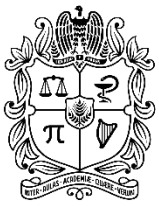

UNIVERSIDAD
NACIONAL
DE COLOMBIA

Modelo Genérico para la Recomendación Híbrida y Adaptativa de Recursos Educativos Digitales

Paula Andrea Rodríguez Marín

Universidad Nacional de Colombia

Departamento de Ciencias de la Computación y de la Decisión

Medellín, Colombia

2017

Modelo Genérico para la Recomendación Híbrida y Adaptativa de Recursos Educativos Digitales

Paula Andrea Rodríguez Marín

Tesis presentada como requisito parcial para optar al título de:

Doctorado en Ingeniería – Sistemas e Informática

Director:

PhD. Néstor Darío Duque Méndez

Codirector:

PhD. Demetrio Arturo Ovalle Carranza

Línea de Investigación:

Inteligencia Artificial

TIC en Educación y Sistemas Adaptativos

Grupos de Investigación:

GAIA – Grupo de Investigación en Ambientes Inteligentes Adaptativos

GIDIA - I+D en Inteligencia Artificial

Departamento de Ciencias de la Computación y de la Decisión

Medellín, Colombia

2017

Le dedico esta tesis a mi familia por todo su apoyo y ayuda durante este proceso, en especial a mi esposo Juan David, quién con su amor hizo este sueño posible.

Agradecimientos

Expreso mi total gratitud a mis directores Néstor Darío Duque y Demetrio Arturo Ovalle por sus contribuciones invaluables a esta tesis, además por su acompañamiento y apoyo. Agradezco también por su amistad y confianza, principalmente por su acompañamiento académico y personal para cumplir con el desarrollo de esta tesis.
A los profesores Ángela Carrilo, Silvana Aciar y Ricardo Silveira, por sus aportes, evaluaciones y contribuciones al trabajo.

También a los integrantes de los grupos de investigación GAIA, GIDIA, BCDS, GTIIA y Computação aplicada, por todos los aportes realizados y la compañía en el proceso de investigación. Su amistad fue muy importante para soportar los días difíciles.

A mi familia, mi mamá Luz Day, mi abuelita Gabriela, mi tío Carlos y mis hermanitas (Eliana y Tatiana), por su comprensión, paciencia y amor, no estuve presente físicamente mucho tiempo, pero siempre estuve de corazón. A mi soporte en el camino, mi esposo Juan David, que siempre está conmigo, me apoya, me incentiva y cree en mí.

También quiero agradecer especialmente a mis amigas Valentina Tabares y Emilcy Juliana Hernández, por su amistad, apoyo, sustento y ayuda prestada en todos estos años, su presencia fue muy especial e importante.

Esta investigación fue apoyada por la Vicerrectoría Académica, el Sistema de Investigación de la Universidad Nacional de Colombia y el Departamento Administrativo de Ciencia, Tecnología e Innovación – Colciencias, en el "Programa Nacional de Formación de Investigadores", convocatoria No. 617.

Resumen

El proceso autónomo de aprendizaje en entornos virtuales requiere la recomendación de recursos educativos digitales, ya que cuando los estudiantes entran a buscar un recurso es difícil encontrar los materiales adecuados y acordes a sus necesidades y para apoyar su proceso de aprendizaje. En esta tesis se propone un modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales, que ayude a los estudiantes en las dificultades a las que se enfrentan para acceder a materiales relevantes para su aprendizaje. En el modelo se adaptan las técnicas, enfoques y algoritmos a la información disponible de ítems y de usuarios. Asimismo, se proponen dos estrategias de aplicación y uso, la primera plantea una metodología para la selección guiada de componentes de recomendación y la segunda integra todas las características de usuarios y de ítems en factorización de matrices para entregar resultados relevantes; aprovechando los datos disponibles desde diferentes fuentes. La validación se hace para ambas estrategias y los resultados son promisorios en cuanto a la relevancia de los materiales encontrados, según el perfil del estudiante. Adicionalmente, se plantea un sistema de recomendación que persuade al usuario a utilizar los materiales recomendados para él, según un enfoque híbrido a través de la argumentación. Finalmente, el modelo propuesto puede ser aplicado a diferentes contextos educacionales, con distintos perfiles de usuario y con recursos heterogéneos.

Palabras clave: informática en la educación, recursos educativos digitales, sistemas de recomendación, sistemas híbridos.

Abstract

The autonomous process on virtual environments learning requires the recommendation of digital educational resources because when students enter to find a resource it is difficult to find the materials they really need and they will support their learning process. This thesis proposes a generic model for the hybrid and adaptive recommendation of digital educational resources, which helps students in the difficulties they face to access materials relevant to their learning. In the model, techniques, approaches, and algorithms are adapted to the available information of items and users. Likewise, two application and use strategies are proposed, the first one proposes a methodology for the guided selection of recommendation components and the second one integrates all the characteristics of users and items in matrix factorization to deliver relevant results. Validation is done in both strategies and the results are promising because they help students find materials relevant to their learning process. In addition, a recommendation system is proposed that persuades the user to use the recommended materials for him, according to a hybrid approach through argumentation. Finally, a hybrid recommendation approach is proposed, estimating the parameters of the existing relationships between the characteristics of the users and the items. The model can be applied to different educational contexts, with different user profiles, and with heterogeneous resources.

Keywords: computer science in education, digital educational resources, hybrid systems, recommendation systems.

Contenido

Resumen ..... **IX**

Lista de figuras ..... **XIV**

Lista de tablas ..... **XV**

Lista de Símbolos y abreviaturas ..... **XVI**

Introducción **1**

1. Metodología ..... ¡Error! Marcador no definido.
1.1 Hipótesis 5
1.2 Objetivos 5
1.2.1 Objetivo general 5
1.2.2 Objetivos Específicos 5
1.3 Metodología utilizada y cumplimiento de objetivos 6

2. Marco teórico **7**
2.1 Sistemas de recomendación 7
2.1.1 SR Colaborativos 9
2.1.2 SR Basado en Contenido 10
2.1.3 SR Basados en el Conocimiento 10
2.1.4 SR basado en utilidad 11
2.1.5 SR Demográfico 11
2.2 Enfoques Híbridos de Recomendación 12
2.3 Sistemas de argumentación 14
2.3.1 Sistemas de recomendación con argumentación 14
2.3.2 Sistemas de recomendación conversacional 15
2.4 Recursos Educativos Digitales RED 16
2.4.1 Características de los RED 16
2.4.2 Estrategia Ministerio de Educación Nacional Colombia 17
2.4.3 Repositorios y Federaciones de RED 19
2.5 Perfiles de usuario 19
2.6 Sistemas adaptativos 20
2.7 Algoritmos computacionales 21
2.8 Modelos genéricos 24
2.9 Conclusiones del capítulo 24
2.10 Aportes 25

3. Trabajos relacionados **27**

3.1 Revisión de literatura 27
3.2 Resultados encontrados 29
3.3 Conclusiones del capítulo 33
3.4 Aportes 35

4. Modelo propuesto 37
4.1 Perspectiva del modelo propuesto 37
4.2 Modelo Genérico 40
4.2.1 Componente 1: entradas 41
4.2.2 Componente 2: proceso de recomendación 42
4.2.3 Componente 3: salidas 43
4.3 Estrategias de aplicación del modelo propuesto 43
4.3.1 Estrategia de selección 43
4.3.2 Estrategia de integración 46
4.4 Conclusiones del capítulo 48
4.5 Aportes 49

5. Validaciones 51
5.1 Métricas de validación utilizadas 51
5.1.1 Medidas de relevancia 51
5.1.2 Medidas de predicción 52
5.2 Validación estrategia de selección 53
5.2.1 Caso de estudio 1 53
5.2.2 Caso de estudio 2 58
5.2.3 Caso de estudio 3 63
5.3 Validación estrategia de integración 70
5.3.1 Modelo propuesto y modelos de comparación 74
5.3.2 Experimentación y validaciones 75
5.4 Conclusiones del capítulo 80
5.5 Aportes 81

6. Consideraciones finales 83
6.1 Conclusiones 83
6.2 Trabajo futuro 85
6.3 Cumplimiento de objetivos y contribuciones principales logradas 86
6.4 Discusión Académica 87

Bibliografía XCIII

Anexo A: Métodos de Factorización de Matrices para Sistemas de Recomendación CV

Anexo B: Sistemas de recomendación utilizando factorización de matrices, información de usuarios e ítems CVII

Anexo C: Comparación de los trabajos relacionados, respecto al modelo propuesto CX

Anexo D: Guía para la implementación de una plataforma que permita el uso del modelo genérico propuesto CXIII

Lista de figuras

Figura 2.1 Componentes de los sistemas de recomendación....8
Figura 2.2 Clasificación de los RED desde lo educativo.....18
Figura 3.1 Estrategia de revisión de la literatura.....28
Figura 4.1 Componentes de un sistema de recomendación en la educación 38
Figura 4.2 Modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales.....41
Figura 4.3 Estrategia de selección 44
Figura 4.4 Estrategia de integración.....46
Figura 5.1 Caso de estudio 1 53
Figura 5.2 Recomendación utilizando RBC 54
Figura 5.3 Interfaz de entrega de los recursos 57
Figura 5.4 Características y técnicas seleccionadas 58
Figura 5.5 Promedio de calificaciones sin y con explicaciones.....68
Figura 5.6 Promedio de calificaciones para cada prioridad de explicaciones 68
Figura 5.7 Cambio en las calificaciones desde la primera iteración hasta el final de la conversación.....69
Figura 5.8 Aceptación de la recomendación.....69
Figura 5.9 Promedio de estudiantes que cambiaron sus preferencias iniciales 69
Figura 5.10 Modelo del estudiante RAIM.....71
Figura 5.11 Interfaz de calificación de los RED 72
Figura 5.12 MAE para el experimento 1 77
Figura 5.13 MAE para el experimento 2 78

Lista de tablas

Tabla 3-1: componentes y palabras clave. 28
Tabla 4-1 Características de los SR (Aggarwal, 2016) 39
Tabla 5-1 Fragmento de la base de casos. 56
Tabla 5-2 Similitud de casos con el caso problema 57
Tabla 5-3 Reglas de argumentación definidas 60
Tabla 5-4 Esquema de explicaciones 61
Tabla 5-5 Resultados Top 5 61
Tabla 5-6 Resultados Top 10 62
Tabla 5-7 Resultados enfoques híbridos top 5 62
Tabla 5-8 Resultados enfoques híbridos top 10 63
Tabla 5-9 Reglas, explicaciones y respuestas del sistema conversacional 64
Tabla 5-10 Modelos de recomendación basados en factorización de matrices 75
Tabla 5-11 Pesos de ponderación de las calificaciones 77
Tabla 5-12 Resultados de la prueba t-Student 79

Lista de Símbolos y abreviaturas

Abreviaturas

Abreviatura	Término
DRAE	Diccionario real academia de la lengua española
FROAC	Federación de Repositorios de Objetos de Aprendizaje Colombia
IEEE	Institute of Electrical and Electronics Engineers
MAE	Mean Absolute Error
MEN	Ministerio de Educación Nacional Colombia
PCC	Coeficiente de Correlación de Pearson
RAIM	Proyecto: tecnologías para entonos educativos
RBC	Razonamiento Basado en Casos
RED	Recursos Educativos Digitales
ROAp	Aplicación de repositorios de objetos de aprendizaje
SR	Sistemas de Recomendación
ToS	Tree of Science

Símbolos con letras griegas

Símbolo	Término
Θ	Características de ítems
X	Características de los usuarios i
Y	Calificaciones del usuario al ítem
Σ	Relación entre características de usuarios y de ítems

Introducción

Actualmente, debido a que la computación de alta velocidad y a las redes ubicuas, la cantidad de información que se tiene disponible a través de la Web aumenta drásticamente cada día (Drachsler, Hummel & Koper, 2009). Dado que este crecimiento es más rápido que la capacidad de las personas para hacer frente a él, surge la importancia de apoyar a los usuarios a seleccionar información relevante (Klašnja-Milićević, Vesin, Ivanović, Budimac & Jain, 2016). Específicamente, en el área de recursos educativos, el crecimiento de materiales disponibles es semejante (Fraihat & Shambour, 2015); esto genera dificultad para que los estudiantes puedan encontrar aquellos recursos que sean acordes con su manera de aprender y que apoyen su proceso de aprendizaje, cumpliendo con los objetivos trazados por el material dentro de un ambiente virtual (Fraihat & Shambour, 2015).

Un Recurso Educativo Digital (RED) puede ser definido como todo tipo de material que tiene una intencionalidad y una finalidad educativa, cuya información es digital y están disponibles en la red (Campo Saavedra, Martínez Barrios, Ruíz Rodgers & Rendón Osorio, 2012; MEN, 2013; UNESCO, 2015). Una característica importante de algunos de los RED son sus metadatos descriptivos que incluyen la información que caracteriza el contenido de los recursos, por ejemplo su título, palabras claves, información de su uso educacional, entre otros (N. D. Duque, Ovalle & Moreno, 2015; N. Duque, Ovalle & Moreno, 2014). Estos metadatos permiten y facilitan su identificación, búsqueda, recuperación y reutilización. Los metadatos se almacenan de manera estructurada utilizando estándares que especifican la semántica y la sintaxis de cada atributo necesario para realizar la descripción de los RED; entre los estándares más utilizados se encuentra LOM (IEEE-LTSC, 2002), Dublin Core (DCMI, 2004) y OBAA (Vicari et al., 2009). A su vez, los RED y sus respectivos metadatos están almacenados en repositorios que permiten su organización y centralización con el fin de tenerlos disponibles y visibles para que los estudiantes descubran materiales adecuados a sus búsquedas (Tabares, Duque, Rodríguez, Moreno & Ovalle, 2015).

Realizar búsquedas refinadas es difícil, incluso para estudiantes avanzados, debido a la definición de los criterios y selección de la cadena de consulta; en un estudio realizado en 2009 con profesores universitarios se concluyó que este proceso de búsqueda es costoso en tiempo, ya que es necesario invertir más de una hora para encontrar un recurso adecuado, lo cual es frustrante para el estudiante (Kay, Knaack & Petrarca, 2009). Para enfrentar este problema los repositorios están implementado diferentes medidas para mejorar los procesos de búsqueda, algunos con el uso de métricas de ranking, otros a través de mecanismos de control de calidad, y finalmente con el desarrollo de sistemas de recomendación educativos (Gordillo, Barra & Quemada, 2017).

Los sistemas de recomendación (SR) son herramientas que ofrecen sugerencias para un usuario, realizando predicciones, por ejemplo, de su nivel de satisfacción con un recurso dado. Estos sistemas se basan en preferencias, gustos, estados de ánimo, estilos de aprendizaje y todas aquellas variables que permitan caracterizar al usuario y que influyan en el proceso de recuperación. Los SR, en entornos virtuales de aprendizaje, tienen como principal objetivo entregar a estudiantes resultados de búsqueda que apoyen su proceso de aprendizaje autónomo (Campo Saavedra et al., 2012; Santos, Boticario & Pérez-Marín, 2014; Tovar, Bohórquez & Puello, 2014). Los SR deben permitir realizar procesos de realimentación e implementar mecanismos que les permitan obtener una gran cantidad de información sobre los usuarios. Los SR se pueden clasificar en varios tipos (Burke, 2002): SR basado en contenido, tiene en cuenta los recursos que el estudiante ha evaluado en el pasado; SR basado en filtrado colaborativo, busca usuarios similares para hacer la recomendación, utilizando las evaluaciones previas; SR basado en conocimiento, tiene en cuenta el conocimiento sobre los usuarios y de los ítems para hacer una relación a través de reglas de correlación; SR basado en utilidad, tiene en cuenta un peso de utilidad de cada característica para el usuario y finalmente; el SR demográfico, que es similar al basado en filtrado colaborativo, pero éste utiliza información demográfica para encontrar los usuarios similares.

Adicionalmente se encuentran, los sistemas de recomendación híbrida de materiales educativos, que son aquellos que combinan varias técnicas de SR con el objetivo de maximizar los resultados, aprovechando las ventajas de cada una y disminuir sus problemas. Los SR híbridos se han venido abriendo paso para apoyar procesos de aprendizaje y ayudar a los estudiantes a encontrar materiales relevantes, los cuales son

aquellos recursos que se adaptan a sus necesidades y preferencias (Baeza-Yates & Ribeiro-Neto, 2011; Burke, 2002; Drachsler et al., 2009; Salehi, Pourzaferani & Razavi, 2013a; Zapata, Menendez, Prieto & Romero, 2011).

Aunque, en la actualidad, existen varios SR que entregan RED a estudiantes, se aprecia que hay dificultades en el momento de definir los componentes de un SR para ser aplicado en caso de tener situaciones diversas, debido que el rendimiento de los sistemas de recomendación, depende de las particularidades del contexto de aplicación y la disponibilidad de información tanto de ítems como de usuarios (Ricci, Rokach, Shapira & Kantor, 2011). Una de las soluciones es plantear un sistema que permita beneficiar las diferentes posibilidades según cada caso, reconociendo las características disponibles: un modelo genérico, híbrido y adaptativo, donde se aproveche i) La diversa información disponible de características del estudiante, utilizando las variables significativas del perfil, al igual que datos relacionados con los ítems a recomendar; ii) Las ventajas y posibilidades de una o varias técnicas de recomendación, realizando una selección ajustada a las necesidades y disponibilidad de requisitos, en este mismo sentido y dado que no existe un enfoque universal que indique cómo integrar estas técnicas (recomendación híbrida), adoptar aquella que ofrezca entregar resultados relevantes y así mejorar las predicciones; iii) Potencializar el uso de algoritmos computacionales, para mejorar el desempeño de los sistemas, dentro de los cuales se pueden encontrar las técnicas de inteligencia artificial y técnicas de aprendizaje de máquina, entre otras.

El objetivo general de esta tesis es proponer, diseñar y validar un modelo genérico para recomendación híbrida y adaptativa de recursos educativos digitales basado en las características del estudiante. Para dar cumplimiento a este objetivo, primero se caracterizaron los elementos que componen el modelo, al igual que los diferentes enfoques, técnicas y algoritmos existentes que se han utilizado para modelar sistemas de recomendación. Después, con la información recolectada y la experiencia en SR, se propuso el modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales que integra los diferentes elementos y técnicas; y finalmente, se valida el modelo propuesto a través del desarrollo de un prototipo aplicado a varios casos de estudio donde se evaluó su desempeño por medio de métricas

El modelo propuesto, tiene dos estrategias a ser utilizadas, la primera de ellas: estrategia de selección, donde, a través de una serie de pasos, se selecciona la información de usuarios e ítems a ser utilizada, las técnicas de recomendación y el enfoque híbrido a aplicar; por último, el algoritmo computacional para ejecutar las técnicas. La segunda es una estrategia de integración, donde el proceso de recomendación es transparente para el usuario del sistema y se toman en cuenta las características de los usuarios y de los ítems, para este caso los RED, como entrada matricial al sistema de recomendación; en esta estrategia, se integran los conceptos de técnica de recomendación, enfoque híbrido y algoritmo computación, combinándose para lograr la recomendación de ítems involucrando todos los aspectos disponibles mediante una operación matemática que entrega las similitudes de los diferentes datos que se proveen en las entradas. En ambas estrategias, el objetivo es entregar RED relevantes a las características y necesidades de los estudiantes.

En resumen, en esta tesis se plantea un modelo genérico de sistemas de recomendación educativo, híbrido y adaptativo, donde se puedan combinar las características de los estudiantes, de ítems y de las interacciones de los usuarios con los RED, utilizando la mayor cantidad de factores posibles, bajo la hipótesis de que, a mayor información, mejores resultados. Igualmente, hacer una integración de varias técnicas de recomendación, potencializando sus ventajas y ayudando a minimizar sus debilidades, y finalmente utilizando algoritmos computacionales que ayuden a resolver el problema. Se implementaron tres casos de estudio en la estrategia de selección y dos en la de integración, todas fueron validadas con estudiantes reales, utilizando los RED disponibles en la Federación de Repositorios de Objetos de Aprendizaje Colombia.

Esta tesis está organizada como sigue: los preliminares de presente trabajo y los conceptos relacionados se encuentran en la sección 1 y hacen parte del cumplimiento del objetivo 1; en la sección 2 se presentan los principales trabajos relacionados con el modelo genérico para la construcción de SR híbridos, cumpliendo así el objetivo específico 2. En la sección 3, se presenta el modelo genérico propuesto y se explica cada uno de sus componentes y las dos estrategias de aplicación, esta sección se refiere al cumplimiento del objetivo 3. En la sección 4 se muestra la validación y pruebas realizadas al modelo propuesto por medio de las dos estrategias, dando cumplimiento al objetivo 4. Finalmente, en la sección 5 se presentan las conclusiones y el trabajo futuro.

1. Preliminares

Este capítulo tiene como objetivo presentar la tesis mostrando el marco del trabajo. Igualmente, presenta los objetivos planteados y la metodología utilizada en el cumplimiento de los mismos.

1.1 Hipótesis

Los sistemas de recomendación de recursos educativos digitales son herramientas idóneas para apoyar el proceso de aprendizaje autónomo en ambientes virtuales, y que el desempeño de dichos sistemas puede ser significativamente mejorado cuando se hace una adecuada integración de diferentes enfoques, técnicas y algoritmos.

Por tanto, el diseño de un modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales basado en un modelo de estudiante que apoye eficazmente el proceso de aprendizaje puede representar un aporte significativo en el área de informática en la educación y ser una alternativa a los SR convencionales. Mejorando la recuperación de recursos para un estudiante a partir de su perfil de usuario.

1.2 Objetivos

1.2.1 Objetivo general

Proponer, diseñar y validar un modelo genérico para recomendación híbrida y adaptativa de recursos educativos digitales basado en las características del estudiante.

1.2.2 Objetivos Específicos

1. Caracterizar los elementos que componen un modelo de recomendación de recursos educativos digitales.

2. Caracterizar diferentes enfoques, técnicas y algoritmos existentes para modelar sistemas de recomendación
3. Proponer un modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales que integre los diferentes elementos y técnicas.
4. Validar el modelo propuesto a través del desarrollo de un prototipo aplicado a varios casos de estudio y evaluar su desempeño a través de métricas.

1.3 Metodología utilizada y cumplimiento de objetivos

Para dar cumplimiento a la consecución de cada uno de los objetivos específicos, se dividen las tareas en seis etapas. A continuación, se describen las etapas:

Etapa 1: Elaboración del marco teórico y revisión del estado del arte.

Etapa 2: Conceptualización del proceso de recomendación.

Etapa 3: Análisis y comparación de las técnicas utilizadas en el proceso de recomendación.

Etapa 4: Definición del modelo genérico híbrido y adaptativo para realizar recomendaciones de recursos educativos digitales.

Etapa 5: Implementación de un prototipo que valide el modelo propuesto, aplicado a varios casos de estudio y análisis de su desempeño.

Etapa 6: Difusión de los resultados obtenidos en los diferentes medios de divulgación científica.

2. Marco teórico

En este capítulo se presentan los conceptos relacionados con la investigación realizada, donde se caracterizan los elementos que componen un modelo de recomendación de recursos educativos digitales. Se exponen conceptos de sistemas de recomendación (SR) híbrido y adaptativo, los perfiles de usuario, en particular el usuario estudiante; recursos educativos digitales y los modelos genéricos. Además, se exploraron algunos algoritmos computacionales para el desarrollo de SR.

2.1 Sistemas de recomendación

Los Sistemas de Recomendación (SR) pueden definirse como una plataforma o una herramienta de software para proporcionar recomendaciones o sugerencias a los usuarios basándose en sus gustos y disgustos (Klašnja-Milićević et al., 2016; Ricci et al., 2011). Burke, agrega que los SR son agentes de información que ofrecen sugerencias de ítems que pueden ser de utilidad para un usuario específico (Burke, 2007). La idea básica de los SR es utilizar diversas fuentes de datos para inferir los intereses de las personas. La entidad a la cual se le entrega la recomendación se conoce como usuario, y el producto que se recomienda también se conoce como ítem (Aggarwal, 2016). Los SR surgieron a mediados de la década de los 90 (Li, 2010) con el fin de brindarle a los usuarios aquellos resultados de búsquedas de información cercanos a sus necesidades (Casali, Gerling, Deco & Bender, 2011). Un SR se compone entonces, de la información de los ítems a ser recomendados, la información de los usuarios que reciben la recomendación y las técnicas que permiten unir estas dos informaciones (Cazella, Reategui & Nunes, 2010), en la figura 2.1 se presentan los componentes de un SR y su relación para entregar una lista ordenada de recomendaciones, a menudo, la entrada al sistema de recomendación se basa en la interacción previa entre los usuarios y los ítems, ya que los intereses y las actividades pasadas, son buenos indicadores de las opciones futuras (Aggarwal, 2016).

Figura 2.1 Componentes de los sistemas de recomendación

Fuente: propia, adaptada de la literatura (Aggarwal, 2016)

Los objetivos operacionales y técnicos comunes de los SR son los siguientes (Aggarwal, 2016):

- Relevancia: recomendar elementos que sean relevantes para el usuario, es decir aquellos que son interesantes o representen importancia para sus preferencias.
- Novedad: entregar ítems que el usuario no ha visto en el pasado, la recomendación repetida de ítems puede causar que el usuario abandone el sistema.
- Serendipia: los ítems recomendados son algo inesperados o distintos a lo que se estaba buscando.
- Aumento de la diversidad de recomendaciones: entregar una lista de recomendaciones con ítems de diferentes tipos. La diversidad tiene el beneficio de asegurar que el usuario no se aburra con la recomendación repetida de artículos similares.

Los sistemas de recomendación pueden funcionar con dos tipos de datos, primero las informaciones disponibles de los ítems y de los usuarios, siendo estos llamados SR basados en el conocimiento del dominio y se establecen por los requisitos de usuario. Y segundo, las interacciones que el usuario hace a los ítems, tales como evaluaciones y retroalimentaciones, en este caso se enmarcan los SR basados en contenido y en filtrado colaborativo; la diferencia entre estos SR es que el basado en contenido se centra en las calificaciones de un solo usuario y el SR basado en filtrado colaborativo utiliza las calificaciones de todos los usuarios. En algunos casos se pueden combinar diferentes

aspectos y crear sistemas híbridos, donde se mezclan los puntos fuertes de las diferentes técnicas de recomendación y así ejecutar de forma más robusta las recomendaciones.
De acuerdo con Burke 2007, los SR pueden ser divididos en cuatro clasificaciones (Aggarwal, 2016); sin embargo en este documento se separa el SR basado en utilidad del SR basado en contenido. A continuación, se explica cada una de ellas y se especifican sus problemas relacionados.

2.1.1 SR Colaborativos

Los SR basados en filtrado colaborativo, recomiendan al usuario activo los elementos que otros usuarios con gustos similares gustaban en el pasado (Ricci et al., 2011), se utilizan medidas de similitud basadas en las calificaciones proporcionadas por los usuarios para hacer dichas recomendaciones. El filtrado colaborativo es considerado como la técnica más popular y ampliamente implementada. Hay dos tipos de métodos que se utilizan comúnmente en el filtrado colaborativo, se denominan algoritmos basados en memoria y basados en modelos. Los basados en memoria utilizan valoraciones que otros usuarios han dado a un ítem, para calcular la posible valoración para el usuario actual y los basados en modelos hacen uso del modelo del usuario para construir un perfil o modelo, a partir del cual se realizan las recomendaciones (Betancur, Moreno & Ovalle, 2009; T. I. Wang, Tsai, Lee & Chiu, 2007).
Los SR basados en filtrado colaborativo presentan ventajas como, por ejemplo, un usuario puede recibir recomendaciones de ítems que no estaban siendo buscados de forma activa, recomendaciones inesperadas; otra contribución de estos SR es la posibilidad de crear comunidades de usuarios identificando sus gustos e intereses similares. Entre sus limitaciones se encuentran (Aggarwal, 2016):
Cold-start, problema del primer evaluador, cuando un nuevo ítem es agregado a la base de ítems no existe manera de recomendarlo por este sistema (Cazella et al., 2010), así mismo cuando se tiene un nuevo usuario que no ha realizado evaluaciones, se dificulta encontrar usuarios similares.
Sparsity, o problema de evaluaciones dispersas, cuando el número de usuarios es pequeño en relación a la cantidad de ítems disponible, existe el riesgo que las puntuaciones sean dispersas y esto dificulte encontrar recomendaciones.
Escalabilidad, dependiendo de la cantidad de usuarios registrados en el sistema se hace difícil encontrar similitudes, teniendo en cuenta la cantidad de ítems evaluados.

Oveja gris, se presenta cuando un usuario tiene gustos muy diferentes a los otros usuarios, se dificulta encontrar similitudes y por lo tanto sus recomendaciones son pequeñas o nulas.

2.1.2 SR Basado en Contenido

En sistemas de recomendación basados en contenido, se tiene en cuenta el histórico de evaluaciones del usuario a los ítems y también el contenido de los ítems. Con el historial se pueden obtener las preferencias e intereses del usuario y con ello obtener la información necesaria para generar recomendaciones de ítems que le gustaron en el pasado. El término "contenido" se refiere a las descripciones de los ítems para buscar similitudes entre ellos. En los métodos basados en contenido, las calificaciones de los usuarios se combinan con la información de contenido disponible en los ítems. Sugiere ítems basado en las inferencias acerca de las necesidades y preferencias del usuario según su historial de navegación (Burke, 2002).

Aunque este SR tiene ventajas al necesitar solo las evaluaciones previas realizadas por el usuario activo, surgen problemas cuando el usuario no ha realizado ninguna interacción con el sistema (nuevo usuario) y no se tienen evaluaciones anteriores para buscar ítems similares. Su otro problema es la capacidad de sorprender al usuario ya que él siempre tendrá recursos similares a los que ya le gustaron en el pasado y finalmente el análisis de las características que describen los ítems para encontrar similitudes.

2.1.3 SR Basados en el Conocimiento

Los sistemas de recomendación basados en el conocimiento son muy útiles cuando no se tienen calificaciones suficientes por parte del usuario para el proceso de recomendación, pero si se cuenta con un perfil que lo caracteriza. El proceso de recomendación se hace entre la similitud de los requisitos del usuario y las descripciones de los ítems, a través de bases de conocimiento que especifican las funciones de similitud usuario – ítem. Este tipo de recomendación aprende de los intereses de los usuarios y hace el proceso de recomendación sobre la base de las características presentes en los ítems (Burke, 2002). Su principal ventaja, a comparación de las otras técnicas utilizadas, es que en los otros casos los intereses y preferencias del usuario se capturan a través de las calificaciones, en esta técnica se capturan explícitamente creando un perfil de usuarios con sus características, gustos, necesidades y preferencias, además se puede complementar

dicho perfil implícitamente con el seguimiento a sus interacciones. Entre sus principales problemas se encuentra el arranque en frío cuando el usuario no ha ingresado su perfil o no ha interactuado con el sistema, así mismo, el nuevo usuario al que no se le conocen sus preferencias; por otro lado se tiene el problema de la sinonimia, es decir, que el resultado de la recomendación pueden ser ítems parecidos entre ellos y finalmente hay problemas al analizar ítems con datos poco estructurados como videos y sonidos (Cazella et al., 2010).

2.1.4 SR basado en utilidad

En estos sistemas se define una función de utilidad según las características de los ítems con el objetivo de conocer la probabilidad de que ese ítem le guste al usuario activo. Su principal desafío es encontrar la función de utilidad que sea apropiada para el usuario y así encontrar los ítems que mejor se adecuen a los intereses del usuario. Entre sus principales problemas se encuentra la captura de la importancia de cada característica de los ítems para el usuario y además definir la función de utilidad, en varios estudios se utiliza una combinación lineal o una función de probabilidad (Aggarwal, 2016).

2.1.5 SR Demográfico

Este tipo de sistemas aprovecha la información demográfica de los usuarios para hacer clasificaciones por características demográficas, en este tipo de sistemas, la similitud entre usuarios se calcula teniendo en cuenta estas características y así entregar recomendaciones. La información demográfica puede ser considerada como parte del contexto del usuario, en algunos casos se utiliza la ubicación geográfica para hacer recomendaciones a través del uso de reglas, en otros se aplican técnicas de filtrado colaborativo sobre grupos de usuarios delimitados demográficamente (Aggarwal, 2016).
El primer problema con estos SR es la captura de la información demográfica sin caer en discriminaciones y el segundo es la cantidad de usuarios registrados con la información completa en el sistema suele ser muy baja y esto dificulta encontrar usuarios similares a las características demográficas.

2.2 Enfoques Híbridos de Recomendación

Los SR híbridos tienen como principal objetivo combinar diferentes técnicas de recomendación para obtener un mejor desempeño, fortaleciendo sus ventajas y reduciendo los problemas comunes cuando se utiliza una sola técnica y así entregar recomendaciones mejor adaptadas al perfil (Cazella et al., 2010). Existen dos enfoques híbridos, el primero se trata de aquellos que trabajan de manera paralela, es decir, son aquellos donde se ejecutan las diferentes técnicas independientemente y al final se combinan los resultados. Y el segundo, se refiere al enfoque secuencial, donde la salida de una técnica de recomendación, es la entrada para otra y se van refinando los resultados.

Para realizar la combinación de técnicas se deben aplicar al menos dos de ellas. Burke (2002) propone diferentes métodos para la combinación, que se explican a continuación:

- Ponderado: para cada técnica de recomendación se le da un puntaje y a través de un consenso se acuerdan los resultados. Donde se combinan las puntuaciones o votos para producir una única recomendación. Esta combinación puede ser aplicada utilizando una función que pondera la importancia de cada uno de los SR. El problema de este método es que el valor relativo a las diferentes técnicas es uniforme, esto no siempre es verdadero porque depende de la cantidad de información (evaluaciones, usuarios similares, entre otros) con la que se cuenta. La ponderación también puede ser definida en función a una realimentación (puntuación) que dan los usuarios a las recomendaciones y/o a las técnicas.
- Conmutación: el sistema conmuta entre las técnicas de recomendación en función de la situación actual según algún criterio de conmutación, analizando los resultados obtenidos en evidencia pasada. Se aplica una de las técnicas, si esta no entrega resultados, se prosigue a aplicar la siguiente técnica. La desventaja de este método es que, si al aplicar la primera técnica si se encuentran resultados, las otras técnicas no se ejecutarán y es posible que se queden sin mostrar algunos resultados relevantes para el usuario.
- Mixto: se presentan las recomendaciones de diferentes sistemas de recomendación al mismo tiempo. Se ejecutan todas las técnicas de recomendación disponibles y se presentan todos los resultados, su principal ventaja es que puede mostrar nuevos elementos. Su principal desventaja es que se pueden mostrar

resultados que no son tan importantes para el usuario, además la cantidad de resultados puede ser inmanejable.

- Cascada: es un proceso por etapas en la cual, una técnica de recomendación se utiliza por primera vez para producir una clasificación gruesa de los ítems candidatos y una segunda técnica refina la recomendación de entre el conjunto de candidatos. Cada una de las recomendaciones refina las recomendaciones dadas por los otros. Tiene problemas cuando al terminar de ejecutar las técnicas no se entrega ningún resultado.
- Combinación de características: se toman las características, de diferentes fuentes de datos, de una técnica de recomendación se procesan y esas características son la entrada a la otra técnica, este método reduce la sensibilidad del sistema al número de usuarios que han valorado un ítem. En este método se combinan las características de los datos en bruto de diferentes fuentes.
- Función de aumento: una característica de salida de una técnica, se usa como una característica de entrada a otra, es decir se utiliza un modelo para generar rasgos para la entrada de un segundo algoritmo.
- Meta-nivel: el modelo aprendido por un SR se utiliza como entrada a otro, es decir todo el modelo es la entrada para la segunda técnica. Por ejemplo, se hace una primera recomendación sobre la base de interés para la comunidad en conjunto y luego se distribuye a los usuarios particulares. Estos modelos, esencialmente manejan vectores de términos y pesos que pueden ser comparados a través de los usuarios para hacer las predicciones.
- Intersección de resultados: a pesar que no está en la revisión bibliográfica como una técnica de combinación, desde el punto de vista de la teoría de conjuntos es posible utilizar la operación intersección que permite obtener los elementos comunes resultados de la aplicación de las técnicas de recomendación. Su principal ventaja es que los resultados entregados son los elementos comunes al aplicar los diferentes SR, además se pueden entregar resultados intermedios, intersecciones de solo dos SR, cuando se están combinando tres o más técnicas.

Los sistemas de recomendación con enfoques híbridos tienen muchas ventajas, ya que, al realizar combinaciones de técnicas de recomendación, se puede llegar a minimizar los problemas que se presentan y entregar mejores resultados, es decir, resultados de calidad. Sin embargo, hay dificultades en su implementación, debido a la definición del modelo de

adaptación que permita la selección de información relevante y los mecanismos para realizar las combinaciones pertinentes con las técnicas a aplicar (Aggarwal, 2016; Ricci et al., 2011)

2.3 Sistemas de argumentación

Los sistemas de argumentación o marcos de argumentación, ofrecen razonamientos por medio de los cuales se puede probar o refutar una proposición. Se han utilizado para realizar justificaciones de las acciones tomadas por un sistema (Briguez et al., 2014a). En muchos casos los sistemas de argumentación tienen dos objetivos, el primero de ellos es entregar explicaciones acerca del funcionamiento interno y el segundo es persuadir al usuario de utilizar o adquirir un bien o servicio que se ofrece (Cleger-tamayo, Picanço-bastos & Figueiras-de-farias, 2017). Los argumentos son entregados para justificar su idoneidad. Así los sistemas de argumentación pueden ser utilizados para apoyar las metas de los sistemas de recomendación. A continuación, se explican dos clases de sistemas de argumentación que pueden ser utilizadas para explicar y persuadir a los usuarios para que acepten las recomendaciones entregadas.

2.3.1 Sistemas de recomendación con argumentación

Utilizar sistemas de argumentación en la entrega de recomendaciones, tiene como ventaja que es una forma directa de generar explicaciones textuales a partir de argumentos. Los argumentos pueden capturar inferencias comunes del razonamiento humano. Por lo tanto, aunque los argumentos son representaciones formales para la justificación de cada recomendación (como elementos de una teoría de argumentación), las explicaciones son representaciones textuales de estos argumentos (como elementos de la interfaz de usuario). Estas explicaciones se utilizan para convencer a los usuarios a aceptar las recomendaciones del sistema y hacer uso de los ítems recomendados.
La implementación de sistemas de argumentación genera ciertas ventajas en el proceso de interacción de los usuarios como las siguientes (Cleger-tamayo et al., 2017):

- Transparencia: al generar una argumentación o explicar los motivos por los cuales se está entregando un ítem específico, genera un estado de transparencia entre la interacción del usuario con el sistema. Esta cualidad es fundamental puesto que incentiva al usuario a un posterior uso.

- Validez: las técnicas de argumentación justifican una entrega determinada. En este caso justifica por qué fue entregado y recomendado un ítem específico. Pero esta justificación no solo se trata de una interacción semántica, pues previo a esto se desarrolla un proceso de validación donde se evalúa la semejanza o adaptabilidad de este ítem con el respectivo usuario. Con este proceso se está garantizando entonces que el sistema propuesto genere resultados válidos o pertinentes para el usuario.
- Confianza: al tener en cuenta las preferencias, gustos y tendencias de los usuarios, genera un estado de confianza en él, pues los resultados obtenidos están adaptados a sus preferencias y necesidades.
- Persuasión: las argumentaciones en lenguaje natural ayudan a incentivar y persuadir al usuario en el uso de ítems entregados.
- Eficacia y eficiencia: el objetivo principal de un sistema de recomendación es entregar y sugerir un ítem o resultado específico, además debe hacerlo optimizando los recursos del sistema.
- Satisfacción: cuando al usuario se le entregan ítems que se adaptan a sus preferencias, se aumenta el grado de satisfacción de los usuarios y la posibilidad de que utilicen el sistema de nuevo.

2.3.2 Sistemas de recomendación conversacional

En los últimos años surgió un nuevo enfoque que apoya las recomendaciones y son aquellos basados en conversaciones, diálogos o críticas entre el usuario y el sistema. Los sistemas de recomendación conversacionales son particularmente efectivos para la obtención de preferencias mediante la formulación de preguntas – respuestas y la crítica de recomendaciones (Briguez et al., 2014a; Chesñevar, Maguitman & González, 2009a). Estos sistemas se basan en la argumentación obtenida después de realizar el proceso de recomendación, después, establecen una negociación con el usuario preguntando si están de acuerdo con los ítems obtenidos o si deberían cambiar las recomendaciones y finalmente, con la realimentación recibida por parte del usuario mediante esos diálogos, se actualiza el perfil y así se mejora el siguiente ciclo de recomendación a través de un proceso iterativo e incremental (Cleger-tamayo et al., 2017; Giustozzi, Casali, Deco, Dos Santos & Cechinel, 2016).

2.4 Recursos Educativos Digitales RED

Un RED puede definirse como cualquier tipo de recurso, incluyendo planes curriculares, materiales de los cursos, libros de texto, vídeo, aplicaciones multimedia, secuencias de audio y cualquier otro material que se haya diseñado para su uso en los procesos de enseñanza y aprendizaje; y que además, están plenamente disponibles en un medio digital para ser utilizados por parte de educadores y estudiantes (Butcher, COL & UNESCO, 2011; UNESCO, 2015). Los RED son todo tipo de material que tiene una intencionalidad y finalidad enmarcada en una acción educativa, cuya información es digital, y se dispone en una infraestructura de red pública, como internet para acceder a ellos (Campo Saavedra et al., 2012; MEN, 2013) .

Los RED surgen con gran potencial para apoyar la transformación educativa, principalmente en el aprendizaje basado en recursos, ya que se pueden transformar fácilmente y después de ser digitalizados se pueden compartir por medio de internet (UNESCO, 2015).

2.4.1 Características de los RED

Los RED deben estar codificados en un lenguaje binario, para facilitar los procesos de producción, almacenamiento, distribución, intercambio, adaptación, modificación y disposición del recurso en un entorno digital (Campo Saavedra et al., 2012). Además, los RED deben cumplir con ciertas características globales de orden técnico y funcional (Campo Saavedra et al., 2012):

- Accesible: garantiza que el RED pueda ser consultado y utilizado por el mayor número de personas, incluyendo las que se encuentran en situación de discapacidad.
- Adaptable: el RED debe permitir ser modificado, ajustado o personalizado, según los intereses, necesidades o expectativas del usuario.
- Durable: cualidad del RED que garantiza su vigencia y validez en el tiempo, esto se logra con el uso de estándares comunes y reconocidos.
- Flexible: el recurso debe responder e integrarse con facilidad en diferentes escenarios digitales para ser configurado por el usuario.

- Granular: cualidad del RED en directa relación entre su nivel de detalle, jerarquía o importancia y su capacidad de articulación y ensamble para construir componentes más complejos.
- Interoperable: capacidad del recurso para ser implementado en diversos entornos tales como ambientes, plataformas, canales y medios.
- Modular: capacidad del RED para interactuar o integrarse con otros recursos, para ampliar sus posibilidades de uso educativo.
- Portable: el recurso debe ser diseñado, construido y ensamblado para ser empleado en una o más plataformas, para ampliar sus posibilidades de almacenamiento y distribución.
- Usable: garantiza la correcta interacción del usuario, para entregar una experiencia cómoda, fácil y eficiente.
- Reusable: el recurso puede ser utilizado en diferentes contextos y con distintas finalidades educativas, permitiendo la adaptación o modificación de sus componentes.

2.4.2 Estrategia Ministerio de Educación Nacional Colombia

Según la estrategia presentada por el Ministerio de Educación Nacional Colombia, presentada en (MEN, 2013). Los RED pueden ser clasificados desde dos enfoques, el primero se refiere a la parte educativa y el segundo a los formatos de información digital (Campo Saavedra et al., 2012). Desde lo educativo se clasifican los recursos según las características comunes entre ellos, las cuales se definen por sus objetivos de aprendizaje, en la Figura 2.2 se presenta la clasificación inicial y no exhaustiva propuesta desde el sistema nacional de innovación educativa con uso de TIC en Colombia.

Figura 2.2 Clasificación de los RED desde lo educativo.

Fuente: Recursos Educativos Digitales Abiertos (Campo Saavedra et al., 2012).

- **Curso virtual:** se refiere a una experiencia educativa que se hace a través de la interacción con información y actividades con las cuales se pueden desarrollar capacidades y competencias, así mismo adquirir conocimientos para alcanzar los objetivos propuestos. La experiencia educativa se hace en un entorno tecnológico.
- **Aplicaciones para educación:** son programas de software diseñados para apoyar el desarrollo y cumplimiento de objetivos, procesos o actividades con fines educativos.
- **Objetos de aprendizaje:** son entidades digitales con propósitos educativos construido por contenidos y actividades. Según la IEEE, un OA puede considerarse como una entidad digital con características de diseño instruccional, que puede ser usado, reutilizado o referenciado durante el aprendizaje soportado en computador; con el objetivo de generar conocimientos, habilidades, actitudes y competencias en función de las necesidades del alumno (Learning Technology Standards Committee, 2002) .

Desde los formatos de información digital los RED se clasifican en (Campo Saavedra et al., 2012):

- **Textuales**: información representada en un sistema de caracteres.
- **Sonoros:** elementos o secuencias de información acústica, cuya vibración se percibe por el oído.

- **Visuales**: elementos tales como imágenes, fotografías, gráficas, y pueden ser captadas mayormente por la vista.
- **Audiovisuales**: elementos que integran lo sonoro, lo textual y lo visual se captan simultáneamente por el oído y la vista.
- **Multi-mediales**: elementos que ofrecen gran variedad de interacción e integran otros elementos textuales, sonoros, visuales y audiovisuales.

2.4.3 Repositorios y Federaciones de RED

Los RED están disponibles a través de repositorios especializados de instituciones educativas o gubernamentales con el objetivo de hacerlos disponibles y permitir su uso por profesores y estudiantes (Campo Saavedra et al., 2012; N. D. Duque et al., 2015; Gamboa, Xavier & Chehab, 2009) .

Los repositorios tienen diferentes funcionalidades para el almacenamiento, organización, publicación y visibilidad de los RED. Además, facilitan la administración, búsqueda, recuperación y uso de dichos recursos (Campo Saavedra et al., 2012). Los repositorios se unen en federaciones para obtener un punto único de entrada para acceder a RED disponibles por cada repositorio. Una federación puede ofrecer un enfoque unificado y uniforme para la representación de los repositorios componentes, tanto en visibilidad como en administración, definiendo un sistema jerárquico que centraliza el acceso e información en un solo portal. La federación de repositorios es la respuesta a los problemas de escalabilidad en el funcionamiento de los repositorios y la administración de los múltiples repositorios distribuidos que contienen colecciones de interés para determinadas comunidades o aplicaciones (Tabares et al., 2015).

2.5 Perfiles de usuario

Otro componente fundamental al momento de realizar recomendaciones adaptadas, son los perfiles de usuario, que almacenan la información de cada uno de ellos, de manera estructurada (Cazella et al., 2010). Un perfil de usuario es el modelado de las características que definen al usuario y pueden comprender datos personales, intereses, preferencias, datos de interacción, evaluaciones realizadas, entre otros (DAgostino, Casali, Corti & Torres, 2005).

En el campo educativo, se hace necesario manejar un perfil de usuario con el fin de asistir a un estudiante o a un docente a elegir recursos de aprendizaje acordes a sus características personales, necesidades y preferencias (Carrillo-ramos, Arias-báez, Torres-ribero, Garzón & González, 2011; Casali et al., 2011). Estas características tienen la particularidad que deben ser relevantes en un proceso educativo.

Para seleccionar las características que afectan el proceso de enseñanza y aprendizaje en Duque (2005) se explican algunas de ellas:

- Perfil psicopedagógico: aunque existen muchas situaciones que influyen en los resultados obtenidos por parte de los aprendices en el proceso enseñanza-aprendizaje, pero en la tesis de Alonso, Gallego y Honey (1999), después de analizar las distintas investigaciones, llegan a la conclusión de que parece suficientemente probado que los estudiantes aprenden con más efectividad cuando se les enseña con sus estilos de aprendizaje predominantes.
- Características personales: atributos relativamente permanentes tales como su edad cognitiva, edad cronológica, sexo, visión, audición, lateralidad, etc.
- Características psicológicas y preferencias: es posible realizar test de actitudes e intereses en los que se emplean cuestionarios de auto-aplicación, donde el propio sujeto indica sus preferencias entre una serie de actividades profesionales lo que permite predecir los índices de satisfacción al recibir un material educativo, entre ellas se encuentra la capacidad de concentración, confianza en sí mismo y la persistencia.
- Características contextuales: este tipo de características se refieren al ambiente tecnológico desde el que se conecta el estudiante, por ejemplo, el tipo de acceso a la red, el estado de la red y el estado de carga del servidor, etc. Desde otras perspectivas, la información contextual, puede incluir: clima, localización, hora del día, día de semana, fecha, días festivos, desde el cual se puede hacer la adaptación del sistema de recomendación (Kirsch-Pinheiro, et al., 2004), llamándose perfil del contexto.

2.6 Sistemas adaptativos

Un sistema es adaptativo, según (Oppermann, 1994) "si tiene la capacidad de cambiar sus propias características automáticamente según las necesidades del usuario". Los sistemas

adaptativos son sistemas interactivos que adaptan su comportamiento a cada usuario individual sobre la base de inferencias no triviales de la información sobre ese usuario (Ricci et al., 2011).

Los sistemas adaptativos tienen la capacidad de ajustar su funcionamiento a las metas, tareas, intereses y otras características de los usuarios, además abarca los procesos de adaptar las características de un sistema para alcanzar un objetivo (Duque Méndez, Jiménez Ramírez & Guzmán Luna, 2005). La adaptatividad puede entenderse como la capacidad del sistema para que se adapte su comportamiento y funcionalidad dinámicamente según la información disponible y a los requerimientos de la interacción usuario – sistema (Brusilovsky & Millán, 2007). La adaptación puede ocurrir en estos tres aspectos:

- Navegación: adaptación al momento de interactuar con una plataforma, manipulación de links
- Presentación: el sistema puede seleccionar ítems y entregarlos adaptados según las necesidades del usuario
- Contenido: se adapta el contenido de los recursos

El modelo de recomendación propuesto, permite la adaptación de las técnicas de recomendación, enfoques híbridos y algoritmos computacionales para aplicar alguna o algunas de ellas según la información disponible, con el objetivo de entregar RED relevantes. La adaptación debe realizarse mediante una determinada estrategia de adaptación y debe incluir: ¿Qué adaptar?, ¿Cuándo adaptar?, las metas de adaptabilidad y las reglas de adaptabilidad (Duque Méndez et al., 2005). En el caso del modelo genérico propuesto en esta tesis, se aplican los términos de adaptación, donde se realizan ajustes de las técnicas de recomendación a través de una selección guiada y adaptatividad, donde a partir de la información disponible el sistema puede integrarse o ajustarse para entregar los resultados de la recomendación.

2.7 Algoritmos computacionales

Los algoritmos de inteligencia computacional se han utilizado ampliamente en los sistemas de recomendación para mejorar los modelos propuestos, además para tener más velocidad en la entrega de las recomendaciones arte (Cumming, 2002; Jiang, Baker,

Paquette, Pedro & Heffernan, 2015), a continuación se presentan algunos de ellos y su aplicación en sistemas de recomendación existentes.

- **Agrupamiento o clúster,** la cual consiste en la asignación de elementos a los grupos, donde los elementos del mismo grupo son muy similares entre sí que a los elementos de los diferentes grupos. Se basan en medidas de similitud. Esta técnica ayuda a encontrar los vecinos más cercanos de un elemento, se utiliza en los SR basados en filtrado colaborativo: (Kim & Ahn, 2017; Nilashi, Bagherifard, Rahmani & Rafe, 2017; Tyagi & Bharadwaj, 2014; Xue et al., 2005).
- **Árboles de decisión** donde se modelan las diferentes características de los usuarios y de los ítems con el fin de clasificarlos en ítem recomendable o no recomendable (Almomani, Saavedra & Sánchez., 2017; Junokas et al., 2017; Pozo, Chiky, Meziane & Métais, 2017).
- **Reglas de decisión**, donde se busca descubrir relaciones entre variables, son comúnmente encontrados en los SR basados en el conocimiento del usuario y del ítem (Meulendijk, Spruit & Brinkkemper, 2017; Pujahari & Padmanabhan, 2014).
- **Sistemas multi-agente,** que representan una forma de análisis y diseño de sistemas complejos, cada agente tiene la autonomía para realizar tareas específicas con poca o sin supervisión humana (Wooldridge, Jennings & Kinny, 2000). En los SR, se han aprovechado muchas de sus características como su capacidad de deliberación, al seleccionar que ítem recomendar, el paralelismo, adaptación, entre (Gil, Prieta & López, 2010; Rodríguez M, Salazar, Duque, Ovalle & Moreno, 2014; Vian, Campos, Palomino & Silveira, 2011).
- **Algoritmos genéticos,** que son una forma de búsqueda aleatoria y de optimización, que se basa en los sistemas genéticos naturales (Padhy, 2005). Son técnicas de búsqueda estocástica que ayudan a resolver problemas de optimización con restricciones. Se utilizan, en SR, para encontrar similitudes entre usuarios e ítems, además para modelar las características de usuarios (Ar & Bostanci, 2016; Gao & Li, 2008; Salehi, Pourzaferani & Razavi, 2013b; Shivhare, Gupta & Sharma, 2015; Srivastava et al., 2017).

- **Redes neuronales artificiales,** también se han utilizado, una red neuronal artificial está compuesta de un número de unidades, cada unidad tiene características de entrada y/o salidas y están interconectadas con otras unidades. Ésta técnica se inspira en las conexiones cerebrales y se refiere a un conjunto de nodos interconectados y enlaces que comunican los nodos. Las redes neuronales se propagan hacia adelante o hacia atrás para encontrar el resultado (Padhy, 2005). Están conformadas por la capa de entrada, una o varias capas ocultas y la capa de salida. En los SR pueden utilizarse para caracterizar al usuario, así implementar un sistema de recomendación basado en filtrado colaborativo realizando predicciones de las votaciones (Jannach & Ludewig, 2017; Lu, Wu, Mao, Wang & Zhang, 2015).
- **Razonamiento basado en casos** que surge de la idea de soluciones similares a problemas similares y aplica sus principios para planes exitosos. Este enfoque ha proporcionado una buena base para un sistema de recomendación personalizado, según los casos similares de éxito (Alemu, Tegegne & Tarekegn, 2017; Andersen & Pettersen, 2017; Jieli, Zhao, Antony & Chen, 2015; Lorenzi & Ricci, 2005; Rossillea, Laurentc & Burguna, 2005; Setten, Veenstra, Nijholt & Dijk, 2004).
- **Redes bayesianas** son una metodología probabilística para resolver problemas de clasificación, se utilizan en los SR donde cada nodo corresponde a un elemento y los estados son los votos posibles, el resultado son las predicciones que darían lugar a la recomendación. Son comunes en el SR de contenido y basado en filtrado colaborativo (Charniak, 1991; De Campos, Fernández-Luna, Huete & Rueda-Morales, 2010; Jannach & Ludewig, 2017; Lu et al., 2015).
- **Sistemas expertos** los cuales emulan la capacidad de tomar decisiones de un experto humano, a través de los procesos de aprendizaje, memorización, razonamiento, comunicación y acción, y con esto poder almacenar datos y conocimientos y así sacar conclusiones lógicas, tomar decisiones y aprender de la experiencia (Briguez et al., 2014b; Carrer-neto, Hernández-alcaraz, Valencia-garcía & García-sánchez, 2012; Lika, Kolomvatsos & Hadjiefthymiades, 2014)
- **Factorización de matrices,** donde se caracterizan tanto a los ítems como a los usuarios, a través de factores que se infieren de los patrones de clasificación de los ítems; tienen como objetivo aprender de los datos disponibles, generalizando comportamientos y teniendo en cuenta la complejidad computacional. Esta inferencia puede hacerse por medio de las evaluaciones que ha realizado un usuario a un ítem (Koren, Bell & Volinsky, 2009; Polatidis & Georgiadis, 2017). Los métodos de

factorización de matrices enfocados a los SR caracterizan tanto los recursos como los usuarios utilizando un conjunto de características definidas de forma vectorial (Alexandridis, Siolas & Stafylopatis, 2017; Feltoni Gurini, Gasparetti, Micarelli & Sansonetti, 2016; Gu, Zhou & Ding, 2010; Luo, Zhou, Xia & Zhu, 2014; Zhang, Wang, Ford & Makedon, 2006). En el anexo A se presenta la funcionalidad de este algoritmo, debido que es utilizado para la validación de la propuesta.

2.8 Modelos genéricos

El término genérico, según la real academia de la lengua española, lo define como común a varias especies y agrega que es perteneciente o relativo al conjunto de los miembros de una clase o especie (DRAE, 2001); cuando se refiere a algo genérico, es porque no se alude a un miembro determinado sino a la totalidad. En esta tesis el término de modelo genérico se refiere al sistema de recomendación común a varios casos y que se adapta a las disponibilidades de información tanto de ítems, como de usuarios. Para lograrlo se propone un sistema adaptativo, basado en la revisión de la literatura para la selección de técnicas de recomendación, según la información disponible, tanto de ítems como de usuarios.

2.9 Conclusiones del capítulo

Se realizó una caracterización de las técnicas de recomendación, enfoques híbridos para hacer recomendaciones y algoritmos computacionales que se utilizan para ejecutar sistemas de recomendación (SR). Esta revisión permitió esclarecer los conceptos relacionados para proponer un modelo genérico y adaptativo de recomendación de recursos educativos. En este capítulo se explican también los sistemas adaptativos y cómo van a ser utilizados en esta tesis, igualmente se explican los modelos genéricos y como se entienden en este trabajo. Además, se presentan los sistemas de argumentación y sus ventajas al utilizarlos con los SR.

Existen muchos tipos de sistemas de recomendación, cada uno puede ser usado para diferentes enfoques y en diferentes contextos, de acuerdo a las necesidades (Hdioud, Frikh & Ouhbi, 2012). Así, para el caso de los recursos educativos digitales (RED) el sistema

debería ser capaz de recomendar RED adaptados a un estudiante específico. Estos diferentes tipos de sistemas de recomendación necesitan una gran cantidad de información sobre los usuarios y los RED para poder realizar recomendaciones de calidad. De esta forma, dichos sistemas deben proporcionar mecanismos para recopilar la mayor cantidad de información posible acerca de los usuarios y de los RED requeridos con el fin de realizar mejores recomendaciones.

Algunos autores afirman que el uso de modelos de factorización matricial son superiores a los algoritmos clásicos de vecinos más cercanos para producir recomendaciones de productos (Koren et al., 2009). Esto se debe a sus ventajas de la incorporación de información adicional, tanto de ítems como de usuarios.

2.10 Aportes

Con la elaboración de este capítulo, se da cumplimiento al objetivo 1: caracterizar los elementos que componen un modelo de recomendación de recursos educativos digitales, debido que se realizó la revisión de los principales conceptos relacionados con los modelos de recomendación en el área educativa.

3. Trabajos relacionados

En este capítulo se presentan los principales trabajos relacionados con los sistemas de recomendación híbridos aplicados en el contexto de la educación, se muestran las principales contribuciones de los últimos 10 años. Este capítulo está organizado como sigue, primero se plantea la metodología propuesta para hacer la revisión del estado del arte, después se explican los resultados encontrados además se agregan algunos artículos relacionados con los sistemas de recomendación adaptativos y otros con el uso de argumentación en la recomendación. Finalmente, se exponen trabajos donde utilizan la matriz de factorización para hacer la recomendación. En las conclusiones se analizan las diferencias y similitudes del estado del arte de esta tesis.

3.1 Revisión de literatura

Para realizar la revisión de literatura se realizó una búsqueda de trabajos relacionados con los sistemas de recomendación híbridos aplicados a materiales de aprendizaje y que trabajaran con un perfil de usuario estudiante, además que estuvieran en la brecha de los últimos 10 años (2007 – 2017). Para ello, primero se seleccionaron las palabras claves y los criterios de inclusión y exclusión. Se utilizó la metodología *My Tree of Science* (ToS), propuesta dentro del grupo de investigación (Robledo-Giraldo, Duque-Méndez & Zuluaga-Giraldo, 2013), donde, basado en análisis de redes sociales complejas, se hace una extracción de publicaciones relevantes a un tema, independiente de su origen de publicación, minimizando el sesgo de aplicar ecuaciones de búsqueda en bases de datos específicas: ToS se enfoca en las diferentes citaciones y citas de cada uno de los artículos para generar una red y al hacer cálculos de algunas métricas utilizando estos índices de citaciones y citas, entrega como resultado una lista ordenada de los principales artículos que han aportado al tema de investigación. Estos están separados en tres grandes conjuntos, el primero son artículos clásicos en la literatura, es decir, los padres de un tema; el segundo, los artículos que le dan estructura y finalmente las nuevas tendencias. Para

seleccionar los artículos del estado del arte este trabajo se enfoca en los dos últimos conjuntos.

Las palabras clave se dividieron en 3 componentes principales, que se presentan en la Tabla 3-1.

Tabla 3-1: componentes y palabras clave.

	COMPONENTES (AND)		
PALABRAS CLAVE (OR)	***Técnicas de recomendación***	***Enfoque híbrido***	***Educación***
	sistemas de recomendación	híbrido	educa*
	recommender system	hybrid	learning
ECUACIÓN DE BÚSQUEDA			
((“sistemas de recomendación” OR “recommender system”) AND (hibrido OR hybrid) AND (educa* OR learning))			

Fuente: elaboración propia

En la Figura 3.1, se presenta la metodología utilizada para la selección de trabajos relevantes, los criterios de exclusión e inclusión, hacen referencia a los años de publicación y si contienen las palabras claves (componentes). Al encontrar artículos de revisión, se analizaban y se buscaban las conclusiones pertinentes que se relacionan con el presente trabajo.

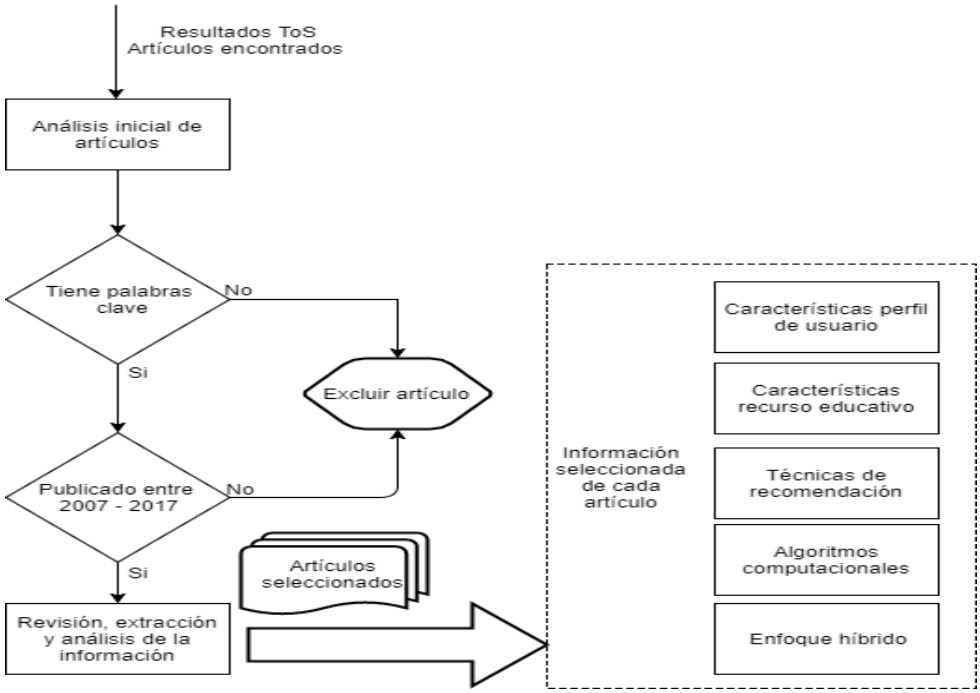

Figura 3.1 Estrategia de revisión de la literatura

Fuente: elaboración propia

3.2 Resultados encontrados

Al iniciar la estrategia de la revisión de la literatura se contaba con 95 artículos y al ir pasando por los diferentes filtros se seleccionaron 28 artículos que aportan directamente al tema de investigación, donde 12 fueron publicados entre el 2007 al 2011 y 16 son del año 2011 en adelante. En el anexo C, se presenta un cuadro comparativo con los principales trabajos relacionados que aportan al modelo propuesto. A continuación, se presentan los principales resultados encontrados.

Dentro de los resultados se encontró que uno de los primeros sistemas de recomendación para recursos educativos fue Altered Vista, un SR colaborativo que tenía como objetivo explorar la forma de recolectar evaluaciones proporcionadas por los usuarios sobre los recursos y usarlos para recomendar a los miembros de una comunidad, tanto recursos interesantes como personas con gustos y creencias similares (Recker & Wiley, 2001).

Además, se encontraron survey, como el de Lu y otros, presentado en 2015, donde hacen una revisión de los principales sistemas de recomendación en diferentes contextos, y entre ellos e-learning, donde encontraron que desde el 2000 se empezó a llevar los SR a los ambientes educativos, ayudando a los estudiantes a elegir cursos, asignaturas y materiales de aprendizaje que les puedan interesar, concluyen que es muy importante utilizar el SR basado en conocimiento, debido que en los sistemas educativos generalmente no se cuenta con un conjunto de datos históricos suficiente para aplicar las técnicas de filtrado colaborativo y basado en contenido. Además, agregan que para los sistemas de recomendación en e-learning, es necesario i) usar técnicas para el análisis y la recopilación de los perfiles de los estudiantes, ii) recolectar datos de los objetivos de aprendizaje, iii) adquirir conocimiento pedagógico relacionado para el grado de adaptación entre el estudiante y los objetivos de aprendizaje (Lu et al., 2015).

Igualmente, en el trabajo de revisión presentado en el handbook de Ricci et al., en 2011, afirman que el desarrollo de los SR es un esfuerzo multidisciplinar que envuelve varios campos como la inteligencia artificial, interacción hombre – computador, tecnologías de la información, minería de datos entre otros. En este libro se presentan diferentes enfoques e investigaciones de los sistemas de recomendación, pasando por las técnicas más utilizadas y llegando a la evaluación de la calidad de las recomendaciones. Entre las

aplicaciones descritas se encuentran los sistemas de recomendación utilizados para mejorar el aprendizaje, hablan de la recuperación adaptativa de recursos de aprendizaje para ayudar a estudiantes y profesores, la adaptación se hace a los objetivos, tareas e intereses de los usuarios. Entre la revisión que realizan concluyen que entre los retos a trabajar en los SR se encuentra cómo mejorar el desarrollo de sistemas de recomendación y cómo evaluar estos sistemas, afirman que se deben tener en cuenta características pedagógicas y diferentes métodos, métricas e instrumentos para realizar las evaluaciones. Además, encuentran que a la fecha la mayoría de trabajos encontrados están en desarrollo de prototipo y solo 10 trabajos realizan evaluaciones con usuarios reales (Ricci et al., 2011).

Por su parte Drachsler, Verbert, Santos y Manouseli (2015), presenta un revisión reciente de los SR aplicados en el aprendizaje, analizan y clasifican 82 SR, en 7 grupos: SR con filtrado colaborativo en otros dominio, SR que mejoran al filtrado colaborativo en educación, SR con restricciones educativas, SR con otras alternativas para las técnicas de filtrado colaborativo, SR con información contextual, SR que evaluan el impacto educativo de las recomendaciones entregadas y SR enfocados a entregar cursos o secuencias de recursos. Concluyen que en muchos casos, fue difícil extraer la información de los artículos seleccionados y hacer la clasificación a los diferentes grupos. También, demuestran que el campo de los SR esta en continua evolución y han surgido nuevos enfoques para investigar, entre ellos se encuentra que las técnicas de recomendación aplicadas a la educación, estan siendo probadas en datasets públicos antes de llevarlas a la implementación en un entorno educativo real.

Por otro lado, hay trabajos donde realizan la revisión de algunos sistemas de recomendación híbrida como el de (Burke, 2002), donde señalan las ventajas, desventajas y usos de los enfoques híbridos. Además, en el trabajo de Degemmis, Lops y Semeraro (2007) proponen un modelo de recomendación híbrida basado en el perfil de usuario donde también realizan la integración de los SR basados en contenido y colaborativo obteniendo buenos resultados, afirman que utilizar sólo el filtrado colaborativo deja de lado algunos usuarios que son similares así no tengan calificaciones de elementos comunes, es por esta razón que integran otra técnica para tener en cuenta los perfiles semánticos de los usuarios y sus intereses

A la par, Masters, Madhyastha y Shakouri (2008) desarrollan *ExplaNet* un SR híbrido basado en la web. *ExplaNet* recomienda un pequeño subconjunto de explicaciones para cada estudiante en función de sus características y preferencias. El algoritmo de recomendación híbrido predijo de manera efectiva, en dos ensayos de clase, las preferencias para las explicaciones de los estudiantes. Tres evaluaciones en el aula de *ExplaNet* demostraron que los estudiantes que utilizaron el SR han mejorado la comprensión y la retención de conceptos difíciles.

También, en el trabajo de Zapata (2011), se entregan materiales educativos ajustados al perfil, combinando varios tipos de filtrado, tratando de utilizar toda la información que se tenga disponible sobre objetos y usuarios. Primero el método preselecciona objetos de aprendizaje del repositorio, usando una búsqueda en base a los metadatos, luego esos objetos pasan por los otros procesos de filtrado para obtener una lista final que será la que mejor se adapte al usuario. En este trabajo combinan varios criterios de filtro: basada en el contenido, la actividad colaborativa y la demográfica.

Asimismo, en el trabajo presentado en Salehi y otros (2013a), realizan recomendación híbrida de materiales educativos, donde utilizan algoritmos genéticos y ejecutan dos procesos de recomendación, el primero de ellos trata de las características explícitas representado en un matriz de preferencias del estudiante. La segunda recomendación es con pesos implícitos a los recursos educativos que son considerados como cromosomas en el algoritmo genético para optimizarlos según los valores históricos.

Adicionalmente, algunos trabajos encontrados por ToS, no realizan una combinación de métricas, sin embargo, son tenidos en cuenta, ya que mejoran algunas técnicas y son aplicados a recursos educativos, como es el caso de (Cechinel, Sicilia, Sánchez-Alonso & García-Barriocanal, 2013), donde trabajan el filtrado colaborativo basado en memoria. En (Fraihat & Shambour, 2015) proponen un *framework* donde utilizan las relaciones intra y extra semánticas entre los recursos educativos y las necesidades del alumno para proporcionar recomendaciones personalizadas para los estudiantes, este sistema ayuda a la reducción del tiempo y el esfuerzo necesarios para encontrar recursos adaptados. También el trabajo de Ruiz-Iniesta, Jiménez-díaz y Gómez-albarrán (2010), se propone un sistema de recomendación basado en contenido para repositorios que prioriza los recursos similares a las consultas de los estudiantes y que tengan una utilidad pedagógica mayor.

En (Gordillo et al., 2017), se presenta un modelo de recomendación híbrido para un repositorio de objetos de aprendizaje (Europeana), en este trabajo combinan las técnicas de contenido, demográfica y utilizan el contexto como el objeto de aprendizaje que está viendo el estudiante en el momento de iniciar la recomendación. Afirman que existe una gran influencia del entorno donde se implemente un SR en un escenario real, debido a las características variadas de los repositorios y la calidad de los objetos almacenados en ellos.

Como el objetivo de esta tesis trata de los modelos genéricos, se realizó una búsqueda que incluyera este tipo de sistemas encontrando el trabajo de (Bustos-López & Alor-Hernández, 2015), donde presentan una arquitectura genérica para el desarrollo de los sistemas de recomendación educativos independientes del tipo de recomendación generada. Asimismo, se identifican las características principales de un sistema de recomendación educativo. Estas características son componentes importantes para lograr los objetivos que tienen los sistemas de recomendación educativos con el fin de proporcionar información precisa a los estudiantes de acuerdo a sus preferencias, perfil de usuario y objetivos de aprendizaje. Sin embargo, no es un modelo genérico que realice adaptaciones de las técnicas de recomendación con las informaciones disponibles.

Así mismo, se quiere revisar los sistemas de recomendación adaptativa, debido a la evolución de los sistemas de recomendación, donde se precisa entregar ítems adaptados a los usuarios con el objetivo de mejorar la precisión y que el usuario confíe más en los resultados del sistema. Entre los sistemas de recomendación adaptativos, enfocados en la recomendación de materiales educativos, se encuentra los trabajos presentados en (Brusilovsky & Millán, 2007), donde se enfocan en la caracterización del modelo de usuario. Los trabajos: (Peissner & Edlin-White, 2013; Uruchrutu, MacKinnon & Rist, 2005), realizan una adaptación a la interfaz. En otros casos, se llama de procesos de adaptación a la recomendación de los recursos según las características de los usuarios (Patil, 2017; S. L. Wang & Wu, 2011) .

Respecto a los sistemas de recomendación que trabajan temas de persuasión y argumentación, con el objetivo de entregar explicaciones válidas a los usuarios para que utilicen el material entregado,, recientemente se han propuesto para diferentes dominios como música (C.E. Briguez, M. Budán, C. Deagustini & M. Capobianco, 2012), noticias

(C.E Briguez, M. Capobianco, 2013), películas (Recio-Garcia, Quijano & Diaz-Agudo, 2013), restaurantes (Heras, Rebollo & Julián, 2008) y búsquedas en internet (Chesñevar, Maguitman & González, 2009b). En el área de educación se encontró el trabajo de Giustozzi y otros (2016) que se basa en los sistemas de recomendación basados en la crítica, donde se plantea un diálogo con el usuario, a partir de las recomendaciones entregadas.

Por último, se realiza una revisión de aquellos SR, que utilizan como algoritmo computacional, la matriz de factorización para entregar materiales y se encontró (Koren et al., 2009), donde analizan los algoritmos ganadores del premio de netflix, y afirman que este tipo de algoritmos mejoran la exactitud de los ítems entregados. Por otro lado en el trabajo de (Gu et al., 2010), se propone un modelo de factorización de matrices no negativas con una regularización y ponderación por grafos para realizar filtrado colaborativo. Construyen dos grafos, el primero con la información demográfica de los usuarios (ocupaciones) y el segundo con los géneros de las películas y sus relaciones, y concluyen que este tipo de métodos mejoran la precisión de las recomendaciones. Igualmente, en (Alexandridis et al., 2017) intentan mejorar el filtrado colaborativo a través del uso de la factorización de matrices y el uso de grafos aleatorios. Por otro lado, (Polatidis & Georgiadis, 2017), proponen un método de filtrado colaborativo, utilizando matrices de factorización negativas y positivas, utilizan las medidas de similitud de Pearson. Finalmente, en (Feltoni Gurini et al., 2016), utilizan estos algoritmos para la recomendación de personas, modelan en las matrices las actitudes y sentimientos que existen entre las personas para conocer el grado de correlación entre ellas y así hacer la recomendación. Sin embargo, no se encontraron trabajos que utilicen la factorización de matrices para recomendar recursos educativos o que utilicen un perfil de estudiante para entregar los ítems.

3.3 Conclusiones del capítulo

Existen numerosas investigaciones recientes sobre la utilización de SR en entornos virtuales de aprendizaje para facilitar a los usuarios la búsqueda de recursos educativos con base a sus necesidades y preferencias. Después de realizar la selección de los trabajos relacionados, se analizaron los artículos en los que se puede concluir que la investigación en los SR va en aumento y que es un interés mundial mejorar las técnicas, enfoques y algoritmos, con el objetivo de ayudar a los estudiantes a encontrar materiales

que se adapten a sus necesidades y preferencias, apoyando su proceso de aprendizaje autónomo.

Entre las técnicas más utilizadas, se encuentra el filtrado colaborativo y en una igual medida los SR basados en el conocimiento que se tiene del estudiante. Además, el uso de enfoques híbridos, combinando diferentes técnicas, mejoran la precisión de las recomendaciones entregadas. Se descubre también que hay pocos trabajos donde se implemente un SR en contextos existentes donde se realice una evaluación con usuarios reales y no se encontró un *dataset* con datos educativos para realizar pruebas.

La revisión de trabajos relacionados permitió esclarecer que dichos trabajos tienen limitaciones lo que deja espacios abiertos que son atacados por esta tesis de doctorado. En Ricci (2011) se afirma que el rendimiento de los algoritmos de recomendación depende de las particularidades del contexto de la aplicación y se aconseja analizar de forma experimental varias opciones de diseño para un SR antes de su implementación real. Por esta razón, se hace necesario proponer un modelo genérico que analice las disponibilidades de información y pueda ser adaptado para ejecutar varias técnicas de recomendación, integrándolas con algunos de los enfoques disponibles y apoyándose en los algoritmos que mejor se adecuen a las técnicas, para entregar recursos relevantes.

En cuanto a los sistemas adaptativos, a diferencia de los trabajos relacionados encontrados, el modelo propuesto en esta tesis, no se realiza adaptaciones de los resultados ni de la interfaz, sino que se adaptan las técnicas, enfoques y algoritmos a ser utilizados para recomendar materiales relevantes, dependiendo de la disponibilidad de información.

Por otro lado, se encuentra que, realizar procesos de argumentación ayuda a los estudiantes para aceptar las recomendaciones dadas y que los sistemas basados en la crítica, donde los usuarios pueden entablar un diálogo con el sistema a partir de las recomendaciones dadas, es una realimentación para el SR y permiten encontrar y actualizar preferencias y necesidades, y así ajustar mejor el modelo de recomendación.

3.4 Aportes

En este capítulo se realiza la caracterización de los diferentes enfoques, técnicas y algoritmos existentes para modelar sistemas de recomendación, dando cumplimiento al objetivo 2 de la presente tesis, haciendo una revisión comparativa de los trabajos relacionados encontrando fortalezas y debilidades de los mismos.

4. Modelo propuesto

Como se evidencia en el capítulo anterior, existen diferentes aproximaciones para realizar recomendaciones de materiales educativos; en este capítulo, se retoma la revisión y los resultados encontrados con el objetivo de proponer un modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales (RED). El modelo tiene tres componentes (entradas, procesos, salidas) y es aplicable en dos estrategias, la primera de ellas es guiada, donde se propone una metodología para generar modelos de recomendación y la segunda es integrativa, donde se combina todos los recursos disponibles para entregar resultados relevantes.

Este capítulo está organizado como sigue, primero se muestra la perspectiva general del modelo propuesto, después se presenta el modelo y se explica cada uno de sus componentes y por último se exponen las dos estrategias de aplicación.

4.1 Perspectiva del modelo propuesto

El modelo propuesto se orienta a cubrir las expectativas de la recomendación de RED que sean relevantes para los estudiantes. Se tienen en cuenta los componentes de los SR, tales como las entradas: información de usuarios y de ítems, así como las evaluaciones realizadas por los usuarios a los ítems; los procesos, que son las técnicas de recomendación y los algoritmos computacionales que pueden ejecutar las recomendaciones y las salidas que son los RED recomendados.

En esta perspectiva se considera un modelo adaptativo de recomendación, donde se tiene en cuenta la información disponible, además se considera que, a mayor cantidad de información tanto de usuarios como de ítems, mejores (más relevantes) son las recomendaciones entregadas. El modelo es híbrido, donde se consideran dos o más técnicas de recomendación, utilizando enfoques híbridos. Además, el modelo es

adaptativo, cabe aclarar que este modelo no adapta los resultados obtenidos, sino que se adapta el proceso de recomendación, a través de las disponibilidades de información.

La definición tradicional de un sistema, es un conjunto de entradas que interactúan en algún proceso para construir unas salidas; en el caso de los sistemas de recomendación esta definición se ajusta y las entradas se componen de la información disponible de los ítems y de los usuarios, también de las relaciones existentes entre ítem y usuario que pueden ser las evaluaciones; el proceso es el modelo de recomendación que se adapta a las informaciones disponibles y las salidas son la lista de recomendaciones que se hacen, retomando la figura 1.1, para el caso de los SR educativos, el sistema de recomendación no cambia mucho, solo se especifican algunos aspectos, como puede verse en la Figura 4.1.

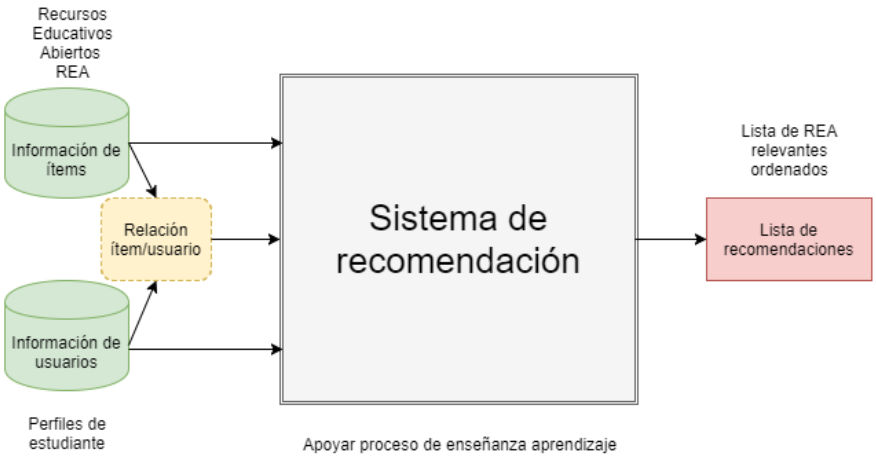

Figura 4.1 Componentes de un sistema de recomendación en la educación

Fuente: elaboración propia adaptada de la literatura

Uno de los mayores retos al desarrollar sistemas de recomendación es la adquisición de información suficiente con el objetivo de entregar mejores recomendaciones. Las diferentes técnicas de recomendación explicadas en el capítulo 1, tienen diferentes fortalezas y debilidades, utilizan diferentes fuentes de entrada y pueden funcionar bien en diferentes escenarios, como se presenta en la Tabla 4-1.

Tabla 4-1 Características de los SR (Aggarwal, 2016)

Técnica de recomendación	**Fuentes de información**	**Funcionan bien**	**No funcionan bien**
Filtrado colaborativo	Calificaciones de un grupo similar	Cuando se dispone de una cantidad significativa de evaluaciones	Nuevo ítem Nuevo usuario Oveja gris
Contenido	Calificaciones de usuario activo e informaciones de los RED	Se tiene características de los ítems y no se tienen calificaciones de un grupo	Nuevo usuario Sobre-especialización
Conocimiento	Información explícita de los usuarios e información de los RED	Son más eficaces cuando no se dispone de una cantidad significativa de datos.	Sinonimia Nuevo usuario, no se conocen las preferencias
Demográfico	Características demográficas	Se puede capturar información demográfica	Pocos usuarios

Fuente: elaboración propia

Cuando se cuenta con mayor variedad de fuentes de entrada de información, existe una mayor flexibilidad hacia la utilización de diferentes tipos de SR para encontrar los mismos ítems. Los sistemas de recomendación híbridos realizan esta tarea, donde los diversos aspectos de diferentes tipos de técnicas se combinan para lograr lo mejor de todos los mundos.

"*Los sistemas recomendadores híbridos están estrechamente relacionados al campo del análisis de conjuntos, en el que la potencia de múltiples tipos de algoritmos de aprendizaje de máquinas se combina para crear un modelo más robusto. Los sistemas recomendadores basados en ensambles pueden combinar no sólo la potencia de múltiples fuentes de datos, sino que también pueden mejorar la eficacia de una clase particular de sistemas de recomendación (por ejemplo, sistemas colaborativos) combinando varios modelos del mismo tipo. Este escenario no es muy diferente del análisis de conjunto en el campo de la clasificación de datos*" (Aggarwal, 2016).

4.2 Modelo Genérico

El término genérico, en esta tesis, se refiere a la capacidad del modelo propuesto para ser aplicable en diferentes espacios computacionales, a cualquier tipo de recursos educativos y en diferentes ambientes educativos, entendiéndose el ambiente educativo como el lugar físico o virtual que facilita el acceso al conocimiento y se compone de actividades, herramientas, actores y objetivos pedagógicos. Cuando se habla que es un sistema adaptativo, se refiere a que el modelo propuesto tiene la capacidad de seleccionar las técnicas y algoritmos de recomendación según la información disponible del estudiante, a través de la selección e integración de las diferentes características del perfil. E igualmente cuando se habla de un enfoque híbrido, se refiere a que el SR debe contener dos o más técnicas de recomendación y un enfoque para hacer las combinaciones.

Respecto a las características de los estudiantes, el sistema al ser genérico contempla a todos los tipos de usuarios, no importa su condición ni nivel de formación. Este modelo no se ata a un tipo de usuario, sólo toma en cuenta la información disponible para hacer la recomendación. Siendo así, el modelo propuesto si puede ser aprovechado para ambientes de inclusión, donde se tenga en cuenta características de necesidades especiales de educación y con cualquier tipo de nivel de formación.
El modelo es aplicable a todo y no está sujeto a nada, es por ello que se definieron los componentes requeridos para ser aplicable en diferentes escenarios y condiciones. Además, como el modelo trabaja con la información disponible, se puede garantizar que sea extensible con una cantidad variable de características de los usuarios – estudiante.

El modelo para la recomendación híbrida y adaptativa de recursos de aprendizaje, es presentado en la Figura 4.2. Se trata de un modelo integral donde, dependiendo de las necesidades y disponibilidad de información, se pueden tomar diferentes elementos, técnicas, enfoques y algoritmos, con el objetivo de entregar recursos educativos digitales según las características, preferencias y necesidades de los estudiantes.

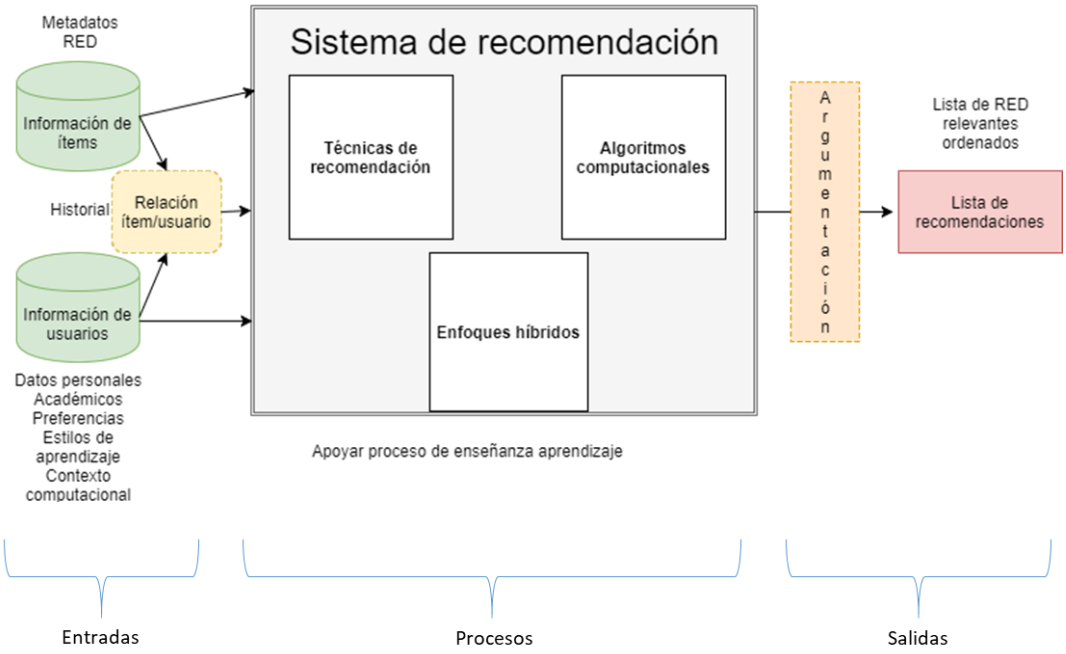

Figura 4.2 Modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales

Fuente: elaboración propia

El modelo propuesto está diseñado en tres componentes principales, las entradas que son la información de ítems y las características de los usuarios; el proceso, donde se encuentran las técnicas, enfoques y algoritmos para hacer la recomendación y finalmente las salidas, donde se ubica el proceso de argumentación para entregar RED relevantes y una explicación del proceso de recomendación. A continuación, se explica cada componente.

4.2.1 Componente 1: entradas

Las entradas al sistema de recomendación se refieren a toda la información necesaria para que el sistema funcione de manera adecuada, los sistemas de recomendación necesitan información tanto de los usuarios como de los ítems para entregar el resultado.

- **Ítems:** en este modelo genérico la información de los ítems se refiere al contenido y metadatos de los recursos educativos digitales.
- **Perfil del usuario**: el usuario en este modelo, se refiere a las características que representan al estudiante, puede utilizarse las características explícitas e implícitas, información dinámica y estática. Específicamente, se pueden tener datos

académicos, como el nivel educativo, los logros académicos, información acerca de su desempeño escolar, por otro lado, están los datos personales básicos y la información socio-demográfica. Igualmente, datos de su perfil psicopedagógico como el estilo de aprendizaje. Cómo el modelo se implementa en los repositorios de RED, estos deben tener un mecanismo que permita la captura y actualización del perfil del usuario. El modelo aprovecha esta información para generar las recomendaciones según la disponibilidad de información.

- **Historial:** en este tipo de entrada, se considera las evaluaciones que ha realizado cada uno de los estudiantes a los recursos educativos que ha visitado en el pasado.

4.2.2 Componente 2: proceso de recomendación

El segundo componente se refiere al proceso de recomendación, este componente se divide en:

- **Técnicas de recomendación:** en el modelo, se pueden tener todas las técnicas de recomendación existentes para los diferentes dominios, explicadas en el capítulo 1 del presente documento, es importante resaltar que como lo que se quiere lograr es la construcción de un SR híbrido, se deben seleccionar como mínimo dos de las técnicas de recomendación para desarrollar el sistema. Es muy importante tener presente que información se encuentra disponible para realizar dicha selección (Tabla 4-1).
- **Enfoques híbridos:** adicional a la selección de técnicas se debe seleccionar el enfoque de combinación a utilizar, se debe tener en cuenta que no todas las técnicas son compatibles con todos los enfoques híbridos y en algunos casos se debe cambiar la manera de programar el enfoque para tener en cuenta la técnica; lo más genérico es llegar a realizar una combinación de todas las técnicas disponibles.
- **Algoritmos computacionales:** dependiendo de la información disponible, las técnicas y enfoques seleccionados, se pueden aplicar diferentes algoritmos computacionales para ejecutar las recomendaciones (según la revisión presentada en el capítulo uno de esta tesis).

4.2.3 Componente 3: salidas

El componente de salidas, se refiere al dominio de aplicación del modelo, en este caso los diferentes tipos de recursos educativos digitales que pueden ser recomendados a los distintos usuarios. Los recursos entregados deben ser adecuados, independientemente de las técnicas, enfoques y algoritmos seleccionados, a las características y preferencias de los estudiantes, siendo así relevantes para aprender un determinado tema.

Además, se propone en esta tesis, para algunos casos, contar con mecanismos de argumentación, para utilizar las ventajas de este tipo de sistemas y entregar a los usuarios una explicación de porqué un determinado recurso, puede ser útil para él y para su proceso de aprendizaje. Con la argumentación, se puede llegar a conseguir un proceso de persuasión, que en esta tesis esta vista como la capacidad que tiene el sistema al entregar explicaciones con argumentos válidos con el porqué un estudiante debe usar el recurso educativo digital que se le recomendó, ayudando para que el estudiante acepte el recurso y lo utilice. Al entregar las recomendaciones, se muestra junto con cada objeto un texto de porqué ese objeto es bueno para su proceso de aprendizaje, realizando una explicación del proceso de recomendación que se siguió.

La persuasión que se propone se logra al entregar argumentos válidos y explicativos del proceso de recomendación que se siguió para llegar a ese RED, sin embargo, la decisión de utilizarlo es del estudiante.

4.3 Estrategias de aplicación del modelo propuesto

El modelo propuesto cuenta con dos estrategias donde puede ser aplicado, donde lo más genérico es aplicar diferentes técnicas, enfoques y algoritmos para realizar el proceso de recomendación, esta ejecución es transparente para el usuario y el resultado deben ser los recursos relevantes. La relevancia se refiere a la importancia que tiene un ítem para un determinado usuario. A continuación, se presentan las dos estrategias.

4.3.1 Estrategia de selección

En esta estrategia se debe realizar la adaptabilidad de los diferentes componentes de manera guiada, donde primero se debe elegir la información que caracteriza a los usuarios y a los ítems, que será utilizada en el proceso de recomendación. Dependiendo de la

información disponible, se pasa a seleccionar las técnicas de recomendación; si se seleccionan dos o más técnicas, se pasa a escoger un enfoque híbrido para hacer la integración de estas; además se debe determinar un algoritmo computacional para ejecutar la recomendación. Por último, se hace el proceso de evaluación de la recomendación a través de métricas de calidad. En la Figura 4.3 se presenta el modelo de recomendación con la estrategia de selección.

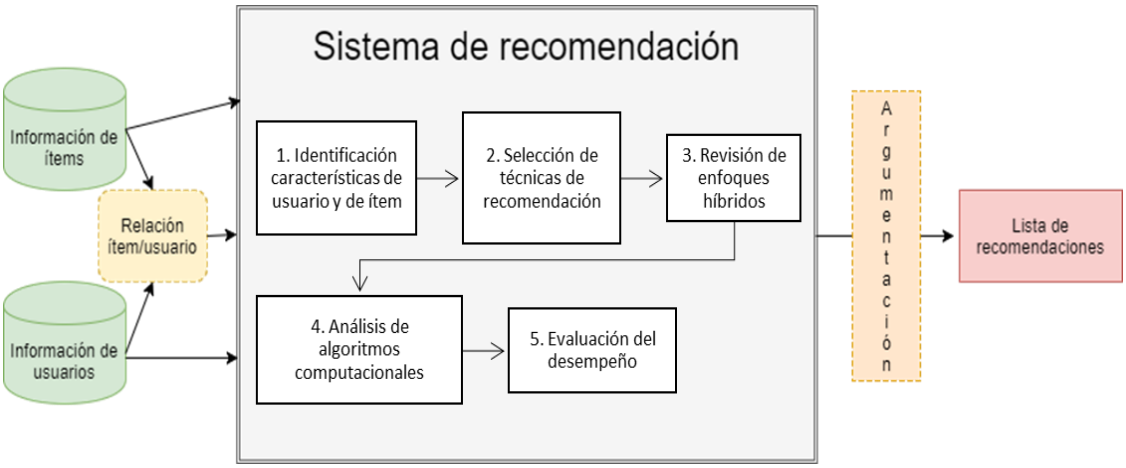

Figura 4.3 Estrategia de selección

Fuente: elaboración propia

El proceso de adaptabilidad del sistema de recomendación en esta estrategia se basa en las disponibilidades de información, a continuación, se explica la metodología propuesta para la formulación de un modelo de recomendación. En el anexo D, se presenta una guía para el uso del modelo propuesto.

1. Identificación características de usuario y de ítem: en esta etapa se deben analizar, la diversa información que se tiene tanto de los usuarios como de los recursos, en la mayoría de los casos, se utilizan los datos de los estudiantes y los metadatos de los RED, además de las evaluaciones realizadas, disponibles en la plataforma.

2. Selección de técnicas de recomendación: dentro de las técnicas disponibles, filtrado colaborativo, contenido, conocimiento y demográfico, se deben seleccionar cuales son las más adecuadas, dependiendo de la disponibilidad de datos, así:

Si se cuenta con el estilo de aprendizaje del usuario activo, se puede ejecutar la técnica de conocimiento. Al igual, si se tiene información de las diferentes preferencias de los usuarios al recibir un recurso, por ejemplo, preferencias de formato, de interactividad o de idioma, se aplica la técnica de conocimiento.

Si se cuenta con información demográfica, se puede ejecutar la técnica demográfica y combinarla con la de conocimiento.
Si se tienen evaluaciones previas o el historial de uso de los recursos por parte de los estudiantes, se puede aplicar el filtrado colaborativo y el basado en contenido.

3. Revisión de enfoques híbridos: después de realizar la selección de las técnicas a aplicar, se deben revisar los enfoques híbridos, tanto secuenciales (cascada, función de aumento, meta-nivel, combinación de características) como los paralelos (ponderado, conmutación, mixto, intersección de resultados), para poder elegir cuál de ellos se adapta mejor a las técnicas seleccionadas.
Si es una combinación entre un SR de contenido y un SR colaborativo, un enfoque secuencial será el más adecuado, pero si por otro lado se quiere trabajar con todas las técnicas de recomendación ya que se cuenta con toda la información necesaria, un enfoque híbrido que trabaje paralelamente con las técnicas y después integre las recomendaciones sería lo más conveniente.

4. Análisis de algoritmos computacionales: al llegar a este paso ya se tiene definido el modelo de recomendación que se quiere aplicar. Ahora, se deben definir cómo se van a aplicar a dicho modelo y para ello existen diferentes algoritmos computacionales que ayudan a la ejecución de las técnicas y enfoques, entre ellos se encuentran minería de datos, inteligencia artificial y algoritmos de aprendizaje de máquina.

5. Evaluación del desempeño: finalmente para validar el modelo generado, se deben aplicar métricas para evaluar el desempeño del modelo, entre las métricas más utilizadas se encuentra el MAE, la precisión, el recall y por último F1 Score.

El proceso de argumentación en esta estrategia, para explicarle al usuario el por qué un recurso puede ser interesante para él, se realiza siguiendo los pasos descritos anteriormente, según las técnicas aplicadas.

4.3.2 Estrategia de integración

A partir de la aplicación de la estrategia anterior en varios casos de estudio, se encontraron limitaciones prácticas para aprovechar el modelo y se exploraron opciones que fortalecieron lo genérico, híbrido y adaptativo de la propuesta.

En la estrategia anterior, se puede ver que el proceso de adaptación del modelo de recomendación se hace de manera guiada, como alternativa se propone una estrategia donde se hace una adaptación automática de las técnicas de recomendación, partiendo de la hipótesis que entre mayor cantidad de información se tenga, tanto de usuarios como de ítems, mejor recomendación entregará el sistema. En la Figura 4.4 se presenta la estrategia de integración.

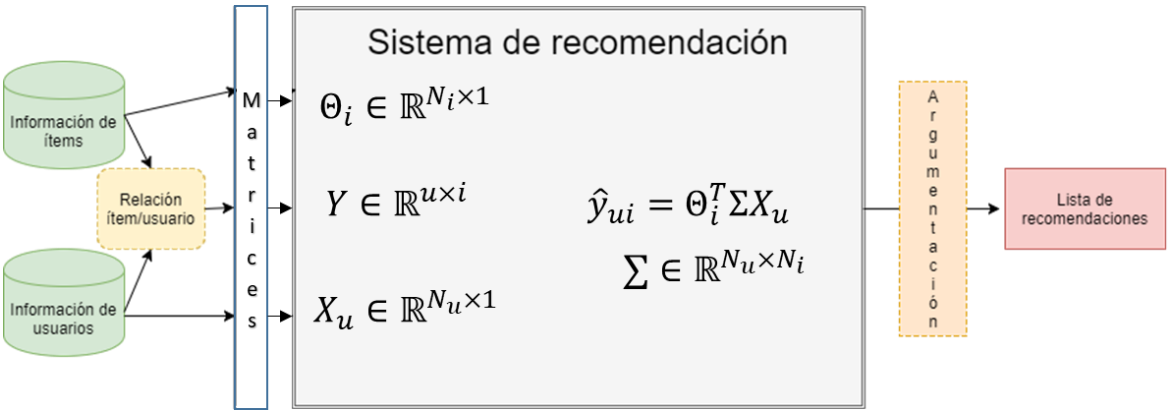

Figura 4.4 Estrategia de integración

Fuente: elaboración propia

En esta estrategia, se utiliza la información disponible a través del uso de matrices, se combinan las técnicas de recomendación y se emplean las similitudes entre los usuarios e ítems. Además, el enfoque híbrido no puede definirse como secuencial o paralelo, debido que toda la información se mezcla en operaciones matemáticas. En este enfoque se utilizan varias técnicas de recomendación (colaborativo, contenido, conocimiento y demográfico) y el algoritmo de factorización de matrices, donde se caracterizan tanto ítems como usuarios utilizando vectores de factores inferidos a través de las calificaciones. Las características de los ítems se representan como: $\Theta_i \in \mathbb{R}^{N_i \times 1}$, donde N_i son los factores o características que describen el ítem i y Θ_i mide qué tanto representa cada factor al ítem.

De igual manera para la representación de las características del usuario u: $X_u \in \mathbb{R}^{N_u \times 1}$, donde, X_u mide el grado de interés del usuario por cada uno de los factores N_u que lo representan. Por otro lado, la relación entre los usuarios y los ítems (calificaciones) se define como $Y \in \mathbb{R}^{u \times i}$.

Con los algoritmos tradicionales de factorización de matrices, se pretende estimar los valores de Θ y X, que mejor representen los usuarios a partir de las Y, evaluaciones conocidas, por medio de: $\hat{y}_{ui} = \theta_i^T X_u$ (Koren et al., 2009), en algunos modelos se conoce la información de los usuarios y solo debe estimarse los parámetros que representan los ítems y en otros casos se conoce la información de los ítems entonces se estiman los parámetros de los usuarios. Estas propuestas son limitadas a la disponibilidad de información. Se generaliza entonces el modelo proponiendo un modelo que integre la información de usuarios y de ítems, ahora el problema cambia y lo que se quiere estimar es la relación Σ entre las características del ítem (conocimiento) y la información demográfica del usuario (θ y X) para mejorar la estimación de las calificaciones (contenido) y así entregar ítems que sean relevantes para el usuario, teniendo en cuenta además los usuarios similares por las evaluaciones previas (colaborativo). Se propone entonces, una estimación aproximada de la calificación que dicho usuario le otorga a tal ítem a través de: $\hat{y}_{ui} = \Theta_i^T \Sigma X_u$, donde $\Sigma \in \mathbb{R}^{N_u \times N_i}$, N_u es el número de características conocidas de los usuarios y N_i es el número de características de los ítems y Σ describe la relación entre la N_u-ésima característica del usuario con la N_i –ésima característica del ítem, en el anexo B, se presenta en detalle cómo se llegó a esta propuesta.

Lo que se quiere lograr con la estrategia de integración es utilizar la mayor cantidad de información de ítems y de usuarios para entregar recomendaciones relevantes, así mismo tener un modelo que funcione cuando se conocen las características e igualmente cuando no se conocen, como es el caso del nuevo usuario. Si al sistema de recomendación llega un usuario que ha realizado pocas o ninguna evaluación a ítems, se utiliza entonces una medida de similitud a través del coeficiente de Pearson, para encontrar usuarios que se parezcan en cuanto a su caracterización y así las evaluaciones del nuevo usuario se pueden obtener como el promedio de las evaluaciones de los usuarios más similares a este.

En esta estrategia, la argumentación se dificulta un poco, debido que no se sabe que técnica se utilizó o que información del usuario fue la que se tuvo en cuenta para realizar la recomendación, solo se puede argumentar a partir de las características del ítem que se recomienda.

4.4 Conclusiones del capítulo

En este capítulo, se presenta el modelo propuesto, la perspectiva del modelo y las dos estrategias de aplicación del modelo. Se concluye que dependiendo del sistema de recomendación que se quiera implementar, se debe analizar cuáles características del estudiante se van a tener en cuenta y como se va a realizar el proceso de captura de las mismas. Muchas veces las características que se quieren usar no están disponibles y no se pueden capturar. Por otro lado, el modelo genérico no está asociado a una sola técnica, se pueden ejecutar diferentes técnicas dependiendo de la información disponible de ítems y usuarios, además, el modelo tiene diferentes datos de entradas, procesos y salidas, siempre buscando la recomendación de recursos relevantes para los estudiantes.

La idea del modelo genérico es que dependiendo de las entradas disponibles el sistema puede ejecutar una o varias técnicas de recomendación, utilizar diferentes enfoques híbridos y algoritmos computacionales, para obtener los resultados. Se proponen, entonces, dos estrategias de aplicación del modelo, donde en la primera de ellas (selección), se realiza un proceso de adaptabilidad guiada de las técnicas, enfoques y algoritmos de recomendación, este proceso está determinado por la disponibilidad de la información de ítems, usuarios y según las necesidades de información de las diferentes técnicas. En cambio, en la segunda estrategia (integración), no hay que definir explícitamente las técnicas a utilizar, ni la información disponible, ya que se utiliza todo lo que esté en la entrada matricial, estrategia adaptativa.

Además, al modelo propuesto se le agrega un sistema de argumentación que consta de un modelo de persuasión/explicación y un sistema conversacional para generar un diálogo con el usuario y conocer las percepciones hacia las recomendaciones recibidas. La argumentación, trata de explicar con lenguaje natural cual fue el proceso que se llevó a cabo para encontrar los ítems que mejor se adaptan a las necesidades y preferencias de

un estudiante y un mecanismo para conocer las retroalimentaciones del usuario a través de un diálogo de aceptación o rechazo de los ítems entregados.

4.5 Aportes

En este capítulo se da cumplimiento al objetivo 3: proponer un modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales que integre los diferentes elementos y técnicas, los principales aportes son el modelo genérico con sus distintos componentes y las dos estrategias de aplicación.

5. Validaciones

Este capítulo expone la aplicación del modelo propuesto a través de las dos estrategias de aplicación presentadas en el capítulo anterior. Las estrategias trabajan con los recursos educativos digitales RED, almacenados en la Federación de Repositorios de Objetos de aprendizaje Colombia FROAC y los estudiantes que hacen parte de la Universidad Nacional de Colombia en dos de sus sedes Manizales y Medellín. Además, se contó con la participación de estudiantes de la Universidade Feevale, en Novo Hamburgo, Brasil. En la estrategia de selección, se valida en conjunto una propuesta de sistema de argumentación con persuasión y conversación. Por otro lado, en la estrategia de integración, se realizan pruebas cuando se conoce la información de los usuarios y cuando es un nuevo usuario.

5.1 Métricas de validación utilizadas

Para realizar la validación al modelo propuesto mediante las dos estrategias, se seleccionaron métricas de calidad clásicas de la recuperación de información (Gunawardana & Shani, 2015) (Drachsler et al., 2009). Estas métricas pueden clasificarse en medidas de relevancia y en medidas de predicción.

5.1.1 Medidas de relevancia

La relevancia es entendida como la importancia que tiene un recurso para apoyar el proceso de aprendizaje de un estudiante específico, adaptándose a sus preferencias y necesidades, la relevancia es determinada por los estudiantes que califican dicho factor. Entre ellas se encuentran (Aggarwal, 2016):

- **Precisión:** la precisión se calcula como el cociente del número de ítems relevantes para el usuario sobre el total de ítems entregados, puede interpretarse como el porcentaje de elementos recomendados que verdaderamente resultan relevantes

para el estudiante. Entre más cercano a 1 este la precisión es mejor la técnica de recomendación. En la fórmula 1 se presenta la precisión.

$$Precisión = \frac{Recursos\ relevantes\ recuperados}{Recursos\ recuperados} \quad (1)$$

- **Recall:** para utilizar esta medida se debe conocer, previamente, del conjunto de posibles resultados, cuántos son relevantes para el estudiante. Al igual que en la precisión entre más cercano a 1 es mejor la recomendación (Ver fórmula 2).

$$Recall = \frac{Recursos\ relevantes\ recuperados}{Recursos\ relevantes} \quad (2)$$

- **F1-score:** es la media armónica ponderada de precisión y recall, donde tiende a 1 cuando el numerador es igual al denominador, indicando una mejor recomendación debido que un aumento en la medida de recall, no siempre lleva a una reducción en la precisión (Ver fórmula 3).

$$F1 - score = \frac{2 * Precisión * Recall}{Precisión + Recall} \quad (3)$$

5.1.2 Medidas de predicción

Existen varias medidas que han sido utilizadas para evaluar la calidad de la predicción, llamada también rendimiento, de los sistemas de recomendación (Adomavicius & Tuzhilin, 2005). La medida más utilizada es el error medio absoluto (Mean Absolute Error, MAE) que permite medir la desviación de las recomendaciones predichas con los valores reales, a menor MAE mejor predicción del sistema (Ver fórmula 4).

$$MAE = \frac{1}{N}\sum_{i=1}^{N} |x_i - \hat{x}_i| \quad (4)$$

Comúnmente, las evaluaciones de los usuarios a los ítems se dividen en un conjunto de entrenamiento utilizado para aprender y un conjunto de pruebas usado para evaluar la calidad de las predicciones midiendo el error absoluto promedio entre la calificación real y la predicción (Ricci et al., 2011).

5.2 Validación estrategia de selección

En la estrategia de selección, se propuso una metodología para la creación de modelos de recomendación híbrida y adaptativa de recursos educativos, para hacer su validación se aplicó el modelo a tres casos de estudio.

5.2.1 Caso de estudio 1

El primer caso de estudio que se propone, tiene en cuenta el algoritmo computacional de razonamiento basado en casos (RBC), donde se aprovechan las experiencias positivas de los estudiantes que tienen características similares para mejorar la relevancia de los recursos recomendados.

Siguiendo el modelo propuesto en la estrategia 1, según la metodología, las características de los usuarios seleccionadas son: nivel educativo, estilo de aprendizaje, preferencias de idioma, formato e interactividad e igualmente las evaluaciones previas dadas a los recursos. Las técnicas de recomendación utilizadas son el filtrado colaborativo, la similitud por características demográficas, el conocimiento del usuario y basado en contenido teniendo en cuenta el historial. El enfoque híbrido es en secuencia, donde cada información de los usuarios con los ítems es almacenada en la base de casos.

Este caso de estudio puede verse en la Figura 5.1, donde primero están los perfiles de los usuarios; después, el sistema de recomendación en el cual se aplica las fases del RBC y finalmente se tiene la federación de repositorios FROAC, para la selección de recursos.

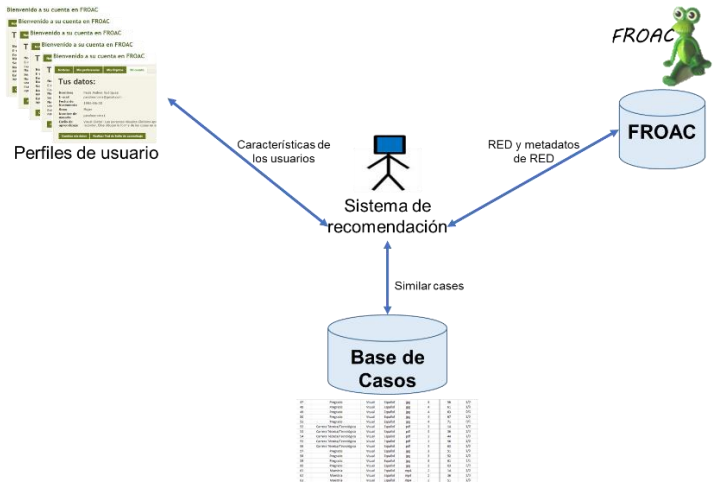

Figura 5.1 Caso de estudio 1

Fuente: elaboración propia.

Para aplicar el algoritmo de RBC, inicialmente, se definen la estructura del caso y la ponderación de las características. Para dar una relevancia diferente a las características, los pesos se asignan y se toman en cuenta al calcular la similitud general entre los casos. Los pesos se asignan de acuerdo con la experiencia en trabajos previos del grupo de investigación y, además, se asignan por la relevancia que cada característica tiene para el trabajo, de la siguiente manera: nivel de educación (0.3), estilo de aprendizaje (0.3), preferencia de idioma (0.2), preferencia de formato (0.05) y preferencia del nivel entre actividades (0.15). En Figura 5.2 se presenta el RBC que realiza la recomendación.

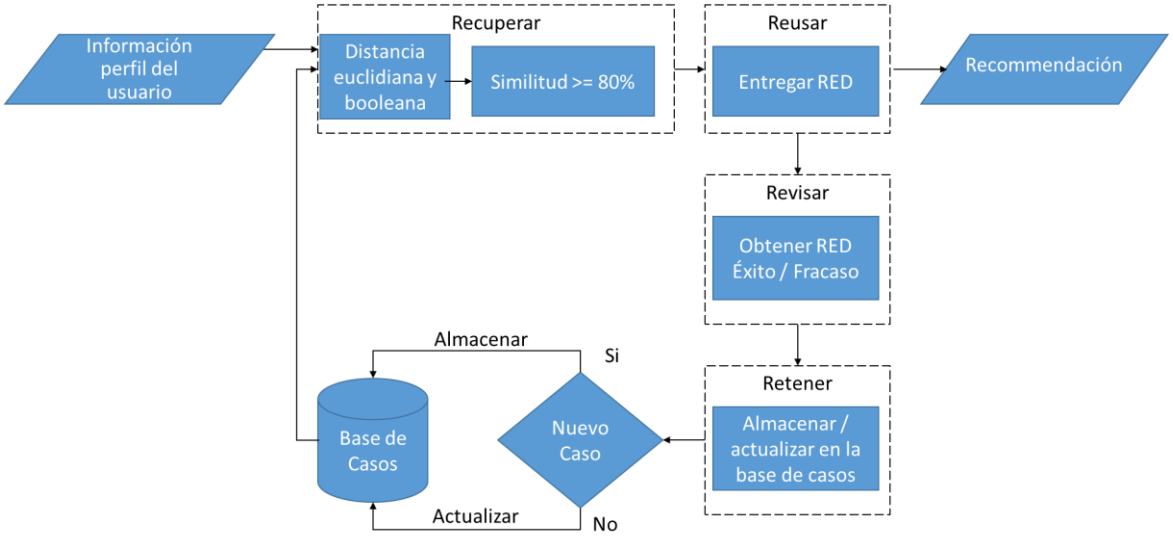

Figura 5.2 Recomendación utilizando RBC

Fuente: elaboración propia

A continuación, se explican las fases que se ejecutan.

- **Recuperación:** lo primero que se hace en esta fase es identificar las características del estudiante (caso problema). Después, se busca en la base de casos los que sean más cercanos al problema; el caso es recuperado considerando la suma más grande de los pesos de cada una de las características que coinciden con el nuevo caso. Para el cálculo de la similitud de las características predictivas asociadas con la preferencia de nivel de interactividad, se usa la distancia euclidiana, donde un valor más pequeño representa una mayor similitud entre los valores analizados. Para las otras características, se aplica la métrica booleana, que identifica si el caso

coincide con el caso problema. Para el cálculo de la similitud global, previamente los resultados están normalizados. Posteriormente, se identifica el caso más similar, es decir, el que tiene un valor de similitud global más alto. Si el nivel de similitud es igual a varios casos, estos se seleccionan.

- **Reutilización:** A partir de la selección de los casos similares, se identifican los recursos que serán recomendados al estudiante, esta solución se puede utilizar directamente como una solución al nuevo problema. La tarea de adaptación se ejecuta en los sistemas de RBC cuando las modificaciones a la solución son necesarias para que se pueda aplicar al nuevo caso. En la recomendación, la solución es específicamente un recurso que cubre las preferencias del usuario, por lo que no es necesario un cambio inicial, lo que implica que el proceso de adaptación se realiza en la siguiente etapa cuando se discute el caso y se determina si la solución propuesta fue adecuada o no.
- **Revisar:** este paso se realiza después de aplicar la solución del problema y consiste en la evaluación positiva / negativa del recurso por parte del usuario. Estos resultados servirán como indicadores para determinar si hubo un éxito o un fracaso en cada caso.
- **Retener:** en esta última etapa, el sistema almacena un nuevo caso en la Base de Casos teniendo en cuenta las características del perfil del estudiante y del recurso seleccionado. Se identifica si los datos de entrada tienen alguna diferencia con respecto al caso recuperado. Dependiendo de esto, cuando hay diferencias, el caso de entrada se incorpora a la base de casos indicando si fue o no un caso exitoso y quedando disponible para su selección en el proceso de la recomendación a otro estudiante. Si los datos de entrada son idénticos, solo se procede a actualizar el indicador de éxito / fracaso con el valor establecido en la etapa anterior.

Se tiene entonces, cinco características predictivas:
Nivel de educación: se refiere al nivel de educación del estudiante
Estilo de aprendizaje: la forma en que el estudiante aprende
Preferencia de idioma: idioma de preferencia de los recursos
Preferencia de formato: formato de preferencia de los recursos
Preferencia de nivel de interactividad: preferencia por la interacción con el sistema
Las características de salida u objetivos son:
id_LO: identificación del recurso recomendado

Éxitos / Fracasos: esta característica tiene la información de los éxitos y fracasos que ha tenido el recurso. Los estudiantes pueden evaluar los objetos en una escala de 1 a 5, donde 1 no le gusta/sirve y 5 le gusta/sirve. Los éxitos se toman como la calificación 4 y 5, y las fallas son las evaluaciones 1 y 2. En la Tabla 5-1 se presenta un fragmento de la base de casos, en total se cuenta con 153 casos.

Tabla 5-1 Fragmento de la base de casos.

id_ caso	Nivel educativo	Estilo de aprendizaje	Preferencia de idioma	Preferencia de formato	Preferencia nivel interactividad	id_ recurso	Éxito/ Fracaso
1	Básica Primaria	Lector	Español	jpg	4	52	1/0
2	Educación Superior	Lector	Español	mp4	2	40	1/0
3	Educación Superior	Lector	Español	mp4	2	41	1/0
4	Educación Superior	Lector	Español	mp4	2	42	1/0
5	Pregrado	Auditivo	Español	mp4	4	9	1/0
6	Pregrado	Visual	Español	jpg	3	71	3/0
7	Pregrado	Visual	Español	jpg	2	36	1/0
8	Educación Superior	Auditivo	Español	mp4	1	71	1/0
9	Básica Secundaria	Visual	Español	mp4	5	71	1/0
10	Carrera Técnica/Tecnológica	Visual	Español	pdf	3	67	1/0
11	Carrera Técnica/Tecnológica	Visual	Español	pdf	3	71	2/1
12	Doctorado	Visual	Español	pdf	2	14	1/0
13	Doctorado	Visual	Español	pdf	2	36	1/0
14	Doctorado	Visual	Español	pdf	2	51	1/0
15	Pregrado	Auditivo	Español	mp4	1	63	1/0
16	Pregrado	Auditivo	Español	mp4	1	67	1/0
17	Doctorado	Visual	Español	pdf	3	63	1/0
18	Pregrado	Visual	Español	jpg	4	63	0/1
19	Pregrado	Visual	Español	jpg	4	67	1/0
20	Pregrado	Visual	Español	jpg	4	71	0/1
21	Carrera Técnica/Tecnológica	Visual	Español	pdf	3	14	1/0
22	Pregrado	Visual	Español	jpg	3	61	1/1
23	Pregrado	Visual	Español	jpg	3	63	2/0
24	Maestría	Visual	Español	mp4	2	14	1/0
25	Educación Superior	Visual	Portugués	pdf	3	67	1/0
26	Educación Superior	Visual	Portugués	pdf	3	71	1/0
27	Pregrado	Visual	Español	pdf	4	9	2/0
…	…	…	…	…	…	…	…

Para mostrar el funcionamiento del sistema de recomendación con RBC, se seleccionó un usuario con las siguientes características: nivel de educación: Doctorado, estilo de aprendizaje: Visual, preferencia de idioma: español, preferencia de formato: *pdf* y preferencia de nivel de interactividad: 2. El sistema realiza la verificación en la base da casos para encontrar los más similares. En la Tabla 5-2 se presenta la similitud de los casos con el caso problema y los valores de similitud para este usuario específico.

Tabla 5-2 Similitud de casos con el caso problema

id_ caso	Nivel educativo	Estilo de aprendizaje	Preferencia de idioma	Preferencia de formato	Preferencia nivel interactividad	id_ recurso	Éxito/ Fracaso	Similitud
28	**Doctorado**	**Visual**	**Español**	**pdf**	**2**	**14**	**1/0**	**1**
29	**Doctorado**	**Visual**	**Español**	**pdf**	**2**	**36**	**1/0**	**1**
30	**Doctorado**	**Visual**	**Español**	**pdf**	**2**	**51**	**1/0**	**1**
31	**Doctorado**	**Visual**	**Español**	**pdf**	**2**	**56**	**1/0**	**1**
40	**Doctorado**	**Visual**	**Español**	**pdf**	**3**	**14***	**1/0**	**0,9625**
41	**Doctorado**	**Visual**	**Español**	**pdf**	**3**	**36**	**1/0**	**0,9625**
42	**Doctorado**	**Visual**	**Español**	**pdf**	**3**	**56***	**1/0**	**0,9625**
43	**Doctorado**	**Visual**	**Español**	**pdf**	**3**	**63**	**1/0**	**0,9625**
105	Educación Superior	Visual	Español	pdf	2	14	2/0	0,7
106	Educación Superior	Visual	Español	pdf	2	27	1/0	0,7
107	Educación Superior	Visual	Español	pdf	2	51	2/0	0,7
108	Educación Superior	Visual	Español	pdf	2	56	2/0	0,7
109	Educación Superior	Visual	Español	pdf	2	63	2/0	0,7
128	Educación Superior	Visual	Español	pdf	2	36	1/1	0,70

Los mejores recursos para el usuario específico son: 14, 36, 51, 56 y 63. Sin embargo, el usuario activo ya ha calificado los recursos 36, 51 y 63; el resultado de la recomendación son los recursos con los identificadores: 14 y 56. En la Figura 5.3, se muestra la interfaz del sistema de recomendación de recursos, donde se le entregan al usuario los recursos. En esta interfaz, el título se presenta con el enlace de acceso; además, como parte de la habilidad de argumentación, se entrega la cantidad de usuarios similares a los que les gustó el objeto (éxito) y el número de usuarios que no les gustó el objeto (fracasos), esto con el objetivo de que el estudiante tome la decisión de acceder o no al recurso.

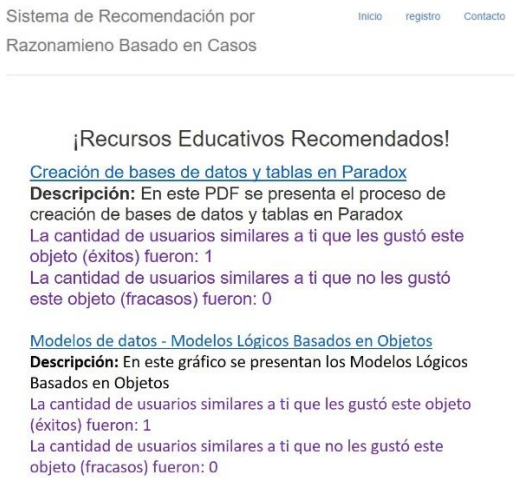

Figura 5.3 Interfaz de entrega de los recursos

Con este trabajo se presenta el gran potencial del modelo genérico propuesto, donde se pueden integrar diferentes técnicas, enfoques y algoritmos para crear nuevos modelos de recomendación que entreguen recursos que apoyen el aprendizaje de los estudiantes. Específicamente, en este caso de estudio se demuestra la posibilidad de utilizar RBC para implementar un sistema de recomendación híbrido que contemple información demográfica y de historial, donde se tenga en cuenta los casos existentes.

5.2.2 Caso de estudio 2

Este caso de estudio se refiere a un sistema de recomendación híbrido basado en reglas donde se propone un método híbrido para entregar los resultados según la teoría de la argumentación, combinando las técnicas basadas en conocimiento, información demográfico y basado en contenido. En la Figura 5.4 se presentan los primeros pasos de la estrategia, donde se identifican las características de los usuarios y de los ítems, además la selección de las técnicas de recomendación a utilizar.

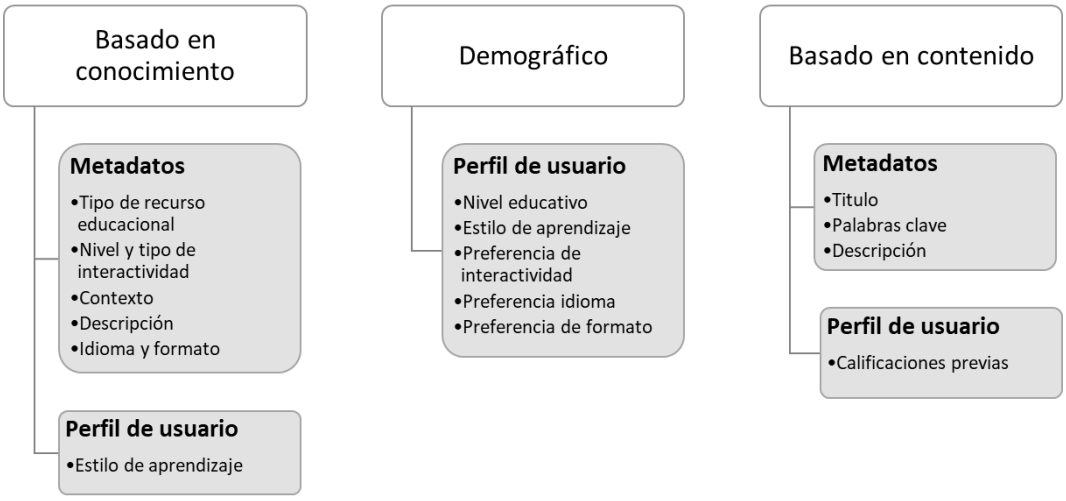

Figura 5.4 Características y técnicas seleccionadas

Fuente: elaboración propia

Se identificó que el enfoque híbrido a utilizar es uno paralelo, donde cada técnica se ejecuta de manera individual y los resultados son combinados. Asimismo, el algoritmo de computación seleccionado fue minería de datos, aplicando reglas de decisión para la técnica basada en conocimiento y medidas de similitud entre usuarios para la técnica demográfica con la medida de *overlap* y similitud entre ítems para la técnica basada en

contenido, utilizando la medida distancia del coseno. El desempeño de este modelo se realizó a través de la precisión, recall y f1-score.

Para aplicar este sistema se seleccionaron 29 estudiantes de la Universidad Nacional de Colombia con las siguientes características y distribución.

- **Nivel de educativo**, se contó con estudiantes de pregrado de las carreras de administración de sistemas informáticos (55%) e ingeniería eléctrica (24%), estudiantes de maestría (14%) y de doctorado en ingeniería de sistemas (7%).
- **Estilo de aprendizaje**, se refiere a la preferencia para procesar la nueva información, se calcula aplicando el test de estilos de aprendizaje de VARK (Fleming & Baume, 2006), la distribución para el estilo de aprendizaje es:
    - Auditivos 31%
    - Kinestésico 7%
    - Lector 10%
    - Visual 52%
- **Preferencias**, además, para caracterizar los estudiantes se les pidió explícitamente algunas preferencias como:
    - **Interactividad:** preferencia relativa a la interacción con el recurso, baja interactividad 48% y alta interactividad 52%
    - **Idioma**: español 90% e inglés 10%
    - **Formato**: jpg 38%, mp4 38% y pdf 24%

Se contó con 312 calificaciones, realizadas a 75 recursos educativos almacenados en una instancia de FROAC (N. Duque et al., 2014; Tabares et al., 2015) disponible en: http://froac.manizales.unal.edu.co/froacPruebas/froacnPruebas/

Además, en este caso, se plantea una propuesta de argumentación basada en reglas por cada una de las técnicas de recomendación y se agrega una regla general de calidad del recurso y su costo. En la Tabla 5-3 se presentan las reglas definidas para cada una de las técnicas de recomendación. Un ejemplo de uso de las reglas propuestas es:

Recomendar (Paula, RED_i) ← educacionalmente_adecuado (Paula, RED_i) ^ generalmente_adecuado (RED_i)

Educacionalmente_adecuado ← (Paula, RED_i) recurso_apropiado (paula, RED_i) ^ Interactividad_apropiada (paula, RED_i).

Recurso_apropiado (paula, RED_i) ← Tipo_usuario (Paula, visual) ^ Tipo de recurso (RED_i, presentación), Interactividad_apropiada (paula, RED_i) ← Tipo_usuario (Paula, visual) ^ tipo_interactividad (RED_i, bajo)

Generalmente_adecuado (RED_i) ← estructura (RED_i, atómica) ^ estado (RED_i, final)

Tabla 5-3 Reglas de argumentación definidas

	Reglas generales
G1	~recomendar (usuario, RED) ← cost (RED) > 0
G2	~recomendar (usuario, RED) ← métrica calidad (RED) < 0.7
	Reglas conocimiento
A1	recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED) A1.1. educacionalmente_adecuado (usuario, RED) ← recurso_apropiado (usuario, RED) ^ interactividad_apropiada (usuario, RED) A1.1.1 recurso_apropiado (usuario, RED) ← tipo_recurso_usuario (usuario, tipo)^tipo_recurso (RED, tipo) A1.1.2 interactividad_apropiada (usuario, RED) ← interactividad_recurso_usuario (usuario, interactividad) ^ interactividad_recurso (RED, interactividad) A1.2. generalmente_adecuado (RED) ← estructura (RED,atomica) ^ estado(RED, final)
A2	Recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED) ^ tecnicamente_adecuado (usuario,RED) A2.1: tecnicamente_adecuado (usuario,RED) ← idioma_adecuado (usuario, RED) ^ formato_adecuado (RED) A2.1.1: idioma_adecuado (usuario, RED) ← preferencia_idioma (usuario, idioma) ^ idioma_recurso (RED, idioma) A2.1.2: formato_adecuado(RED) ← preferencia_formato (usuario, formato) ^ formato_recurso (RED, formato)
A3	Recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED) ^ actualizado (RED) A3.1: actualizado (RED) ← fecha (RED, fecha) < 5 years
A4	Recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED) ^ tiempo de aprendizaje_adecuado (RED) A4.1: tiempo de aprendizaje_adecuado (RED) ← horas(RED) < 1
	Reglas demográfico
B1	Recomendar (usuario1, RED)← similitud(usuario1, usuario2) > 0,7 ^ calificación (usuario2, RED)>= 4

Reglas contenido	
C1	Recomendar (usuario1, RED1)← similitud(RED1, RED2) > 0,7 ^ calificación (usuario1,RED2)>= 4

En la Tabla 5-4 se presenta el esquema de explicaciones dadas a los estudiantes en el momento de hacer la recomendación.

Tabla 5-4 Esquema de explicaciones

Id	Regla	Técnica	Argumento
1	A1	Conocimiento	El RED se ajusta al tema, es adecuado para el estilo de aprendizaje y su estado es atómico y está estable
2	A2	Conocimiento	El RED se ajusta al tema, es adecuado para el estilo de aprendizaje y se ajusta a las preferencias de formato e idioma
3	A3	Conocimiento	El RED se ajusta al tema, es adecuado para el estilo de aprendizaje, se ajusta a las preferencias de formato e idioma y además esta actualizado
4	A4	Conocimiento	El RED se ajusta al tema, es adecuado para el estilo de aprendizaje, se ajusta a las preferencias de formato e idioma y además su tiempo de aprendizaje es menos a 1 hora
5	B1	Demográfico	El sistema encontró usuarios similares por las características demográficas y este le gustó el RED
6	C1	Contenido	El sistema encontró RED similares a los evaluados en el pasado

Después de implementar el sistema, se les pidió a los estudiantes que interactuaran con la aplicación y evaluaran el RED de acuerdo a la relevancia del recurso para su proceso de aprendizaje. Se realizaron pruebas del top 5 (Tabla 5-5) y del top 10 (Tabla 5-6).

Tabla 5-5 Resultados Top 5

	Aleatorio	Conocimiento	Demográfico	Contenido	Híbrido con argumentación
Precisión	0,0896	0,1241	0,1172	0,5310	**0,6620**
Recall	0,0630	0,1105	0,1262	0,3836	**0,5138**
F1-score	0,0740	0,1169	0,1215	0,4454	**0,57860**

Tabla 5-6 Resultados Top 10

	Aleatorio	Conocimiento	Demográfico	Contenido	Híbrido con argumentación
Precisión	0,0931	0,0908	0,1245	0,3853	**0,4494**
Recall	0,10760	0,1962	0,2173	0,4956	**0,6111**
F1-score	0,09983	0,1241	0,1583	0,4336	**0,5179**

En este caso de estudio se ve una mejora significativa al entregar los RED relevantes para los estudiantes utilizando el enfoque híbrido a través de la argumentación, además se vio gran aceptación con las explicaciones dadas. La técnica basada en contenido da muy buenos resultados, debido a que previamente se les pidió a los estudiantes calificar un promedio de 8 RED, entregados aleatoriamente, con el objetivo de tener evaluaciones previas para aplicar las técnicas de contenido y conocimiento, igualmente, el sistema no realiza un filtro para no recomendar RED previamente evaluados, así, entonces, al calcular la similitud en el top 5 y 10, los primeros recursos entregados fueron aquellos evaluados previamente por el usuario.

También se utilizó el sistema de argumentación como un enfoque híbrido, dando pesos a los argumentos que se ejecutan; teniendo en cuenta la Tabla 5-3 donde se presentan los argumentos, se puede dar un peso a la recomendación sumando cada uno de los tipos de argumentos así: R=((A1+A2+A3+A4)/4)+B1+C1. Los RED candidatos a ser recomendados se presentan ordenados según estos pesos dados. Igualmente se obtuvo muy buenos resultados contrastando con los diferentes enfoques híbridos que trabajan en paralelo. Los resultados se presentan en la Tabla 5-7 y la Tabla 5-8 con el top 5 y top 10, respectivamente.

Tabla 5-7 Resultados enfoques híbridos top 5

	Aleatorio	Ponderado	Conmutación	Mixto	Cascada	Intersección de resultados	Híbrido con argumentación
Precisión	0,1931	0,2469	0,2556	0,3997	0,0211	0,1609	**0,6744**
Recall	0,1502	0,2541	0,2551	0,4051	0,0219	0,1795	**0,6694**
F1-score	0,1690	0,2505	0,2554	0,4024	0,0215	0,1697	**0,6719**

Tabla 5-8 Resultados enfoques híbridos top 10

	Aleatorio	Ponderado	Conmutación	Mixto	Cascada	Intersección de resultados	Híbrido con argumentación
Precisión	0,2310	0,2931	0,2637	0,3057	0,0842	0,3160	**0,4494**
Recall	0,3254	0,2895	0,4413	**0,7058**	0,0379	0,1082	0,6111
F1-score	0,27022	0,2913	0,3301	0,4267	0,0523	0,1612	**0,5179**

Con estos resultados, se puede observar que el enfoque mixto tiene buenos resultados en la medida del recall. El motivo puede ser que este enfoque recupera todos los resultados de las tres técnicas de recomendación utilizadas y las presenta en orden aleatorio al estudiante, en estas pruebas sucedió que el orden aleatorio, puso RED relevantes en la parte superior de la lista de 10 recomendaciones.

5.2.3 Caso de estudio 3

En este caso, se pretende validar un sistema de recomendación conversacional, el cual se desarrolló teniendo en cuenta el modelo propuesto, las técnicas de recomendación siguen siendo: demográfico, contenido y conocimiento, el enfoque híbrido es paralelo, donde se distingue cada recurso entregado por cada técnica aplicada. Además, se tienen en cuenta las argumentaciones propuestas en el caso anterior.

Para la evaluación, se implementó un prototipo del sistema conversacional utilizando 75 recursos de FROAC, relacionados con áreas de sistemas, bases de datos y programación; se tomaron sus metadatos de título, descripción, palabras claves, nivel de interactividad, tipo de recurso, formato e idioma.

Un número de 50 estudiantes de la Universidad Nacional de Colombia – Sede Manizales realizaron su registro en el sistema, llenando los campos relacionados con su nivel educativo, tópicos de interés (palabras clave), preferencias y respondiendo el test de estilos de aprendizaje de VARK, la información del perfil del usuario es la siguiente:

- **Información personal:** identificación, nombre, fecha de nacimiento, email, sexo, idioma, localización geográfica.
- **Preferencias:**
    - Nivel de interactividad: donde 3 estudiantes prefieren los recursos con baja interactividad, 38 con un nivel medio de interactividad y 9 con alta interactividad

  - Idioma: todos los estudiantes tienen preferencia por español, debido a que es su idioma nativo
  - Formato: 9 estudiantes seleccionaron jpg como su formato preferido, 31 pdf, 8 mp4 y 2 otros formatos.
- **Estilo de aprendizaje:** para el estilo de aprendizaje se obtuvo una distribución de 25 estudiantes visuales, 6 auditivos, 12 lectores y 7 estudiantes kinestésicos.
- **Historial:** se identificaron el id del recurso evaluado previamente, el valor de la calificación y la fecha en que fue utilizado.

Ahora, se presenta en la Tabla 5-9, el sistema conversacional propuesto, donde el estudiante interactúa según los resultados de recomendación entregados, se debe tener en cuenta que no se entregan explicaciones para todos los argumentos, sino solo para aquellas reglas que representan "hojas" en el árbol de reglas, debido a que representan los predicados más profundos que hacen parte de las reglas más generales de recomendación. Es una decisión de diseño simple que reduce la complejidad del diálogo y mejorar la expresividad del sistema.

Tabla 5-9 Reglas, explicaciones y respuestas del sistema conversacional

Reglas generales
G1. Recomendar (usuario, RED) ← cost (RED) = 0 **Explicación:** *"Este recurso puede interesarte porque es libre"* **Respuestas:** +RG1: *"Acepto el recurso"* ~RG1: *"No estoy seguro, no me interesa el costo"* -RG1: *"Rechazo el recurso. No me gusta"*
G2. Recomendar (usuario, RED) ← métrica calidad (RED) >= 0.7 **Explicación:** *"Este recurso puede interesarte porque su calidad es alta"* **Respuestas:** +RG2: *"Acepto el recurso"* ~RG2: *"No estoy seguro, no me interesa la calidad"* -RG2: *"Rechazo el recurso. No me gusta"*
Reglas conocimiento
A1. Recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED)
A1.1. educacionalmente_adecuado (usuario, RED) ← recurso_apropiado (usuario, RED) ^ interactividad_apropiada (usuario, RED)

A1.1.1 recurso_apropiado (usuario, RED) ← tipo_recurso_usuario (usuario, tipo)^tipo_recurso (RED, tipo) **Explicación:** *"Este recurso puede interesarte porque es un [tipo de recurso], el cual se ajusta a tu estilo de aprendizaje: [estilo de aprendizaje]"* **Respuestas:** +RA1.1.1: *"Acepto el recurso"* ~RA1.1.1: *"No estoy seguro, muéstrame más razones"* -RA1.1.1: *"Rechazo el recurso. Yo prefiero los recursos de tipo [tipo]"*
A1.1.2 interactividad_apropiada (usuario, RED) ← interactividad_recurso_usuario (usuario, interactividad) ^ interactividad_recurso (RED, interactividad) **Explicación:** *"Este recurso puede interesarte porque tiene interactividad [interactividad], la cual se ajusta a tu preferencia de interactividad: [interactividad]"* **Respuestas:** +RA1.1.2: *"Acepto el recurso"* ~R A1.1.2: *"No estoy seguro, muéstrame más razones"* -R A1.1.2: *"Rechazo el recurso. Yo prefiero los recursos de interactividad [interactividad]"*
A1.2. generalmente_adecuado (RED) ← estructura (RED,atomica) ^ estado(RED, final) **Explicación:** *"Este recurso puede interesarte porque es auto contenido"* **Respuestas:** +RA1.2: *"Acepto el recurso"* ~RA1.2: *"No estoy seguro, muéstrame más razones"* -RA1.2: *"Rechazo el recurso. No me gusta"*
A2. Recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED) ^ tecnicamente_adecuado (usuario,RED)
A2.1: tecnicamente_adecuado (usuario,RED) ← idioma_adecuado (usuario, RED) ^ formato_adecuado (RED)
A2.1.1: idioma_adecuado (usuario, RED) ← preferencia_idioma (usuario, idioma) ^ idioma_recurso (RED, idioma) **Explicación:** *"Este recurso puede interesarte porque se ajusta a tu preferencia de idioma"* **Respuestas:** +RA2.1.1: *"Acepto el recurso"* ~RA2.1.1: *"No estoy seguro, muéstrame más razones"* -RA2.1.1: *"Rechazo el recurso. Yo prefiero los recursos de idioma [idioma]"*
A2.1.2: formato_adecuado(RED) ← preferencia_formato (usuario, formato) ^ formato_recurso (RED, formato) **Explicación:** *"Este recurso puede interesarte porque se ajusta a tu preferencia de formato"* **Respuestas:** +RA.2.1.2: *"Acepto el recurso"* ~RA.2.1.2: *"No estoy seguro, muéstrame más razones"*

-RA.2.1.2: *"Rechazo el recurso. Yo prefiero los recursos de formato [formato]"*
A3. Recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED) ^ actualizado (RED)
A3.1: actualizado (RED) ← fecha (RED, fecha) < 5 years **Explicación:** *"Este recurso puede interesarte porque es actual"* **Respuestas:** +RA3.1: *"Acepto el recurso"* ~RA3.1: *"No estoy seguro, no me interesa que el recurso sea actual"* -RA3.1: *"Rechazo el recurso. No me gusta"*
A4. Recomendar (usuario, RED) ← educacionalmente_adecuado (usuario, RED) ^ generalmente_adecuado (RED) ^ tiempo de aprendizaje_adecuado (RED)
A4.1: tiempo de aprendizaje_adecuado (RED) ← horas(RED) < 1 **Explicación:** *"Este recurso puede interesarte porque su duración es menor a una hora"* **Respuestas:** +RA4.1: *"Acepto el recurso"* ~RA4.1: *"No estoy seguro, no me interesa la duración del recurso"* -RA4.1: *"Rechazo el recurso. No me gusta"*
Reglas demográfico
B1. Recomendar (usuario1, RED) ← similitud (usuario1, usuario2) > 0,7 ^ calificación (usuario2, RED)>= 4 **Explicación:** *"Este recurso puede interesarte porque le gustó a usuarios similares a ti"* **Respuestas:** +RB: *"Acepto el recurso"* ~RB: *"No estoy seguro, dame más razones"* -RB: *"Rechazo el recurso. No me gusta"*
Reglas contenido
C1. Recomendar (usuario1, RED1) ← similitud (RED1, RED2) > 0,7 ^ calificación (usuario1, RED2) >= 4 **Explicación:** *"Este recurso puede interesarte porque es similar a [RED2] que te gustó en el pasado"* **Respuestas:** +RC: *"Acepto el recurso"* ~RC: *"No estoy seguro, dame más razones"* -RC: *"Rechazo el recurso. No me gusta"*

Se realiza un encadenamiento hacia atrás de las reglas y los hechos para derivar argumentos que respaldan las recomendaciones, esto permite establecer un proceso conversacional entre el sistema y el usuario. Mediante este proceso, el sistema puede obtener las preferencias reales del usuario y le permite corregir las suposiciones erróneas del sistema. Se estableció el siguiente orden de prioridad para las reglas y sus explicaciones asociadas (como resultado de las posibles combinaciones entre los diferentes tipos de reglas):

P1: primero mostrar argumentos que se ajusten al perfil del estudiante y sus preferencias (argumentos basados en conocimiento) A1.1.1 > A1.1.2 > A1.2 > A2.1.1 > A2.1.2 > A3.1 > A4.1 > B1 > C1 > G1 > G2

P2: primero mostrar argumentos que se ajusten al perfil y preferencias de los usuarios similares (argumentos recomendación demográfica): B1 > A1.1.1 > A1.1.2 > A1.2 > A2.1.1 > A2.1.2 > A3.1 > A4.1 > C1 > G1 > G2

P3: primero mostrar argumentos que se ajusten al historial de uso del usuario (argumentos contenido): C1 > A1.1.1 > A1.1.2 > A1.2 > A2.1.1 > A2.1.2 > A3.1 > A4.1 > B1 > G1 > G2

P4: primero mostrar argumentos generales de costo y calidad: G1 > G2 > A1.1.1 > A1.1.2 > A1.2 > A2.1.1 > A2.1.2 > A3.1 > A4.1 > B1 > C1

Una vez que los estudiantes se registraron, las pruebas de evaluación fueron realizadas de la siguiente manera. Cada estudiante participó en promedio en 10 procesos o iteraciones de recomendación, donde el sistema entregó recursos que coincidían con su perfil, según las técnicas y reglas expuestas anteriormente. En cada iteración, el sistema presentó al azar una explicación asociada del recurso al estudiante y se le pedía que primero respondiera a la conversación, es decir, aceptar el recurso, rechazarlo o pedir más justificaciones y después evaluara el recurso en una escala de 1 a 5, donde 1 no le gustó el recurso y 5 le gustó mucho. Cuando el estudiante pedía más explicaciones, la siguiente iteración mostraba el mismo recurso con la siguiente explicación. En algunos casos, no se presentaba explicación, pero si se le daba la opción al estudiante de solicitarla.

Con este sistema, se verificaron tres objetivos principales:

- Efectividad: proporcionar recomendaciones efectivas que se ajusten al perfil de los estudiantes y los objetivos de aprendizaje.
- Persuasión: persuadir a los estudiantes a utilizar ciertos recursos.

- Capacidad de escrutinio: obtener las preferencias reales del usuario con la opción de corregir las suposiciones del sistema.

En la Figura 5.6 se muestra la diferencia de calificaciones cuando se entregan o no explicaciones, se tiene en cuenta cuando el usuario acepta el recurso, en esta prueba se valida la efectividad del sistema. Como puede observarse, los resultados son mejores al entregar una explicación al estudiante donde se diga por qué el recurso puede ser útil para él. Además, se tienen en cuenta el orden de entregar las explicaciones, en la Figura 5.6 se presentan el promedio de las evaluaciones recibidas al mostrar un orden específico.

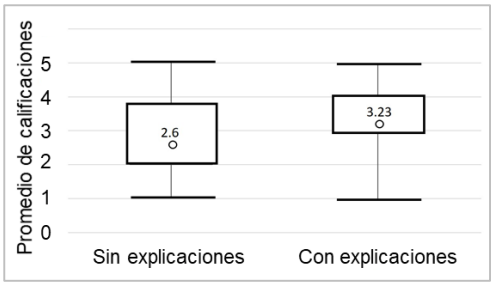

Figura 5.5 Promedio de calificaciones sin y con explicaciones

Fuente: elaboración propia

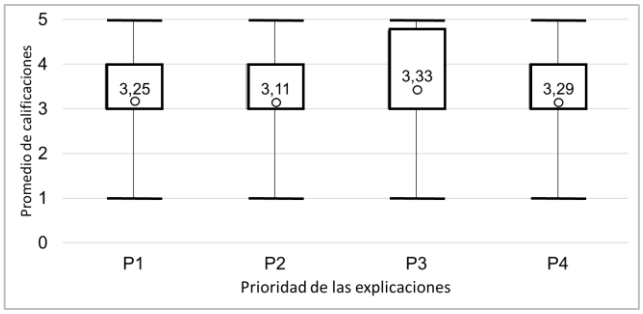

Figura 5.6 Promedio de calificaciones para cada prioridad de explicaciones

Fuente: elaboración propia

El objetivo dos de las pruebas, demuestra que tanto el sistema de recomendación conversacional puede persuadir al estudiante al presentarle más de una explicación, después del proceso de interacción, comparando la calificación inicial dada por un estudiante y la calificación final después de la “conversación”, los resultados en la Figura 5.7. Igualmente, la Figura 5.8 muestra el porcentaje promedio de estudiantes que aceptaron la recomendación en la primera iteración (sin y con explicaciones), y al final del diálogo conversacional.

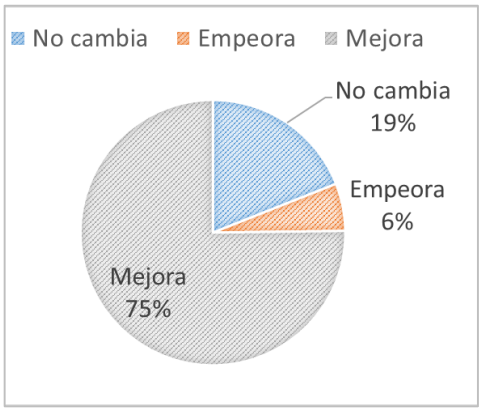

Figura 5.7 Cambio en las calificaciones desde la primera iteración hasta el final de la conversación
Fuente: elaboración propia

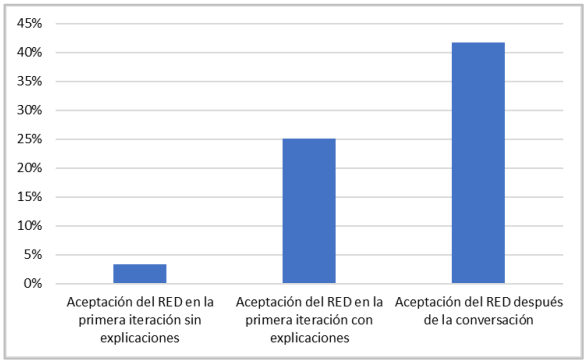

Figura 5.8 Aceptación de la recomendación
Fuente: elaboración propia

Finalmente, para validar la capacidad de escrutinio (en la conversación se da espacio para que el usuario cambie el valor de sus preferencias), se analiza el porcentaje promedio de estudiantes que rechazan los recursos cambiando alguna de sus preferencias declaradas inicialmente. Los resultados que se exhiben en la Figura 5.9 , donde se demuestra que un porcentaje significativo de estudiantes decidieron cambiar sus preferencias en cualquier iteración en el sistema (especialmente las preferencias relacionadas con el tipo de interactividad con el recurso). En promedio el 38% de los estudiantes decidió cambiar cualquier preferencia. Es importante capturar estos cambios de preferencias, debido que este dato no es estático y ayuda a entregar resultados más relevantes para el usuario.

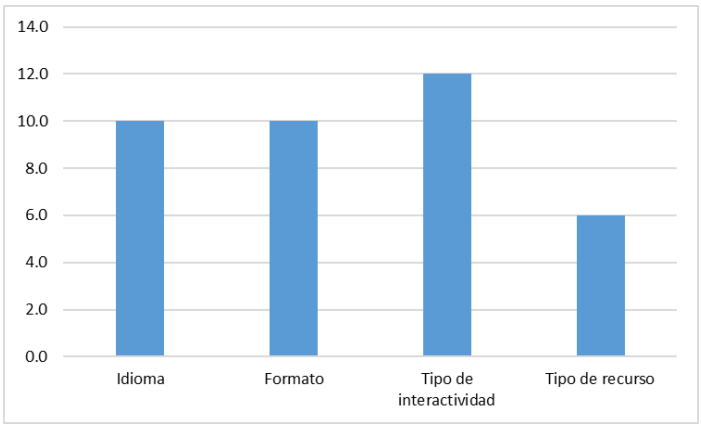

Figura 5.9 Promedio de estudiantes que cambiaron sus preferencias iniciales
Fuente: elaboración propia

En este caso de estudio, los resultados han demostrado la capacidad del sistema para proporcionar recomendaciones efectivas, además, ayuda a persuadir a los estudiantes a probar ciertos recursos y para obtener sus preferencias reales al permitirles corregir las suposiciones erróneas del sistema. La principal contribución del sistema propuesto es que permite al usuario interactuar con el sistema y aceptar o rechazar las recomendaciones, proporcionando razones para tal comportamiento.

5.3 Validación estrategia de integración

Para realizar la validación de la estrategia de aplicación del modelo propuesto a través de la integración, se creó un *dataset* con datos educativos, es decir, con la información de los usuarios, los metadatos de los RED y las calificaciones de los usuarios a los RED. Se utilizó una instancia de la plataforma resultado del proyecto (N. Duque, Ovalle & Moreno, 2017): “RAIM Implementación de un *framework* apoyado en tecnologías móviles y de realidad aumentada para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos”, desarrollado por el grupo de investigación, disponible en froac.manizales.unal.edu.co/raim-brazil/Public/searchOa, en su sección de manejo de los recursos educativos almacenados en FROAC http://froac.manizales.unal.edu.co/froacn/, donde cada estudiante debe hacer un registro de su perfil. En la Figura 5.10 se presenta el modelo del estudiante RAIM y cada una de las características que componen el perfil.

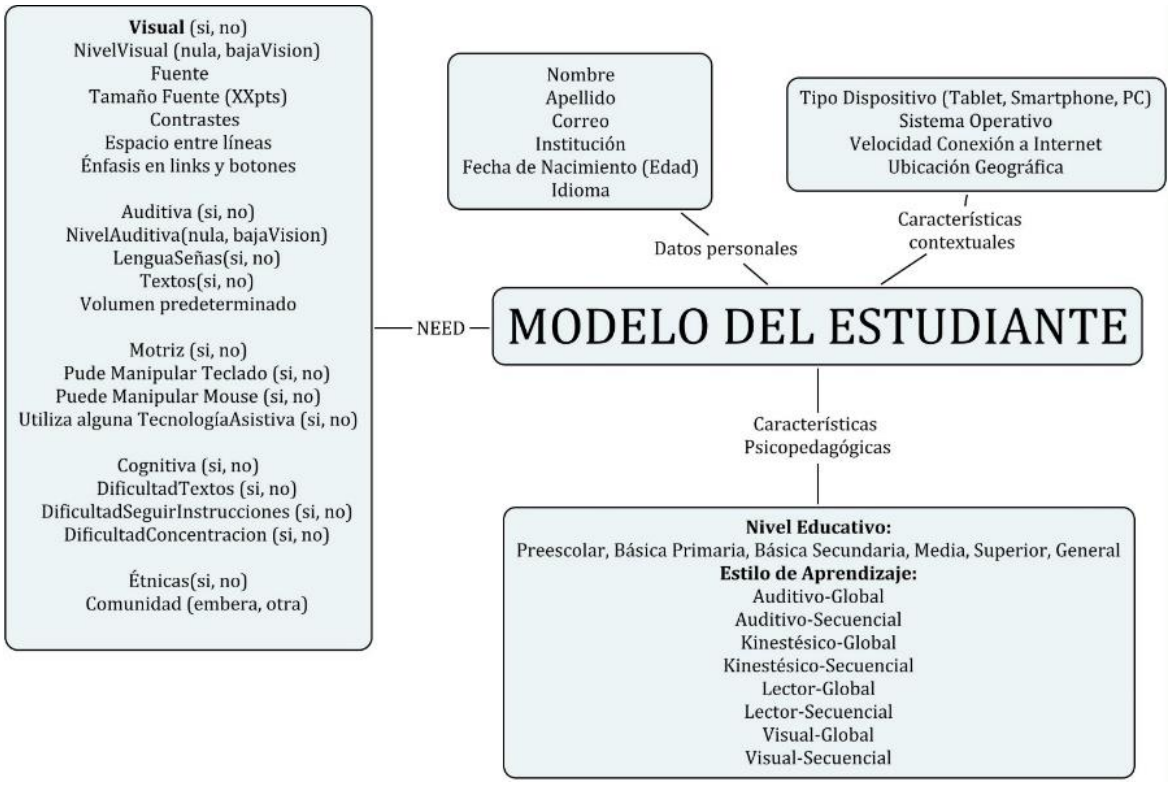

Figura 5.10 Modelo del estudiante RAIM

Fuente: (N. Duque et al., 2017)

De los recursos educativos, se toman algunos de sus metadatos, especialmente los relacionados a la categoría educacional. Muchos de los RED cosechados desde la federación FROAC, están almacenados en instancias de ROAp (Moreno, Duque & Pineda, 2012), un repositorio de objetos de aprendizaje que permite el etiquetado de los recursos y una de las características que lo diferencian de otros, es el manejo personalizado de metadatos, así en el campo descripción de la categoría educacional, el autor del RED puede definir en cuanto el recurso aporta a cada estilo de aprendizaje.

En la plataforma RAIM, los estudiantes pueden evaluar recursos educativos en cinco categorías diferentes de calificación; en la Figura 5.11 se presenta la interfaz de calificación a la que tienen acceso los estudiantes cuando reciben un RED recomendado o recuperado. La primera calificación se refiere a la valoración general del recurso, la segunda se refiere al aporte del recurso al aprendizaje, la tercera es la valoración en cuanto al diseño, la cuarta pregunta es acerca de la calidad del contenido del recurso y finalmente se le pregunta al usuario si recomendaría este recurso a otros usuarios.

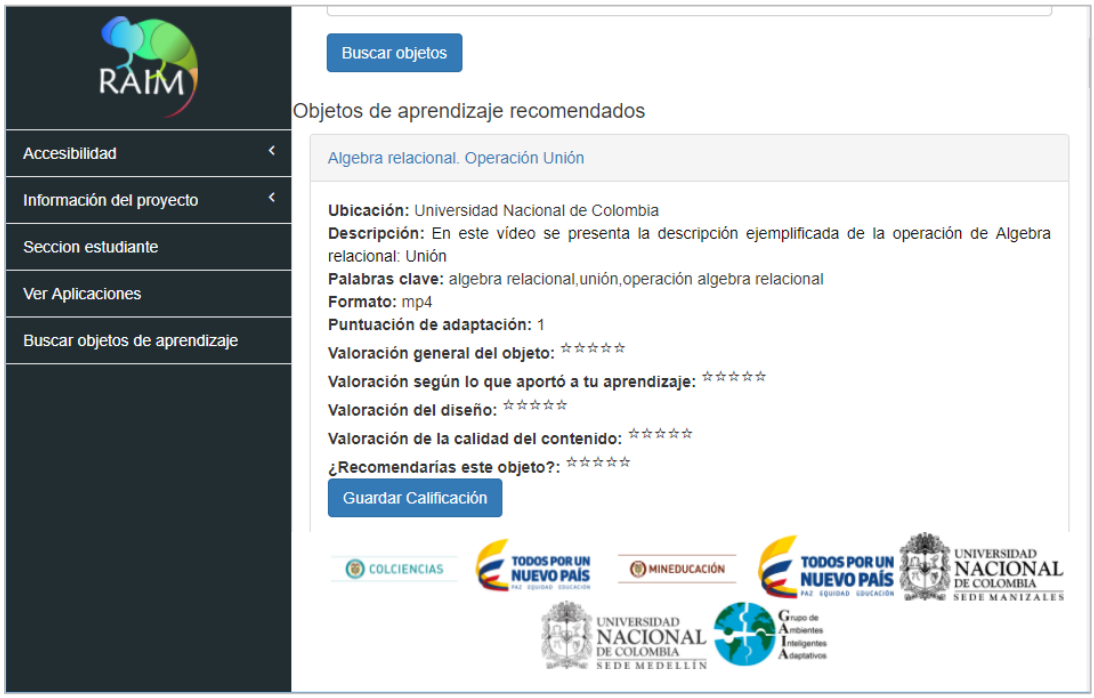

Figura 5.11 Interfaz de calificación de los RED

El *dataset* educativo, se compone entonces, de tres archivos organizados como sigue, donde la selección de las características se realizó teniendo en cuenta la experiencia previa del grupo y poniendo el estilo de aprendizaje como el factor más relevante:

- **Usuarios:** información de los usuarios, donde se omiten las informaciones personales, por cuestiones de mantener el anonimato de los estudiantes; se tiene la identificación del usuario y la distribución por los estilos de aprendizaje, según las respuestas al test propuesto en RAIM, donde se clasifica al estudiante por el test de VARK y se toman las dicotomías de Felder Silverman que se relacionan con la captura de la información: global / secuencial
  - Id_user: identificación del usuario, id único por cada uno de los usuarios
  - Visual
  - Auditivo
  - Lector
  - Kinestésico
  - Global
  - Secuencial

- **Recursos educativos**, se tienen en cuenta algunos metadatos y la descripción educativa del aporte del recurso a cada estilo de aprendizaje del test de VARK. La explicación de los metadatos es tomada de la especificación IEEE-LOM (Learning Technology Standards Committee, 2002).
    - Id_item: identificación única para cada recurso.
    - Aggregationlevel: nivel de agregación del recurso respecto a su granularidad.
    - Structure: la estructura organizativa subyacente del recurso educativo.
    - Interactivitytype: tipo de aprendizaje predominante soportado por el recurso. Aprendizaje activo, expositivo o mixto.
    - Interactivitylevel: grado de interactividad que caracteriza el recurso educativo. La interactividad en este contexto se refiere al grado en el que el estudiante puede influir en el aspecto o comportamiento del recurso.
    - Semanticdensity: el grado de concisión de RED. La densidad semántica de un objeto puede ser estimada en función de su tamaño, ámbito o – en el caso de recursos auto-regulados tales como audio y vídeo – duración. La densidad semántica de un recurso educativo es independiente de su dificultad.
    - Visual: aporte del recurso a un estudiante con estilo de aprendizaje visual.
    - Auditivo: aporte del recurso a un estudiante con estilo de aprendizaje auditivo.
    - Lector: aporte del recurso a un estudiante con estilo de aprendizaje lector.
    - Kinestésico: aporte del recurso a un estudiante con estilo de aprendizaje kinestésico.

- **Calificaciones:** en este archivo se almacenan todas las calificaciones realizadas por los usuarios a los ítems en las cinco categorías explicadas anteriormente.
    - Id_user: identificación del usuario que realizó la evaluación.
    - Id_item: identificación del recurso que recibió la evaluación.
    - Score1: valor de la calificación general.
    - Score2: valor de la calificación del aporte al aprendizaje.
    - Score3: valor de la calificación del diseño.
    - Score4: valor de la calificación de la calidad del contenido.
    - Score5: valor de la calificación si recomendaría el recurso.

El *dataset* cuenta con 400 evaluaciones realizadas por 56 usuarios, estudiantes de la Universidade Feevale y la Universidad Nacional de Colombia, a 152 RED. Con estos datos se aplica la estrategia de integración propuesta. El archivo de usuarios pasa a ser la matriz $\boldsymbol{X} \in \mathbb{R}^{56\times6}$, los recursos son $\boldsymbol{\Theta} \in \mathbb{R}^{152\times9}$, y para las calificaciones, se dividen en cada una de ellas, generando 5 matrices de evaluaciones $\boldsymbol{Y} \in \mathbb{R}^{56\times152}$. Al tener toda la información disponible (usuarios, ítems y evaluaciones) se pueden aplicar diferentes algoritmos de factorización de matrices para hacer combinaciones y estimaciones. A continuación, se presentan los diferentes modelos de recomendación propuestos en el estado del arte y se compara su rendimiento con el modelo propuesto utilizando el MAE. También, se realizan pruebas teniendo en cuenta la falta de calificaciones de los usuarios (problema de *cold-start*), donde se utiliza la similitud por características de usuario para encontrar los recursos que pueden gustarle al usuario sin evaluaciones previas. Cabe anotar, que todos los valores pasaron por un proceso de normalización con el objetivo que su rango oscile entre 0 y 5.

5.3.1 Modelo propuesto y modelos de comparación

A continuación, se presentan los parámetros del modelo de recomendación basado en factorización de matrices utilizando características de usuario, de ítems y las calificaciones. Adicionalmente, se muestran los parámetros de los tres modelos de comparación.

- **Modelo propuesto M1:** se utiliza la información tanto de ítems, $\boldsymbol{\Theta}$, como de usuarios $\mathbf{X}$ y se infiere la matriz $\boldsymbol{\Sigma} \in \mathbb{R}^{6\times9}$ para un total de 54 parámetros a estimar. $\boldsymbol{\Sigma}$ representa la relación entre las características de los ítems contra las características de los usuarios.
- **Modelo M2:** se utilizan las características de los usuarios $\mathbf{X}$, por tanto se infiere la matriz $\boldsymbol{\Theta} \in \mathbb{R}^{152\times9}$, para un total de 1368 parámetros a estimar (Feltoni Gurini et al., 2016).
- **Modelo M3:** se tienen en cuenta solo las características de los recursos, es decir la matriz $\boldsymbol{\Theta}$, entonces se estima $\boldsymbol{X} \in \mathbb{R}^{56\times6}$, con 336 parámetros (Koren et al., 2009).
- **Modelo M4:** no se tiene en cuenta ni las características de los recursos ni de los usuarios, se deben estimar entonces, $\boldsymbol{\Theta} \in \mathbb{R}^{152\times9}$ y $\boldsymbol{X} \in \mathbb{R}^{56\times6}$, con un total de 1704 parámetros (Alexandridis et al., 2017; Gu et al., 2010; Luo et al., 2014).

En la Tabla 5-10 se presenta un resumen de los modelos a comparar, con sus funciones de costo, matrices a estimar con la cantidad de parámetros.

Tabla 5-10 Modelos de recomendación basados en factorización de matrices

	Función de costo	Incógnitas	# de parámetros
M1	$\|\|(\boldsymbol{Y} - \boldsymbol{X\Sigma\Theta^T}) \odot \boldsymbol{R}\|\|_F^2 + \lambda\|\|\boldsymbol{\Sigma}\|\|_F^2$	$\boldsymbol{\Sigma}$	54
M2	$\|\|(\boldsymbol{Y} - \boldsymbol{X\Theta^T}) \odot \boldsymbol{R}\|\|_F^2 + \lambda\|\|\boldsymbol{\Theta}\|\|_F^2$	$\boldsymbol{\Theta}$	1368
M3	$\|\|(\boldsymbol{Y} - \boldsymbol{X\Theta^T}) \odot \boldsymbol{R}\|\|_F^2 + \lambda\|\|\mathbf{X}\|\|_F^2$	$\mathbf{X}$	336
M4	$\|\|(\boldsymbol{Y} - \boldsymbol{X\Theta^T}) \odot \boldsymbol{R}\|\|_F^2 + \lambda(\|\|\mathbf{X}\|\|_F^2 + \|\|\boldsymbol{\Theta}\|\|_F^2)$	$\mathbf{X}, \boldsymbol{\Theta}$	1704

5.3.2 Experimentación y validaciones

Se llevaron a cabo diferentes experimentos para comparar el modelo propuesto contra los otros modelos considerados, utilizando el promedio del error absoluto (MAE), por consiguiente, entre menor el MAE, mejor la recomendación obtenida.

En el primer experimento, se utiliza una metodología de validación cruzada de 10 particiones utilizando todas las calificaciones disponibles. Para esto, las 400 calificaciones se dividen aleatoriamente en 10 grupos de aproximadamente 40 calificaciones cada uno. Después, 9 de los 10 grupos se utilizan para entrenar el algoritmo y realizar las estimaciones de las incógnitas, mientras que el grupo restante se utiliza para la validación. El experimento se repite hasta que cada uno de los grupos sea utilizado para la validación. El segundo experimento considera el problema del nuevo usuario *cold start.* Para esto, se utilizan las calificaciones de 55 de los 56 usuarios como datos de entrenamiento, mientras que las calificaciones del usuario restante se utilizan para validar. Para calcular el valor inicial de las calificaciones del usuario de validación, se obtiene el coeficiente de correlación de Pearson (PCC) entre las características de dicho usuario y las características de todos los usuarios del conjunto de entrenamiento. Después, se promedian las calificaciones de los usuarios con el PCC superior a 0.7. El procedimiento se repite hasta que cada usuario sea utilizado para la validación.

La Figura 5.12 y Figura 5.13 se reportan los diagramas de cajas y bigotes para el MAE obtenido en los experimentos 1 y 2, respectivamente. Para cada algoritmo, se utilizaron diferentes valores del parámetro de regularización $\lambda = \{0.01, 0.1, 1, 10, 100\}$ y se reportan los mejores resultados obtenidos. En ambos casos se puede observar que el modelo más simple (M4), que no incluye las características de usuarios ni de ítems, obtiene los peores resultados. Adicionalmente, se puede observar que a medida que se va incluyendo información adicional de usuarios y/o ítems los resultados mejoran. Más aún, se observa que la información de usuarios tiene mayor influencia en la recomendación que la información de ítems. Esto se evidencia en que los resultados de M2 (con información de usuarios) mejoran los resultados de M3 (con información de ítems). Esta diferencia se nota con mayor claridad en el experimento dos, donde incluir información de ítem no mejora los resultados del modelo que considera únicamente las calificaciones disponibles en el entrenamiento (M4). Este comportamiento se puede explicar dado que, en el experimento del *cold start*, la información de usuario también se utiliza para dar la estimación inicial de las calificaciones dadas por el usuario de validación. Por último, se puede observar que el modelo propuesto (M1), que utiliza tanto la información de usuarios como la información de ítems obtiene, de forma general, los mejores resultados, lo que implica una mejor recomendación.

Estos resultados se mantienen para las cinco clases de calificaciones consideradas. Donde C1 es la calificación general, C2 es la calificación respecto al aporte en el aprendizaje, C3 es la calificación respecto al diseño, C4 es la calificación de la calidad del contenido y C5 es la calificación si recomendaría el recurso o no. Se agregó, además, una ponderación de las 5 calificaciones con el objetivo de incluir aún más información de los usuarios en el modelo y que este sea más general. Primero se ponderaron las calificaciones con un valor igual, como si todas las evaluaciones tuviesen la misma importancia dentro del sistema, esta se definió como C6, después, con un análisis del grupo de investigación, se definió que las preguntas de evaluación más importantes deben ser las relacionadas con el aporte al proceso de aprendizaje y con la calidad del contenido del recurso, así entonces se dio un peso mayor para estas dos evaluaciones generando C7. Al final se decidió que la primera evaluación, respecto a la calificación general del recurso también es un valor importante a considerar en el modelo, así entonces se crea

C8, en la Tabla 5-11 se presentan los valores de ponderación dados para incluir las 5 calificaciones en el modelo.

Tabla 5-11 Pesos de ponderación de las calificaciones

	C6	C7	C8
C1	0,2	0,1	0,2
C2	0,2	0,35	0,3
C3	0,2	0,1	0,1
C4	0,2	0,35	0,3
C5	0,2	0,1	0,1

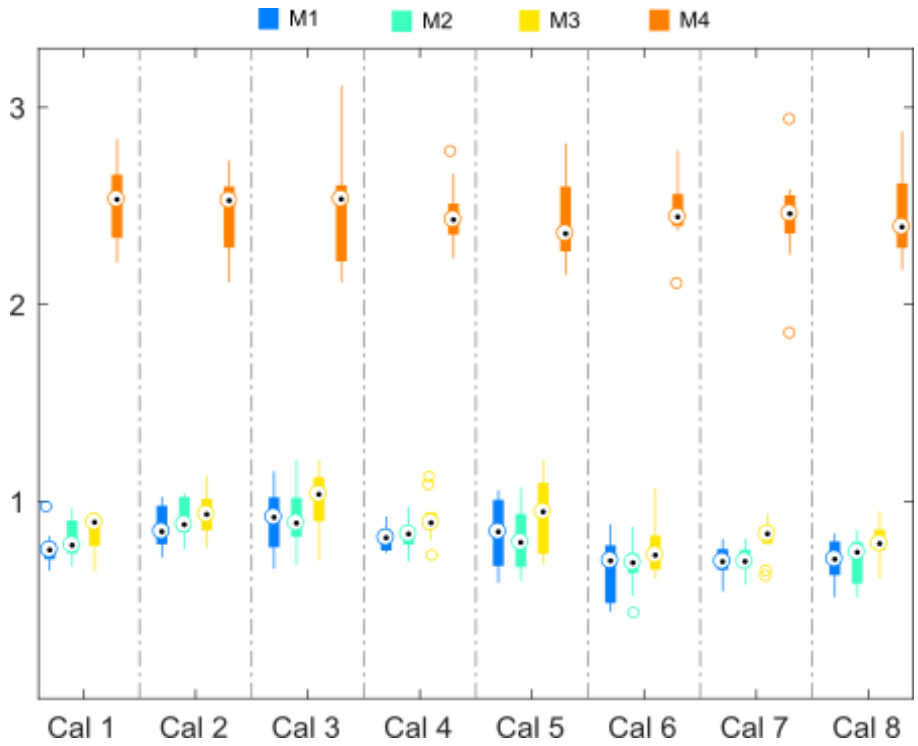

Figura 5.12 MAE para el experimento 1

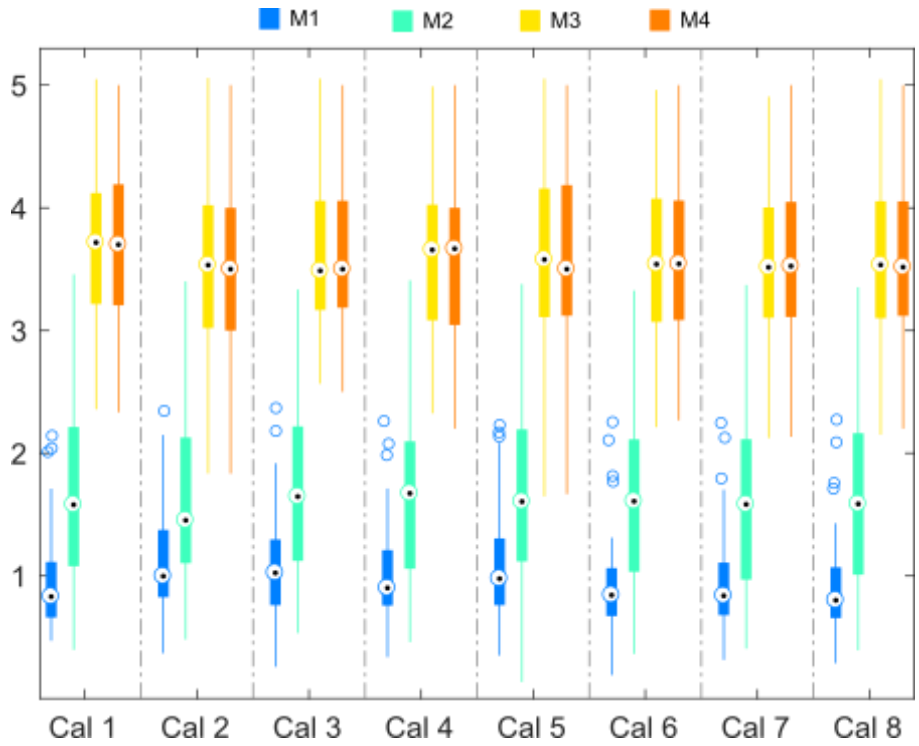

Figura 5.13 MAE para el experimento 2

Con el fin de demostrar que el modelo propuesto obtiene mejores resultados que los modelos de comparación, se cuantifica la diferencia estadística para demostrar que el MAE obtenido por M1 es menor que el obtenido por los demás métodos. Con este fin, se utiliza una prueba de *t-Student* no emparejada con la hipótesis nula que indica que no hay diferencias significativas entre el modelo de referencia (M1) y cada modelo de comparación. Por otro lado, la hipótesis alternativa indica que el valor promedio del MAE del modelo propuesto es diferente al de los demás modelos. Adicionalmente, valores del t-estadístico menores que 0 indicarán que el MAE de M1 es menor al MAE del modelo de comparación. y los valores de p indicarán el valor de significancia de la diferencia. Valores de p menores a 0.05 (5% de significancia) indican que se rechaza la hipótesis nula (se acepta la hipótesis alternativa). Los resultados de la prueba *t-Student* se muestran en la Tabla 5-12.

Tabla 5-12 Resultados de la prueba t-Student

		Validación cruzada			*Cold start*		
		H	T	p	h	t	p
Cal 1	M2	1	-2.8778	0.0182*	1	-7.0444	5.1E-09**
	M3	1	-3.3560	0.0084**	1	-27.2965	1.1E-31**
	M4	1	-21.2013	5.4E-09**	1	-26.8961	2.1E-31**
Cal 2	M2	1	-2.9080	0.0174*	1	-5.2132	3.5E-06**
	M3	1	-2.7540	0.0223*	1	-21.3153	9.5E-27**
	M4	1	-27.7762	4.9E-10**	1	-21.389	8.1E-27**
Cal 3	M2	0	-0.7275	0.4854	1	-6.7497	1.5E-08**
	M3	1	-3.2437	0.0101*	1	-26.4486	4.7E-31**
	M4	1	-14.6146	4.9E-06**	1	-26.332	5.7E-31**
Cal 4	M2	0	-1.4692	0.1759	1	-6.196	1.1E-07**
	M3	1	-3.7676	0.0044**	1	-23.601	9.2E-29**
	M4	1	-31.6121	1.4E-03**	1	-23.7753	6.5E-29**
Cal 5	M2	0	0.7459	0.4748	1	-4.9047	1.0E-05**
	M3	1	-3.9677	0.0033**	1	-17.32	9.0E-23**
	M4	1	-15.0837	1.5E-06**	1	-17.3319	8.7E-23**
Cal 6	M2	0	-0.6004	0.05630	1	-6.2938	7.6E-08**
	M3	1	-3.2583	0.0099**	1	-25.5327	2.4E-30**
	M4	1	-25.0730	1.2E-09**	1	-25.7366	1.7E-30**
Cal 7	M2	0	-0.8198	0.4335	1	-6.2033	1.1E-07**
	M3	1	-9.2140	7.0E-06**	1	-24.9146	7.5E-30**
	M4	1	-21.7319	4.3E-09**	1	-25.0631	5.7E-30**
Cal 8	M2	0	0.1022	0.9208	1	-6.2557	8.8-08**
	M3	1	-2.5091	0.0334	1	-24.3192	2.3E-29**
	M4	1	-25.0668	1.2E-09**	1	-25.1146	5.2E-30**

Fuente: elaboración propia

Se puede observar que, en la gran mayoría de casos, el valor medio del MAE obtenido por el método propuesto es menor que el valor medio del MAE obtenido por los métodos de comparación (valores del t-estadístico negativos), con valores de significancia mucho

menores a 0.01. De esta forma se comprueba que, de forma general, el método propuesto mejora de forma significativa los demás métodos de comparación propuestos en el estado del arte.

5.4 Conclusiones del capítulo

En este capítulo se presenta la aplicación del modelo propuesto con el objetivo de realizar la validación, por medio de prototipos implementados y aplicados a casos de estudio. Se realizan validaciones para las dos estrategias de aplicación planteadas y se utilizan RED almacenados en FROAC, los estudiantes participantes de las pruebas pertenecen a la Universidad Nacional de Colombia y a la Universidade Feevale de Brasil. Se utilizan métricas de relevancia y de cálculo del error de la predicción para realizar las validaciones.

En la primera estrategia, selección, se realiza la validación en tres casos de estudio. En el primero de ellos, a través de la metodología propuesta, se selecciona la información de los usuarios que se almacena en la base de casos, se selecciona las técnicas de recomendación y además se utiliza un algoritmo de RBC para encontrar casos similares y así hacer la recomendación, el enfoque híbrido es secuencial. En el segundo caso de estudio, con la información disponible de los usuarios se propone un sistema de recomendación híbrido, se aplican las técnicas en paralelo y se combinan por medio de la argumentación. Finalmente, el caso de estudio tres se valida un sistema de recomendación híbrido conversacional, donde se plantea la posibilidad de entablar un diálogo con el usuario, para conocer la realimentación de los RED entregados y así conocer si se están dando recomendaciones efectivas, se está persuadiendo al usuario y se están obteniendo las preferencias reales de los mismos.

En la estrategia de integración, con el objetivo de realizar las validaciones y comparaciones, se crea un *dataset* con datos educativos con un total de 400 registros (estudiantes = 56, RED = 152 y calificaciones 400). En esta estrategia se estiman diferentes parámetros (incógnitas), para completar los modelos, se propone un modelo que considera tanto información de usuarios como de ítems e infiere la relación existente entre estas características. Se compara el modelo propuesto, donde se utiliza la información conocida de ítems y usuarios M1, con tres modelos propuestos en la literatura, donde se conoce la información de los usuarios (M2), la información de los ítems (M3) y donde no

se conoce ni la información de usuarios ni de ítems (M4). Para hacer la comparación se utiliza el MAE, donde, entre menor MAE, mejor modelo de recomendación. Se realizan dos experimentos, el primero de ellos se hace por medio de validación cruzada separando el *dataset* en 10 particiones y el segundo se utiliza el nuevo usuario, problema del cold-start, para hacer la validación.

En ambas estrategias, se encontró que el modelo de recomendación híbrido y adaptativo propuesto, puede implementarse en diferentes ambientes, entregando buenos resultados.

5.5 Aportes

Con la elaboración de este capítulo se da cumplimiento al objetivo 4: validar el modelo propuesto a través del desarrollo de un prototipo aplicado a varios casos de estudio y evaluar su desempeño a través de métricas. Los principales aportes del capítulo son: i) aplicación del modelo propuesto a través de las estrategias en diferentes casos de estudio; ii) diseño de prototipos experimentales y creación de un *dataset* de pruebas y iii) análisis de las pruebas, resultando promisorio el uso del modelo propuesto y sus estrategias de aplicación.

6. Consideraciones finales

6.1 Conclusiones

Actualmente, los sistemas de recomendación se utilizan para diversos objetivos, en diferentes áreas del conocimiento, sin embargo, estos sistemas dependen del contexto o dominio en el que operan y no es posible hacer transferencias de las estrategias de recomendación. En el área de educación, estos sistemas tienen como tarea entregar recursos educativos, que ayuden al estudiante en la selección de materiales relevantes para su aprendizaje. En esta tesis se propuso como objetivo enfrentar las limitaciones encontradas en el estado del arte respecto al aprovechamiento de técnicas, enfoques y algoritmos aplicados a los sistemas de recomendación, en particular la falta de un modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales, que apoyen al estudiante en su proceso de aprendizaje.

En esta tesis el término de modelo **genérico** se refiere al **sistema de recomendación** común a varios casos y que se **adapta** a las disponibilidades de información tanto de ítems, como de usuarios. Además, el modelo que se propone, integra diferentes características de usuario, diferentes técnicas y algoritmos aplicables a diferentes casos. Esta integración es armónica, encontrando, para el tipo de necesidad cual combinación entrega mejores resultados, tanto de precisión como de desempeño, representando un aporte significativo en el área de informática en la educación y es una alternativa a los SR convencionales; mejorando la recuperación de **recursos educativos digitales** para un estudiante a partir de su perfil de usuario. Con el desarrollo de esta tesis, se confirma que la utilización de enfoques **híbridos** para hacer recomendaciones, combinan las fortalezas de una técnica para cubrir las limitaciones de otra, además que con mayor cantidad de información del usuario y de los recursos, las recomendaciones pueden ser mejores.

El modelo propuesto, se define en tres componentes a saber, las entradas, donde se especifican las características de los usuarios e ítems a ser utilizados en la recomendación; el proceso de recomendación como tal, donde se adaptan las técnicas de recomendación según la disponibilidad de información, los enfoques híbridos que permitan hacer combinaciones de técnicas y finalmente la selección de un algoritmo computacional que ejecute con efectividad el sistema; por último, se tienen las salidas donde a través de un mecanismo de argumentación se entregan los recursos que son relevantes para un estudiante. El diseño del sistema con la arquitectura por componentes, permite perfeccionar el sistema con facilidad, extendiéndolo con nuevos sub-componentes o bien mejorando los existentes.

Para realizar la validación del modelo, se proponen dos estrategias de aplicación, la primera de ellas es llamada de selección y en la cual se realiza una selección adaptativa y guiada de técnicas, enfoques y algoritmos para hacer las recomendaciones; la segunda es la estrategia de integración, donde se utiliza la factorización de matrices para realizar la combinación de técnicas de recomendación y se propone un sub-modelo, que integra tanto las calificaciones como las características de usuarios y de ítems, con el objetivo de estimar las relaciones existentes entre estas características y entregar recomendaciones relevantes, donde se obtuvo buenos resultados ya que no se basan solo en las evaluaciones recibidas por parte de los usuarios, sino que se tienen en cuenta otro tipo de información, que puede ser implícita o explícita.

El modelo de recomendación entregado como resultado realiza un aporte a la comunidad, ayudando a estudiantes en su proceso de enseñanza – aprendizaje, a partir de la entrega de recursos educativos afines a sus características individuales. Además, al ser un modelo genérico puede ser aplicado en diversos contextos educacionales y con recursos educativos heterogéneos. Finalmente, se concluye que el uso de un sistema de recomendación que entregue explicaciones del proceso realizado, ayuda a los estudiantes a aceptar las recomendaciones entregadas y hace que el sistema sea transparente en cuanto a su funcionamiento para el usuario; asimismo, el uso de diálogos con el usuario, permite ajustar el sistema de recomendación con las inferencias realizadas del perfil.

6.2 Trabajo futuro

El trabajo futuro de la presente tesis, puede enmarcarse en las dos estrategias de aplicación para validar el modelo genérico, con el objetivo de continuar mejorando la entrega de recursos educativos relevantes para los estudiantes y apoyar su proceso de aprendizaje.

Estrategia de selección:

- Entradas:
  - Usuario: se puede tener un perfil ampliado de los estudiantes donde se utilicen otras características que puedan ser útiles al momento de hacer la recomendación, tales como: estado anímico, información contextual y ambiental. Asimismo, monitorear al estudiante durante su interacción para obtener preferencias implícitas que pueden ser refinadas con el sistema de recomendación conversacional, propuesto en esta tesis.
  - Ítems: aún se tiene problemas al momento de etiquetar los recursos, se plantea utilizar el contenido para mejorar las recomendaciones.
- Proceso:
  - Técnicas: utilizar otras técnicas de recomendación, como las basadas en utilidad, social media y confianza.
  - Enfoques: implementar otros casos de estudio donde se combinen las nuevas técnicas utilizadas.
  - Algoritmos: aplicar algoritmos de la literatura en otros casos de estudio.
- Salidas:
  - Mejorar el proceso de argumentación, teniendo en cuenta el contenido de los recursos, además mejorar los diálogos con el usuario realizando preguntas en cuanto al aspecto pedagógico del recurso.

Estrategia de integración

- Entradas: tener en cuenta otras características del perfil del usuario y otros datos de los recursos
- Proceso: cambiar la función de costo para tener en cuenta estructuras no lineales escondidas en las calificaciones
- Salidas: implementar un sistema de argumentación que explique las relaciones de las características de los usuarios y los ítems.

Finalmente, en ambas estrategias se pueden realizar otras validaciones, teniendo en cuenta una cantidad mayor de usuarios que interactúen con los sistemas y las recomendaciones.

6.3 Cumplimiento de objetivos y contribuciones principales logradas

Se lograron cumplir los objetivos planteados en la propuesta inicial así:

Se caracterizaron los elementos que componen un modelo de recomendación de recursos educativos digitales, tales como entradas procesos y salidas, se presenta en el capítulo 1 de esta tesis.
Además, se caracterizaron las diferentes técnicas de recomendación, enfoques híbridos y algoritmos existentes para modelar sistemas de recomendación, además se analizaron los trabajos relacionados, identificando sus fortalezas y limitaciones, ver capítulo 2.
Fue definido un modelo genérico para la recomendación híbrida y adaptativa de recursos educativos digitales que integra los diferentes elementos y técnicas, asimismo se proponen dos estrategias de aplicación del modelo, en el capítulo 3 se explica el modelo y las dos estrategias.
En el capítulo 4, se exhibe la validación del modelo propuesto a través del desarrollo de varios prototipos aplicados a varios casos de estudio y se evalúa su desempeño a través de métricas.

Aunque en los objetivos específicos no se plantea el hecho de crear un *dataset* educativo, sin embargo, como valor agregado se creó un *dataset* educativo que permite realizar pruebas de los sistemas de recomendación, antes de su puesta en marcha. Asimismo, se presenta una metodología para la elaboración de sistemas de recomendación híbridos y adaptativos en la educación, finalmente se logró implementar varios modelos específicos y validar su utilidad.

Además, durante el desarrollo de esta tesis, se realizaron dos trabajos de grado en el área de sistemas de recomendación en la educación y una tesis de maestría:

- Sistema de recomendación de videojuegos para el aprendizaje. Jorge Alexander Loaiza
- Diseño e implementación de un sistema de recomendación de objetos de aprendizaje, basado en técnicas de argumentación utilizando traducción al lenguaje natural. Jhon Mauricio Poveda.
- Modelo de interfaz adaptativa para recomendación de objetos de aprendizaje basado en perfiles de usuario, agentes inteligentes y ontologías. Thomaz Quiroz Vásquez

6.4 Discusión Académica

Con miras a compartir y recibir comentarios de la comunidad científica el trabajo abordado, se produjeron en conjunto con los directores de la tesis, varios artículos científicos en el período 2014 – 2017 (Duración del doctorado).

Artículos en revistas

1. “Intelligent personal assistant for educational material recommendation based on CBR”. Paula Rodríguez, Néstor Duque y Demetrio Ovalle. **Personal Assistants: Emerging Computational Technologies**. Springer International Publishing AG 2018. ISBN: 978-3-319-62529-4, 2018.

2. “Interfaces adaptativas personalizadas para brindar recomendaciones en repositorios de objetos de aprendizaje”. Oscar Salazar, Paula Rodríguez, Demetrio Ovalle y Néstor Duque, **Tecnura**, 21(53), 107-118. ISSN 0123-921X, 2017.

3. “An educational recommender system based on argumentation theory”. Paula Rodríguez, Stella Heras, Javier Palanca, Jhon Poveda, Néstor Duque y Vicente Julián. **AI Communications**, 1, 1-18. ISSN 0921-7126, 2017.

4. “Trace Tourism Experience: Tourism Hybrid Recommender System Design”. Paula Rodríguez y Néstor Duque. **Journal of Convergence Information Technology,** 12(1). ISSN: 2233-9299, 2017.

5. “Método Híbrido de Recomendación Adaptativa de Objetos de Aprendizaje basado en Perfiles de Usuario”. Paula Rodríguez, Néstor Duque, y Demetrio Ovalle. **Formación universitaria**, 9(4), 83-94. ISSN 0718-5006, 2016.

6. “Sistema de recomendación de objetos de aprendizaje a través de filtrado colaborativo”. Paula Rodríguez, Ángela Pérez, Luis Londoño y Néstor Duque. **Revista Teknos**, 16(2), ISSN 1900-7388, 2016.

7. "A Student-Centered Hybrid Recommender System to Provide Relevant Learning Objects from Repositories". Paula Rodríguez, Demetrio Ovalle y Néstor Duque. **Lecture Notes in Computer Science** - LNCS, Vol. 9192, P. Zaphiris and A. Ioannou (Eds.), ISSN: 0302-9743, Springer International Publishing Switzerland, pp. 291-300, 2015.

8. “FROAC: Una Iniciativa Colombiana para la Integración de Repositorios de Objetos de Aprendizaje”. Valentina Tabares, Néstor Duque, Paula Rodríguez, Julián Moreno y Demetrio Ovalle. **Revista campus virtuales** 01, IV. ISSN 2255-1514, 2015

9. “Servicio Web para recomendación en la Federación de Repositorios de Objetos de Aprendizaje Colombia”. Paula Rodríguez, Néstor Duque, Demetrio Ovalle y Oscar M. Salazar. **Ingeniería e Innovación** 3(2). ISSN: 2346-0466, 2015

10. “Un modelo para la composición semiautomática de contenido educativo desde repositorios abiertos de objetos de aprendizaje”. Paula Rodríguez, Julián Moreno, Néstor Duque, Demetrio Ovalle y Ricardo Silveira. **Revista Electrónica de Investigación Educativa** (REDIE), 16, 123-136. ISSN: 1607-4041, 2014

11. “Recomendación de Estrategias de Aprendizaje Personalizadas Basadas en el Test de CHAEA”. Paula Rodríguez, Alejandra Ospina y Néstor Duque. **Revista Virtual Universidad Católica del Norte** 0124-5821 (Enviado).

Artículos en eventos

12. “Comparative analysis of similarity metrics for the collaborative recommendation of learning objects”. Paula Rodríguez, Luis Londoño y Néstor Duque. **LACLO 2017**: 12th Latin-American Conference on Learning Technologies.

13. “Construcción de objetos de aprendizaje con Realidad Aumentada: una experiencia en educación media”. Emilcy Hernández, Néstor Duque, Mauricio Giraldo y Paula Rodríguez. **LACLO 2017**: 12th Latin-American Conference on Learning Technologies.

14. “Sistema de recomendación de videojuegos para el aprendizaje”. Jorge Loaiza y Paula Rodríguez. INNOVAMUNDI 2017.

15. “Validation of a content recommendation system for learning objects, using agents that simulate disabled people”. Paula Rodríguez, Luis Londoño, Mauricio Giraldo, Valentina Tabares y Néstor Duque. **MASLE 2017**, International Conference on Practical Applications of Agents and Multi-Agent Systems. Springer International Publishing, 2017.

16. “Using Argumentation to Persuade Students in an Educational Recommender System”. Stella Heras, Paula Rodríguez, Javier Palanca, Néstor Duque y Vicente Julián. Persuasive Technology: Development and Implementation of Personalized Technologies to Change Attitudes and Behaviors: 12th International Conference, **PERSUASIVE 2017**, Amsterdam, The Netherlands, April 4–6, 2017, Proceedings (Vol. 10171, p. 227). Springer. 2017.

17. “Encourage the use of learning objects, persuading the user with natural language arguments”. Paula Rodríguez, Mauricio Poveda, Néstor Duque y Demetrio Ovalle. Learning Objects and Technology (**LACLO 2016**), Latin American Conference (pp. 1-6). IEEE. 2016.

18. “Rules based system to educative personalized strategy recommendation according to the CHAEA test”. Paula Rodríguez, Alejandra Ospina, Néstor Duque. In Learning Objects and Technology (**LACLO 2016**), Latin American Conference (pp. 1-7). IEEE. 2016.

19. “Argumentation-based Hybrid Recommender System for Recommending Learning Objects”. Paula Rodríguez, Stella Heras, Javier Palanca, Duque Néstor y Vicente Julian. **AT15** International Conference on Agreement Technologies, Grecia 2015.

20. "Guías para que profesores implementen la diversidad en sus aulas”. Paula Rodríguez, Nestor Duque, Silvia Baldiris, Cecilia Avila, Ramon Fabregat, Teo Jové, Jorge Bacca y Roser Vilà.. **LACLO 2015**. Maceio, Brasil

21. “Multi-agent system for Knowledge-based recommendation of Learning Objects using metadata clustering”. Paula Rodríguez, Néstor Duque y Demetrio Ovalle. Highlights of Practical Applications of Agents, **MASLE 2015** ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal. Springer International Publishing, 2015. 356-364.

22. “Servicio Web para recomendación en la Federación de Repositorios de Objetos de Aprendizaje Colombia”. Paula Rodríguez, Néstor Duque, Demetrio Ovalle y Oscar M. Salazar. **CAVA 2015**, Congreso Internacional en Ambientes Virtuales de Aprendizaje adaptativos y accesibles. Novo Hamburgo, septiembre 2015

23. “Un Recomendador Adaptativo Híbrido de Objetos de Aprendizaje basado en perfiles de Usuario”. Paula Rodríguez, Néstor Duque y Demetrio Ovalle. **CAIP’2015,** 12° Congreso Interamericano de Computación Aplicada a la Ingeniería de Procesos.

24. “Interfaces Adaptativas Personalizadas para brindar Recomendaciones en Repositorios de Objetos de Aprendizaje”. Paula Rodríguez, Néstor Duque, Demetrio Ovalle y Oscar Salazar. **Interacción 2014**, Congreso Internacional Realizado entre el 10 y 12 de septiembre de 2014. Universidad de la Laguna, Tenerife-España

25. “Análisis de Características del Perfil de Usuario para un Sistema de Recomendación de Objetos de Aprendizaje”. Paula Rodríguez, Néstor Duque, Demetrio Ovalle y Oscar Salazar. **LACLO 2014**, Universidad Nacional de Colombia – Manizales.

26. “Inclusive Learning Handbook: un REA para Promover una Cultura de Aprendizaje Inclusivo”. Silvia Baldiris, Cecilia Avila, Ramon Fabregat, Teo Jové, Rose Vilà, Paula Rodríguez y Néstor Duque. **LACLO 2014**, Universidad Nacional de Colombia – Manizales.

27. “Using Ontological Modeling for Multi-Agent Recommendation of Learning Objects.” Paula Rodríguez, Oscar Salazar, Demetrio Ovalle, Néstor Duque y Julián Moreno Workshop **MASLE 2014**, Multiagent System Based Learning Environments in ITS Conference, Hawaii. 2014.

Reseña

28. Sistemas de recomendación: El libro de consulta. Paula Rodríguez. **Revista Observatorio** (enviado)

Capítulos de libro

29. “Framework para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos: modelo conceptual”. Néstor Duque, Valentina Tabares y Paula Rodríguez. Tecnologías para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos. Editorial Universidad Nacional de Colombia, 19,32. ISBN: 978-958-783-165-8, 2017.

30. “Framework para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos: plataforma tecnológica”. Valentina Tabares, Néstor Duque, y Paula Rodríguez. Tecnologías para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos. Editorial Universidad Nacional de Colombia, 33,51. ISBN: 978-958-783-165-8, 2017.

31. “Construcción de herramientas para la adaptación de actividades educativas para aprendizaje móvil, situado y accesible”. Néstor Duque, Valentina Tabares, Paula Rodríguez, Emilcy Hernández, Brigeth Ceballos, Mauricio Giraldo, Adrián Arroyave, Daniel Espinosa y Juan Espinosa. Tecnologías para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos. Editorial Universidad Nacional de Colombia, 19,32. ISBN: 978-958-783-165-8, 2017.

Participación en proyectos de investigación

2017-2018. Modelo Orientado a la Accesibilidad y Adaptatividad en Repositorios y Federaciones de Recursos Educativos Digitales. convocatoria nacional de proyectos para el fortalecimiento de la investigación, creación e innovación de la Universidad Nacional de Colombia 2016-2018.

2014-2017. RAIM: Implementación de un framework apoyado en tecnologías móviles y de realidad aumentada para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos. Proyecto de la Universidad Nacional de Colombia financiado por el Ministerio de Educación Nacional y Colciencias.

2015-2017. Fortalecimiento de Competencia Digital Basado en Estilos de Aprendizaje: Estrategia Evaluativa para Estudiantes de Primer Semestre. Convocatoria conjunta para proyectos de investigación e innovación Universidad Nacional de Colombia Sede Manizales y Universidad de Caldas.

2015-2016. Recursos de Hardware y Software para la Atención de Personas con Necesidades Especiales de Educación (NEED). Convocatoria del programa nacional de proyectos para el fortalecimiento de la investigación, la creación y la innovación en posgrados de la Universidad Nacional de Colombia 2013-2015.

2014-2015. Gestión de Recursos Educativos Digitales Accesibles. Convocatoria del programa nacional de proyectos para el fortalecimiento de la investigación, la creación y la innovación en posgrados de la Universidad Nacional de Colombia 2013-2015.

Bibliografía

Adomavicius, G. & Tuzhilin, A. (2005). Toward the Next Generation of Recommender Systems : A Survey of the State-of-the-Art and Possible Extensions. *IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING*, *17*(6), 734–749.

Aggarwal, C. C. (2016). *Recommender systems: The Textbook*. (Springer, Ed.)*Springer International Publishing Switzerland 2016* (Vol. 1). http://doi.org/10.1007/978-3-319-29659-3

Alemu, T. A., Tegegne, A. K. & Tarekegn, A. N. (2017). Recommender System in Tourism Using Case based Reasoning Approach. *I.J. Information Engineering and Electronic Business*, *5*(September), 34–43. http://doi.org/10.5815/ijieeb.2017.05.05

Alexandridis, G., Siolas, G. & Stafylopatis, A. (2017). Enhancing social collaborative filtering through the application of non-negative matrix factorization and exponential random graph models. *Data Mining and Knowledge Discovery*, *31*(4), 1031–1059. http://doi.org/10.1007/s10618-017-0504-3

Almomani, A., Saavedra, P. & Sánchez., E. (2017). Ensembles of Decision Trees for Recommending Touristic Items. In *International Work-Conference on the Interplay Between Natural and Artificial Computation. Springer* (pp. 510–519).

Alonso, C., Gallego, D. & Honey, P. (1999). *Los Estilos de Aprendizaje. Procedimientos de diagnostico y mejora*. Bilbao.

Andersen, L. L. & Pettersen, T. M. (2017). *Developing a Web Application and a Case-based Reasoning Recommender System to Improve Students â€™ Motivation for Exchange Programs Lars Liverød Andersen*. Tesis de Maestría. NTNU.

Ar, Y. & Bostanci, E. (2016). A genetic algorithm solution to the collaborative filtering problem. *Expert Systems with Applications*, *61*, 122–128. http://doi.org/10.1016/j.eswa.2016.05.021

Baeza-Yates, R. & Ribeiro-Neto, B. (2011). *Modern Information Retrieval: The Concepts and Technology Behind Search*. (A. Wesley, Ed.)*Addision Wesley* (Vol. 9). Retrieved from http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Modern+Information+Retrieval:+The+Concepts+and+Technology+Behind+Search#2

Betancur, D., Moreno, J. & Ovalle, D. (2009). Modelo para la recomendación y recuperación de objetos de aprendizaje en entornos virtuales de enseñanza/aprendizaje. *Revista Avances En Sistemas E Informática*, *6*(1), 45–56.

Briguez, C. E., Budán, M. C. D., Deagustini, C. A. D., Maguitman, A. G., Capobianco, M. & Simari, G. R. (2014a). Argument-based mixed recommenders and their application to movie suggestion. *Expert Systems with Applications*, *41*(14), 6467–6482. http://doi.org/10.1016/j.eswa.2014.03.046

Briguez, C. E., Budán, M. C. D., Deagustini, C. A. D., Maguitman, A. G., Capobianco, M. & Simari, G. R. (2014b). Expert Systems with Applications Argument-based mixed recommenders and their application to movie suggestion. *EXPERT SYSTEMS WITH APPLICATIONS*, *41*(14), 6467–6482. http://doi.org/10.1016/j.eswa.2014.03.046

Brusilovsky, P. & Millán, E. (2007). User models for adaptive hypermedia and adaptive educational systems. *The Adaptive Web*, *4321*, 3–53. Retrieved from http://dl.acm.org/citation.cfm?id=1768199

Burke, R. (2002). Hybrid Recommender Systems: Survey and Experiments. *User Modeling and User-Adapted Interaction*, *12*(4), 331–370.

Burke, R. (2007). Hybrid web recommender systems. *The Adaptive Web*, *4321*, 377–408. Retrieved from http://link.springer.com/chapter/10.1007/978-3-540-72079-9_12

Bustos-López, M. & Alor-Hernández, R. V.-R. G. (2015). An Architecture for Developing Educational Recommender Systems. *Research in Computing Science*, *106*, 17–26.

Butcher, N., COL & UNESCO. (2011). *A basic guide to open educational resources (OER)*. (A. Kanwar & S. Uvalić-Trumbić, Eds.)*Commonwealth of Learning & UNESCO*. http://doi.org/10.1111/j.1467-8535.2012.01378.x

C.E. Briguez, M. Budán, C. Deagustini, A. G. M. & M. Capobianco, and G. R. S. (2012). Towards an argument-based music recommender system. In *COMMA* (Vol. 245, pp. 83–90). http://doi.org/10.1049/cp.2011.0499

C.E Briguez, M. Capobianco, and A. G. M. (2013). A theoretical framework for trust-

based news recommender systems and its implementation using defeasible argumentation. *International Journal on Artificial Intelligence Tools*, *22*(4). http://doi.org/10.1142/S0218213013500218

Campo Saavedra, M. F., Martínez Barrios, P. D. P., Ruíz Rodgers, N. & Rendón Osorio, H. J. (2012). *Recursos Educativos Digitales Abiertos COLOMBIA*. *Sistema Nacional de Innovación Educativa con Uso de TIC*.

Carrer-neto, W., Hernández-alcaraz, M. L., Valencia-garcía, R. & García-sánchez, F. (2012). Expert Systems with Applications Social knowledge-based recommender system . Application to the movies domain. *Expert Systems With Applications*, *39*(12), 10990–11000. http://doi.org/10.1016/j.eswa.2012.03.025

Carrillo-ramos, A., Arias-báez, M. P., Torres-ribero, L. G., Garzón, J. P. & González, E. (2011). A Generic Adaptation Contextual Model based on Agents. *IEEE*.

Casali, A., Gerling, V., Deco, C. & Bender, C. (2011). Sistema inteligente para la recomendación de objetos de aprendizaje. *Revista Generación Digital*, *9*(1), 88–95.

Cazella, S. C., Reategui, E. B. & Nunes, M. A. (2010). A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. *JAI: Jornada de Atualização Em Informática Da SBC. Rio de Janeiro, RJ: PUC Rio*, 161–216.

Cechinel, C., Sicilia, M. Á., Sánchez-Alonso, S. & García-Barriocanal, E. (2013). Evaluating collaborative filtering recommendations inside large learning object repositories. *Information Processing and Management*, *49*(1), 34–50. http://doi.org/10.1016/j.ipm.2012.07.004

Charniak, E. (1991). Bayesian networks without tears. *AI Magazine*, *12*(4).

Chesñevar, C. I., Maguitman, A. G. & González, M. P. (2009a). *Empowering recommendation technologies through argumentation*. *Argumentation in Artificial Intelligence*. http://doi.org/10.1007/978-0-387-98197-0_20

Chesñevar, C. I., Maguitman, A. G. & González, M. P. (2009b). Empowering recommendation technologies through argumentation. *Argumentation in Artificial Intelligence*. http://doi.org/10.1007/978-0-387-98197-0_20

Cleger-tamayo, S., Picanço-bastos, M. S. & Figueiras-de-farias, M. S. (2017). Evaluación de interfaces de explicación en los sistemas de recomendación. *Revista Científica*, *29*(2), 129–139. http://doi.org/10.14483/udistrital.jour.RC.2016.29.a2

Cumming, G. (2002). Artificial intelligence in education: an exploration. *Journal of Computer Assisted Learning*, *14*, 251–259. http://doi.org/10.1046/j.1365-

2729.1998.1440251.x

DAgostino, E., Casali, A., Corti, R. & Torres, A. (2005). Sistema de Apoyo al Aprendizaje Diagnóstico Utilizando Perfiles de Usuario : EndoDiag II. *Eia.udg.es*, 1–14. Retrieved from http://eia.udg.es/~blopez/publicacions/SIS_2005_02.pdf

DCMI. (2004). Dublin Core Metadata. Retrieved from http://www.dublincore.org

De Campos, L. M., Fernández-Luna, J. M., Huete, J. F. & Rueda-Morales, M. A. (2010). Combining content-based and collaborative recommendations: A hybrid approach based on Bayesian networks. *International Journal of Approximate Reasoning*, *51*(7), 785–799. http://doi.org/10.1016/j.ijar.2010.04.001

Degemmis, M., Lops, P. & Semeraro, G. (2007). A content-collaborative recommender that exploits WordNet-based user profiles for neighborhood formation. *User Modeling and User-Adapted Interaction*, 217–255. http://doi.org/10.1007/s11257-006-9023-4

Drachsler, H., Hummel, H. G. K. & Koper, R. (2009). Identifying the goal, user model and conditions of recommender systems for formal and informal learning. *Journal of Digital Information*, *10*(2), 1–17. http://doi.org/http://hdl.handle.net/1820/1187

Drachsler, H., Verbert, K., Santos, O. C. & Manouselis, N. (2015). Panorama of Recommender Systems to Support Learning. In *Recommender systems handbook* (pp. 1–37). http://doi.org/10.1007/s13398-014-0173-7.2

DRAE. (2001). Real Academia Española. *Diccionario de La Lengua Española (22.a Ed.). Consultado En Http://www.rae.es/rae.html*. Retrieved from http://dle.rae.es/?id=A7Kk6Zz

Duque, N. D., Ovalle, D. A. & Moreno, J. (2015). *OBJETOS DE APRENDIZAJE, REPOSITORIOS Y FEDERACIONES... CONOCIMIENTO PARA TODOS*. Universidad Nacional de Colombia.

Duque, N., Ovalle, D. & Moreno, J. (2014). *Objetos de Aprendizaje, Repositorios y Federaciones... Conocimiento para Todos*.

Duque, N., Ovalle, D. & Moreno, J. (2017). *Tecnologías para entornos educativos ubicuos, adaptativos, accesibles e interactivos para todos*. Universidad Nacional de Colombia.

Duque Méndez, N. D. (2005). *MODELO DE CURSOS VIRTUALES ADAPTATIVOS EN UN AMBIENTE DE PLANIFICACION INTELIGENTE. Information Systems*. Universidad Nacional de Colombia Sede Medellín.

Duque Méndez, N. D., Jiménez Ramírez, C. & Guzmán Luna, J. A. (2005). IA planning for automatic generation of customized virtual courses. *Frontiers in Artificial Intelligence and Applications. Planning, Scheduling and Constraint Satisfaction: From Theory to Practice*, *117*, 139–148.

Feltoni Gurini, D., Gasparetti, F., Micarelli, A. & Sansonetti, G. (2016). Temporal people-to-people recommendation on social networks with sentiment-based matrix factorization. *Future Generation Computer Systems*. http://doi.org/10.1016/j.future.2017.03.020

Fleming, N. & Baume, D. (2006). Learning Styles Again: VARKing up the right tree! *Educational Developments*, (7). Retrieved from http://www.johnsilverio.com/EDUI6702/Fleming_VARK_learningstyles.pdf

Fraihat, S. & Shambour, Q. (2015). A Framework of Semantic Recommender System for e- Lerning. *Journal of Software*, *10*(3), 317–330. http://doi.org/10.17706/jsw.10.3.317-330

Gamboa, R. M., Xavier, U. D. G. & Chehab, O. (2009). LA FLOR – Repositorio Latinoamericano de Objetos de Aprendizaje. *Recursos Digitales Para El Aprendizaje. Ediciones de La Universidad Autonoma de Yucata*.

Gao, L. & Li, C. (2008). Hybrid Personalized Recommended Model Based on Genetic Algorithm. *2008 4th International Conference on Wireless Communications, Networking and Mobile Computing*, 1–4. http://doi.org/10.1109/WiCom.2008.2152

Gil, A., Prieta, F. D. la & López, V. F. (2010). Hybrid Multiagent System for Automatic Object Learning Classification. *HAIS 2010, Part II, LNAI 6077*, 61–68.

Giustozzi, F., Casali, A., Deco, C., Dos Santos, H. L. & Cechinel, C. (2016). Recommender system of educational resources: A critiquing-based proposal. *Proceedings - 2016 11th Latin American Conference on Learning Objects and Technology, LACLO 2016*. http://doi.org/10.1109/LACLO.2016.7751779

Gordillo, A., Barra, E. & Quemada, J. (2017). A Hybrid Recommendation Model for Learning Object Repositories. *IEEE LATIN AMERICA TRANSACTIONS, 15*(3), 462–473. http://doi.org/10.1002/ace

Gu, Q. ., Zhou, J. . & Ding, C. . (2010). Collaborative filtering: Weighted nonnegative matrix factorization incorporating user and item graphs. *Proceedings of the 10th SIAM International Conference on Data Mining, SDM 2010*, 199–210. http://doi.org/10.1137/1.9781611972801.18

Gunawardana, A. & Shani, G. (2015). Evaluating recommender systems. In *In Recommender Systems Handbook* (pp. 265–308). http://doi.org/10.1007/978-0-387-85820-3_8

Hdioud, F., Frikh, B. & Ouhbi, B. (2012). A comparison study of some algorithms in Recommender Systems. *Information Science and Technology (CIST)*, *Colloquium*, 130–135. Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6388076

Heras, S., Rebollo, M. & Julián, V. (2008). A dialogue game protocol for recommendation in social networks. *Hybrid Artificial Intelligence Systems*, *5271 LNAI*, 515–522. http://doi.org/10.1007/978-3-540-87656-4_64

IEEE-LTSC. (2002). IEEE Standard for Learning Object Metadata Summary of Changes from to Final Draft * LOM Standard v1 . 0. *Learning Technology*.

Jannach, D. & Ludewig, M. (2017). when recurrent neural networks meet. In *In Proceedings of the Eleventh ACM Conference on Recommender Systems* (pp. 306–310).

Jiang, Y., Baker, R. S., Paquette, L., Pedro, M. S. & Heffernan, N. T. (2015). *Artificial Intelligence in Education*. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (Vol. 9112). http://doi.org/10.1007/978-3-319-19773-9

Jieli, S., Zhao, Q., Antony, S. & Chen, S. (2015). Personalized Recommendation Systems: An Application in Case-based Reasoning. *Proceedings of the 2015 AASRI International Conference on Circuits and Systems*, (Cas), 369–371. http://doi.org/10.2991/cas-15.2015.88

Junokas, M. J., Kohlburn, G., Kumar, S., Lane, B., Fu, W. T. & Lindgren, R. (2017). Using one-shot machine learning to implement real-time multimodal learning analytics. *CEUR Workshop Proceedings*, *1828*, 89–93. http://doi.org/10.1145/nnnnnnn.nnnnnnn

Kay, R., Knaack, L. & Petrarca, D. (2009). Exploring teachers perceptions of Web-based learning tools. *Interdisciplinary Journal of E-Learning and Learning Objects*, *5*, 27–50. Retrieved from http://ijello.org/Volume5/IJELLOv5p027-050Kay649.pdf

Kim, K.-J. & Ahn, H. (2017). Recommender systems using cluster-indexing collaborative filtering and social data analytics. *International Journal of Production Research*,

55(17), 5037–5049. http://doi.org/10.1080/00207543.2017.1287443

Kirsch-Pinheiro, M., Gensel, J., Martín, H. (2004). Representing Context for an Adaptative Awareness Mechanism. *Proceedings de 10th International Workshop on Groupware*, *LNCS, Vol. 3198, Springer, pp. 339-348*

Klašnja-Milićević, A., Vesin, B., Ivanović, M., Budimac, Z. & Jain, L. C. (2016). Recommender Systems in E-Learning Environments . In *Intelligent Systems Reference Library 112* (Springer I, pp. 51–76). Switzerland. http://doi.org/10.1007/978-3-319-41163-7_7 77

Koren, Y., Bell, R. & Volinsky, C. (2009). Matrix Factorization Techniques for recommender systems. *Computer*, *42*(8), 42–49.

Learning Technology Standards Committee. (2002). IEEE Standard for Learning Object Metadata. *Institute of Electrical and Electronics Engineers, New York*.

Li, J. Z. (2010). Quality, Evaluation and Recommendation for Learning Object. *International Conference on Educational and Information Technology*, (Iceit), 533–537.

Lika, B., Kolomvatsos, K. & Hadjiefthymiades, S. (2014). Expert Systems with Applications Facing the cold start problem in recommender systems. *Expert Systems With Applications*, *41*(4), 2065–2073. http://doi.org/10.1016/j.eswa.2013.09.005

Lorenzi, F. & Ricci, F. (2005). Case-Based Recommender Systems : A Unifying View. *Lecture Notes in Computer Science*, *3169*, 89–113.

Lu, J., Wu, D., Mao, M., Wang, W. & Zhang, G. (2015). Recommender system application developments: A survey. *Decision Support Systems*, *74*, 12–32. http://doi.org/10.1016/j.dss.2015.03.008

Luo, X., Zhou, M., Xia, Y. & Zhu, Q. (2014). An efficient non-negative matrix-factorization-based approach to collaborative filtering for recommender systems. *IEEE Transactions on Industrial Informatics*, *10*(2), 1273–1284. http://doi.org/10.1109/TII.2014.2308433

Masters, J., Madhyastha, T., & Shakouri, A. (2008). ExplaNet: A collaborative learning tool and hybrid recommender system for student-authored explanations. *Journal of Interactive Learning Research*, *19*(1), 51–74.

MEN, M. de E. N. (2013). Estrategia REDA, Ministerio de Educación Nacional.

Meulendijk, M. C., Spruit, M. R. & Brinkkemper, S. (2017). Risk Mediation in Association Rules : The Case of Decision Support in Medication Review. In *En Conference on*

Artificial Intelligence in Medicine in Europe. Springer (pp. 327–331).

Moreno, J., Duque, N. D. & Pineda, A. F. (2012). ROAp : Una Propuesta de Repositorio de Objetos de Aprendizaje basada en el estándar LOM. In *LACLO 2012 - Séptima Conferencia Latinoamericana de Objetos y Tecnologías de Aprendizaje*.

Nilashi, M., Bagherifard, K., Rahmani, M. & Rafe, V. (2017). A recommender system for tourism industry using cluster ensemble and prediction machine learning techniques. *Computers & Industrial Engineering*, *109*, 357–368. http://doi.org/10.1016/j.cie.2017.05.016

Oppermann, R. (1994). Adaptively supported Adaptability. *International Journal of Human-Computer Studies*. http://doi.org/10.1006/ijhc.1994.1021

Padhy, N. P. (2005). *Artificial intelligence and intelligent systems*. (Oxford University Press, Ed.).

Patil, N. D. (2017). Providing highly accurate service recommendation for semantic clustering over big data. *International Research Journal of Engineering and Technology(IRJET)*, *4*(2), 1889–1892. Retrieved from https://irjet.net/archives/V4/i2/IRJET-V4I2372.pdf

Peissner, M. & Edlin-White, R. (2013). User Control in Adaptive User Interfaces for Accessibility. *Lecture Notes in Computer Science*, *8117*, 623–640. http://doi.org/10.1007/978-3-642-40483-2_44

Polatidis, N. & Georgiadis, C. K. (2017). A dynamic multi-level collaborative filtering method for improved recommendations. *Computer Standards and Interfaces*, *51*, 14–21. http://doi.org/10.1016/j.csi.2016.10.014

Pozo, M., Chiky, R., Meziane, F. & Métais, E. (2017). Enhancing new user cold-start based on decision trees active learning by using past warm-users predictions. In *Conference on Computational Collective Intelligence Technologies and Applications. Springer* (pp. 137–147).

Pujahari, A. & Padmanabhan, V. (2014). An approach to content based recommender systems using decision list based classification with k-DNF rule set. *Proceedings - 2014 13th International Conference on Information Technology, ICIT 2014*, 260–263. http://doi.org/10.1109/ICIT.2014.13

Recio-Garcia, J. A., Quijano, L. & Diaz-Agudo, B. (2013). Including social factors in an argumentative model for Group Decision Support Systems. *Decision Support*

Systems. http://doi.org/10.1016/j.dss.2013.05.007

Recker, M. M. & Wiley, D. A. (2001). A Non-authoritative Educational Metadata Ontology for Filtering and Recommending Learning Objects. *Interactive Learning Environments*, *9*(3), 255–271. http://doi.org/10.1076/ilee.9.3.255.3568

Ricci, F., Rokach, L., Shapira, B. & Kantor, P. B. (2011). *Recommender Systems Handbook*. *Springer Science+Business Media, LLC 2011* (Springer, Vol. 1). http://doi.org/10.1007/978-0-387-85820-3

Robledo-Giraldo, S., Duque-Méndez, N. D. & Zuluaga-Giraldo, J. I. (2013). Difusión de productos a través de redes sociales: una revisión bibliográfica utilizando la teoría de grafos. *Revista Respuestas*, *18*(2), 27–41.

Rodríguez M, P. A., Salazar, O., Duque, N. D., Ovalle, D. & Moreno, J. (2014). Using Ontological Modeling for Multi-Agent Recommendation of Learning Objects. In *Workshop MASLE -Multiagent System Based Learning Environments, Intelligent Tutoring Systems (ITS) Conference, Hawaii, USA*. Retrieved from http://iate.ufsc.br/masle/masle2014/papers/paper_7a.pdf

Rossillea, D., Laurentc, J. & Burguna, A. (2005). Modelling a Decision-Support System for Oncology using Rule-Based and Case-Based Reasoning Methodologies. *International Journal of Medical Informatics*, *74*(2–4).

Ruiz-Iniesta, A., Jiménez-díaz, G. & Gómez-albarrán, M. (2010). Personalización en Recomendadores Basados en Contenido y su Aplicación a Repositorios de Objetos de Aprendizaje. *IEEE-RITA*, *5*(1), 31–38.

Salehi, M., Pourzaferani, M. & Razavi, S. A. (2013a). Hybrid attribute-based recommender system for learning material using genetic algorithm and a multidimensional information model. *Egyptian Informatics Journal*, *14*(1), 67–78. http://doi.org/10.1016/j.eij.2012.12.001

Salehi, M., Pourzaferani, M. & Razavi, S. A. (2013b). Hybrid attribute-based recommender system for learning material using genetic algorithm and a multidimensional information model. *Egyptian Informatics Journal*, *14*(1), 67–78. http://doi.org/10.1016/j.eij.2012.12.001

Santos, O. C., Boticario, J. G. & Pérez-Marín, D. (2014). Extending web-based educational systems with personalised support through User Centred Designed recommendations along the e-learning life cycle. *Science of Computer Programming*, *88*, 92–109. http://doi.org/10.1016/j.scico.2013.12.004

Setten, M. Van, Veenstra, M., Nijholt, A. & Dijk, B. Van. (2004). Case-Based Reasoning as a Prediction Strategy for Hybrid Recommender Systems 2 Hybrid Recommenders and Prediction Strategies, 13–22.

Shivhare, H., Gupta, A. & Sharma, S. (2015). Recommender system using fuzzy c-means clustering and genetic algorithm based weighted similarity measure. In *IEEE International Conference on Computer, Communication and Control (IC4-2015)* (pp. 1–8). http://doi.org/10.1109/IC4.2015.7375707

Srivastava, B. V., Sharma, S., Datta, D., Sriram, G., Jambhulkar, S., Naik, S. & Reddy, G. J. (2017). Genetic algorithm based parallel matrix factorization for recommender systems. *Proceedings - 2016 15th International Conference on Information Technology, ICIT 2016*. http://doi.org/10.1109/ICIT.2016.39

Tabares, V., Duque, N., Rodríguez, P., Moreno, J. & Ovalle, D. (2015). FROAC : Una Iniciativa Colombiana para la Integración de Repositorios de Objetos. *Campus Virtuales*, *IV*(1), 108–117.

Tovar, L. C., Bohórquez, J. a & Puello, P. (2014). Propuesta Metodológica Para La Construcción De Objetos Virtuales De Aprendizaje Basados En Realidad Aumentada. *Formación Universitaria*, *7*(2), 11–20. http://doi.org/10.4067/S0718-50062014000200003

Tyagi, S. & Bharadwaj, K. (2014). A hybrid knowledge-based approach to collaborative filtering for improved recommendations. *International Journal of Knowledge-Based and Intelligent Engineering Systems*, *18*, 121–133. http://doi.org/10.3233/KES-140292

UNESCO. (2015). *Guía Básica de Recursos Educativos Abiertos (REA)*. (UNESCO, Ed.) (Organizaci, Vol. 6). Retrieved from http://unesdoc.unesco.org/images/0023/002329/232986s.pdf

Uruchrutu, E., MacKinnon, L. & Rist, R. (2005). User cognitive style and interface design for personal, adaptive learning. What to model? *User Modeling*, *3538*, 154–163. http://doi.org/10.1007/11527886_20

Vian, J., Campos, R. L. R., Palomino, C. E. G. & Silveira, R. A. (2011). A Multiagent Model for Searching Learning Objects in Heterogeneous Set of Repositories. *2011 IEEE 11th International Conference on Advanced Learning Technologies*, 48–52. http://doi.org/10.1109/ICALT.2011.22

Vicari, R. M., Ribeiro, A., Marques, J., Rizzon Santos, E., Primo, T. & Bez, M. (2009). Brazilian Proposal for Agent-Based Learning Objects Metadata Standard - OBAA. *Universidad Federal Do Rio Grande Do Sul*.

Wang, S. L. & Wu, C. Y. (2011). Application of context-aware and personalized recommendation to implement an adaptive ubiquitous learning system. *Expert Systems with Applications*, *38*(9), 10831–10838. http://doi.org/10.1016/j.eswa.2011.02.083

Wang, T. I., Tsai, K. H., Lee, M. C. & Chiu, T. K. (2007). Personalized Learning Objects Recommendation based on the Semantic Aware Discovery and the Learner Preference Pattern. *Educational Technology & Society*, *10*(3), 84–105.

Wooldridge, M., Jennings, N. R. & Kinny, D. (2000). The Gaia Methodology for Agent-Oriented Analysis and Design. *Autonomous Agents and Multi-Agent Systems*, *3*, 285–312. http://doi.org/10.1145/301136.301165

Xue, G., Lin, C., Yang, Q., Xi, W., Zeng, H., Yu, Y. & Chen, Z. (2005). Scalable Collaborative Filtering Using Cluster-based Smoothing *. *Proceedings of the 2005 ACM SIGIR Conference, Salvador, Brazil*, 114–121.

Zapata, A., Menendez, V., Prieto, M. & Romero, C. (2011). A Hybrid Recommender Method for Learning Objects. *Design and Evaluation of Digital Content for Education Proceedings Published by International Journal of Computer Applications.*, 1–7. Retrieved from http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:A+Hybrid+Recommender+Method+for+Learning+Objects#0

Zhang, S., Wang, W., Ford, J. & Makedon, F. (2006). Learning from Incomplete Ratings Using Non-negative Matrix Factorization. *Computer*, 549–553. http://doi.org/10.1.1.108.415

Anexo A: Métodos de Factorización de Matrices para Sistemas de Recomendación

Los métodos de factorización de matrices para sistemas de recomendación se basan en modelos de factores latentes, donde se caracterizan tanto ítems como usuarios utilizando vectores de factores inferidos a través de las calificaciones. Considere un conjunto de ítems, donde $\theta_i \in \mathfrak{R}^{1\times N}$ representa un conjunto de factores o características que describen el i-ésmimo ítem, $\forall i \in I$. Adicionalmente, a cada usuario $u \in U$, siendo U el número de usuarios, se le asocia un vector $\mathbf{x}_u \in \mathfrak{R}^{1\times N}$. Así, los elementos de θ_i miden qué tanto representa cada factor al item i (positivo o negativo), mientras que los elementos de $\mathbf{x}_u$ miden el grado de interés que el usuario u presenta por cada uno de los factores que caracterizan los ítems (positivo o negativo). Además, el producto punto entre $\mathbf{x}_u$ y θ:

$$\widehat{y}_{ui} = \mathbf{x}_u \theta_i^\top \quad (1),$$

que captura la interacción entre el usuario u y el ítem i, y se puede ver como una aproximación de la calificación que dicho usuario le da a tal ítem $\widehat{y}_{ui} \in \mathfrak{R}$. Por consiguiente, el reto de los métodos de factorización de matrices consiste en calcular, a partir del conjunto de calificaciones dadas, los vectores de factores $\mathbf{x}_u$ y θ_i para todos los usuarios y todos los ítems. Como resultado, después de que el sistema de recomendación completa dicha estimación, este puede fácilmente estimar las calificaciones que los usuarios darían a cualquier ítem, utilizando la ecuación (1).

Los vectores de factores de los ítems se pueden agrupar en la matriz $\mathbf{\Theta} \in \mathfrak{R}^{I\times N}$, donde la i-ésima fila de esta matriz representa los factores del ítem . Así mismo, los factores de los usuarios se pueden agrupar en la matriz $\mathbf{X} \in \mathfrak{R}^{U\times N}$, donde su u-ésima fila representa los factores del usuario u. Adicionalmente, las calificaciones que los usuarios han asignado a los ítems se pueden almacenar en la matriz $\mathbf{Y} \in \mathfrak{R}^{U\times I}$. Como no todos los usuarios han evaluado todos los ítems, se crea una matriz $\mathbf{R} \in \mathfrak{R}^{U\times I}$ donde $r_{ui} = 1$ (u-ésima fila, i

-ésima columna de $\mathbf{R}$) si el usuario u ya calificó el item i, y $r_{ui} = 0$ en el caso contrario. De esta forma, para estimar las matrices de factores, el sistema de recomendación minimiza el error cuadrático medio regularizado utilizando las calificaciones conocidas:

$$L(\mathbf{X}, \mathbf{\Theta}) = \frac{1}{2}||(\mathbf{Y} - \mathbf{X}\mathbf{\Theta}^\top) \odot \mathbf{R}||_F^2 + \lambda(||\mathbf{X}||_F^2 + ||\mathbf{\Theta}||_F^2) \quad (2),$$

$$\{\widehat{\mathbf{X}}, \widehat{\mathbf{\Theta}}\} = \underset{\mathbf{X},\mathbf{\Theta}}{\operatorname{argmin}}\{L(\mathbf{X}, \mathbf{\Theta})\} \quad (3),$$

donde $\lambda \in \Re^+$ es un parámetro de regularización, $||\cdot||_F$ denota la norma de Frobenius y $\odot$ denota el producto hadamard. Bajo esta formulación, el sistema se aprende el modelo ajustando las calificaciones previamente observadas. Adicionalmente, como el objetivo es generalizar las calificaciones previas de forma tal que permitan predecir las calificaciones que aún no se han asignado, se utiliza el término de regularización para evitar el sobre-entrenamiento.

El aprendizaje de las matrices $\mathbf{X}$ y $\mathbf{\Theta}$ se puede realizar utilizando métodos de optimización como Gradiente Descendiente, en la forma:

$$\mathbf{X}_j = \mathbf{X}_{j-1} - \gamma \frac{\partial L(\mathbf{X}, \mathbf{\Theta})}{\mathbf{X}} \quad (4),$$

$$\mathbf{\Theta}_j^\top = \mathbf{\Theta}_{j-1}^\top - \gamma \frac{\partial (\mathbf{X}, \mathbf{\Theta})}{\mathbf{\Theta}^\top} \quad (5),$$

donde $\gamma \in \Re^+$ es la taza de aprendizaje, las matrices $\mathbf{X}_j, \mathbf{\Theta}_j$ denotan la $j-$ésima iteración del algoritmo de optimización, y las derivadas se definen como:

$$\frac{\partial L(\mathbf{X}, \mathbf{\Theta})}{\mathbf{X}} = ||(\mathbf{Y} - \mathbf{X}\mathbf{\Theta}^\top) \odot \mathbf{R}||_F \mathbf{\Theta}^\top + \lambda \mathbf{X} \quad (6),$$

$$\frac{\partial L(\mathbf{X}, \mathbf{\Theta})}{\mathbf{\Theta}^\top} = ||(\mathbf{Y} - \mathbf{X}\mathbf{\Theta}^\top) \odot \mathbf{R}||_F \mathbf{X} + \lambda \mathbf{\Theta}^\top \quad (7).$$

Anexo B: Sistemas de recomendación utilizando factorización de matrices, información de usuarios e ítems

Además de las calificaciones, los sistemas de recomendación pueden incluir fuentes adicionales de información de los usuarios y/o ítems con el fin de mejorar la predicción. Así, los historiales de búsqueda, o la caracterización de los estilos de aprendizaje, se pueden utilizar para describir las tendencias de los usuarios y para construir su matriz de factores $\mathbf{X}$. De esta forma, las incógnitas en la ecuación (2) serán únicamente los factores de los ítems Θ, y su estimación se puede realizar utilizando las ecuaciones (5) y (7). Como resultado, θ_{if} (fila i, columna f de Θ), indicará que tanto de la característica f que describe a todos los usuarios aparece en el ítem i. Por otro lado, si se cuenta con una caracterización de los ítems, por ejemplo, describiendo el nivel de interactividad, o cuanto de cada estilo de aprendizaje incluye, las incógnitas en la ecuación (2) serán los factores de los usuarios $\mathbf{X}$, y su estimación se puede realizar utilizando las ecuaciones (4) y (6). Como resultado x_{uf} indicará qué tan importante para el usuario u es la característica f que describe a los ítems.

Sin embargo, cuando se cuenta tanto con una descripción de los usuarios como con una descripción de los ítems, es decir, las matrices $\mathbf{X}$ y Θ son conocidas, la formulación de las ecuaciones (2) y (3) se podría aplicar únicamente si existe una correspondencia directa entre la caracterización de los ítems y de los usuarios, lo que incluye i) un mismo número de características, ii) la misma caracterización para usuarios e ítems. Por lo tanto, dado que en pocos casos reales se puede obtener dicha correspondencia en la caracterización, nosotros proponemos un modelo que permite utilizar tanto, descripciones de usuarios como de ítems. Para esto, asumamos que los usuarios se describen con un número N_u de características, dando como resultado la matriz $\mathbf{X} \in \mathfrak{R}^{U \times N_u}$. Adicionalmente, los ítems se

describen con un número N_i de características, dando como resultado la matriz $\mathbf{\Theta} \in \mathfrak{R}^{I \times N_i}$. La ecuación (2) se puede re-escribir incluyendo una matriz de factores $\mathbf{\Sigma} \in \mathfrak{R}^{N_u \times N_i}$, de la siguiente forma:

$$L(\mathbf{\Sigma}) = \frac{1}{2}||(\mathbf{Y} - \mathbf{X}\mathbf{\Sigma}\mathbf{\Theta}^\top) \odot \mathbf{R}||_F^2 + \lambda||\mathbf{\Sigma}||_F^2 \quad (8),$$

$$\widehat{\mathbf{\Sigma}} = \underset{\mathbf{X},\mathbf{\Theta}}{\operatorname{argmin}}\{L(\mathbf{\Sigma})\} \quad (9).$$

donde la derivada se define como:

$$\frac{\partial L(\mathbf{\Sigma})}{\mathbf{\Sigma}} = -\frac{1}{2}\mathbf{X}^\top(\mathbf{Y} \odot \mathbf{R})\mathbf{\Theta} + \mathbf{X}^\top\left((\mathbf{X}\mathbf{\Sigma}\mathbf{\Theta}^\top) \odot \mathbf{R}\right) + \lambda\mathbf{\Sigma} \quad (10),$$

De acuerdo con la ecuación (1), una vez obtenida la matriz $\mathbf{\Sigma}$, la estimación de la calificación que el usuario u le otorga al ítem i se da como:

$$\widehat{y}_{ui} = \sum_{n_i=1}^{N_i} \mathbf{x}_u \sigma_{n_i} \theta_{n_i,i} \quad (11),$$

donde $\mathbf{x}_u \in \mathfrak{R}^{1 \times N_u}$ son las características del usuario u, $\sigma_{n_i} \in \mathfrak{R}^{1 \times N_u}$ es la relación entre las características del usuario u con el objeto i, y $\theta_{n_i,i}$ en la n_i-ésima característica del objeto i.

Problema del nuevo usuario, *cold start*

A menudo, los sistemas de recomendación tienen que tratar con el problema del *cold start*, donde un nuevo usuario ha evaluado muy pocos, o inclusive, ningún ítem, dificultando la tarea de predicción. Una forma de resolver esta tarea es utilizar los factores $\mathbf{X}$ para encontrar similitudes entre el nuevo usuario y los demás usuarios de la base de datos. Como resultado, las evaluaciones del nuevo usuario se pueden obtener como el promedio de las evaluaciones de los usuarios más similares a este. Como medida de similitud entre el usuario u y el usuario u', se utiliza el Coeficiente de Correlación de Pearson, definido como:

$$\mathrm{Sim}(u,u') = \frac{\sum_{n_u=1}^{N_u}(x_{u,n_u} - \bar{x}_u)(x_{u',n_u} - \bar{x}_{u'})}{\sqrt{\sum_{n_u=1}^{N_u}(x_{u,n_u} - \bar{x}_u)^2}\sqrt{\sum_{n_u=1}^{N_u}(x_{u',n_u} - \bar{x}_{u'})^2}} \quad (12),$$

donde x_{u,n_u} es la n_u-ésima característica del usuario u, $\bar{x}_u$ es el promedio de las características del usuario u, y $\mathrm{Sim}(u, u') \in [-1, 1]$. Como resultado, se selecciona el subgrupo del usuario con una similitud superior a un umbral con respecto al nuevo usuario. La estimación inicial de las calificaciones asignadas por el nuevo usuario se estima como el promedio de las calificaciones que los usuarios más similares han asignado.

Anexo C: Comparación de los trabajos relacionados, respecto al modelo propuesto

En este anexo, se presenta una tabla resumen donde se realiza la comparación de los trabajos relacionados, señalando los aspectos que son de interés para el desarrollo de la tesis. Por motivos de espacio en el documento, se crean las siguientes convenciones para numerar cada aspecto a comparar.

Características del perfil del estudiante:

1. Datos académicos
2. Preferencias
3. Estilos de aprendizaje
4. Información demográfica
5. Calificaciones usuario al RED

Características del recurso educativo digital:

6. Metadatos
7. Contenido
8. Calificaciones

Técnicas de recomendación:

9. SR Conocimiento
10. SR Colaborativo
11. SR Contenido
12. SR Demográfico

Algoritmos computacionales

13. Clúster
14. Similitudes
15. Minería de datos
16. Reglas de asociación
17. Algoritmos genéticos
18. Factorización de matrices

Enfoques híbridos:

19. Unión de técnicas aplicadas separadamente
20. Unión en la aplicación misma de las técnicas

Referencia	usuario					ítem			Técnica Recomen				Algoritmos						Híbrido		Argum
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	
Hsu, 2008					X	X		X		X	X		X	X					X		
Romero, Ventura, Zafra, & Bra, 2009						X			X				X		X						
Biletskiy, Baghi, Keleberda, & Fleming, 2009	X	X				X			X		X					X			X		
Drachsler, Pecceu, et al., 2009		X				X		X		X										X	
Cobos et al., 2013								X		X	X				X					X	
Salehi y otros (2013a)		X							X		X						X		X		
Cechinel, Sicilia, Sánchez-Alonso & García-Barriocanal, 2013					X	X		X		X				X							
Capuano, Gaeta, Ritrovato, & Salerno, 2014	X	X	X			X		X		X	X							X	X		
Zapata, Menéndez, Prieto, & Romero, 2015					X			X		X	X									X	
Fraihat & Shambour, 2015				X		X			X			X		X					X		
Bustos-López & Alor-Hernández, 2015		X	X				X				X			X		X					
Giustozzi, Casali & Deco 2016	X	X			X	X		X		X				X		X				X	X
Gordillo et al., 2017	X			X		X		X			X	X		X					X		
Modelo propuesto	**X**	**X**	**X**	**X**	**X**	**X**		**X**	**X**	**X**	**X**	**X**	**X**	**X**	**X**	**X**	**X**	**X**		**X**	**X**

Anexo D: Guía para el uso del modelo genérico propuesto

En este anexo, se presenta una guía para el uso del Modelo Genérico para la Recomendación Híbrida y Adaptativa de Recursos Educativos Digitales. Primero se debe tener clara la disposición de información de los ítems (Recursos Educativos Digitales – RED) y de los perfiles de usuario (estudiantes). El sistema tiene la capacidad de realizar la selección adaptable con ayuda del usuario o de realizar la integración utilizando los mecanismos de adaptabilidad, para proponer los recursos recomendados.

En la **Figura 1** se presenta la guía para la estrategia de selección, que consiste en los siguientes pasos: i) se debe elegir la información disponible de los usuarios (estudiantes) y de los ítems (RED), ii) seleccionar las técnicas de recomendación aplicables y iii) revisar los enfoques híbridos. En este trabajo se propone que, al aplicar las técnicas basadas en filtrado colaborativo y basadas en el contenido, según la revisión de la literatura y los resultados encontrados, es mejor utilizar un enfoque secuencial para realizar la combinación (híbrido). Por el contrario, si lo que se quiere es aplicar todas las técnicas de recomendación es mejor utilizar el enfoque en paralelo.

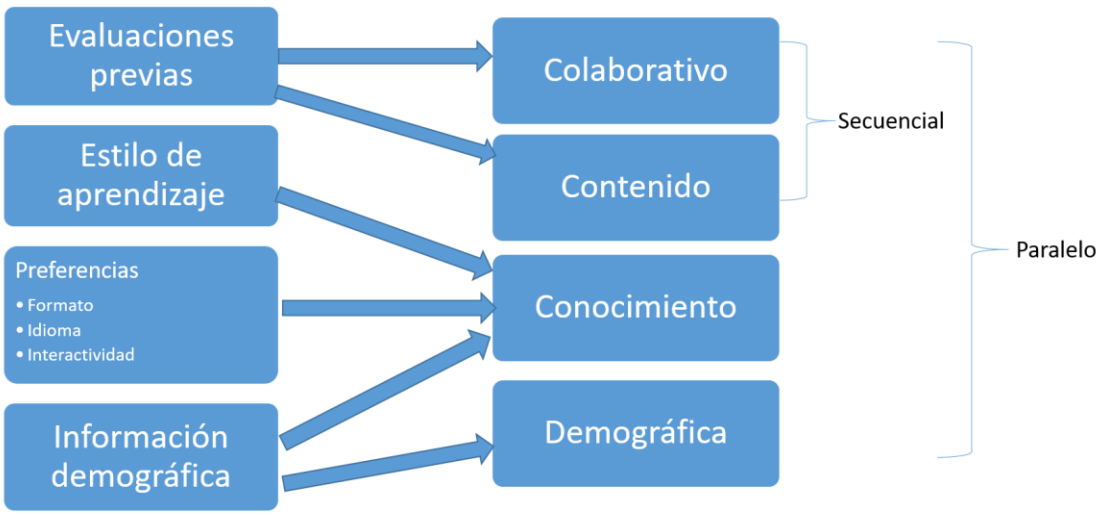

Figura 1 Reglas de selección de técnicas de recomendación

Fuente: elaboración propia.

Para el análisis de los algoritmos computacionales, en la tabla 1 de este anexo, se condensa una revisión realizada, donde a partir de la selección de la técnica de recomendación se puede escoger un algoritmo computacional que ayude en su implementación y rendimiento.

Tabla 1. Análisis de algoritmos computacionales según las técnicas de recomendación

Técnicas de recomendación	Algoritmo computacional	Referencias de uso
SR basados en filtrado colaborativo	Agrupamiento o clúster	(Kim & Ahn, 2017; Nilashi, Bagherifard, Rahmani & Rafe, 2017; Tyagi & Bharadwaj, 2014; Xue et al., 2005).
SR Conocimiento	Árboles y reglas de decisión	(Almomani, Saavedra & Sánchez., 2017; Junokas et al., 2017; Pozo, Chiky, Meziane & Métais, 2017; Meulendijk, Spruit & Brinkkemper, 2017; Pujahari & Padmanabhan, 2014).
SR Conocimiento, Contenido y Colaborativo	Sistemas multi-agente	(Gil, Prieta & López, 2010; Rodríguez M, Salazar, Duque, Ovalle & Moreno, 2014; Vian, Campos, Palomino & Silveira, 2011)

Colaborativo y Contenido	Algoritmos genéticos	(Ar & Bostanci, 2016; Gao & Li, 2008; Salehi, Pourzaferani & Razavi, 2013b; Shivhare, Gupta & Sharma, 2015; Srivastava et al., 2017).
Colaborativo	Redes neuronales artificiales	(Jannach & Ludewig, 2017; Lu, Wu, Mao, Wang & Zhang, 2015)
Colaborativo, Conocimiento, Contenido y Demográfico	Razonamiento basado en casos	(Alemu, Tegegne & Tarekegn, 2017; Andersen & Pettersen, 2017; Jieli, Zhao, Antony & Chen, 2015; Lorenzi & Ricci, 2005; Rossillea, Laurentc & Burguna, 2005; Setten, Veenstra, Nijholt & Dijk, 2004).
Contenido y Colaborativo	Redes bayesianas	(Charniak, 1991; De Campos, Fernández-Luna, Huete & Rueda-Morales, 2010; Jannach & Ludewig, 2017; Lu et al., 2015).
Colaborativo y Contenido	Sistemas expertos	(Briguez et al., 2014b; Carrer-neto, Hernández-alcaraz, Valencia-garcía & García-sánchez, 2012; Lika, Kolomvatsos & Hadjiefthymiades, 2014)
Colaborativo, Conocimiento, Contenido y Demográfico	Factorización de matrices	(Alexandridis, Siolas & Stafylopatis, 2017; Feltoni Gurini, Gasparetti, Micarelli & Sansonetti, 2016; Gu, Zhou & Ding, 2010; Luo, Zhou, Xia & Zhu, 2014; Zhang, Wang, Ford & Makedon, 2006)

Fuente: elaboración propia.

Por otro lado, para la estrategia de integración el sistema realiza un proceso de adaptatividad, donde dependiendo de las entradas matriciales de información de los usuarios y de los ítems, se aplica alguno de los 4 modelos presentados en la sección 5.3.1. Modelo propuesto y modelos de comparación, disponible en la página 74. En la **Figura 2**. se presenta una guía de cómo el sistema realiza el proceso de adaptatividad según la información disponible.

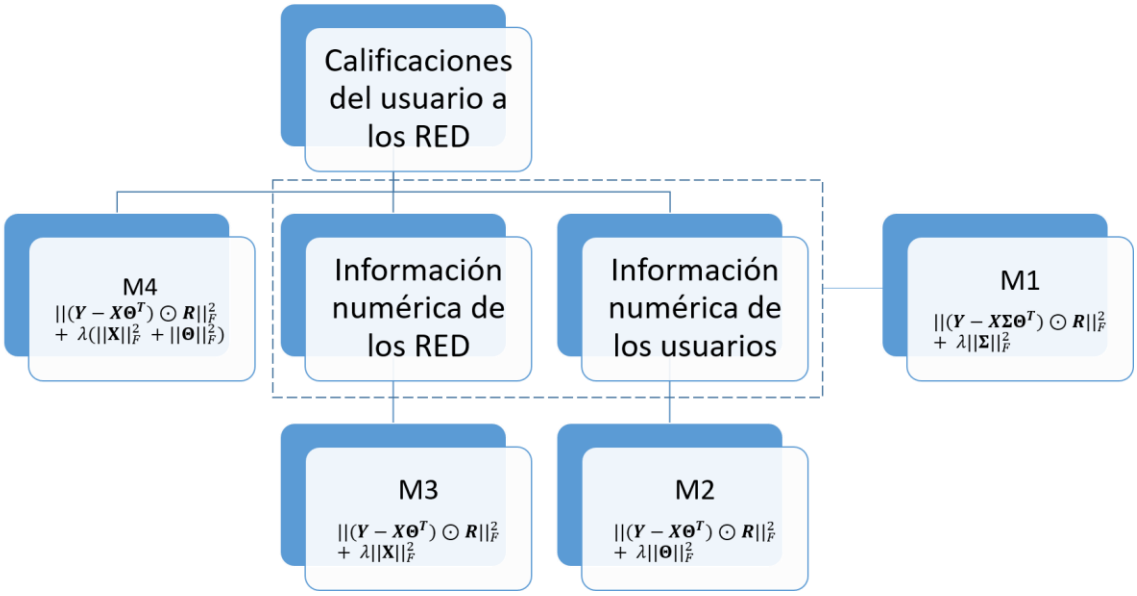

Figura 2 Estrategia de Integración adaptativa

Fuente: elaboración propia.

Es importante señalar que para que la estrategia de integración pueda ser aplicada de manera adecuada se debe contar con algunas calificaciones de usuarios a ítems, debido que es la base de su funcionamiento.

Si sólo se cuenta con dichas calificaciones, el modelo a aplicar es el M4, pues no necesita de otra información para entregar la recomendación. Si, además, se cuenta con información de los RED o de los Usuarios, se aplicará el modelo M3 o M2 respectivamente. El mejor caso es cuando se cuenta con información tanto del RED como de los usuarios, donde el sistema aplicará el M1, que es el propuesto en esta tesis y que según las pruebas presentadas en la sección 5.3 Validación de la estrategia de integración, es el que presenta mejores resultados que se acercan más a lo que el usuario quiere recibir.