedades

Una ontología está compuesta de clases C , propiedades P e instancias I (o recursos), a partir de la cual se forma una secuencia de propiedades que consta de relaciones semánticas extraídas

al asociar los atributos de los contenidos, que son denotadas por $PS = P_1, P_2, \dots, P_n$. Como ejemplo, la Figura 3.6 muestra el modelo de la película *Piratas del Caribe*.

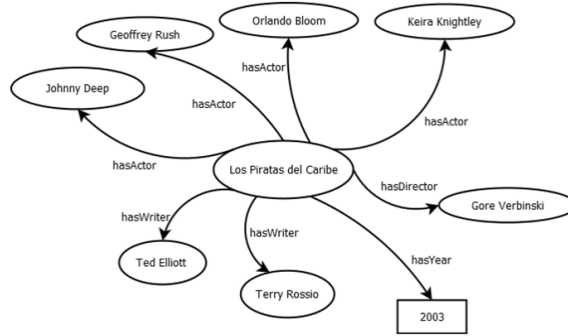


Figura 3.6: Modelo ontológico de la película *Piratas del Caribe* [9]

Partiendo de este ejemplo, el objetivo es encontrar contenidos televisivos que incluyan el recurso *Johnny Deep* entre sus atributos, debido a que este actor constituye el vínculo que los relaciona entre sí. En la Figura 3.7, el modelo expresa el rol del recurso *hasActor*, que representa a la clase Actor, entonces $C = Actor$ y $P = JohnnyDeep$, lo que permite buscar relaciones de P en el dominio de C .




Figura 3.7: Relación del recurso Johnny Deep con otros contenidos [9]

El algoritmo demuestra la capacidad de descubrir el conocimiento entre dos o más contenidos televisivos mediante los recursos que comparten. Las películas *Piratas del Caribe*, *Alicia en el país de las Maravillas* y *Rango* se relacionan por su recurso *Johnny Deep*. Este procedimiento es recursivo, de tal modo que se pueda formar un conjunto de propiedades en función de la condición de $DOI_{p(n)} > DOI_{p(n-1)}$ para cada P dentro del ámbito C , lo que se explica como el hecho de que la siguiente secuencia debe tener un DOI mayor al anterior, como se observa en la Figura 3.8.

Al considerar $DOI = 3$, los actores, y sus calificaciones respectivas son:

$$(P, DOI) = \begin{cases} (JohnnyDeep, & 4,5) \\ (GeoffreyRush, & 3,8) \\ (KeiraKnightley, & 4,2) \\ (OrlandoBloom, & 2,8) \end{cases}$$

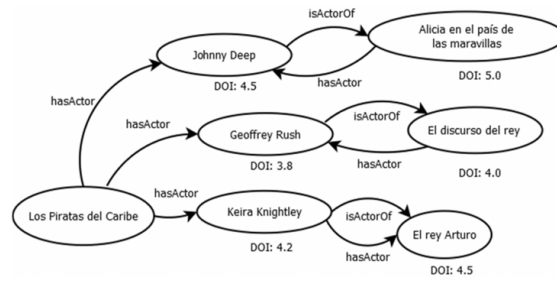


Figura 3.8: Secuencias uno y dos de la película “Piratas del Caribe” [9]

En este caso el actor *Orlando Bloom* será descartado, debido a que no cumple la condición, en consecuencia, aquellos recursos que sí lo hacen, como las películas *Alicia en el país de las maravillas*, *El discurso del Rey* y *El Rey Arturo* se agregan a la secuencia.

La agregación de propiedades a la secuencia termina cuando no se dispone de más relaciones que agregar o cuando haya llegado al límite de profundidad, definido como **path**. Una vez finalizado el proceso de obtención de secuencias, el resultado se puede representar gráficamente como en la Figura 3.9. Es importante destacar que en las posiciones impares están los recursos tipo película y en las posiciones pares están las propiedades (actor, escritor, director).




Figura 3.9: Conjunto de secuencias de propiedades [9]

De esta manera se forma una lista de propiedades:

$$PS = \left\{ \begin{array}{l} P1 = \text{Piratas del Caribe, Alicia en el país de las maravillas} \\ P2 = \text{Piratas del Caribe, Rango} \\ P2 = \text{Piratas del Caribe, El discurso del Rey} \\ P3 = \dots \\ \dots \\ \dots \\ P_{(n-1)} \\ P_{(n)} \end{array} \right.$$

En este conjunto de secuencias en particular, se ha empleado el dominio de actores y la propiedad *Johnny Deep*. Un procedimiento similar se aplica para el resto de propiedades como: escritor, director, género y el título de la película, que se obtiene al analizar cada propiedad. Esta lista permitirá encontrar las relaciones **rho-path**, que se describe en la siguiente etapa del algoritmo.

2. Explorar Relaciones rho-path

Hay una relación rho-path entre dos recursos semánticos siempre y cuando exista un camino que se los pueda conectar. En la Figura 3.9, se observa la relación mencionada entre la película *Piratas del Caribe* y *Alicia en el País de las Maravillas*, dado que se pueden conectar mediante la propiedad *Johnny Deep* que es el actor de las dos películas. Para encontrar todas las relaciones rho-path se debe descomponer la secuencia de propiedades *PS* formada en el paso 1.

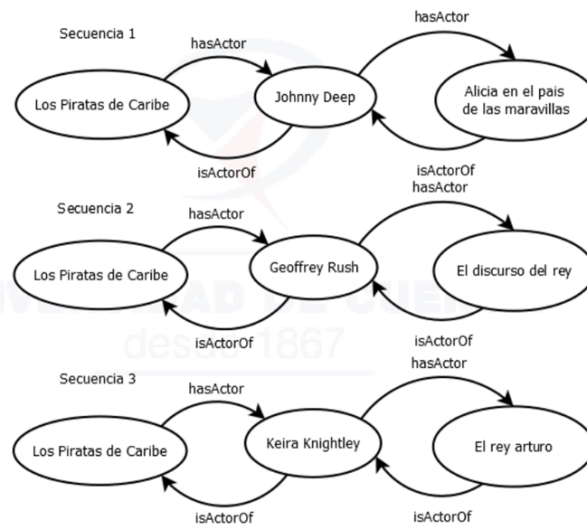


Figura 3.10: Descomposición individual de la secuencias de propiedades [9]

El resultado final son secuencias individuales tomando en cuenta solo contenidos televisivos, tal como se aprecia en la Figura 3.11.

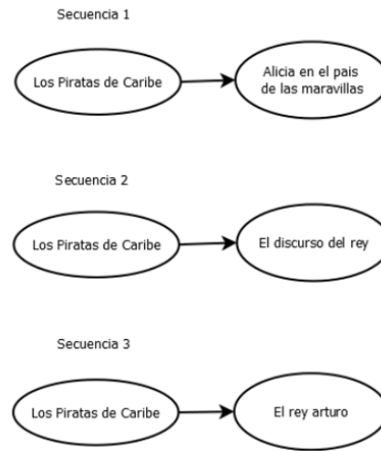


Figura 3.11: Relaciones rho-path [9]

Con los resultados obtenidos se encuentran las relaciones rho-join entre dos recursos cuando pertenezcan a la misma clase de unión, tal como lo menciona en [12].

3. Cálculo del DOI

Las relaciones encontradas a partir de la lista de secuencia de propiedades PS permiten determinar la calificación para la película que se está analizando mediante la ecuación 3.1, la cual fue definida en [9]:

$$DOI_t = \frac{\sum_{i=1}^n DOI(R_i)/length(R_i)}{\sum_{i=1}^n 1/length(R_i)} \quad (3.1)$$

Donde:

N , corresponde al número de relaciones rho-path y rho-join

DOI , se define como el nivel de interés del usuario

$Length$, hace referencia a la longitud de la relación rho-path y rho-join.

3.3. Identificación de Integrantes de Grupos de Usuarios

En la Sección 2.5 se mencionó que uno de los retos presentes en los sistemas recomendadores de grupos de usuarios corresponde a la determinación precisa de los integrantes presentes en la actividad televisiva, por lo que el uso de métodos no invasivos y automáticos contribuyen a mejorar la experiencia de los televidentes. Es así que este proceso permite que los usuarios no tengan que acceder al servicio de recomendación de contenidos de forma manual, por ejemplo, utilizando un control remoto u otro dispositivo similar, sino que bastaría con contar con una cámara integrada al televisor o en su defecto al dispositivo decodificador de TV digital denominado set-top-box.

El objetivo de la identificación de los integrantes de un grupo es proporcionar la entrada principal al sistema de recomendación de contenidos; es decir, proporcionar el grupo de usuarios al que se pretende realizar la recomendación. Por esta razón se espera que su nivel de precisión sea aceptable de tal manera que identifique los usuarios que estén en frente de la televisión con

un mínimo de error. En la Figura 3.12 se presenta la estructura general para la identificación de usuarios y posteriormente se detalla su desarrollo.

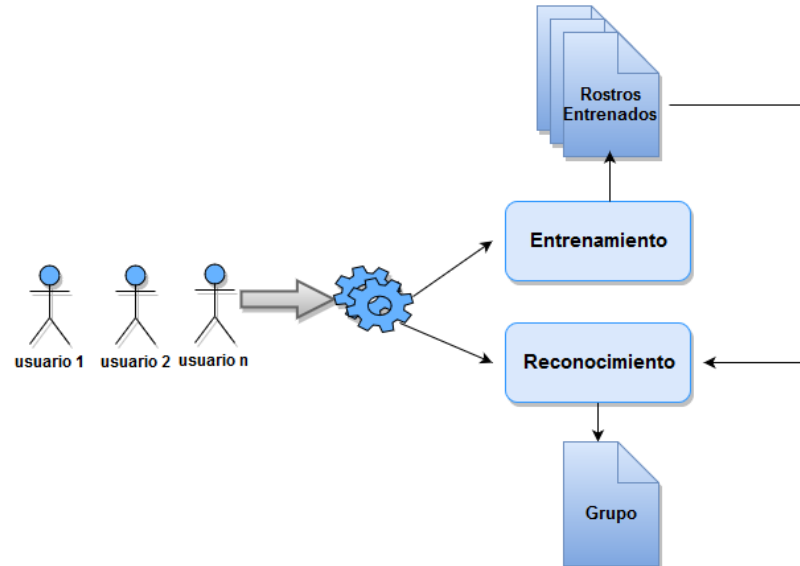


Figura 3.12: Estructura para la identificación de usuarios

3.3.1. Proceso de Captura de Imágenes y Detección

Una cámara digital se encarga de capturar un conjunto de imágenes en tiempo real por un periodo de tiempo determinado, a manera fotogramas o *frames* que en primera instancia se convierten a escala de grises, puesto que originalmente las imágenes se adquieren en color. Este paso con el objetivo de reducir la complejidad computacional de los algoritmos de reconocimiento que se utilizan posteriormente. Adicionalmente, de cada fotograma se obtiene la región principal de la cara de las personas detectadas, que se establece como una zona segmentada o subimagen de la imagen original y cuya dimensión se establece en 320×240 píxeles.

Para procesar la información en escala de grises presente en los fotogramas y encontrar los rostros de los usuarios, se utiliza el clasificador incorporado en las librerías de OpenCV conocido como *Haar Cascade*, el mismo que hace uso de una serie de características almacenadas en un archivo *haarcascade_frontalface_default.xml*, que contiene el modelo o patrón con forma de un rostro humano básico con el que se intentará identificar los rostros humanos en los fotogramas. Por cada rostro que el clasificador detecte, se dibujan rectángulos que encierran los mismos y de los cuales es posible determinar sus respectivas coordenadas espaciales.

3.3.2. Proceso de Entrenamiento

Este proceso se enfoca en obtener un conjunto de imágenes que posibilitan que los algoritmos de reconocimiento puedan identificar los rostros detectados en la fase anterior como pertenecientes a una determinada persona. Durante este paso, las imágenes son adquiridas mientras el usuario observa el televisor con el objetivo de que esté informado del procedimiento. Las imágenes son redimensionadas y convertidas a escala de grises y luego se transforman a formato



JPEG¹⁸ para que puedan ser almacenadas en un directorio que se ha denominado *TrainedFaces*. Cada imagen es almacenada con un nombre compuesto por el identificador (ID) del usuario y un valor que identifica el número de imagen por usuario. Estos valores serán guardados como etiquetas en un archivo XML para saber a qué usuario está asociada cada imagen; la etiqueta *FACE*, almacena el identificador de usuario y *FILE*, hace referencia al archivo JPEG correspondiente al usuario, esto se ilustra en el Listado 3.1, donde muestra un segmento de código asociado a la fase de entrenamiento.

Listado 3.1: Código de entrenamiento

```
<?xml version="1.0" encoding="utf-8"?>
<Faces_For_Training>
  <FACE>
    <NAME>Usuario</NAME>
    <FILE>face_Usuario_660580739.jpg</FILE>
  </FACE>
  <FACE>
    <NAME>Usuario</NAME>
    <FILE>face_Usuario_1386664251.jpg</FILE>
  </FACE>
</Faces_For_Training>
```

Es recomendable que las imágenes de entrenamiento se capturen diferentes posiciones de la cara del sujeto, incluyendo su vista frontal, lateral izquierdo, lateral derecho, frontal con inclinación hacia abajo y frontal con inclinación hacia arriba. También es conveniente que se cuente con al menos cinco imágenes para el entrenamiento, según se recomienda en la documentación de OpenCV. Estas imágenes se utilizan en los algoritmos de reconocimiento para crear un espacio multidimensional sobre el cual se mapean todos las personas que forman el grupo a ser recomendado.

3.3.3. Proceso de Reconocimiento

El proceso de reconocer a uno o varios miembros de un grupo puede realizarse mediante diferentes técnicas, para lo cual se ha creado un procedimiento que permite instanciar el reconocedor o clasificador con sus respectivos parámetros en función del algoritmo seleccionado:

Algoritmo EigenFaces

Este algoritmo recibe dos parámetros: El primero que corresponde al número de componentes reservados para realizar el Análisis de Componentes Principales (Sección 2.5.1). La documentación de OPENCV recomienda que se utilicen al menos 80 componentes; el segundo parámetro corresponde a un umbral de predicción; es decir, un valor que determina si la imagen capturada se puede establecer como conocida o desconocida. En el reconocedor implementado se utiliza el valor de retorno denominado *distancia Eigen* que determina la similaridad entre la imagen de prueba y los sujetos de entrenamiento. Experimentalmente se determinó que un adecuado valor para el umbral de reconocimiento es de 2000.

¹⁸<http://www.jpeg.org/jpeg/>



Algoritmo FisherFaces

El algoritmo de FisherFaces recibe dos parámetros de manera similar que lo hace EigenFaces. El primero, es el número de componentes reservados para realizar el Análisis de Discriminante Lineal (Sección 2.5.1) con el criterio de Fisherfaces mientras que el segundo corresponde a un umbral para las incógnitas; si la distancia Eigen resultante está por encima del valor regresado por un método de OpenCV *Predict(imagen)* se devolverá un valor de -1 que significa desconocido. El umbral se establece en un valor predeterminado de 3500, si este valor se altera, un reentrenamiento del sistema es requerido.

Algoritmo LBPH

El algoritmo LBPH (Sección 2.5.1), a diferencia de los otros dos algoritmos, utiliza cinco parámetros:

- *radio*: El valor utilizado para la construcción del Patrón Local Binario Circular, definido como píxel central.
- *vecinos*: El número de puntos de muestreo para construir el Patrón Local Binario Circular. Un valor sugerido por la documentación de OpenCV es de 8.
- *grid_x*: El número de cuadros en la dirección horizontal, OPENCV recomienda 8.
- *grid_y*: El número de cuadros en la dirección vertical, OPENCV recomienda 8.
- *umbral*: Si la distancia al vecino más cercano es mayor que el umbral, funciona al igual que en el algoritmo de Fisherfaces. El valor por defecto del umbral es de 100.

En general los algoritmos tomarán las imágenes de entrenamiento y las capturas en tiempo real para construir los componentes que serán utilizados en los análisis respectivos, que se basan en medidas de similaridad a través de una función de umbral.

3.3.4. Proceso de Optimización

Los resultados del proceso de reconocimiento son devueltos de sus respectivos algoritmos a través de una salida en forma de una cadena (*string*), que contiene una lista de los ID de los usuarios reconocidos más los que no fueron reconocidos. Posteriormente se ejecuta un proceso de filtrado en función de las siguientes etapas:

- Limpieza: Se mantiene únicamente los resultados positivos, se eliminan los rostros desconocidos.
- Agrupación: Se agrupan los resultados por usuario, incluyendo su identificador de usuario y el número de veces que fue reconocido positivamente.
- Ordenamiento: Los usuarios que han sido reconocidos el mayor número de veces se ubican en la parte superior de una lista.

El conjunto de individuos reconocidos, se obtiene a partir de la lista de los de usuarios definido al aplicar el proceso de optimización. El grupo de usuarios formado será enviado al *Servicio de Recomendación*.



3.4. Procedimiento de Clasificación de Grupos

¿Cómo saber que los miembros de un grupo determinado tienen gustos similares o dispersos? En esta sección se presentan los enfoques propuestos en este trabajo para poder contestar a esta pregunta. Con este fin, es necesario analizar los perfiles ontológicos de cada integrante del grupo, para obtener información relacionada a sus preferencias televisivas. Como resultado de este análisis, se puede determinar si los usuarios frente al televisor se identifican como un grupo homogéneo o un grupo heterogéneo. En este contexto se ha planteado dos diferentes enfoques, que se han denominado: 1. Enfoque de Votación, y 2. Enfoque de Promedios; los mismos que se explican más adelante.

3.4.1. Grupos Homogéneos y Heterogéneos

En el ámbito de entretenimiento con la TV, lo más común es encontrar varias personas de una familia que la observan juntas, muchas de las veces el conjunto de espectadores puede estar conformado por un grupo de amigos; por ejemplo, aquellos que se reúnen los domingos a ver un partido de fútbol. Un grupo G_i de n miembros, puede incluir tanto usuarios muy afines como usuarios diferentes, por lo que se debe analizar sus atributos como un punto de partida para buscar medidas de similaridad entre ellos, como por ejemplo su edad y género, entre otros, que aparte de sus intereses televisivos, posibilitan generar recomendaciones adecuadas a partir del descubrimiento de conocimiento a partir del perfil de cada uno. De esta forma, los grupos de usuarios se clasifican en dos categorías o tipos: grupos homogéneos y grupos heterogéneos, según se indica en [59] y [54].

Homogéneos

Este tipo de grupo lo pueden conformar un conjunto de amigos/as, un grupo de niños/as, cuyos intereses no son totalmente similares; sin embargo, se considera que puede haber un pequeño número de coincidencias entre algunas de sus preferencias, lo que significa que comparten intereses comunes. Por ejemplo, un grupo de jóvenes como los que se presenta en la Figura 3.13. Si a todos los integrantes les fascinan los partidos de fútbol, se podría considerar homogéneos.

Heterogéneos

Un grupo heterogéneo generalmente lo conforma una familia, dado que en este escenario se encuentran personas de diferente género, edad, profesión o educación y por ende los intereses difieren entre uno y otro, tal es el caso de una familia de cinco integrantes tal como presenta la Figura 3.13, compuesta de tres hijos y sus padres. Si al papá le agrada los partidos de fútbol, a la mamá, le fascina los documentales médicos, y los gustos de los hijos son películas basadas en animación y aventura. Realizando un simple análisis, dicha familia posee gustos disímiles. Se pueden dar muchos escenarios donde varía la cantidad de miembros en una familia o amigos, en la que no siempre van a estar todos observando la TV.




Figura 3.13: (izq.) Grupo heterogéneo, (der.) Grupo homogéneo

3.4.2. Enfoque de Votación

El conjunto de integrantes puede estar conformado por n personas, expresados así, $G_i = \{u_1, u_2, \dots, u_n\}$. El proceso de análisis se efectúa para dos usuarios, luego se analiza al grupo con los resultados de cada subgrupo. Como ejemplo, $G_i = \{u_1, u_2, u_3\}$, está compuesto de tres personas.

Paso 1: Combinaciones

Tomando el conjunto de usuarios del grupo G_i , que está conformado por sus identificadores, se procede a formar parejas, con la restricción de que un elemento no se vuelva a repetir; es decir, no puede darse lo siguiente:

1. (u_1, u_2)
2. (u_1, u_3)
3. (u_2, u_1)
4. (u_2, u_3)
5. (u_3, u_1)
6. (u_3, u_2)

Claramente se observa que se formaron seis combinaciones, donde $(u_1, u_2) = (u_2, u_1)$, $(u_1, u_3) = (u_3, u_1)$ y $(u_2, u_3) = (u_3, u_2)$. Lo que resulta que se debe obtener solamente tres subgrupos, esto se logra empleando Combinaciones sin Repetición o Variación¹⁹, dado por la Fórmula 3.2.

$$C_m^n = \frac{m!}{n!(m-n)!} \quad (3.2)$$

¹⁹Fuente: <http://www.aulafacil.com/cursos/111231/ciencia/estadisticas/estadisticas/combinaciones-variaciones-y-permutaciones-ii>



Del cual se puede obtener grupos de m elementos tomados de n en n . Dado que existen tres usuarios en el grupo G_i , entonces $m = 3$ y $n = 2$.

$$C_3^2 = \frac{3!}{2!(3-2)!} = 3$$

Significa que existen tres combinaciones o subgrupos de los tres usuarios, representados de la siguiente manera:

1. (u_1, u_2)
2. (u_1, u_3)
3. (u_2, u_3)

El subgrupo formado será estudiado en los pasos posteriores, el resultado de cada uno permitirá realizar la clasificación.

Paso 2: Filtrado de Propiedades Televisivas

Analizando el subgrupo (u_1, u_2) , de cada miembro se obtiene el perfil ontológico para extraer las características descriptivas de los contenidos televisivos tales como:

- Título del contenido
- Género
- Actor
- Escritor
- Director

Esto se consigue mediante el uso del algoritmo de inferencia semántica explicado en la Sección 3.2.7, aquí, es necesario un valor entre 1 y 5, debido a que las propiedades semánticas tienen una calificación denominada DOI. Las propiedades a extraer deben cumplir la condición de tener el $DOI \geq 2,5$, para seleccionar los relevantes. Si el subgrupo posee la lista de películas con sus respectivas calificaciones, representada en la Tabla 3.2.

Si $DOI \geq 3$, luego de inferir las propiedades actor, género y película, se presenta un porcentaje de los resultados en la Tabla 3.3.

Según la Tabla 3.3, a los usuarios uno y dos les agradan las películas de la actriz Angelina Jolie y del actor David Schwimmer. Los géneros en común son de Animación y Familia. Algunas de las películas afines son Sr. Y Sra. Smith, Kung Fu Panda, etc. Estas pautas indican que existen preferencias similares entre el par de usuarios.

Paso 3: Creación de Vectores

La información levantada en el paso anterior se almacena en vectores, estos son creados por propiedades y usuarios, se representan de la siguiente manera:

$$\begin{aligned} v_{\rho u1} &= (\rho_1, \rho_2, \dots, \rho_n) \\ v_{\rho u2} &= (\rho_1, \rho_2, \dots, \rho_n) \end{aligned} \tag{3.3}$$



CAPÍTULO 3. DESARROLLO E IMPLEMENTACIÓN DEL SISTEMA

Usuario 1		Usuario 2	
Película	DOI	Película	DOI
La familia P. Luche (2002–)	4	La familia P. Luche (2002–)	4
Piratas del Caribe. En mareas misteriosas(2011)	3	Los Simpson (1989–)	3
Kung Fu Panda 2 (2011)	4	The Amazing Spider-Man (2012)	3
Gru - Mi villano favorito 2(2013)	4	Kung Fu Panda 2 (2011)	4
Enredados (2010)	2	Thor: El mundo oscuro (2013)	4
Ice Age. La edad de hielo (2002)	4	Harry Potter y la cámara secreta (2002)	3
Sr. y Sra. Smith (2005)	3	Gru - Mi villano favorito 2(2013)	4
Shrek tercero (2007)	4	Enredados (2010)	3
Rio (2011)	4	Ice Age. La edad de hielo (2002)	4
El amanecer del Planeta de los Simios (2014)	3	Sr. y Sra. Smith (2005)	3
Las crónicas de Narnia: El príncipe Caspian (2008)	3	Maléfica (2014)	3
Shrek, felices para siempre (2010)	4	Monstruos contra alienígenas (2009)	4
Harry Potter y el prisionero de Azkaban (2004)	1	Shrek tercero (2007)	3

Tabla 3.2: Lista de películas de u_1 y u_2

Actor		Género		Película	
Usuario 1	Usuario 2	Usuario 1	Usuario 2	Usuario 1	Usuario 2
Angelina Jolie	Angelina Jolie	ANIMATION	ANIMATION	La familia P. Luche (2002–)	La familia P. Luche (2002–)
David Schwimmer	Florinda Meza	FAMILY	COMEDY	Piratas del Caribe. En mareas misteriosas (2011)	Los Simpson (1989–)
Ving Rhames	John Goodman		ADVENTURE	Kung Fu Panda 2 (2011)	The Amazing Spider-Man (2012)
Jon Voight	David Schwimmer		FAMILY	Gru - Mi villano favorito 2(2013)	Kung Fu Panda 2 (2011)
Steve Carell	Steve Carell			Enredados (2010)	Thor: El mundo oscuro (2013)
Penélope Cruz	Jack Black			Ice Age. La edad de hielo (2002)	Harry Potter y la cámara secreta (2002)
ShiaLaBeouf	John Leguizamo			Sr. y Sra. Smith (2005)	Gru - Mi villano favorito 2(2013)
Andy Serkis	Paul Newman			Shrek tercero (2007)	Enredados (2010)
John Leguizamo	Emma Stone			Rio (2011)	Ice Age. La edad de hielo (2002)
Josh Duhamel	Eugenio Derbez			El amanecer del Planeta de los Simios (2014)	Sr. y Sra. Smith (2005)
Karen Disher	Steve Buscemi			Las crónicas de Narnia: El príncipe Caspian (2008)	Maléfica (2014)

Tabla 3.3: Propiedades semánticas de u_1 y u_2

Donde $v_{\rho u_1}$ y $v_{\rho u_2}$, son los vectores del usuario uno y dos respectivamente, además ρ corresponde a los atributos de la película, como se describe a continuación:

$$\rho = \{\text{título}(t), \text{actor}(a), \text{género}(g), \text{director}(d), \text{escritor}(e)\}$$



Ejemplificando este proceso los vectores de actores para u_1 y u_2 se forma de la siguiente manera:

$$v_{au1} = \{Angelina Jolie, David Schwimmer, Ving Rhames, actor_{n-1}, actor_n\}$$

$$v_{au2} = \{Angelina Jolie, Florinda Meza, John Goodman, actor_{n-1}, actor_n\}$$

El mismo procedimiento se sigue para el resto de propiedades. Los vectores son de tipo *String* o cadenas, que posteriormente se comparan con el fin de encontrar un nivel de similaridad.

Para la combinación (u_1, u_2) , luego de obtener sus propiedades y formar los vectores, los resultados están en la Tabla 3.4, donde se visualiza las propiedades, la cantidad (tamaño de los vectores) de películas, actores, géneros, escritores y directores para cada usuario. El usuario uno y dos poseen 148 y 144 películas respectivamente, las cuales cumplen con la condición del valor del DOI ya establecido. De igual forma se analiza para los siguientes.

Propiedad	Usuario1	Usuario 2
Título	148	144
Actor	91	86
Género	6	5
Escritor	19	19
Director	31	32

Tabla 3.4: Número de propiedades semánticas por propiedad, para u_1 y u_2

En el punto que se trate, las columnas respectivas están resaltadas con fondo celeste.

Paso 4: Fijar un Umbral

Se determina un valor por propiedad, definido como umbral; este, permite obtener el número de atributos que deben coincidir entre u_1 y u_2 . Representado con la siguiente fórmula.

$$\mu_\rho = \frac{\frac{v_{\rho u1(size)}}{2} + \frac{v_{\rho u2(size)}}{2}}{2} \quad (3.4)$$

Donde, $v_{\rho u1(size)}$ y $v_{\rho u2(size)}$ son los tamaños de los vectores de la propiedad ρ , creado en el paso anterior tanto para el usuario u_1 como para el u_2 .

En el ejemplo, se procede a calcular el valor del umbral de la propiedad actor, entonces $\rho = a$, $v_{au1(size)} = 91$ y $v_{au2(size)} = 86$, con dichos datos, el valor de μ_a es:

$$\mu_a = \frac{\frac{91}{2} + \frac{86}{2}}{2} = 44$$

Empleando el procedimiento para todas las propiedades se obtiene los resultados expresados en la Tabla 3.5.

Para la característica actor, el valor calculado indica que entre el par de usuarios deben existir

Propiedad	Usuario 1	Usuario 2	Umbral
Título	148	144	73
Actor	91	86	44
Género	6	5	3
Escritor	19	19	10
Director	31	32	16

Tabla 3.5: Umbral de las propiedades

al menos 44 actores en común; así, los dos son considerados con gustos similares en dicha propiedad.

Paso 5: Determinar el Número de Coincidencias

Obtener la cantidad de características similares de (u_1, u_2) , comparando los vectores por propiedad. En el caso de actores, representado por α_a refleja el número de similitudes o coincidencias. Considerando la información del paso dos, u_1 y u_2 poseen en común a la actriz Angelina Jolie, entonces α_a se incrementará en uno, con esta idea se recorre el vector comparando posición por posición. El pseudocódigo se presenta en la Figura 3.14:

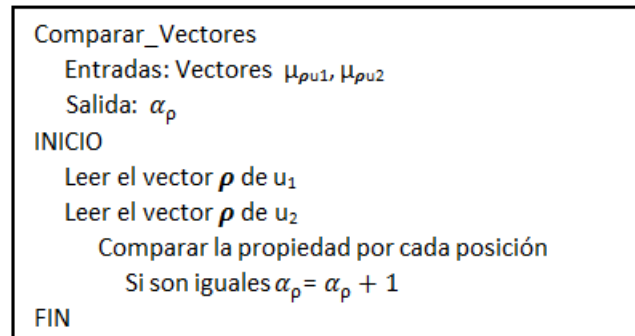


Figura 3.14: Pseudocódigo para encontrar el número coincidencias de la propiedad ρ

La variable ρ , representa a cada uno de los atributos de la película, según se estableció en el paso dos. La salida del algoritmo es el valor necesario es este paso, quedando definido así.

$$\alpha_\rho \tag{3.5}$$

Continuando con el ejemplo, se ha determinado 82 actores repetidos entre u_1 y u_2 . Con esta información se podría decir que el par de usuarios, son homogéneos, lo cual se espera corroborar al concluir el proceso de clasificación de grupos. De todas las propiedades semánticas están ilustradas en la Tabla 3.6.

Propiedad	Usuario 1	Usuario 2	Umbral	Coincidencias
Título	148	144	73	137
Actor	91	86	44	82
Género	6	5	3	5
Escritor	19	19	10	19
Director	31	32	16	31

Tabla 3.6: Número de similitudes de las propiedades

Paso 6: Valoración (Votación) por Propiedad

En este paso se asigna un valor por propiedad dependiendo del umbral y el número de coincidencias calculado en los paso 4 y 5, este corresponde a cero o uno, que estará simbolizado por β . Si el número de semejanzas de la propiedad actor α_a es mayor o igual al umbral μ_a , entonces β_a toma el valor de uno, caso contrario es cero. Las valoraciones para todas las propiedades se representan de la siguiente manera:

$$\beta_p = 1 \quad \text{si} \quad \alpha_p \geq \mu_p \quad (3.6)$$

Haciendo referencia al ejemplo, el umbral de actores es $\mu_a = 73$, el número de coincidencias es $\alpha_a = 137$, entonces α_a es mayor a μ_a , por ende $\beta_a = 1$. Las condiciones establecidas se cumplen en todas las propiedades, por tal razón, el valor de β asignado para cada una de ellas toma el valor de 1, como se observa en la Tabla 3.7.

Propiedad	Usuario 1	Usuario 2	Umbral	Coincidencias	Votación por propiedad
Título	148	144	73	137	1
Actor	91	86	44	82	1
Género	6	5	3	5	1
Escritor	19	19	10	19	1
Director	31	32	16	31	1

Tabla 3.7: Votación para cada propiedad

Paso 7: Asignación de Pesos

Las propiedades son relevantes una respecto a la otra, debido a que permite distinguir los gustos por una película si no se conoce todo acerca de éste. Por ejemplo, al usuario u_1 le place ver las películas del género aventura tales como: Transformers, Iron Man, entre otros; dándole importancia a los contenidos más por dicha característica que por los demás atributos.

Se considera que están en el mismo nivel el actor y el título de la película. Finalmente a las propiedades escritor y director se asigna el mismo valor, dado que no tienen tanta relevancia que permitan determinar las distinciones televisivas del usuario. La asignación de pesos se realiza



de acuerdo a su importancia.

$$\begin{aligned}
 \omega_g &= 0,5 && \text{género} \\
 \omega_a &= 0,2 && \text{actor} \\
 \omega_t &= 0,2 && \text{título} \\
 \omega_e &= 0,05 && \text{escritor} \\
 \omega_d &= 0,05 && \text{director}
 \end{aligned}
 \tag{3.7}$$

Con la regla de la normalización, la sumatoria de los pesos debe ser igual a uno, como lo demuestra la siguiente definición.

$$\sum \omega_p = 1
 \tag{3.8}$$

En el ejemplo se puede observar que en la columna Pesos de la Tabla 3.8, se encuentra asignado su respectivo valor, según la relevancia de las propiedades.

Propiedad	Usuario 1	Usuario 2	Umbral	Coincidencias	Votación por propiedad	Pesos
Título	148	144	73	137	1	0.2
Actor	91	86	44	82	1	0.2
Género	6	5	3	5	1	0.5
Escritor	19	19	10	19	1	0.05
Director	31	32	16	31	1	0.05

Tabla 3.8: Asignación de pesos por propiedad

Paso 8: Clasificación de Subgrupo

Con todo el desarrollo previo realizado para (u_1, u_2) , finalmente se clasifica en homogéneo o heterogéneo. El cómputo de los valores obtenidos en el paso 6 y los pesos asignados en el paso 7 permiten clasificar a los usuarios en cuestión. Primero, se debe obtener el porcentaje total aplicando la siguiente fórmula:

$$\xi = \left(\sum \beta_p * \omega_p \right) * 100, \quad 0 \leq \xi \leq 100
 \tag{3.9}$$

El resultado de ξ está en el rango de cero y cien. Lo siguiente es fijar un valor que posibilite la clasificación final, que se define por δ , este representa el porcentaje que debe cumplir los usuarios para considerarse homogéneos. Se plantea la condición $\xi \geq \delta$, si la respuesta es verdadera el par de usuarios es homogéneo. Además, el mismo valor del umbral será considerado en el siguiente paso para la clasificación general del grupo después de haber evaluado todos los subgrupos del grupo en análisis. También se utilizará en el *Enfoque de Promedios*.

Demostrando con el ejemplo anterior, se visualiza en la Tabla 3.9, donde la columna total representa el valor final por propiedad. Aplicando la Fórmula 3.9, se obtiene:

$$\xi = ((1 * 0,5) + (1 * 0,2) + (1 * 0,2) + (1 * 0,05) + 1 * 0,05)) * 100 = 100$$

Este resultado demuestra, lo antes mencionado, los usuarios (u_1, u_2) son homogéneos con el



100%, valor expuesto en la última fila de la Tabla 3.9.

Propiedad	Usuario 1	Usuario 2	Umbral	Coincidencias	Votación por propiedad	Pesos	Total
Título	148	144	73	137	1	0,2	0,2
Actor	91	86	44	82	1	0,2	0,2
Género	6	5	3	5	1	0,5	0,5
Escritor	19	19	10	19	1	0,05	0,05
Director	31	32	16	31	1	0,05	0,05
(u1,u2) 100% Homogéneo							1,00

Tabla 3.9: Clasificación del subgrupo - Enfoque Votación

Paso 9: Clasificación del Grupo

Luego de concluir con el desarrollo para todos los subgrupos de dos, determinados en el paso uno para el grupo $G_i = \{u_1, u_2, u_3\}$, se categoriza a este en homogéneo o heterogéneo. Para esto, se determina el número de homogéneos y heterogéneos dentro del grupo G_i , según las fórmulas siguientes:

$$N_h = \sum Hom \tag{3.10}$$

$$N_x = \sum Het \tag{3.11}$$

$$T_{hx} = N_h + N_x \tag{3.12}$$

N_h , Cantidad de subgrupos homogéneos

N_x , Cantidad de subgrupos heterogéneos

T_{hx} , Número de subgrupos

El porcentaje de homogeneidad del grupo se calcula de acuerdo a la cantidad del tipo de grupo. Si existe mayor cantidad de subgrupos homogéneos se define al grupo como tal con su respectivo porcentaje, de la misma manera si la cantidad de subgrupos heterogéneos es mayor que de los homogéneos.

$$G_h = \frac{N_h}{T_{hx}} * 100 \tag{3.13}$$

$$G_x = \frac{N_x}{T_{hx}} * 100 \tag{3.14}$$

G_h , Grupo homogéneo

G_x , Grupo heterogéneo

Por último se establece la condición $G_h \geq \delta$, al ser positiva se puede afirmar que el grupo es homogéneo.



Continuando con el ejemplo, si los resultados son los siguientes:

$$G_i = \begin{cases} (u_1, u_2) & \text{Hom}(100\%) \\ (u_1, u_3) & \text{Hom}(51\%) \\ (u_2, u_3) & \text{Het}(48\%) \end{cases}$$

Si el umbral $\delta = 50$. El subgrupo (u_1, u_2) está especificado como homogéneo con el valor del 100 %, lo que indica que todas sus preferencias televisivas son similares. En el caso de los televidentes (u_1, u_3) también están definidos como homogéneos con un porcentaje menor de 51 %. Por último el par de usuarios (u_2, u_3) se categoriza como heterogéneo porque no cumple la condición establecida, debido a que su total es 48 %. Resultando lo siguiente:

$$N_h = 2$$

$$N_x = 1$$

$$T_{hx} = 3$$

Se cumple $N_h > N_x$, entonces, G_i es considerado homogéneo con el siguiente porcentaje.

$$G_h = \frac{2}{3} * 100 = 66,67\%$$

Dado que $\delta = 50$, y G_h es mayor a δ , se confirma la homogeneidad del grupo.

3.4.3. Enfoque de Promedios

Esta perspectiva sigue el mismo procedimiento del enfoque de Votación, con algunas variaciones. Tomando el ejemplo explicado en el enfoque anterior, el grupo $G_i = \{u_1, u_2, u_3\}$, de tres usuarios, de igual forma, el análisis se lleva a cabo para cada par de usuarios, de allí, con los resultados obtenidos se categoriza al grupo. El desarrollo general se describe a continuación:

Paso 1: Combinaciones

El paso inicial es la generación de combinaciones de dos usuarios del grupo G_i , el resultado esta descrito la Fórmula 3.2.

Paso 2: Filtrado de Propiedades Televisivas

Del subgrupo en análisis se obtiene el perfil ontológico para extraer sus propiedades semánticas más relevantes estipuladas en la ontología, Sección 3.4.2.

Paso 3: Creación de Vectores

Una vez obtenido las propiedades filtradas aplicando inferencia semántica, se forman vectores respectivos, estos están representados en la Fórmula 3.3.

Paso 4: Promedio de las Propiedades

El siguiente paso de este enfoque es comparar los vectores para determinar el número de similitudes. Posteriormente se promedia estos valores, el mismo que define el porcentaje de coincidencias entre el par de usuarios (u_1, u_2) , descrito a continuación:

$$\lambda_\rho = \frac{\left(\frac{\alpha_\rho}{v_{\rho u_1(size)}} * 100\right) + \left(\frac{\alpha_\rho}{v_{\rho u_2(size)}} * 100\right)}{2} \quad (3.15)$$

Donde, $v_{\rho u_1(size)}$ y $v_{\rho u_2(size)}$ son el tamaño de los vectores. Y, α_ρ , es el número de coincidencias entre los dos usuarios.

Los valores calculados representan el promedio de las propiedades similares obtenidas. Teniendo en cuenta los datos empleados en el ejemplo del enfoque anterior, para la propiedad actor, $\alpha_a = 82$, $v_{au_1(size)} = 91$ y $v_{au_2(size)} = 86$, entonces λ_a es:

$$\lambda_a = \frac{\left(\frac{82}{91} * 100\right) + \left(\frac{82}{86} * 100\right)}{2} = 92,73 \%$$

El resultado refleja que los usuarios (u_1, u_2) tienen en común el 92.73% de actores, de esta manera se obtiene los porcentajes respectivos para cada propiedad como se observa en la Tabla 3.10.

Propiedad	Usuario 1	Usuario 2	Coincidencias	Promedio
Título	148	144	137	93.85
Actor	91	86	82	92.73
Género	6	5	5	91.67
Escritor	19	19	19	100.00
Director	31	32	31	98.44

Tabla 3.10: Promedio de las propiedades

Paso 5: Asignación de Pesos

En el presente enfoque también se establece pesos para cada propiedad según su relevancia, con el fin de mantener los valores anteriores, se toma lo establecido en la Fórmula 3.7.

La columna Total de la Tabla 3.11, representa el valor por propiedad una vez que ya se ha multiplicado por el respectivo peso asignado.

Paso 6: Clasificación de Subgrupo

El porcentaje total de un subgrupo se obtiene al sumar los promedios de cada propiedad, para esto se aplica la fórmula planteada a continuación:

$$\eta = \sum \lambda_\rho * \omega_\rho, \quad 0 \leq \eta \leq 100 \quad (3.16)$$



Propiedad	Usuario 1	Usuario 2	Coincidencias	Promedio	Pesos	Total
Título	148	144	137	93,85	0,2	37,54
Actor	91	86	82	92,73	0,2	27,82
Género	6	5	5	91,67	0,5	18,33
Escritor	19	19	19	100,00	0,05	5,00
Director	31	32	31	98,44	0,05	4,92
(u1,u2) 93.62% Homogéneo						93,62

Tabla 3.11: Clasificación del subgrupo - Enfoque Promedios

En la última fila de la Tabla 3.11, se visualiza el total. Concluyendo que el par de usuarios u_1 y u_2 son homogéneos con el 93.63 %, el enfoque de votación también lo discrimina como homogéneo, pero con el 100 %.

A continuación se fija un valor denominado umbral, para determinar si cada combinación es homogénea o heterogénea, se utiliza el mismo valor fijado en el enfoque anterior, que está definido por δ . Así, se garantiza la equidad para la generación de resultados y en la parte de evaluación del sistema.

Paso 7: Clasificación de Grupo

El proceso es similar al enfoque anterior, el cual está detallado en el paso nueve, Sección 3.4.2.

3.4.4. Clasificación de Grupo Promediando los Enfoques

Los enfoques analizados para la discriminación de grupos en sus dos variantes: homogéneo y heterogéneo, en algunos casos pueden generar diferentes resultados; si se procesa al grupo $G_i = \{u_1, u_2, u_3\}$, el enfoque de Votación determina que el grupo es homogéneo con el 60 %, en cambio el resultado del enfoque de Promedios es heterogéneo con el 58 %, existe un desajuste, al determinar el tipo de grupo. Para esta clasificación se pueden dar algunos casos, con los que se procederá de diferente manera.

El umbral determinado para clasificar cada combinación de usuarios, el mismo se utiliza para clasificar al grupo en general en los dos enfoques, también se emplea en este punto. Este está expresado por δ . Entre los casos que puede darse, está:

Caso 1: Los dos enfoques discriminan al grupo como homogéneo.

- Votación: *Homogéneo*
- Promedios: *Homogéneo*
- Umbral: δ

Para obtener el tipo de grupo se debe promediar los resultados de los enfoques, según la Fórmula 3.17, posteriormente se aplica la condición especificada en 3.18; el promedio obtenido debe ser



mayor o igual al umbral expresado en δ .

$$P' = \frac{V_h + P_h}{2} \tag{3.17}$$

Si $P' \geq \delta$ entonces,

$$G_h = P' \tag{3.18}$$

Caso contrario, el promedio se resta de cien, el resultado representa el porcentaje de un grupo heterogéneo.

$$G_x = 100 - P' \tag{3.19}$$

P' , promedio de los enfoques.

G_h , el grupo es homogéneo, promediando los dos enfoques.

V_h , el grupo es homogéneo según el enfoque de Votación.

P_h , el grupo es homogéneo según el enfoque de Promedios.

Para los tres valores G , V y P , si el grupo es heterogéneo, se representa con x , en lugar de h . Los posibles casos se resume en la Tabla 3.12:

Casos	E. Votación	E. Promedios	Promedio	Cumple la Condición *	No cumple la Condición *
1	Homogéneo	Homogéneo	$P' = \frac{V_h + P_h}{2}$	$G_h = P'$	$G_x = 100 - P'$
2	Homogéneo	Heterogéneo	$P' = \frac{V_h + (100 - P_x)}{2}$	$G_h = P'$	$G_x = 100 - P'$
3	Heterogéneo	Homogéneo	$P' = \frac{(100 - V_x) + P_h}{2}$	$G_h = P'$	$G_x = 100 - P'$
4	Heterogéneo	Heterogéneo	$P' = \frac{V_x + P_x}{2}$	$G_x = P'$	

Tabla 3.12: Clasificación de grupo - Promediando los Enfoques de Votación y Promedios

* El promedio calculado debe ser mayor o igual al umbral determinado, para que el grupo se considere homogéneo; siendo, $P' \geq \delta$. Si los enfoques retornan al grupo como heterogéneo, no es necesario aplicar ninguna condición.

En el caso 2, donde el enfoque por votación caracteriza al grupo como homogéneo, y como heterogéneo el enfoque de promedios. Para determinar el promedio de los homogéneos, se considera, si P_x es el valor de disparidad, $(100 - P_x)$ representa el porcentaje de similitud, entonces se aplica la Fórmula 3.17.

$$P' = \frac{V_h + (100 - P_x)}{2}$$

Con la respectiva variación, del promedio obtenido, ya se puede caracterizar al grupo como homogéneo o heterogéneo si cumple la condición impuesta.

Para el caso 3, la lógica es la misma, el enfoque de votación clasifica al grupo como heterogéneo, entonces este valor se resta de cien, para obtener el porcentaje de homogeneidad. En el último caso, los dos enfoques discriminan al grupo como heterogéneo, se procede como en el caso 1, con la variación que no cumple con ningún condicionante.

3.5. Algoritmo de Recomendación para Grupos Homogéneos

La estructura de recomendación para grupos homogéneos se ilustra en la Figura 3.15, la cual se desglosa de la arquitectura general del sistema, representado en la Figura 3.4. La entrada del conjunto de usuarios está previamente clasificada, luego se aplica la metodología de fusión de perfiles, explicado en la Sección 2.4.2. Finalmente se genera las recomendaciones de contenidos para el grupo.




Figura 3.15: Procedimiento de Recomendación para grupos homogéneos

3.5.1. Modelado de Grupo

Fusión de Perfiles.- Es un enfoque de agrupamiento de usuarios, el cual, colecciona características similares que describen a los usuarios. Su función es tomar los identificadores de cada televidente, de esta manera se forma un identificador único de grupo, con el que se busca el perfil ontológico, sino existe se crea el perfil grupal.

El procedimiento de la fusión de perfiles es agregar las preferencias individuales en uno solo, se toma la lista de contenidos calificados por el usuario, recorre uno a uno; si encuentra un mismo contenido, el valor se promedia, de esta forma se agrega los contenidos por usuarios. La ontología final, contiene las preferencias de todos, si en caso que existió películas iguales entre los integrantes no constará la calificación original sino la promediada. Por ejemplo, la lista de películas de tres usuarios del grupo $G_i = \{u_1, u_2, u_3\}$ descrita en la Tabla 3.13.

En la ontología grupal se incluirá la lista de películas visualizadas en la Tabla 3.14.

Cada integrante tiene una lista de 4 películas, el total del grupo es 7, dado que se ha promediado los contenidos similares.

Con el listado de ratings para el grupo, se procede a crear el perfil grupal de la misma manera como se crea el perfil personal (Sección 3.2.4), dado que la fusión de perfiles representa a todos los miembros en un solo usuario común.

3.5.2. Técnica de Recomendación

En el Sistema de Recomendación de Contenido Personalizado [9], se analizó el algoritmo de recomendación con Inferencia Semántica y Semántico por dispersión. Según los resultados expuestos el algoritmo basado en inferencia semántica realiza mejores sugerencias, dado que el



Usuario 1			Usuario 2			Usuario 3		
Película	DOI		Película	DOI		Película	DOI	
 Piratas del Caribe	5		 Piratas del Caribe	4		 Piratas del Caribe	5	
 Mi Villano Favorito	5		 Avatar	5		 Spider Man	4	
 Transformers	3		 Yo, Robot	4		 Transformers	4	
 El gato con botas	5		 Transformers	5		 El gato con botas	4	

Tabla 3.13: Listado de películas de los integrantes de G_i

Num.	Película	DOI
1	Piratas del Caribe	4.66
2	Mi Villano Favorito	5
3	Avatar	5
4	Spider Man	4
5	Transformers	4
6	Yo, Robot	4
7	El gato con botas	4

Tabla 3.14: Listado de películas del grupo G_i

margen de error es menor respecto al algoritmo semántico por dispersión, este, fue determinado utilizando la métrica de Error Absoluto Medio (MAE).

Con lo antes expuesto, para la recomendación de contenidos audiovisuales para grupos de televidentes se usa el algoritmo de inferencia semántica. El parámetro de entrada es el perfil ontológico de un determinado usuario, debido a que el algoritmo fue implementado para recomendar a un solo usuario. Para que el algoritmo no sufra modificaciones, se usó la metodología de fusión de perfiles, el cual genera un usuario virtual, donde contiene al grupo, de esta manera el recomendador toma al grupo como un usuario único. Al terminar generará una lista de contenidos audiovisuales para el grupo.

El proceso de recomendación se expresa a manera de pseudocódigo, el cual se ilustra en la Figura 3.16.

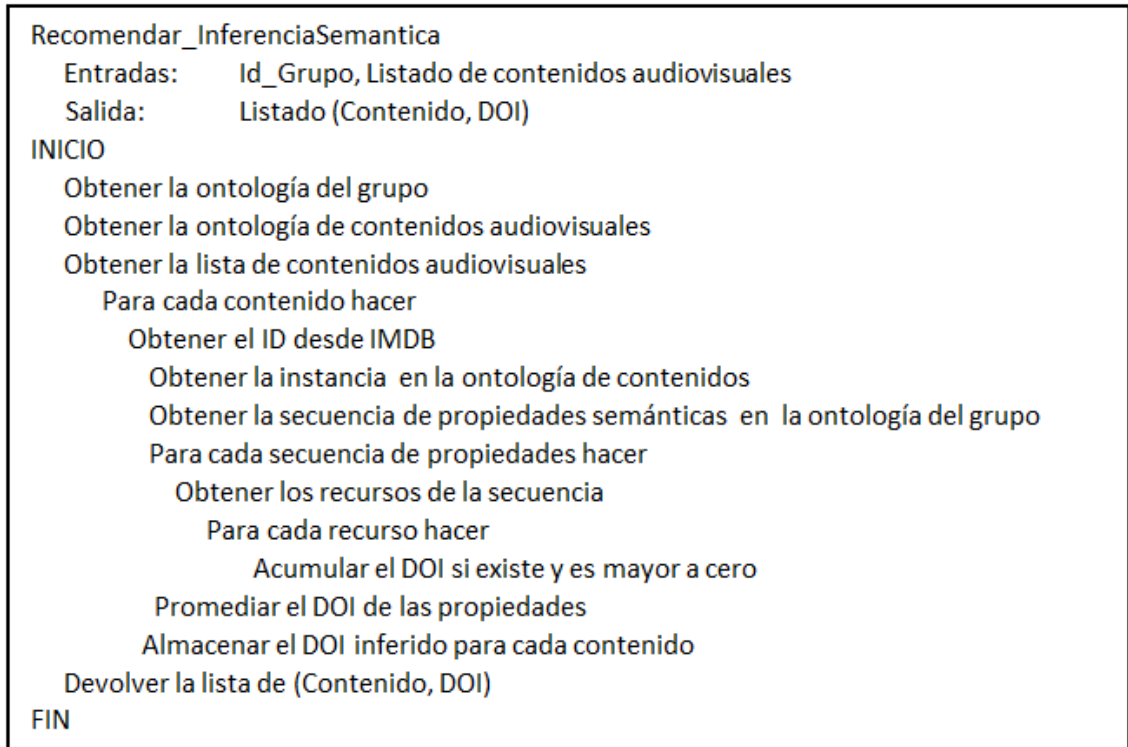


Figura 3.16: Pseudocódigo del algoritmo de recomendación de inferencia semántica

3.6. Algoritmo de Recomendación para Grupos Heterogéneos

La propuesta desarrollada en este apartado de la tesis, toma el nombre de “Recomendación de contenido para usuarios heterogéneos a través de la técnica de reducción de la miseria”, el que implementa la metodología de fusión de recomendaciones (Sección 2.4.2). Está marcada principalmente por el análisis de las propiedades semánticas de cada contenido audiovisual, además toma en cuenta una característica fundamental de cada integrante del grupo como lo es su edad, este, permitirá restringir el contenido inadecuado para ciertos miembros del grupo. A continuación se muestra la Figura 3.17, con una descripción general.




Figura 3.17: Descripción gráfica de la técnica de recomendación de grupos heterogéneos

Se puede observar al grupo heterogéneo $G_i = \{u_1, u_2, \dots, u_n\}$, que será objeto de análisis para obtener una recomendación. Cada integrante del grupo: u_1, u_2 y u_n , ingresarán en primer lugar al “Sistema Recomendador Semántico Individual”, descrito en la arquitectura general del sistema SRGU, en la Figura 3.4, obteniéndose así las recomendaciones de manera individual.

Luego estas serán almacenadas temporalmente en una base de datos para que puedan ser usadas como entradas del recomendador heterogéneo. Finalmente, este regresará las recomendaciones para el grupo. El desarrollo consta de los siguientes pasos:

3.6.1. Generación de Recomendación Individual

La entrada al recomendador individual es la lista de usuarios del grupo G_i , el cual, devolverá una lista de sugerencias de contenidos P , en donde para cada contenido p_i del conjunto existe su correspondiente DOI (predicho por el sistema) d_i . Por lo tanto, se tendrá n conjuntos P , compuesta de m contenidos, estas recomendaciones serán las entradas para el módulo de Recomendación Heterogéneo.

Para explicar el funcionamiento, se establecerá un ejemplo con un grupo de tres miembros $G_i = \{u_1, u_2, u_3\}$. Además un conjunto de películas $P = \{(p_1, d_1), (p_2, d_2), (p_3, d_3), (p_4, d_4), (p_5, d_5)\}$, en donde, después de haber pasado por el recomendador individual, se tendrán las recomendaciones: R_{u_1} , R_{u_2} y R_{u_3} , cada recomendación está compuesta por el conjunto de películas P ; es decir:

$$R_{u_1} = \{(p_1, d_1), (p_2, d_2), (p_3, d_3), (p_4, d_4), (p_5, d_5)\}$$

$$R_{u_2} = \{(p_1, d_1), (p_2, d_2), (p_3, d_3), (p_4, d_4), (p_5, d_5)\}$$

$$R_{u_3} = \{(p_1, d_1), (p_2, d_2), (p_3, d_3), (p_4, d_4), (p_5, d_5)\}$$

Las recomendaciones de cada usuario constan de 5 contenidos audiovisuales, no necesariamente las mismas.

3.6.2. Cálculo de DOI

Del conjunto de recomendaciones R se realizará el siguiente análisis, tomando como parámetro de ordenamiento cada película por separado, así:

$$R_{u_1} = \{(p_1, d_1), (p_2, d_2), (p_3, d_3), (p_4, d_4), (p_5, d_5)\}$$

$$R_{u_2} = \{(p_1, d_1), (p_2, d_2), (p_3, d_3), (p_4, d_4), (p_5, d_5)\}$$

$$R_{u_3} = \{(p_1, d_1), (p_2, d_2), (p_3, d_3), (p_4, d_4), (p_5, d_5)\}$$

Figura 3.18: Conjunto de recomendaciones de los miembros del grupo G_i

La película p_1 tiene el DOI de recomendación d_1 para el usuario u_1 , de la misma forma para los tres usuarios. Luego se procede a realizar un análisis que determinara el nivel de miseria de la película de los integrantes. Los niveles de miseria se definen dependiendo de un valor de umbral (μ), el cual será la mitad del máximo DOI ($\omega = 5$) posible, entonces el umbral se define como $\mu = \omega/2$, por lo tanto $\mu = 2,5$:




Figura 3.19: Escala de Representación del valor DOI

Una vez que se ha decidido si la película tiene o no miseria para el miembro del grupo analizado, se procede a normalizar el DOI recomendado individualmente (DRN) de la siguiente manera:

$$DRN_{ij} = |d_{ij} - \mu| \quad (3.20)$$

Donde i , es el identificador de la película analizada y j , el identificador del usuario que recibe el análisis. Después, se va a obtener el DOI promedio normalizado que se denominará DPN , esto se realiza sumando todos los DRN obtenidos para la película p_i de los n usuarios del grupo:

$$DPN_i = \frac{1}{n} \sum_{j=1}^{j=n} DRN_{ij} \quad (3.21)$$

Tomando en consideración:

- Si la miseria es nula ($miseria = 0$)
- Si existe miseria $DRN_{ij} = miseryAdjustment(DRN_{ij})$

Por último se obtendrá el DOI final del método de recomendación heterogéneo (DRH) para la película i , sumándole μ , en otras palabras, realizando un proceso inverso a la normalización:

$$DRH_i = DPN_i + \mu \quad (3.22)$$

3.6.3. Reducción de la Miseria($miseriaAdjustment$)

La reducción de la miseria es una técnica propuesta con la finalidad de reducir el nivel de miseria de una película p_i determinada. Para ello la entrada de esta técnica será la película i que está siendo analizada, el integrante j al cual se la recomendó y el nivel de miseria normalizado (NMN) que será igual a:

$$NMN_{ij} = DRN_{ij} \text{ si } misery \neq 0 \quad (3.23)$$

El siguiente paso consiste en obtener un nivel de coincidencia normalizado (α_k $k \neq i$) para el resto de películas m del conjunto P . Este nivel de coincidencia determinará en cuanto coincide una película k con la película analizada i . Para obtener esta información lo que se hace es una comparación de las características semánticas de las dos películas, entre las características

que se considerarán en este estudio están: género, actor, director y escritor. Gráficamente se representa en la Figura 3.20.

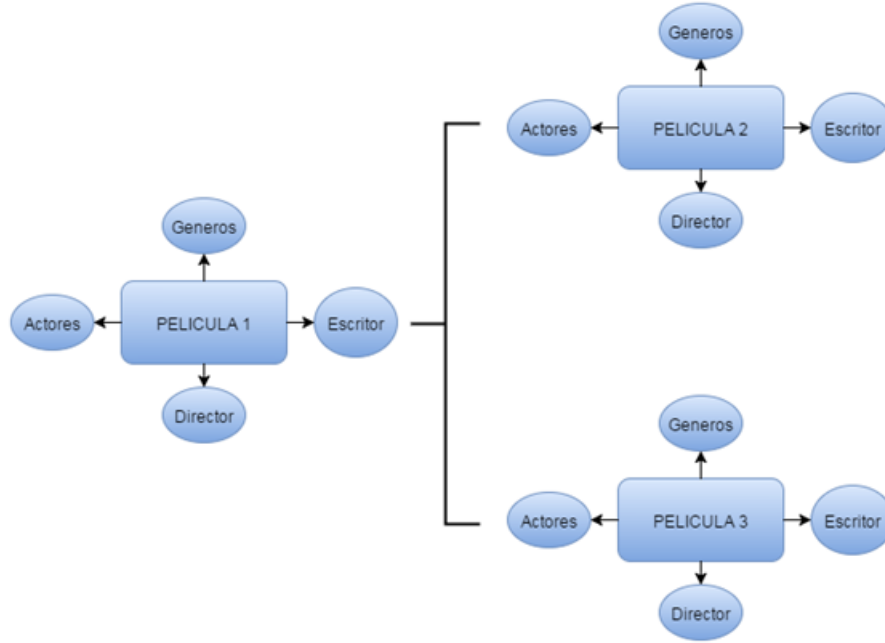


Figura 3.20: Relación de la película i con otros contenidos

A cada característica se le da un valor específico, en otras palabras, si las dos películas coinciden en el género se sumará 2, en actor 1.5, en director 1 y en escritor 0.5. Obteniendo un nivel de coincidencia (NC) sobre 5 (ω). Luego a este nivel de coincidencia se le realizará una normalización con el objetivo de dejar estos valores calculados de manera porcentual, según se especifica a continuación:

$$\alpha_k = \frac{NC_k}{\frac{1}{m} \sum_{k=1}^{k=m} NC_k} \text{ para } \forall_k \text{ en } P \text{ donde } k \neq i \quad (3.24)$$

Los niveles de coincidencia del resto de películas permite obtener un parámetro promedio para la película i , denominado nivel de satisfacción β , que será el promedio de los resultados que se obtengan de multiplicar el nivel de coincidencia α_k de la película k con el DOI de recomendación obtenido para la película k sobre el miembro j :

$$\beta_i = \frac{NC_k}{\frac{1}{m} \sum_{k=1}^{k=m} \alpha_k * DRN_{kj}} \quad (3.25)$$

Finalmente la reducción de la miseria procede como sigue:

- Si $\beta_i > NMN_{ij}$, entonces $DRN_i = 0$
- Si $\beta_i = 0$, entonces $DRN_{ij} = NMN_{ij}$
- Si $\beta_i < NMN_{ij}$, entonces $DRN_{ij} = NMN_{ij} - \beta_i$



3.6.4. Función Control Parental

Si los usuarios u_1 , u_2 y u_3 tienen las edades establecidas como ejemplo:

$$\begin{cases} u_1 = 16 \\ u_2 = 8 \\ u_3 = 24 \end{cases}$$

Se pretende restringir de alguna manera películas que no son aptas para algún televidente, esto se da en el caso especial de que hayan menores de edad entre la audiencia. La clasificación se basa en la norma estadounidense de la Motion Picture Association of América (MPAA), a través de la Administración de Clasificación y Valoración (CARA) para control de contenido, la misma que es utilizada por la base de datos de IMDB y esta categorizada de la siguiente manera:

- *G*. Todo público.
- *PG*. Algún material puede no ser apropiado para niños.
- *PG – 13*. Algún material puede ser inapropiado para niños menores de 13 años.
- *R*. Los menores de 17 años requieren estar acompañados de padres o un tutor.
- *NC – 17*. Películas solo para público adulto.

Con estos se determina la censura de edad (η), de acuerdo a la edad (x) del integrante, los cuales quedarán determinados así:

$$\begin{cases} \eta = G & \text{si } 0 < x \leq 5 \\ \eta = PG & \text{si } 5 < x \leq 12 \\ \eta = PG - 13 & \text{si } 12 < x \leq 17 \\ \eta = R & \text{si } 17 < x \leq 21 \\ \eta = NC - 17 & \text{si } x > 21 \end{cases} \quad (3.26)$$

Basándose en esta clasificación, lo que se realiza es una asignación de un DOI a η , definido como ϵ , a cada película p_i , dependiendo dentro de que rango se encuentre la misma. Para esto primero se calcula cual es el integrante de menor edad dentro del grupo, este, es el que dará la pauta para la asignación de los DOI, así:

$$\begin{cases} \epsilon = 5 & \text{si } \eta = G \text{ y } p_i = G \\ \epsilon = 4 & \text{si } \eta = G \text{ y } p_i = PG \\ \epsilon = 3 & \text{si } \eta = G \text{ y } p_i = PG - 13 \\ \epsilon = 2 & \text{si } \eta = G \text{ y } p_i = R \\ \epsilon = 1 & \text{si } \eta = G \text{ y } p_i = NC - 17 \end{cases} \quad (3.27)$$

Si el menor del grupo pertenece a la categoría *PG*, las películas con clasificación de tipo *G* y *PG* recibirían el valor $\epsilon = 5$, las del tipo *PG – 13*, tomarán el valor de $\epsilon = 4$ y así sucesivamente.



Luego de obtener ϵ , este quedará almacenado en la base de datos para que después de realizar el método de reducción de la miseria se sume al DOI de la película (d_i) y así se pueda tener el orden en el que serán recomendados los contenidos.

El d_i es el DOI que será válido para las evaluaciones del método de recomendación para grupos heterogéneos, el valor de ϵ no afecta a la salida total del algoritmo.

3.7. Limitación del Sistema

Una desventaja del sistema SRGU es el impedimento que presenta al recomendar a nuevos usuarios (no disponen de películas calificadas), denominado como *Arranque en Frío*, siendo detallado a continuación.

3.7.1. Problema de Arranque en Frío

Problema

El sistema SRGU facilita la recomendación de contenidos para usuarios que previamente han calificado un conjunto de películas. En el caso particular de un nuevo usuario que desee recibir sugerencias televisivas, se presenta un inconveniente con un alto grado de afectación al sistema. Dado que el nuevo usuario no dispone de información de un conjunto de películas calificadas, lo que impide el modelado ontológico del perfil. Por tal razón es necesario idear una solución satisfactoria que pueda mitigar de alguna forma los inconvenientes que esto podría acarrear.

Solución

En la base de conocimiento (Sección 3.2.3) se formalizó la información, que consta de usuarios, películas y películas calificadas. Los datos personales del usuario que se encuentran almacenados son: nombre, edad y género. A partir de estos se puede realizar la clasificación expresada en la Tabla 3.15.

Género	Rango de Edad
Femenino	menor a 12
Masculino	menor a 12
Femenino	12-18
Masculino	12-18
Femenino	19-35
Masculino	19-35
Femenino	36-52
Masculino	36-52
Femenino	53 en adelante
Masculino	53 en adelante

Tabla 3.15: Clasificación de Usuarios

La información personal del nuevo usuario, permitirá clasificarlo en uno de los rangos definidos, según la Tabla 3.15, tratando de encontrar un usuario registrado que cumpla las siguientes condiciones:



CAPÍTULO 3. DESARROLLO E IMPLEMENTACIÓN DEL SISTEMA

- Género similar.
- La edad más aproximada, dado que pueden existir varios usuarios que esten en el rango que ha sido clasificado.

Al encontrar el usuario similar, se procede a duplicar el perfil ontológico con el identificador correspondiente, de esta manera se solventa el problema planteado.



Capítulo 4

EVALUACIÓN DEL SISTEMA

4.1. Introducción

Este capítulo tiene por objeto evaluar la efectividad de los distintos algoritmos implementados para el SRGU. Para esto, se procede a conformar los grupos de usuarios a partir de la base de conocimiento creada (Sección 3.2), a partir de este se formarán todos los posibles subgrupos, los cuales se categorizan de acuerdo a parámetros que definen a cada uno. Posteriormente, la cantidad total de contenidos televisivos calificados por persona son divididos para dos funciones: entrenamiento y pruebas. Seguidamente, se realiza las evaluaciones correspondientes tanto para el servicio de identificación de usuarios como para en el servicio de recomendación de contenidos de TV. Los resultados cuantitativos obtenidos del análisis de los algoritmos posibilita la obtención de conclusiones que servirán a la determinación de las mejores técnicas de identificación de usuarios y la recomendación de programas televisivos.

4.2. Procedimiento de Evaluación para el Sistemas de Recomendación de Grupos de Usuarios

Esta sección presenta los procedimientos de evaluación para sistemas de recomendación enfocados a grupos de usuarios. Estos procedimientos difieren de los mecanismos de evaluación de sistemas para usuarios individuales puesto que se debe considerar todas las posibilidades que pueden presentarse en un grupo de televidentes, desde diferentes edades de sus miembros, preferencias, número de miembros, etc.

4.2.1. Análisis de los Datos

En la Sección 3.2.3 se definió la base del conocimiento donde describe un conjunto de 100 usuarios quienes han calificado aproximadamente 400 contenidos audiovisuales. Existe gran variedad de calificaciones por usuario, es decir, en el rating o valor que cada uno le otorgó a cada contenido. En la Figura 4.1 se representa el promedio de los valores de ratings. En la misma sección se puede observar el porcentaje correspondiente a la escala de calificaciones donde los valores más altos equivalen a uno.




Figura 4.1: Promedio de Ratings

4.2.2. Conformación de Grupos Pseudoaleatorios

Es común encontrar diferentes tipos de personas que observan la televisión en conjunto, en un hogar común, lo puede hacer la familia completa (padres e hijos). También, se puede formar subgrupos entre distintos miembros resultado de todas las posibles combinaciones. En ciertas ocasiones únicamente los padres observan la TV; otros escenarios pueden ser: un padre y su hijo o hermanos. Por otra parte, existen ocasiones en las que reúne un grupo de amigos/as a ver un partido de fútbol, películas, programas de cocina, entre otros; o en su defecto, niños observando sus programas favoritos de dibujos animados.

Según el INEC (Instituto Nacional de Estadística y Censos), en el año 2013 el tamaño del hogar fue de 3.9 miembros ¹, lo que equivale a cuatro personas. Debido a esto, es justificable conformar inicialmente grupos de cinco integrantes, los mismos que estarán compuestos de manera pseudoaleatoria. De otra manera se puede decir que cada grupo represente una familia o grupos de amigos, en los que constan miembros de diferentes edades y géneros. Los datos están detallados en la Tabla 4.1.

Existe un total de veinte grupos de cinco usuarios cada uno. La columna miembros corresponde al número de integrantes, la columna final caracteriza al grupo (niños, familia con niños, amigos, etc). Para esta conformación se ha desarrollado un algoritmo que sea capaz de analizar los usuarios por edades y género. Un usuario de género masculino de más de treinta años constará como padre, un usuario de género femenino mayor a treinta se considera madre o esposa y por último los usuarios menores de 12 años figurarán como sus hijos. En cierto número de grupos, se considera que deben contar con padre, madre, dos niños y un adolescente. También, existe la conformación de grupos sin niños. Otro tipo de conformación es la agrupación de niños y niñas. Se incluye también el caso del escenario que describe una reunión de amigos

¹Fuente: https://storify.com/el_telegrafo/como-son-las-familias-en-ecuador

Grupo	Num. Miembros	Característica Grupal
1	5	niños y niñas
2	5	niños y niñas
3	5	amigos
4	5	amigos
5	5	amigas
6	5	amigas
7	5	familia con un niño
8	5	familia con dos niños
9	5	familia con dos niños
10	5	familia con dos niños
11	5	familia con dos niños
12	5	familia con dos niños
13	5	familia con dos niños
14	5	familia con dos niños
15	5	familia con dos niños
16	5	familia con un niño
17	5	familia sin niños
18	5	amigos y amigas
19	5	amigos y amigas
20	5	amigos y amigas

Tabla 4.1: Conformación de grupos

(solo hombres), y de la misma manera se considera la conformación de grupos de amigas (solo mujeres). Como es lógico, existen grupos de amigos, donde están miembros de los dos géneros. Estos tipos de grupos, son aquellos que en la vida real se forman.

De la agrupación inicial se genera los subgrupos de dos, tres y cuatro, para cada grupo de cinco integrantes. La Ecuación 3.2 se utilizó en la sección de clasificación de tipos de grupos, la misma que se aplica en este apartado.

Al realizar las combinaciones necesarias se obtiene los siguientes resultados:

Para $m = 5$ y $n = 2$.

$$C_5^2 = \frac{5!}{2!(5-2)!} = 10$$

Para $m = 5$ y $n = 3$.

$$C_5^3 = \frac{5!}{3!(5-3)!} = 10$$

Para $m = 5$ y $n = 4$.

$$C_5^4 = \frac{5!}{4!(5-4)!} = 5$$

Para $m = 5$ y $n = 5$.

$$C_5^5 = \frac{5!}{5!(5-5)!} = 1$$

Lo que genera diez subgrupos de dos, diez de tres, cinco de cuatro y uno de cinco integrantes, en total se puede formar 26 grupos en una familia de cinco miembros como se muestra en la Figura 4.2.

Al combinar cinco integrantes resulta el mismo grupo, las combinaciones de cuatro, tres y




Figura 4.2: Representación de un familia

dos miembros, se muestran en la Figura 4.3.







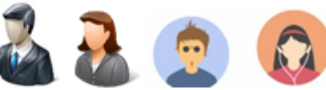

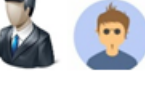
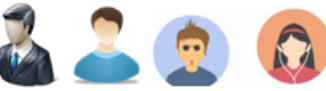

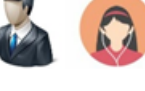
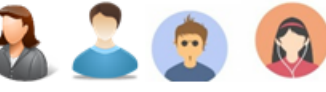


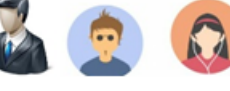
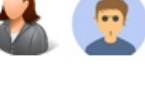
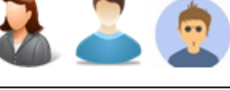
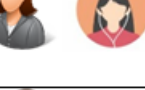
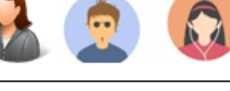
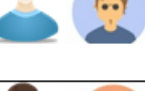


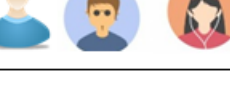

Num.	Combinaciones de 4	Combinaciones de 3	Combinaciones de 2
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			

Figura 4.3: Conformación de subgrupos dentro de una familia

Existen 26 escenarios que se pueden dar con un grupo de 5 personas. En la descripción de los usuarios de la base del conocimiento se detalla el número total de usuarios (Tabla 3.1) con

los que se trabaja en el sistema desarrollado. Con los 100 usuarios seleccionados, al generar los 20 grupos de 5, se obtiene 520 grupos.

4.2.3. Conjunto de datos de entrenamiento y pruebas

Esta sección describe la conformación de los diferentes tipos de conjuntos de contenidos televisivos, utilizados para las fases de entrenamiento y pruebas para cada uno de los servicios implementados.

Identificación de Grupos

Para realizar las pruebas de identificación de usuarios se utilizará un grupo en particular, donde cada miembro presenta características diferentes tanto en edad como en género. El tamaño del grupo será de 5 miembros, de estos, se realizará las agrupaciones o escenarios de subgrupos utilizando la fórmula 3.2. El resultado total se expresa en la Tabla 4.2.

Grupos	Cantidad
Grupos de 5 integrantes	1
Grupos de 4 integrantes	5
Grupos de 3 integrantes	10
Grupos de 2 integrantes	10
1 Integrante	5

Tabla 4.2: Grupo para evaluación del módulo de reconocimiento facial

Gráficamente el grupo de miembros a evaluar se presenta en la Figura 4.4:




Figura 4.4: Grupo a evaluar en el de reconocimiento facial

Recomendacion de Contenidos

Para definir el conjunto de datos que permitan la evaluación de los algoritmos de recomendación de contenidos se divide el conjunto de películas calificadas por cada usuario: el 80 % para el ambiente de entrenamiento y el 20 % para realizar las pruebas. En el último conjunto la selección se realiza tomando al grupo inicial de 5 miembros, por ejemplo el grupo $G_i = \{u_1, u_2, u_3\}$ de tres miembros tienen diferente cantidad de películas, se verifica las comunes. La Figura 4.5 muestra el conjunto de cada miembro del grupo, la variable x es el número de contenidos audiovisuales que pertenecen al grupo G_i .

Dado que los miembros del grupo tienen diferente cuantía de contenidos calificados es necesario saber el 20 % de cada usuario y de este modo conocer el valor máximo de x . Luego, se

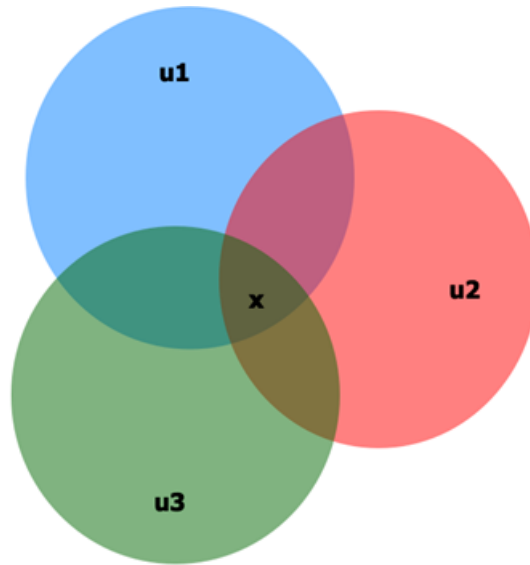


Figura 4.5: Número de películas para el grupo G_i

procede a verificar los contenidos calificados por todos los miembros, al encontrar un contenido que cumpla la condición se agrega a una lista final y se elimina dicho contenido de la lista original de cada miembro. El pseudocódigo de la Figura 4.6 detalla la manera de obtener el listado de contenidos audiovisuales para el entorno de pruebas.

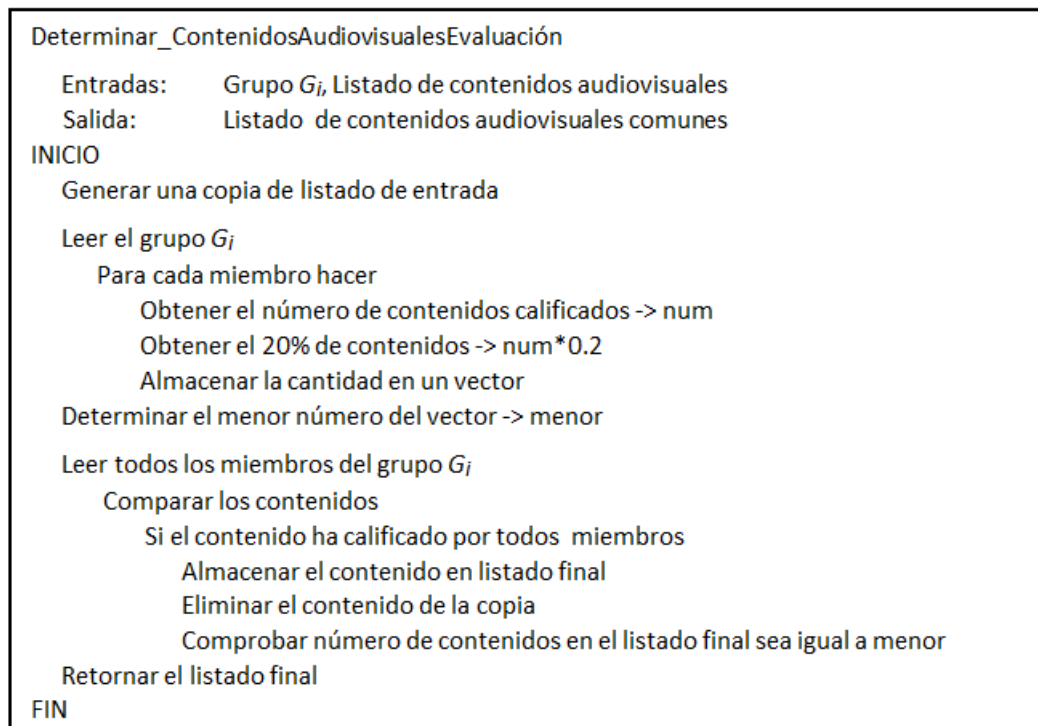


Figura 4.6: Conjunto de contenidos para el entorno de pruebas

En la determinación del conjunto de contenidos audiovisuales para el proceso de entrena-

miento se emplea el pseudocódigo definido en la Figura 4.7.

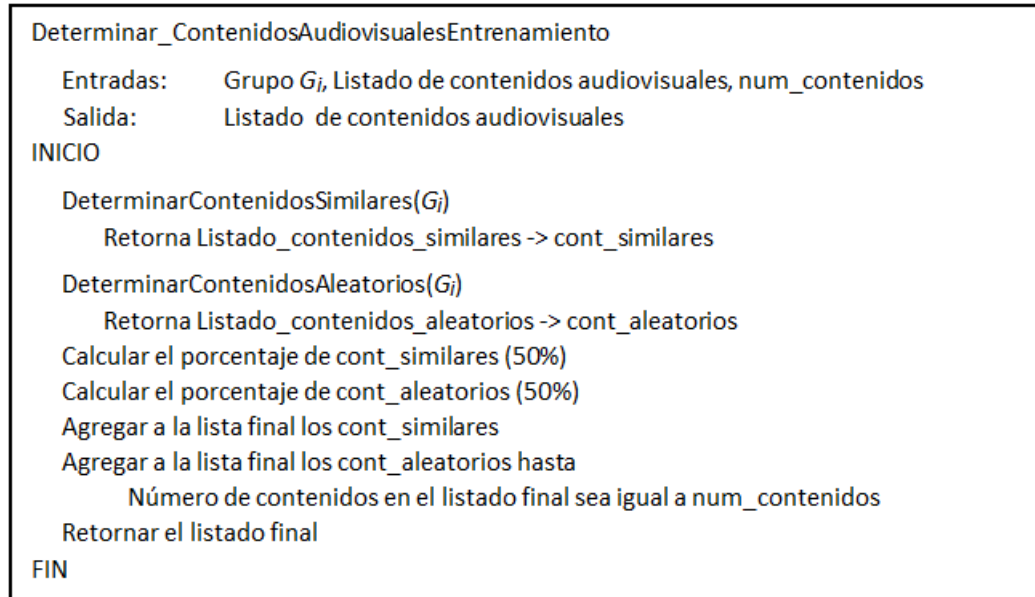


Figura 4.7: Conjunto de contenidos para el entorno de entrenamiento

Para la formación de los dos conjuntos se ha desarrollado un algoritmo capaz de realizar una selección adecuada de películas. El archivo de pruebas contiene películas con diferentes ratings, esto es, rating igual a: uno, dos, tres, cuatro y cinco, para grupos homogéneos y heterogéneos. Así, se garantiza equidad para las evaluaciones o determinación del error de recomendación. Además, están divididas de manera proporcional: 30 % de 5, 20 % de 4, 20 % de 3, 15 % de 2, 15 % de 1.

4.2.4. Métricas de Evaluación

Recomendación de Contenidos

MAPE

Una de las métricas de evaluación utilizada es el Error Porcentual Absoluto Medio (MAPE, Mean Absolute Percentage Error), este determina el error en términos porcentuales; se obtiene al promediar las diferencias absolutas entre el valor real R_i y el predicho P_i . Dada por la siguiente fórmula:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{R_i - P_i}{R_i} \right| \quad (4.1)$$

N , número de contenidos audiovisuales evaluados,

P_i , valor predicho por el sistema,

R_i , calificación real del grupo, se obtiene al promediar la calificación de cada miembro del grupo:

$$R_i = \frac{1}{m} \sum_{j=1}^m R'_{uj} \quad (4.2)$$



m , número de miembros del grupo,
 R'_{uj} calificación del miembro.

NDCG

Ganancia Acumulada con Descuento (nDCG, normalized Discounted Cumulative Gain) mide la efectividad o utilidad de un contenido, basado en la posición que se encuentre dentro del listado de recomendaciones emitidos por el sistema SRGU (en el ámbito de recomendación de contenidos audiovisuales). La ganancia se acumula desde la parte superior del listado y se descuenta en los rangos inferiores. La lista previamente debe ser ordenado, según un parámetro de relevancia.

El primer valor a calcular es el DCG, donde el listado de contenidos recomendados está ordenado por P_i DOI predicho por el sistema. Dado por:

$$DCG = R_1 + \sum_{i=2}^N \frac{R_i}{\log_2 i} \quad (4.3)$$

N , número de contenidos audiovisuales evaluados,
 R_i calificación del grupo.

El segundo valor es el IDC, el cual se obtiene al aplicar la ecuación 4.4, aquí, el parámetro de relevancia es la calificación real R_i , por ende se ordena con dicho valor. Finalmente se obtiene el nDCG con la siguiente fórmula:

$$nDCG = \frac{DCG}{IDCG} \quad (4.4)$$

4.2.5. Procedimiento de Evaluación

Identificación de Grupos

El proceso de evaluación para el reconocimiento de integrantes de un grupo es el siguiente:

- Realizar el registro de integrantes del grupo asignando un identificador a cada integrante, para el grupo definido anteriormente sería: Rosa (R), Cristina (C), Wilson (W), Blanca (B) e Kevin (K).
- Se capturan fotografías del rostro de cada integrante en diferentes perfiles (izquierdo, derecho y frontal) y expresiones (alegría, tristeza, etc.). Para obtener mayor precisión en el reconocimiento se necesita al menos quince tomas, de las cuales son necesarias tres de la parte izquierda, tres de la parte derecha, uno con el rostro hacia arriba, uno hacia abajo y el resto frontales.
- Una vez registrado a los integrantes del grupo, se forma los subgrupos definidos en la Tabla 4.2. A cada uno de ellos se pretende identificar de manera precisa, empleando las tres técnicas de reconocimiento (Eigenfaces, Fisherfaces o LBPH).
- Para cada subgrupo se realiza diez pruebas de identificación, donde los integrantes deben cambiar los perfiles del rostro, posiciones o lugares entre los miembros.

- De las pruebas realizadas se contabiliza el número de personas identificadas correctamente y las que no. Luego con estos valores se calculará el porcentaje de acierto (la precisión del algoritmo) aplicando la siguiente fórmula:

$$P = \frac{n_+ \cdot 100}{n} \quad (4.5)$$

Donde n_+ es el número de miembros estén identificados correctamente y n es el número de miembros del grupo.

Recomendación de Contenidos

Del total de grupos definidos anteriormente se selecciona 286, los cuales constan en la Tabla 4.3.

Grupos	Cantidad
Grupos de 5 integrantes	11
Grupos de 4 integrantes	55
Grupos de 3 integrantes	110
Grupos de 2 integrantes	110
Total	286

Tabla 4.3: Conjunto de grupos para la evaluación en el módulo recomendador

El proceso de evaluación para la recomendación de contenidos es el siguiente:

- Determinar la lista de contenidos para el entorno de entrenamiento, el cual se obtiene al aplicar el algoritmo expresado en pseudocódigo en la Figura 4.7.
- Creación del perfil ontológico de los usuarios seleccionados con el listado de contenidos determinados.
- Selección del conjunto de contenidos para el entorno de pruebas, aplicando el algoritmo detallado a manera de pseudocódigo en la Figura 4.6.
- Clasificar a cada grupo en homogéneo o heterogéneo.
- Se recomienda a cada grupo, ya sea este homogéneo o heterogéneo aplicando la técnica de Fusión de Perfiles y Fusión de Recomendaciones.
- Finalmente se evalúa el conjunto de sugerencias de contenidos audiovisuales emitidos por el recomendador. La métrica MAPE propicia la determinación del error de recomendación. El NDCG se utiliza para obtener la efectividad del recomendador.

4.3. Evaluación del Sistema

Esta sección consta de generación de resultados de manera cuantitativa de los diferentes algoritmos implementados dentro del sistema SRGU. Los cuales se representan mediante indicadores numéricos que permiten medir la efectividad de un algoritmo respecto a otro. Se detalla las evaluaciones efectuadas a continuación:

4.3.1. Algoritmos de identificación de usuarios

La finalidad en esta evaluación es determinar la mejor o mejores técnicas de identificación de usuarios de un grupo, debido a que se ha implementado tres, los que se denominan: Eigenfaces, Fisherfaces y LBPH. Luego de haber efectuado el procedimiento de evaluación explicado anteriormente, los resultados se presentan en la Figura 4.8. La coordenada x refleja los tamaños de grupo, y en la coordenada y se expresa el porcentaje de acierto (porcentaje de las veces que el reconocimiento se realizó de manera correcta); los colores rojo, verde y azul corresponde a las técnicas Fisherfaces, LBPH y Eigenfaces respectivamente. Se puede observar que conforme el grupo crece la precisión de la identificación reduce, esto lo confirman las tres técnicas. Además, la estrategia de Eigenfaces presenta mayor porcentaje de acierto, en cambio LBPH se reduce frente a la técnica anterior. Finalmente Fisherfaces es el que menos precisión posee.




Figura 4.8: Gráfica de la eficiencia de las técnicas de reconocimiento.

Los resultados obtenidos se apoyan en la Tabla 4.4, donde se obtuvo los promedios de aciertos en el reconocimiento de usuarios, aplicada a cada una de las técnicas evaluadas.

Miembros	Promedio Eigen	Promedio Fisher	Promedio LBPH
5	82 %	14 %	68 %
4	88 %	28 %	69 %
3	90 %	42 %	82 %
2	93 %	53 %	90 %
1	98 %	70 %	96 %

Tabla 4.4: Resultados promedio totales de la evaluación



Conclusiones

- Uno de los factores determinantes para el buen rendimiento de los algoritmos de reconocimiento facial independientemente del que sea elegido, es la iluminación adecuada. Esto se comprobó al realizar las pruebas en ambientes con poca o mucha iluminación que no permitían a la aplicación comportarse de manera satisfactoria.
- Los resultados de las pruebas han dado por descartado al algoritmo Fisherfaces debido a su bajo rendimiento en casi todos los tamaños de grupos.
- El algoritmo LBPH tiene un rendimiento cuestionable en grupos grandes como aquellos conformados de cinco miembros, pero al reducirse el tamaño del grupo la diferencia de eficiencia con respecto al algoritmo de Eigenfaces empieza a tender a cero.
- Eigenfaces resultó tener mejor comportamiento superando a las otras técnicas para los diferentes tamaños de grupos.

4.3.2. Algoritmos de clasificación de grupos

Para la clasificación de grupos se ha desarrollado dos algoritmos denominados: Enfoque de Votación y Enfoque de Promedios. Los enfoques están descritos en la Sección 3.4. El objetivo es determinar el mejor algoritmo o dicho de otra manera, descubrir cuál es el más preciso al momento de clasificar un grupo.

Resultados según la métrica MAPE

La evaluación se centra en el valor de umbral respecto a un error porcentual de recomendación MAPE, es decir, con un umbral específico se clasifica al grupo. Luego se genera las recomendaciones para cada tipo de grupo, de esta forma se obtiene el MAPE. Finalmente estos valores son promediados. La Figura 4.9, muestra que el comportamiento de los dos enfoques son similares, con la diferencia de que el enfoque de promedios, posee menos error al momento de la clasificación de grupos. El color azul representa los resultados para el enfoque de votación y el rojo, para el enfoque de promedios.




Figura 4.9: Umbral-MAPE, Enfoque de Votación vs Promedios

En la Figura 4.10, se observa la consición de los dos enfoques, donde se apoya los resultados obtenidos al evaluar los dos enfoques. Al momento de determinar el porcentaje de homogeneidad, el enfoque de votación clasifica al grupo con el 100 %, en cambio el enfoque de promedios lo clasifica con el 93,62 %. Este desajuste se da porque al momento de la asignación del valor de votación por propiedad en el primer enfoque se da el valor de 1 o 0, haciendo que el subgrupo sea 100 % homogéneo en cada propiedad. El segundo enfoque no asigna valores por propiedad sino que promedia las similitudes encontradas.

Enfoque de Votación

Propiedad	Usuario 1	Usuario 2	Umbral	Coincidencias	Votación por propiedad	Pesos	Total
Título	148	144	73	137	1	0,2	0,2
Actor	91	86	44	82	1	0,2	0,2
Genero	6	5	3	5	1	0,5	0,5
Escritor	19	19	10	19	1	0,05	0,05
Director	31	32	16	31	1	0,05	0,05
(u1,u2) 100% Homogéneo							1,00

Enfoque de Promedios

Propiedad	Usuario 1	Usuario 2	Coincidencias	Promedio	Pesos	Total
Título	148	144	137	93,85	0,2	37,54
Actor	91	86	82	92,73	0,2	27,82
Genero	6	5	5	91,67	0,5	18,33
Escritor	19	19	19	100,00	0,05	5,00
Director	31	32	31	98,44	0,05	4,92
(u1,u2) 93.62% Homogéneo						93,62

Figura 4.10: Resultado de clasificación de subgrupo de cada enfoque

Determinar el umbral adecuado para la clasificación de grupos

En la sección de clasificación de grupos, en uno de los pasos finales se explicó la importancia de un valor (δ) que permite discriminar a un grupo. Si el porcentaje de homogeneidad x supera a δ , el grupo se define como tal, caso contrario se define como heterogéneo con su respectivo porcentaje. En este apartado se pretende determinar el valor adecuado que posibilite la correcta discriminación de grupos, donde el error sea mínimo y se ajuste a los dos tipos de grupos. Además, una vez que los resultados demuestran la precisión del enfoque de promedios, el análisis se realiza con dicho enfoque. La Figura 4.10, representa el valor del umbral respecto al MAPE, el que está en el rango de 60 a 68.




Figura 4.11: Determinación del umbral adecuado para la clasificación

Conclusión

En este apartado se concluye que el enfoque de promedios es más preciso frente al enfoque de votación. El valor adecuado que posibilita una clasificación correcta de grupos, fluctúa entre 60 y 68 aproximadamente. Debido a que valores posteriores obligan a grupos homogéneos a poseer la mayor cantidad de preferencias similares entre el grupo y no es necesario esta situación para que el grupo sea catalogado como tal, los valores menores hacen que el error crezca y su comportamiento es irregular.

4.3.3. Técnicas de recomendación para grupos homogéneos y heterogéneos

A partir del umbral determinado se obtiene la cantidad de grupos homogéneos y heterogéneos. Posteriormente pasan a ser recomendados empleando las técnicas de Fusión de Perfiles y Fusión de Recomendaciones. Las dos técnicas son evaluadas usando las métricas MAPE y NDCG. El propósito es verificar la mejor metodología para la recomendación de contenidos dirigidos a los dos tipos de grupos.

Resultados según la métrica MAPE

Grupos homogéneos

En la Figura 4.12 se presenta los resultados de la recomendación de cada grupo. En el eje x están los grupos, en el eje y se encuentra el error obtenido al emplear MAPE. El color azul pertenece a la técnica de Fusión de Perfiles y el rojo a la técnica de Fusión de Recomendaciones. Se puede observar que el comportamiento de las dos técnicas son similares pero la técnica de Fusión de Recomendaciones posee menos error en la recomendación de contenidos dado que los picos ocasionados por el método de Fusión de Perfiles, se ven reducidos por la otra técnica.




Figura 4.12: Grupos-MAPE: Recomendación para grupos homogéneos

Grupos heterogéneos

El análisis de este tipo de grupos es similar al anterior, en la Figura 4.13, se visualiza de igual manera los grupos en el eje x , y en el eje y el error calculado para cada grupo. Según los resultados obtenidos, la técnica de Fusión de Recomendaciones reduce el error de la técnica de Fusión de Perfiles.




Figura 4.13: Grupos-MAPE: Recomendación para grupos heterogéneos

Resultados según la métrica NDCG

Grupos homogéneos

A continuación, en la Figura 4.14 se presenta la efectividad del recomendador al momento de generar las sugerencias para los grupos homogéneos, el cual ha sido validado con la métrica NDCG. Según los resultados graficados, la técnica de Fusión de Recomendaciones (color rojo) es la más efectiva, dado que tiene mayor porcentaje de acierto que la estrategia de Fusión de Perfiles.




Figura 4.14: Grupos-NDCG: Recomendación para grupos homogéneos

Grupos heterogéneos

Análogo al análisis anterior, donde el porcentaje de acierto usando la técnica de Fusión de Recomendaciones (color rojo) es mejor frente a la técnica de Fusión de Perfiles.




Figura 4.15: Grupos-NDCG: Recomendación para grupos heterogéneos

Conclusión

Las evaluaciones obtenidas de las dos métricas empleadas demuestran que existen mayor precisión en la generación de las recomendaciones al utilizar la técnica de Fusión de Recomen-

daciones. El error es mayor al tratarse con grupos heterogéneos, por ende la efectividad es menor comparado con los grupos homogéneos.

4.3.4. Técnicas de recomendación según el número de miembros

Anteriormente se mencionó la importancia de definir los diferentes escenarios de grupos frente a la TV, por tal razón, de los grupos iniciales de 5 integrantes se formó subgrupos de 2, 3 y 4 integrantes. La finalidad es analizar el comportamiento del recomendador frente al número de integrantes.

Resultados según la métrica MAPE

Grupos homogéneos

Los resultados expresados en la Figura 4.16 detallan los promedios de los grupos de n integrantes obtenidos al aplicar la técnica de Fusión de Perfiles (color azul) y Fusión de Recomendaciones (color rojo) específicamente para los grupos homogéneos. Gráficamente se observa que conforme el número de integrantes incrementa, el error de recomendación reduce.




Figura 4.16: Tamaño_Grupos-MAPE: Recomendación para grupos homogéneos

Grupos heterogéneos

En los grupos heterogéneos presentado en la Figura 4.17, existe el mismo comportamiento de los grupos homogéneos, con la diferencia, que el error de recomendación se incrementa, dado a que los perfiles de los integrantes son divergentes unos de otros y por ende es difícil para el sistema ofrecer sugerencias adecuadas.




Figura 4.17: Tamaño_Grupos-MAPE: Recomendación para grupos heterogéneos

Resultados según la métrica NDCG

Grupos homogéneos

La métrica NDCG permite obtener la efectividad de las recomendaciones para los diferentes tamaños de grupos, dado que el valor está entre 0 y 100, los valores que oscilen cerca al máximo, demuestra que las sugerencias emitidas por el recomendador son propicias para cada integrante del grupo. En la Figura 4.18, se grafica los resultados para los grupos homogéneos.




Figura 4.18: Tamaño_Grupos-NDCG: Recomendación para grupos homogéneos

Grupos heterogéneos

Para este tipo de grupo, el porcentaje de acierto se reduce, respecto de los grupos homogéneos, y esto sucede en todos los tamaños de grupos. En la Figura 4.19, se presenta los resultados obtenidos.




Figura 4.19: Tamaño_Grupos-NDCG: Recomendación para grupos heterogéneos

Conclusión

En las diferentes dimensiones de grupos homogéneos y heterogéneos el error de recomendación (MAPE) reduce conforme los integrantes del grupo se incrementa. Los resultados según la métrica NDCG confirma los valores de MAPE, dado que este calcula el porcentaje de acierto de un contenido para un grupo, demostrando que existe mayor efectividad en las recomendaciones de grupos grandes. Se ha llegado a esta conclusión debido a que en los grupos de dos integrantes existe poca información disponible (perfiles de los integrantes) el recomendador puede analizar y proceder a la recomendación. En cambio, conforme los grupos crecen la información también crece, por lo que el error decrece si el tamaño del grupo se incrementa.

4.3.5. Técnicas de recomendación según el tipo de grupo

En este apartado se pretende analizar como actúa el recomendador con los dos tipos de grupos. Para esta finalidad se determina los promedios de los grupos homogéneos y heterogéneos utilizando las dos técnicas estudiadas. El experimento se realiza con las métricas definidas previamente. En la Figura 4.20, el color rojo representa a los grupos homogéneos y color azul representa a los grupos heterogéneos.

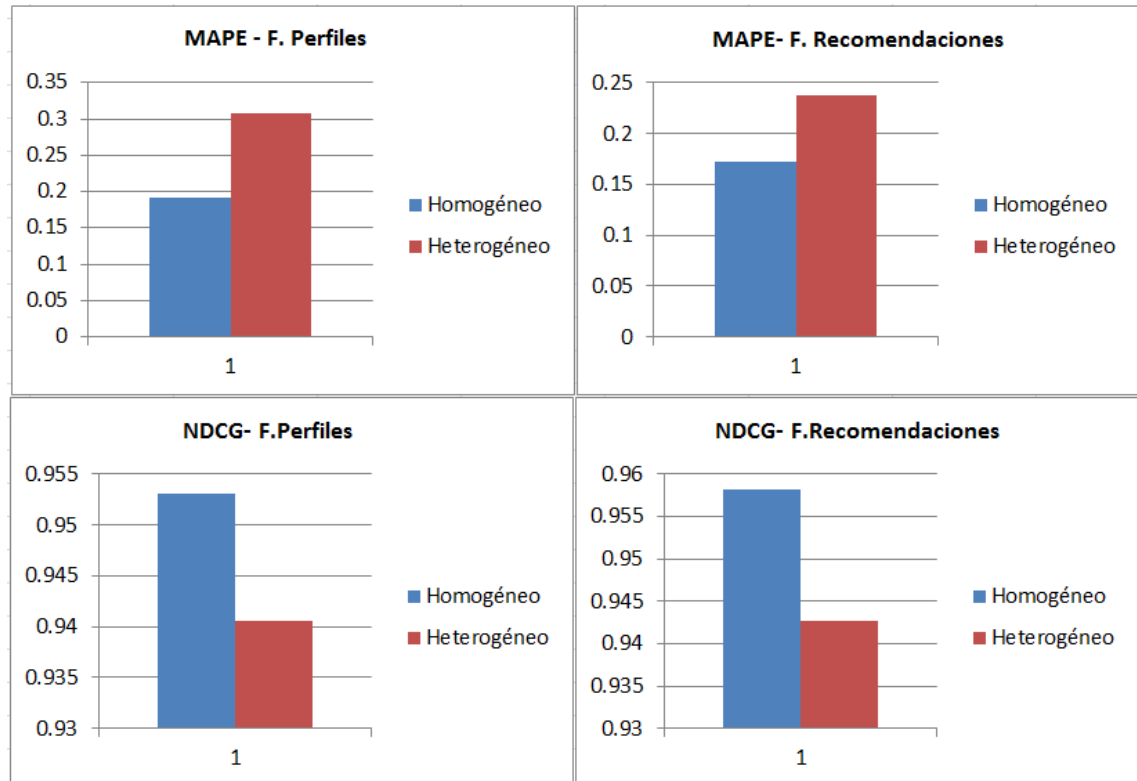


Figura 4.20: Promedios de las recomendación de grupos

Conclusión

Según los resultados obtenidos empleando la métrica MAPE, se concluye que el recomendador tiene menor error en los grupos homogéneos y mayor en los heterogéneos. Lo mismo sucede al aplicar la métrica NDCG, existe mayor efectividad en los grupos homogéneos.

4.4. Análisis de Resultados

Con los trabajos realizados por los diferentes autores de los sistemas recomendadores en el ámbito de entretenimiento, se compara los resultados obtenidos, se dice que:

- En el trabajo de Francesco Ricco [10], en el que se utiliza el Filtrado Colaborativo para la generación de recomendaciones individuales y posteriormente con las diferentes técnicas pertenecientes a la de Fusión de Recomendaciones, se obtiene un conjunto de películas para el grupo de usuarios. Se utilizó el nDCG para la evaluación de las recomendaciones. Previamente el conjunto de datos fue dividido en grupos randómicos (heterogéneos) y grupos de usuarios con preferencias similares (homogéneos). Este trabajo demuestra que la efectividad de las recomendaciones no necesariamente se reduce, conforme crece el tamaño del grupo; además, demuestra que las recomendaciones para grupos similares son mas efectivas que para los disímiles. Los resultados de esta investigación confirman lo determinado en este trabajo de tesis.



- En la investigación “Design and evaluation of a group recommender system.” [46], enfocada en recomendación de audio y video, se emplearon diferentes metodologías de recomendación. La evaluación realizada para diferentes tamaños de grupos, concluye que la exactitud de recomendación disminuye si el tamaño del grupo crece, se utilizó la métrica nDCG.
- El trabajo documentado [3], analiza las relevancias (puntuaciones altas) y desacuerdos (puntuaciones bajas) de los contenidos entre los integrantes del grupo. Experimenta diferentes estrategias para la tarea de recomendación. Por medio de la métrica nDCG, concluye que una de las estrategias es la que da mejores resultados en grupos con gustos disímiles. Además, todas las estrategias demuestran que en grupos de usuarios similares existe mayor efectividad. Por último en grupos pequeños con preferencias similares, el recomendador es más preciso. Las evaluaciones fueron realizadas para dos tamaños de grupos (pequeños y grandes), no existe un desglose que permita identificar el comportamiento conforme crece el grupo.
- Las métricas utilizadas en el trabajo [14], es Root Mean Squared Error (RSME) y Mean Absolute Error (MAE), similar al MAPE, miden el error en las predicciones de las recomendaciones. El recomendador desarrollado está dirigido a grupos homogéneos y heterogéneos. En el cual se implementa la técnica de fusión de perfiles para el modelado de grupo y el enfoque híbrido que contiene la técnica de filtrado colaborativo basado en contenidos y la información demográfica para la recomendación de contenidos. La evaluación se centra en agregar usuarios con perfiles divergentes a un grupo de usuarios con perfiles similares. De esta manera se concluye que el error se incrementa cuando se agrega este tipo de usuarios al grupo. Además el error disminuye conforme el tamaño del grupo decrece.

Capítulo 5

CONCLUSIONES Y TRABAJO A FUTURO

5.1. Conclusiones

En este trabajo se ha analizado, desarrollado e implementado un sistema de recomendación de contenidos audiovisuales para grupos de usuarios de la TV utilizando la tecnología semántica. El sistema se compone principalmente de dos servicios: el primero orientado a la identificación automática de los miembros de un grupo de televidentes, y el segundo que corresponde al servicio de recomendación de contenidos audiovisuales. Los miembros del grupo se identifican mediante técnicas de reconocimiento facial, lo que facilita la operación del servicio de recomendación sin requerir mayor intervención de los usuarios presentes.

En este trabajo se ha considerado que los grupos de usuarios pueden clasificarse de dos maneras, en grupos homogéneos y heterogéneos. Esta clasificación se fundamenta en el grado de similitud que los usuarios de un grupo pueden tener entre sí en función de sus gustos y preferencias televisivas. En este contexto se tomó este antecedente como punto de partida para evaluar diferentes técnicas de recomendación de grupos, entre otras, aquellas enfocadas a crear un perfil ontológico de usuario único a partir de las preferencias de todos los miembros del grupo para el caso de usuarios homogéneos y la técnica de agregación de recomendaciones para aquellos grupos de usuarios heterogéneos. El resultado de la operación del sistema consiste en una lista ordenada de programas de televisión que se sugieren al grupo de usuarios en base a la predicción de su calificación.

Al concluir esta tesis, se confirma el cumplimiento de los objetivos específicos planteados:

1. Desarrollar un procedimiento de identificación de grupos de usuarios mediante técnicas de reconocimiento facial.
 - Mediante la utilización de las herramientas de software enfocadas a aplicaciones de visión por computador, con el soporte de OpenCV. Entre las librerías utilizadas se cuenta con el detector HaarCascade, que fue utilizado para la detección de rostros y además tres algoritmos utilizados para el reconocimiento de los usuarios, específicamente: Fisherfaces, Eigenfaces y LBPH.
 - El uso de técnicas de visión por computador demostro facilitar el proceso de identificación de usuarios, minimizando su interacción con el televisor.



- Se implementó un procedimiento para determinar con precisión los usuarios de un grupo, a partir de los resultados obtenidos con cada algoritmo de reconocimiento de rostros utilizado.
2. Desarrollar un procedimiento para la clasificación de grupos homogéneos y heterogéneos de usuarios de TV digital.
 - El resultado del estudio del estado del arte en el campo de la generación de recomendaciones para grupos de usuarios contribuyó a identificar la necesidad de producir recomendaciones para dos tipos de grupos específicos: homogéneos y heterogéneos.
 - Se ha propuesto dos diferentes enfoques para la identificación del tipo un grupo de usuarios, en función de las preferencias de sus miembros: Enfoque de Votación y Enfoque de Promedios, los cuales utilizan como elemento central el algoritmo de Inferencia Semántica parte del sistema desarrollado en [9] para extraer las propiedades televisivas relevantes del perfil del usuario; a partir de la información obtenida.
 3. Extender los alcances del algoritmo de recomendación desarrollado en [9] para recomendar a grupos de usuarios.
 - Una vez identificado el tipo de grupo, se propuso y evaluó dos diferentes técnicas para la generación de recomendaciones de grupo. En el caso de los usuarios de grupos homogéneos, se genera un perfil ontológico común agregando la información de sus integrantes, lo que se conoce como *fusión de perfiles*; el resultado de este procedimiento de agregación y creación de un perfil genérico para el grupo, posibilita utilizar un enfoque de recomendación individual, como el planteado en [9], que considera a todo el grupo como un individuo que recoge las preferencias de todos los miembros. En el caso de los grupos heterogéneos se utiliza un enfoque diferente, basado en la técnica de *fusión de recomendaciones*, en la que a cada integrante recibe sugerencias personalizadas mediante un sistema de recomendación personalizado a partir de sus preferencias individuales para posteriormente, unir los listados de los integrantes mediante un proceso de agregación en función de la afinidad que los usuarios puedan tener por las películas recomendadas a los otros miembros.
 4. Desarrollar los procedimientos de evaluación necesarios para el sistema implementado considerando su arquitectura modular.

Las evaluaciones realizadas a cada módulo permiten concluir lo siguiente:

 - En el módulo de identificación de usuarios, el algoritmo de reconocimiento facial más adecuado es Eigenfaces, puesto que presentó los mejores resultados de reconocimiento.
 - En el módulo clasificador de grupos se determinó que el algoritmo más eficaz en la categorización de grupos es el enfoque de promedios respecto al enfoque de votación.
 - El porcentaje que posibilita la determinación de homogeneidad de un grupo oscila entre 60 y 68 por ciento, lo que significa que en un grupo, el nivel de similaridad de las preferencias televisivas debe superar el 60 %, caso contrario el grupo se considera heterogéneo.



- En la recomendación de grupos homogéneos y heterogéneos, el algoritmo de fusión de recomendaciones tiene menos error de recomendación frente a la metodología de fusión de perfiles.
- Las recomendaciones generadas para grupos homogéneos son más precisas que aquellas para grupos heterogéneos.
- Las precisiones de las recomendaciones guardan una cercana relación con el tamaño de grupo.

5.2. Trabajo Futuro

Tras haber evaluado y realizado diferentes pruebas en el sistema desarrollado, se han identificado oportunidades de continuidad para este proyecto que se detallan a continuación:

- En el ámbito de reconocimiento facial es importante determinar el número de fotografías necesarias para la fase de entrenamiento y a partir de ello se pueda mejorar los resultados de identificación.
- Analizar los diferentes escenarios de iluminación posibles. En el contexto de este prototipo, las pruebas fueron realizadas bajo condiciones ideales y homogéneas de iluminación, por lo que es pertinente la implementación de un mecanismo de adaptación del sistema a las variaciones de este parámetro.
- En el ámbito del servicio de identificación de usuarios, es importante mencionar que el valor de resolución de la cámara a utilizarse constituye también un parámetro que requiere de evaluación futura.
- Para este prototipo, se contó con un limitado número de grupos de usuarios, por lo que se estima que una evaluación con un mayor número de usuarios, y consecuentemente, con un mayor número de grupos es pertinente para poder generalizar los resultados preliminares obtenidos en los experimentos realizados.
- Este grupo de trabajo considera también que debe profundizarse el estudio de los procedimientos para la presentación de las recomendaciones generadas para el grupo. Al considerar que en un grupo puede existir una serie de subgrupos producto de todas las posibles combinaciones entre sus miembros; se debe establecer una forma amigable e intuitiva, acorde al contexto de la experiencia televisiva.
- Implementar una aplicación que posibilite el ingreso de los datos de usuario y posibilite el proceso de calificación de programas televisivos. Para este prototipo se asume que cada usuario ha calificado ya un conjunto pequeño de contenidos que permiten formar una base de conocimiento utilizada para alimentar al sistema recomendador.
- Entre muchas otras aplicaciones posibles, se estima que mediante el servicio de identificación de usuarios frente al televisor, se puede además determinar la pertinencia de ciertos programas televisivos en función de la edad de las personas.

Anexos



UNIVERSIDAD DE CUENCA
desde 1867

Anexo A

Tablas de Resultados

A.1. Módulo de Recomendación

A.1.1. Fusión de Perfiles vs Fusión de Recomendaciones para grupos homogéneos

#	MAPE- E	MAPE- RM	NDCG- E	NDCG- RM	#	MAPE- E	MAPE- RM	NDCG- E	NDCG- RM
1	0.111252	0.075715	0.986409	0.994535	76	0.151787	0.134128	0.935325	0.938989
2	0.131078	0.137996	0.968145	0.954093	77	0.109287	0.095541	0.975500	0.983198
3	0.132471	0.134163	0.943061	0.951865	78	0.170082	0.119698	0.962893	0.962762
4	0.075466	0.110505	0.976337	0.964362	79	0.468869	0.350041	0.876253	0.901857
5	0.235338	0.185570	0.907306	0.921741	80	0.306760	0.227276	0.922355	0.934790
6	0.149120	0.111393	0.983909	0.993601	81	0.278244	0.204217	0.944221	0.936773
7	0.116563	0.077531	0.982369	0.996389	82	0.363372	0.300134	0.906739	0.945851
8	0.151486	0.108381	0.983723	0.993309	83	0.216516	0.158938	0.915491	0.934544
9	0.140623	0.111168	0.967395	0.969850	84	0.211174	0.143584	0.913810	0.921952
10	0.099397	0.090527	0.985035	0.983180	85	0.310879	0.236079	0.905476	0.963865
11	0.154959	0.156240	0.968591	0.962756	86	0.140843	0.117030	0.950710	0.953374
12	0.198685	0.208836	0.961988	0.936354	87	0.201224	0.135801	0.908191	0.959068
13	0.106286	0.110731	0.967614	0.961391	88	0.175108	0.139937	0.917866	0.955264
14	0.113721	0.124368	0.960587	0.949898	89	0.373421	0.294573	0.984579	0.957788
15	0.130402	0.127097	0.971144	0.962259	90	0.184729	0.121381	0.949866	0.950801
16	0.139781	0.130455	0.973045	0.951483	91	0.131279	0.146069	0.992686	0.987570
17	0.148627	0.153974	0.944605	0.955493	92	0.304857	0.227478	0.937106	0.968014
18	0.148340	0.151959	0.915984	0.949160	93	0.288707	0.250962	0.972472	0.971532
19	0.168556	0.158558	0.929883	0.951764	94	0.180622	0.171649	0.960545	0.957663
20	0.119550	0.113623	0.960563	0.947935	95	0.188236	0.121586	0.949792	0.950801
21	0.113949	0.113908	0.987805	0.988424	96	0.135619	0.140538	0.990952	0.987337
22	0.089199	0.128387	0.991078	0.974995	97	0.118035	0.119881	0.948125	0.960982
23	0.099606	0.128260	0.971987	0.960850	98	0.176861	0.168103	0.961079	0.957968



ANEXO A. TABLAS DE RESULTADOS

#	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM	#	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM
24	0.090721	0.115446	0.971289	0.944939	99	0.311797	0.273982	0.934290	0.942610
25	0.081102	0.089537	0.973976	0.983064	100	0.360693	0.331085	0.906966	0.926428
26	0.090721	0.114954	0.971289	0.944939	101	0.345411	0.330493	0.937752	0.937725
27	0.329209	0.251759	0.901484	0.923728	102	0.083108	0.116114	0.979291	0.968135
28	0.276215	0.199120	0.883050	0.916808	103	0.098587	0.098017	0.993325	0.989656
29	0.194973	0.129151	0.921425	0.942521	104	0.112863	0.109289	0.976330	0.985897
30	0.180894	0.122193	0.929858	0.938262	105	0.183412	0.199551	0.925537	0.914861
31	0.246126	0.183580	0.901956	0.941921	106	0.183938	0.180808	0.967325	0.958205
32	0.165589	0.123556	0.978556	0.991594	107	0.196753	0.196314	0.949834	0.915135
33	0.258547	0.197506	0.985817	0.979595	108	0.107810	0.109384	0.974415	0.974702
34	0.173392	0.137067	0.964297	0.971621	109	0.189037	0.164512	0.899528	0.954084
35	0.130683	0.118351	0.989813	0.983860	110	0.206918	0.205257	0.968080	0.948878
36	0.168077	0.120281	0.978181	0.991134	111	0.156464	0.139117	0.959577	0.960986
37	0.153445	0.100551	0.951277	0.973369	112	0.171909	0.176459	0.946483	0.955527
38	0.098738	0.103177	0.986902	0.989138	113	0.134099	0.105924	0.908848	0.922704
39	0.174191	0.133763	0.963863	0.971621	114	0.156510	0.134164	0.936527	0.951310
40	0.133307	0.115585	0.989813	0.983478	115	0.270857	0.260035	0.940925	0.947606
41	0.155624	0.137384	0.958559	0.954999	116	0.164596	0.151859	0.911188	0.927648
42	0.310238	0.286262	0.958819	0.944771	117	0.170745	0.166880	0.943005	0.951594
43	0.122048	0.123958	0.970513	0.967911	118	0.167675	0.161334	0.914976	0.938326
44	0.136440	0.142105	0.958098	0.941767	119	0.173876	0.158461	0.928538	0.956102
45	0.146651	0.138375	0.962102	0.963509	120	0.141581	0.139326	0.966592	0.975034
46	0.185804	0.185297	0.920975	0.937570	121	0.227709	0.167746	0.917927	0.937557
47	0.184581	0.205997	0.951827	0.909935	122	0.372208	0.285652	0.926112	0.931126
48	0.200839	0.206884	0.963036	0.944117	123	0.116118	0.118681	0.981250	0.986478
49	0.111707	0.116921	0.969967	0.965247	124	0.133579	0.553668	0.979058	0.978781
50	0.106758	0.100964	0.982383	0.977047	125	0.330221	0.294296	0.984825	0.989546
51	0.107309	0.112781	0.967727	0.964114	126	0.757626	0.635532	0.977547	0.975615
52	0.161934	0.154507	0.951125	0.961447	127	0.271271	0.211698	0.946862	0.985935
53	0.144551	0.137714	0.920600	0.946097	128	0.654670	0.578688	0.982668	0.982988
54	0.162606	0.152976	0.955195	0.947757	129	0.168551	0.198198	0.980152	0.983733
55	0.130382	0.106113	0.954547	0.952913	130	0.108698	0.112665	0.974832	0.985079
56	0.182883	0.182116	0.925693	0.947581	131	0.168551	0.197295	0.980152	0.983733
57	0.207232	0.192355	0.941565	0.951873	132	0.092245	0.105796	0.978263	0.975119
58	0.140563	0.133575	0.953272	0.950400	133	0.115264	0.167998	0.944961	0.930196
59	0.195029	0.189707	0.919265	0.947214	134	0.092245	0.104424	0.978263	0.975119
60	0.128123	0.125772	0.924909	0.931724	135	0.140397	0.099604	0.976309	0.986555
61	0.153935	0.132760	0.930205	0.946536	136	0.286196	0.204434	0.912272	0.913942



ANEXO A. TABLAS DE RESULTADOS

#	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM	#	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM
62	0.186079	0.145946	0.931800	0.944657	137	0.140397	0.100091	0.976309	0.986555
63	0.112235	0.108445	0.972455	0.976822	138	0.221417	0.158754	0.965862	0.983240
64	0.152071	0.132227	0.939913	0.945471	139	0.136213	0.162275	0.958689	0.961856
65	0.152250	0.147413	0.985885	0.982285	140	0.596997	0.394241	0.952101	0.956370
66	0.164281	0.112030	0.946237	0.947753	141	0.135096	0.122442	0.964828	0.950439
67	0.305316	0.271084	0.982010	0.963019	142	0.465869	0.349294	0.907080	0.931582
68	0.128020	0.161376	0.978771	0.987469	143	0.403123	0.298496	0.899864	0.918285
69	0.089006	0.137947	0.987083	0.964165	144	0.678788	0.538091	0.883060	0.934206
70	0.091458	0.103137	0.982385	0.978764	145	0.239444	0.204464	0.958408	0.958377
71	0.089006	0.137327	0.987083	0.964165	146	0.321110	0.270557	0.915248	0.959400
72	0.127392	0.141239	0.968715	0.953064	147	0.307058	0.262312	0.967156	0.956073
73	0.099615	0.083399	0.970593	0.982750	148	0.150976	0.135548	0.945604	0.940234
74	0.127392	0.140471	0.968715	0.952963	149	0.216272	0.164032	0.930896	0.953143
75	0.109287	0.095789	0.975500	0.982720	150	0.211336	0.164957	0.925096	0.956381
					151	0.154345	0.142623	0.945932	0.976209

Tabla A.1: Técnicas de recomendación para grupos homogéneos

UNIVERSIDAD DE CUENCA
desde 1867



A.1.2. Fusión de Perfiles vs Fusión de Recomendaciones para grupos heterogéneos

#	MAPE- E	MAPE- RM	NDCG- E	NDCG- RM	#	MAPE- E	MAPE- RM	NDCG- E	NDCG- RM
1	0.284283	0.204519	0.898081	0.906084	68	0.398817	0.287267	0.943380	0.954371
2	0.095973	0.114036	0.962972	0.960184	69	0.262296	0.224683	0.959651	0.961217
3	0.131993	0.113084	0.963845	0.969182	70	0.268767	0.180745	0.917257	0.955031
4	0.370486	0.298596	0.964574	0.948419	71	0.252508	0.179513	0.916173	0.944573
5	0.302250	0.219313	0.972262	0.961009	72	0.297427	0.200947	0.925087	0.940093
6	0.182425	0.121665	0.957935	0.955360	73	0.377435	0.317856	0.957762	0.970865
7	0.269865	0.191400	0.938289	0.932437	74	0.325032	0.236671	0.966438	0.956826
8	0.355218	0.237858	0.900857	0.903828	75	0.397479	0.259438	0.973898	0.962975
9	0.298135	0.223982	0.884588	0.902757	76	0.647244	0.544331	0.982209	0.983106
10	0.332960	0.234787	0.922879	0.902538	77	0.334453	0.200206	0.901888	0.892472
11	0.319984	0.202764	0.878958	0.894542	78	0.407010	0.330202	0.952930	0.957854
12	0.098529	0.122035	0.955291	0.951637	79	0.435111	0.311995	0.960848	0.975351
13	0.132014	0.138199	0.966804	0.965724	80	0.256168	0.170435	0.953765	0.948544
14	0.106554	0.121194	0.951951	0.953228	81	0.270303	0.180337	0.939851	0.957918
15	0.114298	0.127244	0.942750	0.948902	82	0.118677	0.124642	0.964936	0.969922
16	0.089363	0.109008	0.962789	0.958929	83	0.290795	0.195554	0.956466	0.922305
17	0.131994	0.113507	0.961194	0.952554	84	0.299852	0.184268	0.962058	0.924664
18	0.167623	0.142759	0.956810	0.969853	85	0.131407	0.152441	0.942639	0.943681
19	0.118863	0.095440	0.958634	0.968942	86	0.431211	0.286462	0.959904	0.918533
20	0.168382	0.142750	0.966149	0.970384	87	0.150525	0.139632	0.936349	0.935167
21	0.372581	0.295855	0.981361	0.973718	88	0.178975	0.165664	0.915064	0.941297
22	0.606862	0.483414	0.951564	0.945517	89	0.317620	0.274060	0.958043	0.949435
23	0.375925	0.302148	0.982112	0.966169	90	0.613948	0.430956	0.872623	0.912155
24	0.407711	0.273450	0.928260	0.941280	91	0.424469	0.271424	0.908875	0.935153
25	0.298044	0.240184	0.948304	0.954698	92	0.351483	0.293611	0.938536	0.932042
26	0.248500	0.212620	0.958876	0.961662	93	0.272129	0.223158	0.912932	0.920357
27	0.357681	0.267968	0.985816	0.970825	94	0.320441	0.201493	0.897316	0.888871
28	0.277406	0.193197	0.943370	0.933898	95	0.442323	0.344617	0.880773	0.840675
29	0.318424	0.203499	0.947332	0.942108	96	0.410338	0.295601	0.883077	0.899158
30	0.420905	0.344283	0.970377	0.982118	97	0.497545	0.309027	0.864205	0.922170
31	0.174605	0.122753	0.962065	0.961821	98	0.524694	0.419709	0.848087	0.845055
32	0.187338	0.116670	0.956674	0.951983	99	0.204575	0.192157	0.924804	0.944775
33	0.243308	0.162246	0.932710	0.929899	100	0.171792	0.182531	0.948425	0.950674
34	0.253456	0.176866	0.959833	0.940313	101	0.158369	0.143551	0.945072	0.931182



ANEXO A. TABLAS DE RESULTADOS

#	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM	#	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM
35	0.128242	0.132582	0.951717	0.951795	102	0.164189	0.158632	0.943466	0.929352
36	0.394454	0.283459	0.900428	0.938228	103	0.241552	0.199982	0.892370	0.906992
37	0.249801	0.196590	0.927371	0.939622	104	0.183336	0.178178	0.960258	0.972923
38	0.324709	0.231922	0.932678	0.900300	105	0.165512	0.150235	0.960825	0.963728
39	0.274544	0.173853	0.889069	0.899096	106	0.160521	0.173494	0.955907	0.955798
40	0.342472	0.244434	0.932520	0.883014	107	0.139394	0.141212	0.942837	0.931764
41	0.443072	0.282078	0.878986	0.894869	108	0.193736	0.163078	0.941035	0.948225
42	0.398871	0.244915	0.882570	0.914030	109	0.100981	0.107160	0.995062	0.995267
43	0.376689	0.300047	0.885445	0.884286	110	0.375926	0.227889	0.895015	0.963339
44	0.364925	0.252744	0.867167	0.856465	111	0.112440	0.141610	0.988675	0.988601
45	0.362432	0.237885	0.895003	0.893649	112	0.803113	0.519475	0.962641	0.965485
46	0.136905	0.154818	0.958407	0.958189	113	0.576714	0.511178	0.952744	0.956640
47	0.126518	0.115068	0.922988	0.945227	114	0.344751	0.287932	0.988993	0.991958
48	0.149045	0.144035	0.939404	0.935387	115	0.214156	0.217852	0.975707	0.976385
49	0.123273	0.122613	0.949727	0.944139	116	0.241854	0.155708	0.944882	0.933056
50	0.161468	0.152061	0.952175	0.965557	117	0.835534	0.562201	0.940264	0.947186
51	0.152352	0.153481	0.948755	0.959313	118	0.544985	0.497156	0.951620	0.951685
52	0.124171	0.134272	0.964850	0.961154	119	0.565662	0.379315	0.925417	0.958668
53	0.130005	0.135228	0.952573	0.949935	120	0.239483	0.169424	0.963202	0.958937
54	0.126276	0.116754	0.951584	0.947065	121	0.413429	0.299449	0.921896	0.909463
55	0.140402	0.131336	0.946559	0.940818	122	0.377687	0.261867	0.911591	0.906162
56	0.175244	0.145429	0.947907	0.947338	123	0.345447	0.293405	0.937855	0.950114
57	0.325089	0.243007	0.930981	0.974451	124	0.401846	0.291084	0.917871	0.948207
58	0.077758	0.106054	0.992551	0.991088	125	0.435875	0.251579	0.920449	0.920277
59	0.152300	0.154440	0.987461	0.990476	126	0.685592	0.610268	0.977620	0.982606
60	0.164714	0.112785	0.942432	0.960647	127	0.772529	0.557379	0.970364	0.974801
61	0.666085	0.540784	0.969504	0.969177	128	0.402249	0.300860	0.922388	0.919219
62	0.349668	0.299302	0.983108	0.979087	129	0.341432	0.224220	0.917265	0.931395
63	0.375719	0.264841	0.977618	0.971578	130	0.350829	0.197791	0.919386	0.955886
64	0.260449	0.235403	0.986939	0.957521	131	0.143489	0.160312	0.958224	0.956051
65	0.664259	0.530186	0.976186	0.952310	132	0.754539	0.507661	0.949620	0.881353
66	0.689957	0.462717	0.920863	0.935561	133	0.153489	0.137613	0.950674	0.931075
67	0.511429	0.443436	0.942256	0.954163	134	0.169169	0.192545	0.935693	0.920763
					135	0.290797	0.242976	0.858599	0.915879

Tabla A.2: Técnicas de recomendación para grupos heterogéneos

A.1.3. Fusión de Perfiles vs Fusión de Recomendaciones según tamaño de grupo

Tamaño	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM
Grupos de 2	0.231508	0.209129	0.950799	0.958382
Grupos de 3	0.173136	0.152537	0.953349	0.958040
Grupos de 4	0.149185	0.135044	0.956216	0.958664
Grupos de 5	0.137121	0.128790	0.956252	0.957319

Tabla A.3: Técnicas de recomendación - tamaño de grupos homogéneos

Tamaño	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM
Grupos de 2	0.360680	0.277715	0.932621	0.937680
Grupos de 3	0.298991	0.230552	0.940398	0.942795
Grupos de 4	0.254302	0.197609	0.948617	0.948540
Grupos de 5	0.227902	0.178535	0.952347	0.948976

Tabla A.4: Técnicas de recomendación - tamaño de grupos heterogéneos

A.1.4. Fusión de Perfiles vs Fusión de Recomendaciones según tipo de grupo

Tipo	MAPE-E	MAPE-RM	NDCG-E	NDCG-RM
Homogéneo	0.192173	0.172350	0.953099	0.958262
Heterogéneo	0.307709	0.237583	0.940635	0.942709

Tabla A.5: Técnicas de recomendación - según tipo de grupo

A.2. Módulo de Reconocimiento

A.2.1. Resultados por técnicas: Eigenfaces, Fisherfaces y LBPH

Miembros	Eigen	Fisher	LBPH
5	82 %	14 %	68 %
4	88.2 %	27.8 %	69.2 %
3	90.3 %	42.33 %	82 %
2	93 %	53 %	89.5 %
1	98 %	70 %	96 %

Tabla A.6: Promedio de los resultados por técnica

A.2.2. Resultados según tamaño de grupo

Miembros	Combinación	Eigen	Fisher	LBPH
5	RCWBK	82 %	14 %	68 %
4	RCWB	83 %	20 %	68 %
4	RCWK	80 %	23 %	68 %
4	RCBK	95 %	28 %	70 %
4	RWBK	93 %	35 %	70 %
4	CWBK	90 %	33 %	70 %
3	CWB	93 %	50 %	83 %
3	RCW	93 %	40 %	87 %
3	RWB	87 %	33.33 %	87 %
3	RCB	90 %	40 %	83 %
3	WBK	90 %	36.66 %	90 %
3	RWK	87 %	33.33 %	77 %
3	RBK	90 %	36.66 %	70 %
3	CBK	90 %	53.33 %	73 %
3	CWK	90 %	53.33 %	83 %
3	KRC	93 %	46.66 %	87 %
2	RC	95 %	40 %	85 %
2	CW	95 %	45 %	90 %
2	CB	90 %	50 %	90 %
2	RB	95 %	50 %	95 %
2	RW	95 %	60 %	85 %
2	RK	90 %	50 %	90 %
2	CK	100 %	75 %	90 %
2	WK	85 %	45 %	85 %
2	BK	90 %	50 %	90 %
2	WB	95 %	65 %	95 %
1	R	90 %	60 %	100 %
1	C	100 %	60 %	100 %
1	W	100 %	70 %	90 %
1	B	100 %	80 %	100 %
1	K	100 %	80 %	90 %

Tabla A.7: Promedio de los resultados según tamaño de grupo

A.2.3. Evidencias




Figura A.1: Reconocimiento de Integrantes

Anexo B

Manual de Usuario

Con los diferentes algoritmos estudiados dentro de los módulos pertenecientes al sistema SRGU, se ha desarrollado un prototipo que permita el logueo de usuarios mediante el reconocimiento facial y estos puedan acceder al servicio de recomendación de contenidos audiovisuales.

La funcionalidad del sistema se probará con un grupo de tres integrantes:

- **Inicio del sistema**, al arrancar la aplicación no existen usuarios registrados, por tal razón se mostrará un mensaje indicando la necesidad de realizar el registro de usuarios y se habilitará el botón *Registrar*.

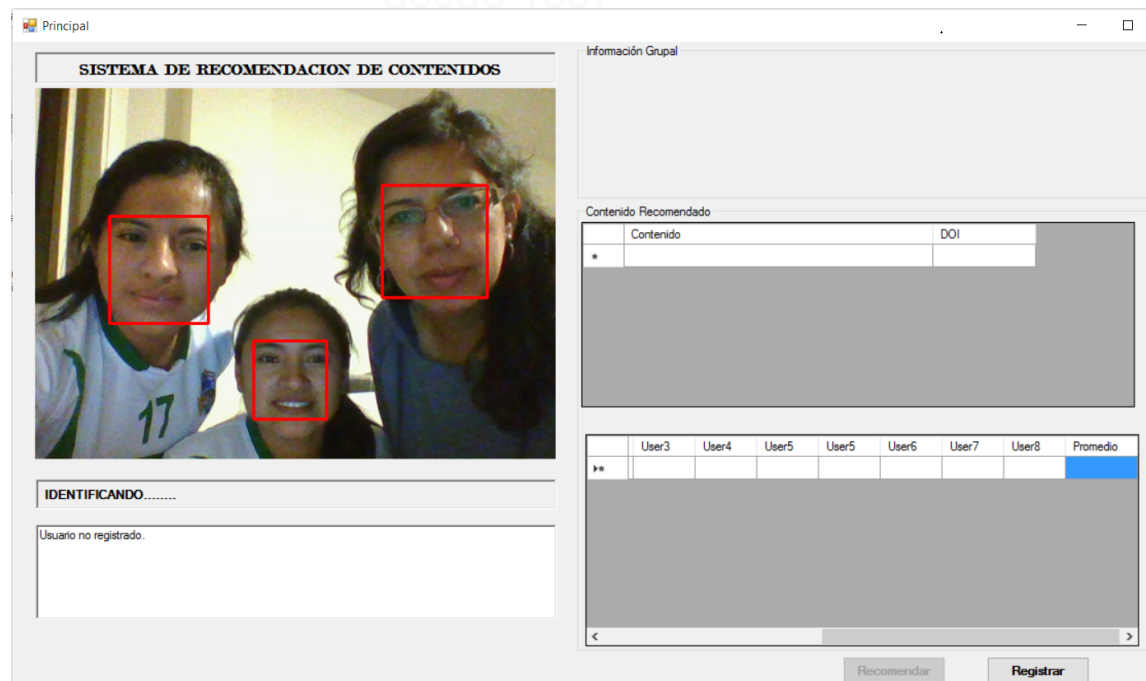


Figura B.1: Inicio del sistema recomendador

- **Identificación de usuarios**, previamente se ha registrado un usuario (MarthaS), en la Figura siguiente cada rostro identificado se enmarca con un cuadrado de color rojo,

asociando con un identificador (nombre de usuario único). Los usuarios identificados se presentan en la parte derecha superior, con la foto de perfil y nombre de usuario. Se procede a verificar en la base si existe el registro. El sistema detecta dos usuarios: un conocido y uno desconocido, por lo que, se debe realizar el registro respectivo.

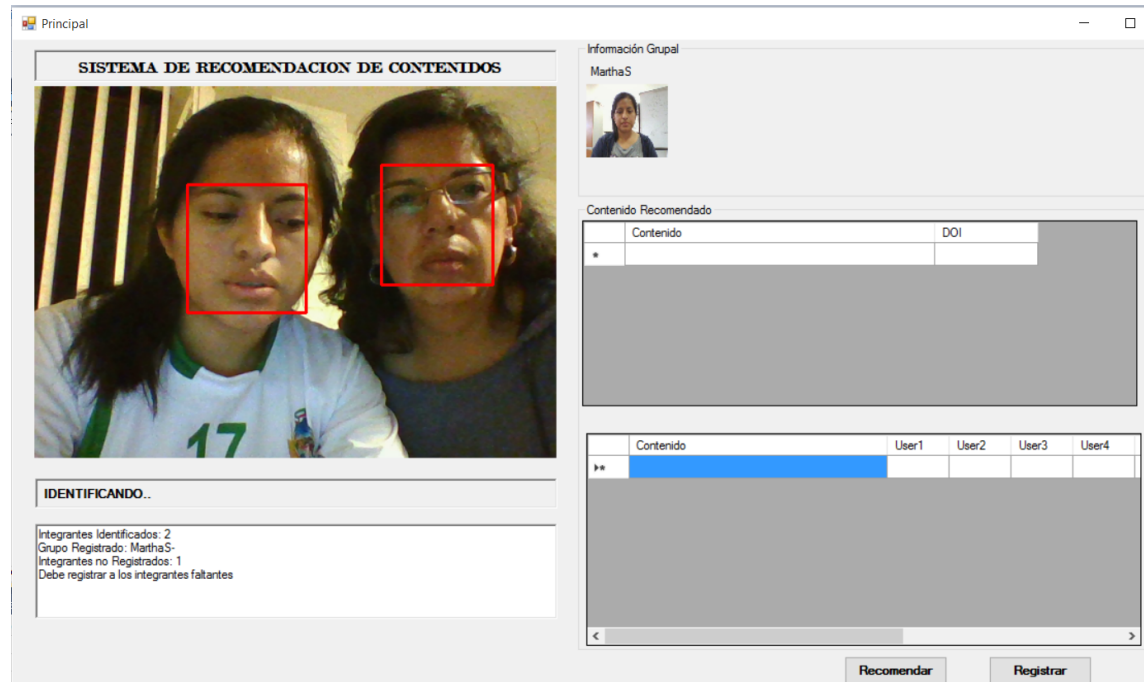


Figura B.2: Identificación del usuario: MarthaS

- **Registro de integrantes del grupo**, se carga los datos del usuario registrado, visualizado en la Figura B.3. Para el registro de cada integrante es necesario el ingreso del número de cédula y el nombre de usuario, el cual funciona como clave, dado que no se puede repetir para otro usuario. Posteriormente al presionar el botón *Tomar Fotos* se realiza la captura de rostros empezando por el perfil derecho, es recomendable seguir la figura de un pajarito, que cambia de posición en el lapso de un segundo, tratando de guiar el perfil correcto.




Figura B.3: Carga de datos del usuario registrado

Los integrantes que se registran se agrega en la parte inferior, con una foto de perfil y nombre de usuario. Al finalizar el registro de usuarios se guarda el grupo al presionar el botón *Registrar Grupo*.

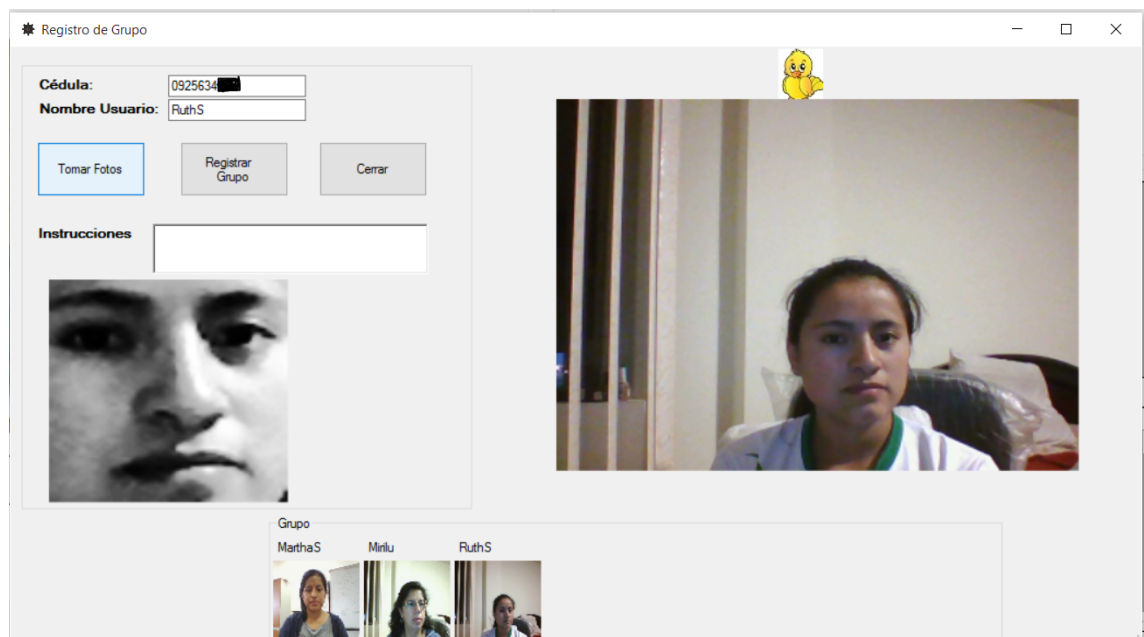
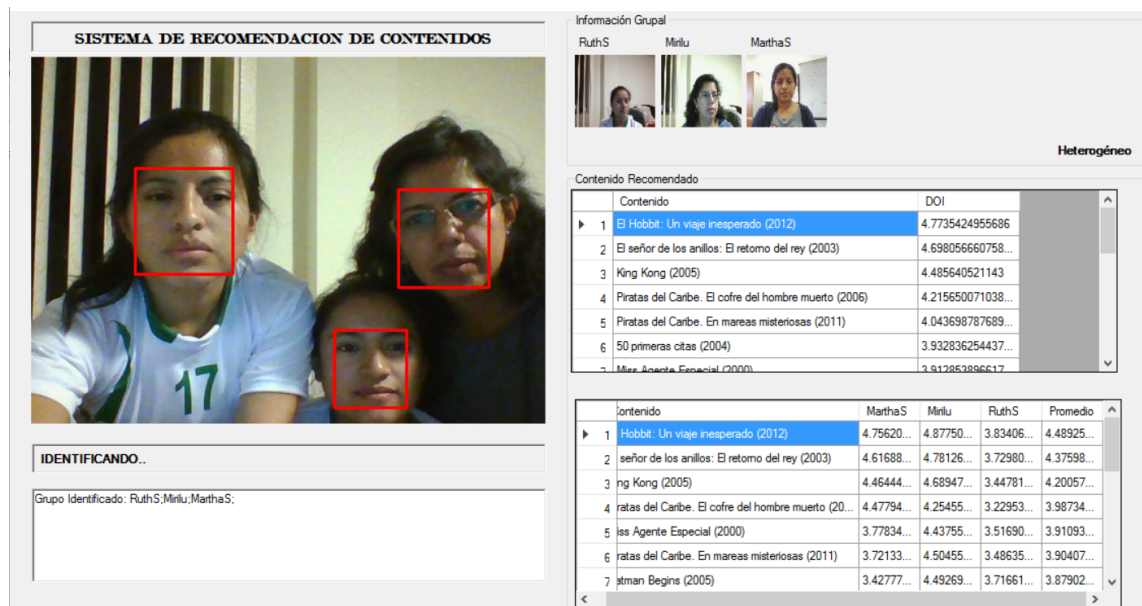


Figura B.4: Registro de grupo

Para cerrar la ventana de registro presionar el botón *Cerrar*.

- Tipo de Grupo**, se describe en la sección derecha de la interfaz principal, en la parte *información grupal* si es que existe más de dos usuarios, visualizados en la Figura B.5.
- Recomendación de Contenidos**, en la parte derecha de la interfaz representada en la Figura B.5, al presionar el botón *Recomendar* se genera las listas de los contenidos televisivos, en la tabla superior están los resultados del algoritmo de Fusión de perfiles, debido a que este representa un usuario único retorna un solo valor para cada contenido del conjunto recomendado al grupo. En la tabla inferior constan los resultados al aplicar el algoritmo de Fusión de Recomendaciones, el cual posibilita obtener un valor (DOI) de la película por integrante. En la primera columna está el nombre del contenido y en las siguientes las columnas de un valor hacia la película de acuerdo al número de integrantes, la última corresponde al valor promedio para el grupo.



Contenido	DOI
1 El Hobbit: Un viaje inesperado (2012)	4.7735424955686
2 El señor de los anillos: El retorno del rey (2003)	4.698056660758...
3 King Kong (2005)	4.485640521143
4 Piratas del Caribe. El cofre del hombre muerto (2006)	4.215650071038...
5 Piratas del Caribe. En mareas misteriosas (2011)	4.043698787689...
6 50 primeras citas (2004)	3.932836254437...
7 Miss Agente Especial (2000)	3.912863896617

Contenido	MarthaS	Mirilu	RuthS	Promedio
1 Hobbit: Un viaje inesperado (2012)	4.75620...	4.87750...	3.83406...	4.48925...
2 El señor de los anillos: El retorno del rey (2003)	4.61688...	4.78126...	3.72980...	4.37598...
3 King Kong (2005)	4.46444...	4.68947...	3.44781...	4.20057...
4 Piratas del Caribe. El cofre del hombre muerto (2006)	4.47794...	4.25455...	3.22953...	3.98734...
5 Miss Agente Especial (2000)	3.77834...	4.43755...	3.51690...	3.91093...
6 Piratas del Caribe. En mareas misteriosas (2011)	3.72133...	4.50455...	3.48635...	3.90407...
7 Superman Begins (2005)	3.42777...	4.49269...	3.71661...	3.87902...

Figura B.5: Identificación del grupo: MarthaS, RuthS y Mirilu

- Verificación de Integrantes logueados**, el sistema contiene un proceso que trabaja cada cierto tiempo, tratando de verificar los usuarios presentes, si se integraron más usuarios o se retiraron, de esta manera se puede actualizar las recomendaciones para el grupo presente. Es el caso de la Figura B.5, el grupo está constituido de tres integrantes, se retira un usuario seguidamente el sistema actualiza la lista de usuarios identificados, y posteriormente se puede realizar la recomendación. Estos escenarios se presentan en las Figuras B.6 y B.7.

SISTEMA DE RECOMENDACION DE CONTENIDOS

IDENTIFICANDO...

Grupo Identificado: Mirilu;RuthS;

Información Grupal
Mirilu RuthS

Heterogéneo

Contenido Recomendado

Contenido	DOI
1 El Hobbit: Un viaje inesperado (2012)	4.794403624534...
2 El señor de los anillos: El retorno del rey (2003)	4.725871499379...
3 King Kong (2005)	4.537124070856...
4 Piratas del Caribe. En mareas misteriosas (2011)	4.176204302731...
5 Sin compromiso (I) (2011)	4.160312190651...
6 Miss Agente Especial (2000)	4.148004007339...
7 Batman Begins (2005)	4.147767490910...

Contenido	RuthS	Mirilu	Promedio
1 El Hobbit: Un viaje inesperado (2012)	3.83406...	4.87750...	4.35578...
2 El señor de los anillos: El retorno del rey (2003)	3.72980...	4.78126...	4.25553...
3 Batman Begins (2005)	3.71661...	4.49269...	4.10465...
4 King Kong (2005)	3.44781...	4.68947...	4.06864...
5 X-Men orígenes: Lobezno (2009)	3.75188...	4.34607...	4.04898...
6 Chicas malas (2004)	3.68361...	4.34000...	4.01180...
7 Piratas del Caribe. En mareas misteriosas (2011)	3.48635...	4.50455...	3.99545...
8 Sin compromiso (I) (2011)	3.41217	4.56301	3.98759

Figura B.6: Identificación del grupo: Mirilu y RuthS

SISTEMA DE RECOMENDACION DE CONTENIDOS

GENERANDO RECOMENDACION.....

Grupo Identificado: MarthaS;RuthS;

Información Grupal
MarthaS RuthS

Heterogéneo

Contenido Recomendado

Contenido	DOI
1 El Hobbit: Un viaje inesperado (2012)	4.7368714928627
2 El señor de los anillos: El retorno del rey (2003)	4.6491619904836
3 Piratas del Caribe. El cofre del hombre muerto (2006)	4.537714656194...
4 King Kong (2005)	4.511905773480...
5 Piratas del Caribe. En mareas misteriosas (2011)	4.08880986909...
6 Transformers: La venganza de los caídos (2009)	3.974616656700...
7 Miss Agente Especial (2000)	3.859494294439

Contenido	MarthaS	RuthS	Promedio
1 El Hobbit: Un viaje inesperado (2012)	4.75620...	3.83406...	4.29513...
2 El señor de los anillos: El retorno del rey (2003)	4.61688...	3.72980...	4.17334...
3 King Kong (2005)	4.46444...	3.44781...	3.95613...
4 Piratas del Caribe. El cofre del hombre muerto (20...	4.47794...	3.22953...	3.85373...
5 Miss Agente Especial (2000)	3.77834...	3.51690...	3.64762...
6 Transformers: La venganza de los caídos (2009)	3.88397...	3.40302...	3.64349...
7 Piratas del Caribe. En mareas misteriosas (2011)	3.72133...	3.48635...	3.60384...
8 50 primeras citas (2004)	3.65725	3.51521	3.58623

Figura B.7: Identificación del grupo: MarthaS y RuthS

Bibliografía

- [1] Leon Harmon AJ Goldstein. Identification of human faces. Bell Telephone Laboratories, 1971.
- [2] Matthew Turk Alex Pentland. Face recognition using eigenfaces. MIT, 1991.
- [3] Sihem Amer-Yahia, Senjuti Basu Roy, Ashish Chawla, Gautam Das, and Cong Yu. Group recommendation: Semantics and efficiency. *PVLDB*, 2(1):754–765, 2009.
- [4] David Isern Antonio Moreno, Aida Valls. Ontology based personalized recommendation of tourism and leisure activities. *Bibliometrics*, 2012.
- [5] Kemafor Anyanwu and Amit Sheth. Queriess: Enabling querying for semantic associations on the semantic web. In *Proceedings of the 12th International Conference on World Wide Web*, WWW '03, pages 690–699, New York, NY, USA, 2003. ACM.
- [6] Liliana Ardissono, Anna Goy, Giovanna Petrone, Marino Segnan, and Pietro Torasso. Intrigue: Personalized recommendation of tourist attractions for desktop and hand held devices. *Applied Artificial Intelligence*, 17(8-9):687–714, 2003.
- [7] J. Avila, X. Riofrio, K. Palacio-Baus, M. Espinoza-Mejia, and V. Saquicela. Semantic recommender systems for digital tv: From demographic stereotyping to personalized recommendations. In *Computer Aided System Engineering (APCASE), 2015 Asia-Pacific Conference on*, pages 392–396, Jul. 2015.
- [8] J Ávila, X Riofrío, Kenneth Palacio-Baus, M Espinoza-Mejía, V Saquicela, et al. Sistema de recomendación de contenidos audiovisuales: Algoritmo de inferencia semántica. *Revista Maskana, Volumen 5 No. especial - TIC.EC: Congreso Ecuatoriano de Tecnologías de la Información y Comunicaciones*, 2014.
- [9] J Avila, X Riofrío, and K Palacio. *Sistema de recomendación de contenido para TV digital basado en ontologías*. Universidad de Cuenca, May. 2014.
- [10] Linas Baltrunas, Tadas Makcinskas, and Francesco Ricci. Group recommendations with rank aggregation and collaborative filtering. In *Proceedings of the Fourth ACM Conference on Recommender Systems*, RecSys '10, pages 119–126, New York, NY, USA, 2010. ACM.
- [11] Y. Blanco-Fernández, J.J. Pazos-Arias, A. Gil-Solla, M. Ramos-Cabrer, M. López-Nores, J. García-Duque, A. Fernández-Vilas, R.P. Díaz-Redondo, and J. Bermejo-Muñoz. A flexible semantic inference methodology to reason about user preferences in knowledge-based recommender systems. *Knowledge-Based Systems*, 21(4):305–320, 2008.



- [12] Y. Blanco-Fernandez, J.J. Pazos-Arias, M. Lopez-Nores, A. Gil-Solla, and M. Ramos-Cabrer. Avatar: an improved solution for personalized tv based on semantic interface. In *Consumer Electronics, 2006. ICCE06. 2006 Digest of Technical Papers. International Conference on*, pages 145–146, Jan. 2006.
- [13] Iván Cantador, Pablo Castells, and David Vallet. Enriching group profiles with ontologies for knowledge-driven collaborative content retrieval. In *WETICE*, pages 358–363. IEEE Computer Society, 2006.
- [14] Ingrid Christensen and Silvia Schiaffino. A hybrid approach for group profiling in recommender systems. *JUCS*, 20(4):507–533, Apr. 2014.
- [15] Lluís Codina and Cristòfol Rovira. La web semántica. *Tendencias en documentación digital*, 2006.
- [16] Oskar Van Deventer, Joost De Wit, Jeroen Vanattenhoven, and Mark Guelbahar. Group recommendation in an hybrid broadcast broadband television context.
- [17] M. Espinoza-Mejía, V. Saquicela, K. Palacio-Baus, and H. Albán. Extracción de preferencias televisivas desde los perfiles de redes sociales. *Revista Politécnica, Escuela Politécnica Nacional - EPN*, 2014.
- [18] Raúl Castro Fernández. Representación del conocimiento. web semántica. *Universidad Carlos III de Madrid*, 2008.
- [19] Marcelo Naiouf Franco Chichizola, Armando De Giusti. Eigenfaces de imagen reducida para el reconocimiento automático de rostros. Instituto de Investigación en Informática LIDI, 2012.
- [20] Jorge Castro Gallardo. Un nuevo modelo ponderado para sistemas de recomendación basados en contenido con medidas de contingencia y entropía. Jaen, 2012.
- [21] Patty Kostkova Gawesh Jawaheer, Martin Szomszor. Comparison of implicit and explicit feedback from an online music recommendation service. *Recommendation*, 2010.
- [22] Rafael C. Gonzalez and Richard E. Woods. *Digital Image Processing (3rd Edition)*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA, 2006.
- [23] Dina Goren-Bar and Oded Glinansky. Family stereotyping - a model to filter tv programs for multiple viewers. In *Proceedings of the Workshop on Personalization in Future TV at the Conference on Adaptive Hypermedia and Adaptive Web-Based Systems (AH-2002)*, Malaga, Spain, 2002. Springer Verlag.
- [24] Diego Guerrero. Reconocimiento facial, pasado, presente y futuro. *Reconocimiento Facial*, 2012.
- [25] Xuetao Guo. Personalized government online services with recommendation. Sidney, 2006.
- [26] Junning Liu James Davidson, Benjamin Liebald. The youtube video recommendation system. *Recommendation*, 2010.



- [27] Anthony Jameson and Barry Smyth. Recommendation to groups. In Peter Brusilovsky, Alfred Kobsa, and Wolfgang Nejdl, editors, *The Adaptive Web*, volume 4321 of *Lecture Notes in Computer Science*, pages 596–627. Springer, 2007.
- [28] C Johnson. Emgu multiple face recognition using pca and parallel optimisation. Code Project, 2014.
- [29] Judy Kay and William Niu. Adapting information delivery to groups of people.
- [30] Michal Kompan and Mária Bielíková. Group recommendations: Survey and perspectives. *Computing and Informatics*, 33(2):446–476, 2014.
- [31] Mark Kiby L. Sirovich. A low-dimensional procedure for the characterization of human faces. *Journal of the Optical Society of America*, 1987.
- [32] Kuei-Hong Lin, Yu-Shian Chiu, and Jia-Sin Chen. An adaptive correlation-based group recommendation system. In *ISPACS*, pages 1–5. IEEE, 2011.
- [33] M. López-Nores, Y. Blanco-Fernandez, J.J. Pazos-Arias, and R.P. Diaz-Redondo. Property-based collaborative filtering: A new paradigm for semantics-based, health-aware recommender systems. In *Semantic Media Adaptation and Personalization (SMAP), 2010 5th International Workshop on*, pages 98–103, Dec. 2010.
- [34] Martín López-nores and Belén Barragáns-martínez. Avatar: Modeling users by dynamic ontologies in a tv recommender system based on semantic reasoning, 2005.
- [35] Yoav Shoham Marko Balabanovic. Content-based, collaborative recommendation. Moscú, 1997.
- [36] Judith Masthoff. Group modeling: Selecting a sequence of television items to suit a group of viewers. *User Modeling and User-Adapted Interaction*, 14(1):37–85, 2004.
- [37] Judith Masthoff. Group recommender systems: Combining individual models. In Francesco Ricci, Lior Rokach, Bracha Shapira, and Paul B. Kantor, editors, *Recommender Systems Handbook*, pages 677–702. Springer, 2011.
- [38] Manu Mateos. Así funcionan las recomendaciones de amazon. www.genbeta.com, Jan. 2014. Amazon.
- [39] J.F. McCarthy and T.D. Anagnost. Musicfx: An arbiter of group preferences for computer supported collaborative workouts. In *Proceedings of Conference on Computer Supported Cooperative Work*, pages 363–372, 1998.
- [40] J Medina, C Villa, V Saquicela, M Espinoza-Mejía, D Astudillo, H Albán, Kenneth Palacio-Baus, et al. On the implementation of a laboratory of digital television according to the isdb-tb standard. *Revista Maskana, Volumen 5 No. especial (2014) - TIC.EC: Congreso Ecuatoriano de Tecnologías de la Información y Comunicaciones*, 2014.
- [41] Mauricio Espinoza Mejía, Víctor Saquicela, Kenneth Palacio Baus, and Humberto Albán. Extracción de preferencias televisivas desde los perfiles de redes sociales. *Revista Politécnica - EPN*, 34(1), 2014.



- [42] B. N. Miller, I. Albert, S. K. Lam, J. A. Konstan, and J. Riedl. MovieLens unplugged: Experiences with an occasionally connected recommender system. In *2003 Conference on Intelligent User Interfaces (IUI'03)*. ACM, 2003.
- [43] Mark O'Connor, Dan Cosley, Joseph A. Konstan, and John Riedl. PolyLens: A Recommender System for Groups of Users. In *Proceedings of ECSCW 2001*, pages 199–218, 2001.
- [44] Eduardo Peis, Enrique Herrera-Viedma, Yusef Hassan-Montero, and JC Herrera. Análisis de la web semántica: estado actual y requisitos futuros. *El Profesional de la Información.*, 2003.
- [45] Alex Pentland. Face recognition using eigenfaces and distance classifiers. onionesquereality.wordpress.com, Feb. 2015. OpenCV.
- [46] Toon De Pessemier, Simon Dooms, and Luc Martens. Design and evaluation of a group recommender system. In Padraig Cunningham, Neil J. Hurley, Ido Guy, and Sarabjot Singh Anand, editors, *RecSys*, pages 225–228. ACM, 2012.
- [47] Deepesh Raj. A realtime face recognition system using pca and various distance classifiers. IEEE, 2012.
- [48] Ramón Invarato Ricardo Moya. Que son los sistemas de recomendación. Jarroba.com, Jul. 2013. Sistemas de Recomendación.
- [49] Francesco Ricci, Lior Rokach, Bracha Shapira, and Paul B. Kantor. *Recommender systems handbook*. Springer, New York; London, 2011.
- [50] Victor Saquicela, Mauricio Espinoza-Mejia, Kenneth Palacio, and Humberto Alban. Enriching electronic program guides using semantic technologies and external resources. In *Computing Conference (CLEI), 2014 XL Latin American*, pages 1–8. IEEE, 2014.
- [51] Benjamin Scheibehenne, Rainer Greifeneder, and Peter M Todd. Can there ever be too many options? a meta-analytic review of choice overload. *Journal of Consumer Research*, 37(3):409–425, 2010.
- [52] Nigel Shadbolt, Wendy Hall, and Tim Berners-Lee. The semantic web revisited. *Intelligent Systems, IEEE*, 21(3):96–101, 2006.
- [53] Lara Quijano Sánchez, Juan A. Recio-García, and Belén Díaz-Agudo. Personality and social trust in group recommendations. In *ICTAI (2)*, pages 121–126. IEEE Computer Society, 2010. 978-0-7695-4263-8.
- [54] R. Sotelo, Y. Blanco, M. Lopez, A. Gil, and J. Pazos. Tv program recommendation for groups based on multidimensional tv-anytime classifications. In *Consumer Electronics, 2009. ICCE '09. Digest of Technical Papers International Conference on*, pages 1–2, Jan. 2009.
- [55] R. Sotelo, M. Juayek, and A. Scuoteguazza. A comparison of audiovisual content recommender systems performance: Collaborative vs. semantic approaches. In *Broadband*



- Multimedia Systems and Broadcasting (BMSB)*, 2013 IEEE International Symposium on, pages 1–5, Jun 2013.
- [56] Rafael Sotelo. Recomendación de contenidos audiovisuales para familias y grupos de amigos, basado en clasificaciones tv-anytime multidimensionales. Universidad de Montevideo, 2010.
- [57] Rafael Sotelo, Marcos Juayek, and Alejandra Scuoteguazza. A comparison of audiovisual content recommender systems performance: Collaborative vs. semantic approaches. In *Broadband Multimedia Systems and Broadcasting (BMSB)*, 2013 IEEE International Symposium on, pages 1–5. IEEE, 2013.
- [58] IEEE Timo Ahonen, Student Member. Face description with local binary patterns. Application to Face Recognition, 2006.
- [59] R. Tubio, R. Sotelo, Y. Blanco, M. Lopez, A. Gil, J. Pazos, and M. Ramos. A tv-anytime metadata approach to tv program recommendation for groups. In *Consumer Electronics, 2008. ISCE 2008. IEEE International Symposium on*, pages 1–3, Apr. 2008.
- [60] International Telecommunication Union. Measuring the information society 2013. *ITU*, 2013.
- [61] Pattie Maes Upendra Shardanand. Social information filtering: algorithms for automating "word of mounth". Filtering, 1995.
- [62] Juan Alfonso Urtiaga. Reconocimiento facial. Reconocimiento, Sep. 2014.
- [63] Stathes Hadjiefthymiades Vassileios Tsetsos, Vassilis Papataxiarhis. Personalization based on semantic web. IGI Global, 2009.
- [64] Paul Viola and Michael Jones. Rapid object detection using a boosted cascade of simple features. In *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on*, volume 1, pages I–511. IEEE, 2001.
- [65] Paul Viola and Michael J Jones. Robust real-time face detection. *International journal of computer vision*, 57(2):137–154, 2004.