

UNIVERSIDAD DE GRANADA



Departamento de Ciencias de la Computación  
e Inteligencia Artificial

Programa de Doctorado en Ciencias de la Computación  
y Tecnología Informática

*Sistemas de recomendaciones lingüísticos difusos  
para la difusión de información  
en bibliotecas digitales*

Tesis Doctoral

Álvaro Tejeda Lorente

Granada, Julio de 2014

Editor: Editorial de la Universidad de Granada  
Autor: Álvaro Tejada Lorente  
D.L.: GR 2334-2014  
ISBN: 978-84-9083-379-7



UNIVERSIDAD DE GRANADA



*Sistemas de recomendaciones lingüísticos difusos  
para la difusión de información  
en bibliotecas digitales*

MEMORIA PRESENTADA POR

Álvaro Tejeda Lorente

PARA OPTAR AL GRADO DE DOCTOR EN INFORMÁTICA

Julio de 2014

DIRECTORES

**Enrique Herrera Viedma, Carlos Porcel Gallego y Chris Cornelis**

Departamento de Ciencias de la Computación  
e Inteligencia Artificial



La memoria titulada “*Sistemas de recomendaciones lingüísticos difusos para la difusión de información en bibliotecas digitales*”, que presenta D. Álvaro Tejada Lorente para optar al grado de doctor, ha sido realizada dentro del Programa Oficial de Doctorado en “*Ciencias de la Computación y Tecnología Informática*”, en el Departamento de Ciencias de la Computación e Inteligencia Artificial de la Universidad de Granada bajo la dirección de los doctores D. Enrique Herrera Viedma, D. Carlos Porcel Gallego y D. Chris Cornelis.

El doctorando y los directores de la tesis garantizamos, al firmar esta tesis doctoral, que el trabajo ha sido realizado por el doctorando bajo la dirección de los directores de la tesis, y hasta donde nuestro conocimiento alcanza, en la realización del trabajo se han respetado los derechos de otros autores a ser citados cuando se han utilizado sus resultados o publicaciones.

Granada, Julio de 2014

El Doctorando

Los directores

Fdo: Álvaro Tejada Lorente

Fdo: Enrique Herrera Viedma

Fdo: Carlos Porcel Gallego

Fdo: Chris Cornelis

Esta tesis doctoral ha sido desarrollada con la financiación de la beca predoctoral adscrita al proyecto de investigación de excelencia P10-TIC-05299 de la Junta de Andalucía. También ha sido subvencionada por los proyectos TIN2010-22145-C02-01 y TIN2010-17876 del Ministerio de Ciencia e Innovación.

*A la memoria de mi padre:*

*D. Juan Tejeda Ortiz*

*- Para ser feliz, solo hay que querer serlo -*



# Agradecimientos

Esta tesis está especialmente dedicada a la memoria de mi padre. Aun sin haberme podido ver acabar la carrera, el máster y la consiguiente tesis, ha sido la motivación más que suficiente para esta dedicación. Agradecer a mi madre y a mis hermanas su cariño, comprensión y apoyo, pero sobre todo el aguantarme y quererme, que no es fácil. Esta memoria es por y para vosotros.

Agradecer a mis directores de tesis, Enrique Herrera, Carlos Porcel y Chris Cornelis su esfuerzo y dedicación no solo desde el ámbito académico donde sin su guía y conocimientos no hubiese podido hacer nada de lo que se ve reflejado en esta memoria, sino también desde el ámbito personal por la ayuda, por todos los consejos que me han dado y los buenos ratos que he pasado con ellos.

También tengo que agradecer a mis compañeros de tesis y amigos, a los más nuevos y a los que ya estaban cuando yo llegué, los momentos pasados y los desayunos: Julián, Christoph, Sara, Joaquín, Victoria, Manolo Cobo, Michela, Dani, Juanan, Rosa y todos los del grupo *SCI<sup>2</sup>S*.

Agradecer también a mis amigos: a Isaac su amistad y compañía durante todos estos años que ha aguantado las mismas bromas día tras día (lo de la pantalla se hubiese ido si le hubieses dado con alcohol). A Nacho su compañía, que me “convenciese” y me haya hecho de guía en esto de hacer un doctorado. A Alberto los buenos momentos pasados en los monólogos y en el café de los domingos y los que quedan. A Juan, que además de compañero de tesis, jefe y consejero en mi periplo alemán me ha ofrecido una gran amistad sin pedir

nada a cambio, bueno, solo un par de mudanzas. A Albert, por compartir mi misma filosofía de la sonrisa y del optimismo. No olvidar a mis amigos Héctor, Raúl y mi amigo y primo Dani.

Agradecer también a la persona que me ha acompañado en mi etapa final de la tesis y la ha sufrido de primera mano no sin dejar de apoyarme en todo momento. Gracias Bojana :).

Mi agradecimiento también a todas aquellas personas que no por no citarlas han sido menos importantes en el término de esta memoria.

GRACIAS A TODOS

# Table of Contents

<b>1. Approach, Objectives and Structure of this Thesis</b>	<b>1</b>
1.1. Approach . . . . .	1
Planteamiento . . . . .	3
1.1.1. Recommender Systems . . . . .	6
1.1.2. Using Fuzzy Linguistic Modeling on Information Access . . . . .	8
1.1.3. Quality Treatment . . . . .	10
1.1.4. Digital Libraries . . . . .	14
1.2. Objectives . . . . .	16
1.3. Structure of the Thesis . . . . .	16
<b>2. Sistemas de Recomendaciones</b>	<b>19</b>
2.1. Introducción . . . . .	19
2.2. Definición . . . . .	22
2.3. Uso de los Sistemas de Recomendaciones . . . . .	25
2.4. Estructura de los Sistemas de Recomendaciones . . . . .	27
2.5. Información sobre la Preferencias de los Usuarios . . . . .	28
2.6. Técnicas de Recomendación . . . . .	31
2.6.1. Enfoque Basado en Contenidos . . . . .	34
2.6.2. Enfoque Colaborativo . . . . .	38
2.6.3. Enfoque Híbrido . . . . .	46
2.7. Fase de Realimentación . . . . .	48
2.8. Evaluación de un Sistema de Recomendaciones . . . . .	49

---

2.8.1. Métodos de Evaluación <i>Offline</i> . . . . .	50
2.8.2. Métricas de Evaluación . . . . .	51
2.9. Aspectos a Considerar en el Diseño de Sistemas de Recomendaciones . . . . .	53
2.10. Problemas Asociados a los Sistemas de Recomendaciones . . . . .	55
<b>3. Modelado Lingüístico Difuso</b>	<b>59</b>
3.1. Introducción . . . . .	59
3.2. Conceptos Básicos . . . . .	62
3.2.1. Conjuntos Difusos y Definiciones básicas . . . . .	62
3.2.2. Definiciones Básicas . . . . .	64
3.2.3. Operaciones con Conjuntos Difusos . . . . .	66
3.2.4. Pasos para la Aplicación de un Enfoque Lingüístico Difuso	67
3.3. Modelado Lingüístico Difuso Clásico . . . . .	69
3.4. Modelado Lingüístico Difuso Ordinal . . . . .	70
3.4.1. Modelo de Representación en el Enfoque Lingüístico Ordinal . . . . .	70
3.4.2. Modelo Computacional en el Enfoque Lingüístico Ordinal	71
3.5. Modelado Lingüístico Difuso 2-tupla . . . . .	76
3.5.1. Modelo de Representación Lingüística 2-tupla . . . . .	77
3.5.2. Modelo Computacional Lingüístico 2-tupla . . . . .	78
3.6. Modelado Lingüístico Difuso Multi-granular . . . . .	80
3.7. Modelado Lingüístico Difuso no Balanceado . . . . .	84
3.8. Modelado Lingüístico Difuso Vacilante . . . . .	87
3.9. Aplicaciones del MLD en Sistemas de Acceso a la Información .	90
3.10. Sistemas de Recomendaciones Basados en el MLD . . . . .	91
3.10.1. Sistemas de Recomendaciones Basados en el MLD 2-tupla	92

---

---

3.10.2. Sistemas de Recomendaciones Basados en el MLD Multi-granular . . . . .	93
3.10.3. Sistemas de recomendaciones basados en el MLD multi-granular aplicados en bibliotecas digitales universitarias .	97
<b>4. A quality based recommender system to disseminate information in a University Digital Library</b>	<b>105</b>
4.1. Introduction . . . . .	106
4.2. System architecture . . . . .	110
4.2.1. Resources representation . . . . .	115
4.2.2. User profiles representation . . . . .	116
4.2.3. Hybrid recommendation approach . . . . .	119
4.2.4. Computing the quality of research resources . . . . .	123
4.2.5. Re-ranking . . . . .	125
4.2.6. Feedback phase . . . . .	126
4.3. Experiments and evaluation . . . . .	126
4.3.1. Data set . . . . .	127
4.3.2. Assessing the capacity of recommendations . . . . .	128
4.3.3. Assessing the capacity of ratings predictions . . . . .	131
4.4. Discussion . . . . .	132
<b>5. REFORE: A recommender system for researchers based on bibliometrics</b>	<b>135</b>
5.1. Introduction . . . . .	136
5.2. REFORE architecture . . . . .	142
5.2.1. Resources representation . . . . .	148
5.2.2. User profiles representation . . . . .	149
5.2.3. Hybrid recommendation approach . . . . .	151
5.2.4. Computing the quality of research resources and users . .	155
5.2.5. Re-ranking . . . . .	158

---

5.2.6. Feedback phase . . . . .	162
5.3. System development . . . . .	164
5.3.1. Implementation . . . . .	164
5.3.2. Application description . . . . .	164
5.4. Experiments and evaluation . . . . .	167
5.4.1. Data sets . . . . .	170
5.4.2. Assessing the capacity of recommendations . . . . .	172
5.5. Discussion . . . . .	175
<b>6. Concluding Remarks and Future Works</b>	<b>179</b>
6.1. Concluding remarks . . . . .	179
Conclusiones . . . . .	182
6.2. Future works . . . . .	185
Associated Publications to the Dissertation Thesis . . . . .	186
<b>Bibliography</b>	<b>189</b>

---

# Table Index

2.1. Ejemplo de perfil de usuario . . . . .	37
2.2. Ejemplo de perfiles de películas . . . . .	37
2.3. Ejemplo de matriz de valoraciones . . . . .	39
2.4. Tabla de contingencia. . . . .	52
3.1. T-normas y T-conormas . . . . .	67
3.2. LOWA con $m = 2$ . . . . .	76
3.3. Granularidad en Jerarquías Lingüísticas. . . . .	82
4.1. Confusion matrix. . . . .	129
4.2. Experimental contingency table. . . . .	129
4.3. Precision, recall and F1 values for all the users. . . . .	130
5.1. Papers structure . . . . .	148
5.2. MAE for all the different configuration. . . . .	174



# Figure Index

2.1. Esquema de funcionamiento de un sistema de recomendaciones.	21
2.2. Esquema del proceso de generación de una recomendación . . . . .	27
2.3. Esquema de recomendaciones basado en contenidos. . . . .	36
2.4. Esquema de recomendaciones basado en contenidos. . . . .	41
2.5. Enfoque colaborativo basado en usuarios o memoria. . . . .	43
2.6. Enfoque colaborativo basado en ítems o modelos. . . . .	44
3.1. Ejemplo de función de pertenencia. . . . .	64
3.2. Ejemplo de una variable lingüística. . . . .	65
3.3. Intersección y Unión en conjuntos difusos . . . . .	68
3.4. Un conjunto de 7 términos lingüísticos y su semántica. . . . .	72
3.5. Semántica asociada al conjunto de términos lingüísticos. . . . .	75
3.6. Jerarquía lingüística de 3, 5 y 9 etiquetas. . . . .	82
3.7. Conjunto de términos lingüísticos de 7 etiquetas no balanceado.	85
3.8. Representación de un conjunto de términos lingüísticos no balanceado. . . . .	87
4.1. Basic operating scheme. . . . .	113
4.2. Interface to define the disciplines of the resource scope. . . . .	115
4.3. Interface to define the user preferences about the five most relevant resources. . . . .	117
4.4. F1 values for all the users. . . . .	131

4.5. Comparison of MAE. . . . .	132
5.1. The research process . . . . .	138
5.2. Results obtained looking for articles about the topic “decision making” in ScienceDirect . . . . .	139
5.3. Structure of the system . . . . .	144
5.4. Linguistic Hierarchy of 2, 3, 5 and 9 labels . . . . .	147
5.5. Profile’s papers . . . . .	150
5.6. Profile’s papers . . . . .	151
5.7. Re-Ranking on Content-based previous list . . . . .	158
5.8. Combination of both approach in one final list . . . . .	161
5.9. Recommendations for a user . . . . .	163
5.10. Identification screen REFORE. . . . .	165
5.11. Main user menu . . . . .	166
5.12. Personal data and user keywords. . . . .	166
5.13. Selected, non selected user papers and options. . . . .	167
5.14. Recommendations in user profile. . . . .	168
5.15. Format used in the email to deliver recommendations. . . . .	169
5.16. Users’ similarities from University of Granada, weighted accor- ding to topics and quality . . . . .	171
5.17. Evolution of MAE during the year 2013 . . . . .	175

---

# Chapter 1

## Approach, Objectives and Structure of this Thesis

### 1.1. Approach

In recent years, the digital revolution is leading to a huge expansion in the amount of information created and distributed in electronic format. In any field, we can have available a large volume of information, which makes difficult a fast and simple access to the information we are really interested in or we require[106]. e.g. users subscribed to a distribution list waste most of their time watching, reading or just deleting irrelevant emails. Being that the access to information in any environment is a complex task. Hence, users necessities are shifting to tools to aid them with their requirements. Being up to date in an interesting field allows users or companies to be more competitive and plays a critical role in the decision making process.

As a result, it is necessary the development and use of efficient Information Access Systems (IASs) that allow users in a easy and flexible way to access to relevant information. IASs must be adapted to users for the following reasons:

- The search, information retrieval and information filtering derive from

non necessary rational human capacities. It can be based on explicit assumptions, where users express some specifications of what they desire and there are no specific requirements in terms of accuracy and completeness over the set of items.

- “relevance” and “quality” are key concepts in IASs, although users can establish real relevance or quality of an information item, that is, its utility, relevance, chance or utility regarding users’ necessities or users’ preferences (usually expressed through a query or users profiles).

There are many studies and systems proposed to tackle the problem in the Web or in any other field [13, 14, 39, 40, 85, 105]. All these research are based on different techniques or work philosophies but all under the same notion, that is, the *Information Access* concept. This term describes any process that make possible to filter big amount of available information and the retrieval to the users of only relevant information for him/her. However, the big amount of information we face nowadays restricts systems performance. So, it becomes critical the application of artificial intelligence (AI) techniques to aid users to access information since they improve the obtained results. Hence, the study of information access process, as well as the application of techniques to obtain higher efficiency is shown as a very active research line.

The term Soft Computing [176] is a synergy of methodologies as fuzzy sets, neural networks, probabilistic reasoning, rough-sets, evolutionary computation and some machine learning approaches. It is useful to solve problems which require some kind of “intelligence”. The advantage of use Soft Computing based techniques is the tolerance to imprecision, uncertainty, partial knowledge and approximation. Due to these properties, these techniques are appropriate to model activities related to information access problems. More information

---

about these topic can be found in the works [24, 39, 40, 85, 89, 90, 105].

In this thesis, we will focus on provide solution to the information overload problem in digital libraries. We will do it applying recommender system and using a fuzzy linguistic modeling to shape aspects related to the subjective perception, and using quality as key concept in the recommendation process.

In the next sections we will introduce the basic notions about IASs, in our case, recommender systems as well as the fuzzy linguistic model as an utility tool to apply in these system. Then, we point out the quality treatment used as key aspects in our recommender system and the basics of digital libraries.

## **Planteamiento**

Desde hace unos años, la revolución digital está provocando un descomunal crecimiento de la cantidad de información que se crea y distribuye en formato electrónico. En cualquier ámbito en el que nos encontremos, podemos tener disponible un gran volumen de información de todo tipo, lo cual dificulta el acceso de una manera rápida y sencilla a la información que realmente nos interesa o necesitamos [106]. Por ejemplo, los usuarios suscritos a una lista de distribución pierden gran parte del tiempo ojeando, leyendo o simplemente eliminando mensajes de correo irrelevantes para ellos. Este hecho provoca que el acceso a la información en cualquier ámbito sea una tarea compleja, por lo que los usuarios cada vez más necesitan herramientas automáticas que les ayuden a encontrar la información que mejor se adapte a sus requerimientos. Estar actualizado desde el punto de vista de la información disponible en cualquier ámbito, permite tanto a los usuarios individuales como a empresas ser más competitivos y adoptar mejores decisiones.

---

Como consecuencia, se hace necesario el desarrollo y uso de Sistemas de Acceso a la Información (SAIs) eficientes, que permitan a los usuarios acceder de forma fácil y flexible a información relevante. Estos SAIs deben estar adaptados a los usuarios por dos motivos:

- Por un lado, la búsqueda, recuperación y el filtrado de información son inherentes a capacidades humanas que no son necesariamente racionales, que pueden estar basadas en suposiciones explícitas y que no necesitan medidas precisas y completas sobre el conjunto de ítems de información factible.
- Por otro lado, los conceptos de “relevancia” y “calidad” son los dos conceptos clave en los SAIs, aunque sólo los usuarios pueden determinar la relevancia real o calidad actual de un determinado ítem de información, es decir, su utilidad, pertinencia, oportunidad o utilidad respecto a las necesidades o preferencias de los usuarios (habitualmente expresadas mediante una consulta o un perfil de usuario).

Son numerosos los estudios realizados y sistemas propuestos para dar solución al problema, ya sea en la Web o en cualquier otro ámbito de aplicación [13, 14, 39, 40, 85, 105]. Todas estas investigaciones están basadas en diferentes técnicas o filosofías de trabajo, pero se pueden englobar bajo un mismo concepto, el de *Acceso a la Información*. Entre ellas encontramos cualquier proceso que hace posible filtrar la gran cantidad de información disponible, y que el usuario únicamente acceda a información relevante para él. Sin embargo, el gran volumen de información al que nos enfrentamos actualmente limita el rendimiento de estos sistemas, por lo que se hace preciso la aplicación de técnicas de Inteligencia Artificial (IA) para ayudar a los usuarios en sus procesos de acceso a la información, ya que permiten mejorar los resultados obtenidos.

---

Por ello, el estudio de los procesos de acceso a la información, así como la aplicación de mejoras en ellos con el fin de obtener una mayor eficiencia, se muestra como una línea de investigación muy activa.

El término Soft Computing [176] constituye una sinergia de metodologías (incluyendo la teoría de conjuntos difusos, redes neuronales, razonamiento probabilístico, *rough-sets*, computación evolutiva y algunos enfoques de aprendizaje automático) que son útiles para resolver problemas que requieren algún tipo de “inteligencia”. La ventaja de usar técnicas basadas en Soft Computing es su tolerancia a la imprecisión, incertidumbre, conocimiento parcial y aproximación. Debido a estas propiedades, dichas técnicas son muy apropiadas para modelar actividades relacionadas con los problemas de acceso a la información. Para más información sobre el tema se pueden consultar los trabajos [24, 39, 40, 85, 89, 90, 105].

En esta tesis nos centraremos en dar solución a los problemas de sobrecarga de información en bibliotecas digitales. Lo haremos mediante sistemas de recomendaciones en los que usaremos un modelado lingüístico difuso para modelar los aspectos relacionados con la percepción subjetiva, y donde tendremos en cuenta la calidad de los recursos como aspecto fundamental en la generación de recomendaciones. Todo esto se llevará a cabo en el ámbito académico de las bibliotecas digitales.

En las siguientes secciones introducimos las nociones básicas sobre SAIs e introducimos el modelado lingüístico difuso como herramienta de gran utilidad para aplicar en los SAI. A continuación hablaremos acerca del tratamiento de calidad usado en nuestros sistemas de recomendaciones como concepto de especial relevancia a la hora de generar las recomendaciones así como haremos

---

una introducción breve sobre bibliotecas digitales.

### 1.1.1. Recomender Systems

*Recommender System* are tools used to aid in the recommendation process over some items based on users' preferences and opinions. These systems offer tools to separate relevant from irrelevant information. They provide users with personalized assistance in their process of accessing the information, by filtering the information and delivering to whom it may need [137]. The widespread use of recommender system is due to the fact that they evaluate and filter a big amount of accessible information to help users in their seek of information to discover and access to information. This fact reveals its great functionality in any field like companies, organizations, research centers, etc., where they are configured as useful tools for knowledge distribution among the users.

These systems are characterized by the following features [27, 61, 137]:

- They can be applied on fields where the work is performed with unstructured or semi-structured information, e.g. a Web page or an email. This features separates them from a normal application for a database where the information is structured in tables and records. Furthermore, records' fields consist of simple data with a defined meaning.
  - Users show long term interest, that is, they do not handle concrete and temporal needs. These interests are represented by the users' profiles.
  - Managing of large amounts of information.
  - Usually acting on a stream of incoming information from remote sources, removing irrelevant information for users.
-

As we see, we found some features also present in the traditional information retrieval systems. However, the difference between these systems is that in recommender systems the corpus automatically changes, the users have long term needs (described by users' profile instead of being inserted by users as queries) and their objective is to remove the input flow of irrelevant items [61, 137]. The result or output of a recommender system can be understood as a recommendation, an option to be considered. Conversely, the result of a traditional information retrieval system is the equivalence of the query introduced by the user [27].

A recommender system is basically composed by four main components [27, 61, 137]:

1. A proper users' profile representation, inasmuch as they represent their long term information needs.
2. A proper items' representation that the system will recommend later on.
3. The method of generating recommendations.
4. The set of ratings that users provided about items.

The construction of accurate profiles is a key task and the system's success will depend on a large extent on the ability of the learned profiles to represent the user's preferences. Then, in order to generate personalized recommendations that are tailored to the users preferences or needs, recommender systems must collect personal preference information, such as users history of purchase, items which were previously interesting for the user, click-stream data, demographic information, and so on. Two different ways to obtain information about user preferences are distinguished [61], although many systems adopt a hybrid approach:

---

- The *implicit approach* is implemented by inference from some kind of observation. The observation is applied to the user behavior, such as the bookmarks or visited URL. The user preferences are updated by detecting changes while observing the user.
- The *explicit approach* interacts with the users by acquiring feedback on information that is filtered, that is, the users express some specifications of what they desire and ratings about the explored items. This approach is currently the most common one.

### 1.1.2. Using Fuzzy Linguistic Modeling on Information Access

As above mentioned, nowadays there are an ever increasing interest in the application on artificial intelligence based techniques in the field of information access. The purpose of these techniques is to solve the performance issues caused by the constant growth of the available information volume. The Soft Computing techniques are from the artificial intelligent the most used and successful [39, 40, 177]. The concept of Soft Computing was introduced by Zadeh [175] as a synergy of methodologies like fuzzy logic, neural networks, probabilistic reasoning, evolutionary computation, etc. These techniques provide the basis to the idea, design, construction and utilization of intelligent information systems. The key rule of Soft Computing is the allowance of imprecision, uncertainty and approximation [176]. The fact that the subjectivity and uncertainty are typical properties of any information access process, above all with the users interaction, has led to Soft Computing techniques have been shown as an excellent tool to deal with the subjectivity and the uncertainty in the information access system definition. The use of Soft Computing techniques can provide an increased flexibility to those systems [39, 40]. There is a lot

---

---

of contributions facing the use of Soft Computing techniques in the field of access to information. In particular, Fuzzy Logic [173, 175] is being used to model the subjectivity and uncertainty existing in the activity of information retrieval [37, 39, 40, 156].

There are several situations or areas where the information can not be precisely quantitatively evaluated, but it may be feasible and useful to do in a qualitatively manner. Thus, when we try to quantify some phenomenon related to human perceptions, we often use words or descriptions in natural language instead of numerical values. e.g. when when we assess the beauty of a person, we often use terms such as *beautiful*, *normal* o *ugly*. In other cases, to work quantitatively with accurate information is not possible, either because it is not available or because the computational cost is too high and it is enough applying an “approximate value”. e.g. when we evaluate the speed of a car, instead of using numerical values, we often use terms such as *fast*, *fast* or *slow*.

In this sense, the use of the Fuzzy Sets Theory has proved very good results for the treatment of qualitative information [174]. The *fuzzy linguistic modeling* is a a tool based on the concept of *linguistic variable* [174] to deal with qualitative assessment. The values assigned to these variables are not numeric, but words or judgments expressed in natural language [174]. Each value is characterized by a syntactic value or *label* and a semantic one or *meaning*. It has being demonstrated that the fuzzy sets theory is a very useful tool in many challenges. e.g. decision making [72, 162, 170], quality evaluation of information in Web documents [80], information retrieval models [23, 76, 77], clinical diagnostics or health related[42, 154], social media [158], etc.

To apply a fuzzy linguistic modeling, we can consider different approaches to

---

represent the linguistic information:

1. *Classic fuzzy linguistic modeling* [174], Consists of using a context-free grammar, where the term set belongs to the language generated by the grammar.
2. *Ordinal fuzzy linguistic modeling* [67, 72], it is defined to eliminate the excessive complexity of the classical fuzzy linguistic modeling. Symmetrical and uniformly distributed sets of labels are used for that purpose.
3. *2-tuple fuzzy linguistic modeling* [73, 74], it is developed to improve the performance of the ordinal fuzzy linguistic approach.
4. *Multi-granular fuzzy linguistic modeling* [69, 75], it is defined to deal with situations where the linguistic information can be evaluated over different sets of labels.
5. *Unbalanced fuzzy linguistic modeling* [70, 71], it is developed to deal with situations where the linguistic information has to be evaluated over a unbalanced set of labels, that is, an asymmetric and nonuniform set of labels.
6. *Hesitant fuzzy linguistic modeling* [142, 163], it is defined to deal with situations where the linguistic information can be evaluated in different ways, that is, it makes to hesitate about which one would be the right one.

### 1.1.3. Quality Treatment

Nowadays, is well known that Internet is the largest information repository with the largest number of users searching for information. However, due to its fast, disorganized and uncontrolled growth, its heterogeneity and absence of

---

control, to publish content there is some “bad” information [106]. As a results, internet users end up accessing low-quality information, but the problem can be tackled applying filtering mechanisms [164].

There is a big discussion about information quality on the Web and about how to recognize useful and quality information in a unregulated place as Internet [106]. Nevertheless, there is not theoretical basis or any framework on the subject [57]. Thus, a lot a researchers have tried to use frameworks well recognized in other fields to evaluate the quality. One of the widely used frameworks for information quality is the one defined in the context of information systems management [99, 109, 155, 168]. This framework suggests that different dimensions like precision, accessibility or relevance, used to evaluate the quality of the information of a system can be group in four categories: intrinsic quality information, contextual quality information, representative quality information and accessibility quality information. The first two are content referred, while the last two are technical referred.

Evaluating the quality of information provided by a Web site is a difficult task that has not being deeply addressed [140]. Nonetheless, a methodology for a flexible and robust Web quality evaluation should combine in an appropriate way both aspects, technical and content based. But the reality is that most of the proposed methodologies tend to be more objective than subjective, more quantitative than qualitative, and they do not have into account the users’ perception [25, 46, 126]. However, from the information consumers perspective, the quality of a Web site or a Web resource can not be independently evaluated from the quality of the information contents provided [91]. An additional disadvantage of most of methodologies is that their indicators are relevant to Web designers and providers but not to users [6]. A global methodology to evaluate

---

the Web quality should let users participate in the evaluation strategy.

In general, a global methodology to Web quality evaluation shows the following components [91, 92, 125]:

- An *evaluation scheme*: It establishes the different criteria or evaluation indicators which have to be considered, as well as their relevance degrees. It is appropriate to take into account not only the subjective and objective criteria but also the users participation.
- A *measurement method*: It establishes how to obtain the associated ratings with each of the evaluation criteria. i.e. we would have to define a questionnaire to collect the users' perceptions. It also establishes an aggregation mechanism or synthesis in order to obtain the associated quality assessment with a particular Web resource.

In a lot of commercial information systems, especially those that manage some kind of recommendation, it is usual that users provide as input evaluative judgments over the products. The system will aggregate this judgments to obtain recommendations that will be stored. e.g. the policies for recommendation used by Amazon<sup>1</sup>, TripAdvisor<sup>2</sup> or Booking<sup>3</sup>. Then, these recommendations can be used to assist other users in their seek process to locate similar items. In this sense, the recommendations are a kind of measure over the quality of these items. From a user point of view who demands information quality, their opinion can help to evaluate the quality of Web sites or documents where the users have accessed, because the concept of information quality is specific to

---

<sup>1</sup> <http://www.amazon.com/>

<sup>2</sup> <http://www.tripadvisor.es/>

<sup>3</sup> <http://www.booking.com/>

---

---

the user. Hence, users must be the last instance judging the quality of a place or a document.

Moreover, the quality is not always something relative based on tastes. On the one hand, when we speak about Web documents we can also consider an article of a journal, helping the research community to increase their knowledge and to stay aware of the latest developments in specific areas. The quality of the resources can be measured in different and more dependable ways, not only by users. To do that, the use of bibliometrics indicators to measure the quality of some publications is very extended and accepted [47]. Bibliometrics is commonly used for the quantitative research assessment of academic output, and it is also used for practice based research [62, 135, 165]. Specifically, bibliometrics is a set of methods used to study or measure texts and information. Many research fields use bibliometric methods to explore the impact of their field, the impact of a set of researchers, or the impact of a particular paper [62, 165]. In bibliometrics, there are two main procedures to explore a research field: performance analysis and science mapping [165]. The former is focused on the citation-based impact of the scientific production, and the latter is focused on the discovering of the conceptual structure of the scientific production, in this dissertation we will use the first one. On the other hand, as we pointed out before, users are not only receivers of information but also are considered information sources since the system starts to use their opinions to generate recommendations for other users. That is, it is also necessary to measure the quality of the users since they are an active part within the recommendation process. The way of measuring the quality of a user can variate depending on the field. It can be their reputation as users in a commercial recommender system [172] or their quality based on some indicators in an academic field [9, 29, 49, 50, 97, 118].

---

#### 1.1.4. Digital Libraries

The revolution that the Internet has brought to information dissemination is two-folded: huge volumes of information have been made available -something that long before belonged to the libraries realm-, and improved accessibility to the existing information. Among the variety of digital information sources, Digital Libraries [55, 107] are playing an important role in terms of the information and services they provide to the information society.

In last years the new concept of digital library experimented an important growth. *Digital libraries* are information collections that have associated services delivered to user communities using a variety of technologies [58, 95, 145]. Much of the research during the initial stages was on digitizing existing sources, creating large-scale collections, technological solutions, and providing simple ways of access. The information collections can be scientific, business or personal data, and can be represented as digital text, image, audio, video, or other media. This information can be displayed on a digitized paper or born digital material and the services offered on such information can be varied and can be offered to individuals or user communities [30, 58, 138].

Digital libraries are the logical extensions of physical libraries in the electronic information society. Internet access enabled the advent of digital libraries that are increasingly used by different communities for diverse purposes, and in which sharing and collaborating have become important social elements. The resulting communities are becoming more and more heterogeneous in terms of their interests, backgrounds, and skill levels, ranging from novices to experts in a specific subject area. The growing diversity of digital libraries, the communities accessing them, and how the information is used introduces the need

---

for higher effectiveness at providing information that is tailored to a person's background knowledge, skills, tasks, and intended use of the information [138]. In practice, a digital library makes its contents and services remotely accessible through networks such as the Web or limited-access intranets [116]. When digital libraries become commonplace, their contents and services become more varied, as a result, the expectations for better more sophisticated services increase [31].

An essential component of digital libraries is the specialized human staff, who handle and enable users the access to those documents that are more relevant for them, taking into account their needs or interest areas. The library staff searches, evaluates, selects, catalogs, classifies, preserves and schedules the digital documents access [58]. Some of the main digital libraries functions are the following [132]:

- To evaluate and select digital materials to add in its repository.
- To preserve the security and conservation of the materials.
- To describe and index the new digital materials (catalog and classify).
- To deliver users the material stored in the library.
- Other managerial tasks.

Digital libraries have been applied in a lot of contexts. In this thesis we are going to focus on the academic environment. *University digital libraries* (UDLs) provide information resources and services to students, faculties and researchers in an environment that supports learning, teaching and research [32].

---

## 1.2. Objectives

The objectives of this thesis include the research about the current state of recommender systems and the development of proposals to deal with the information overload problem in digital libraries. To tackle the problem, we present a study of artificial intelligent techniques as fuzzy linguistic modeling.

More specifically, the main objectives are the following ones:

- To study and analyze the concept and features of recommender systems as helpful tools to assist users in their process of accessing the information. To stress the importance of the use of this kind of systems in different fields as effective tools for knowledge broadcasting.
- To study and analyze the different approaches of management of fuzzy linguistic information and their applications.
- To present a system that increase the information discovering properties in an university digital library. The system is designed to combine the estimated relevance of an item for a user along with its quality. The system is developed using a fuzzy linguistic approach.
- To design and develop a quality based fuzzy linguistic recommender system for researchers. The system is tailored researchers and is tested in some departments of the University of Granada and the TU Delft, it is aimed to assist them in the access to valuable information for their research using digital libraries.

## 1.3. Structure of the Thesis

This thesis consist of this introduction Chapter, four additional chapters where we explain the performed research and the final one, where we draw our

---

conclusions and suggest future research lines.

In Chapter Two, we will review the features and the main aspects of recommender systems. We will study the two main types of systems, content-based and collaborative as well as the combination of both techniques to obtain the hybrid approach. Then, we will see how to evaluate a recommender system as well as some considerations and problems associated to the design and the performance of recommender systems.

Next, the study of the different fuzzy linguistic modeling approaches to represent the information is provided in Chapter Three. Some of these approaches are the classical fuzzy linguistic modeling, the ordinal fuzzy linguistic modeling, the 2-tuple fuzzy linguistic modeling, the non-balanced fuzzy linguistic approach and hesitant fuzzy linguistic approach. Furthermore, digital libraries are presented along with some examples of recommender system, using fuzzy linguistic modeling, already applied on this field.

In Chapter Four, we present a quality based recommender system to disseminate information in a university digital library. The system measures the item quality and takes into account this measure as a new factor to be considered in the recommendation process

In Chapter Five we continue the study of recommender systems focused in information dissemination in digital libraries. Specifically, we design and implement REFORE, a REcomender system FOr REsearchers based on bibliometrics. This system follows the lines pointed in the last chapters extending the scope to a much larger digital library such as Thomson Reuters Web of Science (WOS).

---

Finally, we conclude the thesis with the Chapter Six even, where a summary of the conclusions is drawn and where we point out several open future lines of work derived from the results achieved.

---

# Chapter 2

## Sistemas de Recomendaciones

Los sistemas de recomendaciones son sistemas de acceso a la información que facilitan el acceso personalizado a información de interés con el objetivo de recomendar ítems e información a partir de las preferencias y opiniones de los usuarios. El uso de estos sistemas se está convirtiendo en un recurso cada vez más utilizado en Internet debido a que son muy útiles para evaluar y filtrar la gran cantidad de información disponible en la Web para asistir a los usuarios en sus procesos personalizados de acceso a la información, disminuyendo así el problema persistente de la sobrecarga de información. En este capítulo realizaremos una revisión de las características y aspectos fundamentales relacionados con el diseño e implementación de los sistemas de recomendaciones analizando los distintos tipos que han ido apareciendo en la literatura al respecto.

### 2.1. Introducción

A menudo es necesario seleccionar una entre varias alternativas sin tener un conocimiento exacto de cada una de ellas. En estas situaciones, la decisión final suele depender de las recomendaciones de otras personas o de nuestras experiencias pasadas [137], como ocurre cuando vamos a comprar algún producto y para elegir entre un modelo u otro nos basamos en la recomendación de alguien

que previamente lo haya adquirido, o que tenga un conocimiento más preciso al respecto o bien, si nada de esto es posible, de nuestras experiencias pasadas con objetos similares. En los procesos de acceso a la información, los sistemas de recomendaciones son herramientas cuyo objetivo es asistir a los usuarios en sus procesos de acceso a la información, ayudando a filtrar los ítems de información recuperados según sus intereses, usando para ello recomendaciones pasadas dadas por otros usuarios sobre esos ítems o sus valoraciones sobre ítems similares. Éstos podrían ser definidos como sistemas cuyas salidas son recomendaciones individualizadas, o cuyo efecto es guiar de forma personalizada a los usuarios de cara a encontrar información útil e interesante en un amplio espacio con multitud de opciones entre las que elegir [26].

Las raíces de los sistemas de recomendaciones provienen del trabajo realizado en teorías de aproximación, de previsión y en la recuperación de información entre otros. Se convierte en un área independiente de trabajo a mitad de los años 90 [96, 139], cuando la investigación se centra en la calidad de las recomendaciones, y el problema pasa a ser la estimación de dicha calificación.

Este tipo de sistemas se está extendiendo cada vez más, como herramientas que ayudan a reducir la sobrecarga de información y a mejorar las ventas en sitios Web de comercio electrónico [27, 98, 137, 148]. Los sistemas de recomendaciones juegan un importante papel en sitios Web altamente valorados como por ejemplo Amazon <sup>1</sup>, YouTube <sup>2</sup>, Netflix <sup>3</sup>, Tripadvisor<sup>4</sup> o IMDb <sup>5</sup>. Se trata, pues, de un área de investigación que ofrece herramientas para discernir entre información relevante e irrelevante, proporcionando asistencia persona-

---

<sup>1</sup> <http://www.amazon.es/>

<sup>2</sup> [www.youtube.com/](http://www.youtube.com/)

<sup>3</sup> [www.netflix.com/](http://www.netflix.com/)

<sup>4</sup> [www.tripadvisor.es/](http://www.tripadvisor.es/)

<sup>5</sup> [www.imdb.com/](http://www.imdb.com/)

---

lizada para los continuos accesos a la información por parte de los usuarios, filtrando la información y mostrándola sólo a quienes puedan estar interesados en ella o la necesiten [137]. Los sistemas de recomendaciones consideran que diferentes usuarios tendrán distintas preferencias y distintas necesidades de información [148]. Por ejemplo, si nos fijamos en el ámbito de la recomendación de libros, a un estudiante del Grado de Ingeniería Eléctrica le podría interesar más un libro con aplicación en ingeniería, por ejemplo de fundamentos de la programación, que un libro de arte rupestre, lo cual tampoco implica que este otro tipo de lectura no le interese.

En la Figura 2.1 podemos ver el esquema de funcionamiento básico de un sistema de recomendaciones, cuyos elementos principales se desglosan en los siguientes apartados.

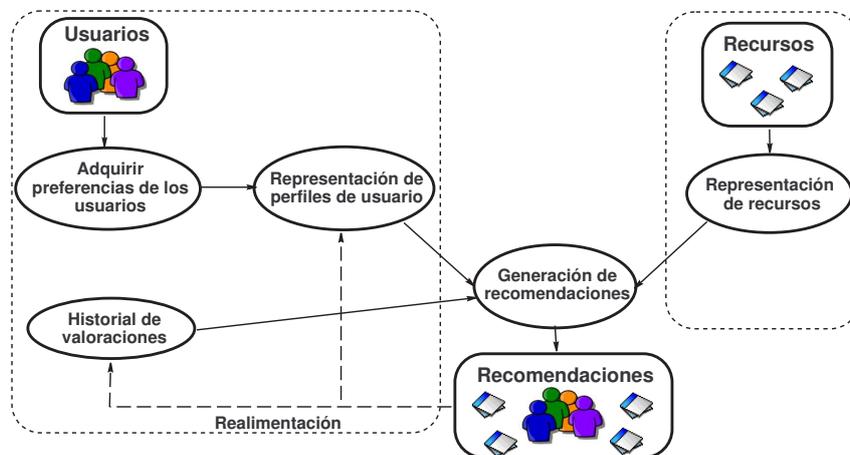


Figure 2.1: Esquema de funcionamiento de un sistema de recomendaciones.

La idea principal de este capítulo es presentar un estudio sobre los sistemas de recomendaciones, describiendo los aspectos más significativos de su diseño y problemas fundamentales con los que nos encontramos a la hora de construir un sistema de este tipo. Veremos también los grandes tipos de sistemas de recomendaciones, entre los que prestaremos especial atención a los colaborativos

y los basados en contenidos, así como la combinación de los diferentes tipos que dan lugar a los sistemas híbridos.

El capítulo se estructura en diez secciones, incluyendo esta introducción. En la sección 2 veremos la definición de los sistemas de recomendaciones. Durante la sección 3 veremos el uso que se le da a estos sistemas. En la sección 4 abordaremos la estructura de dichos sistemas. A continuación en la sección 5 realizamos un estudio acerca de la información sobre las preferencias de usuario las cuales son usadas para definir los perfiles de usuario. Dedicamos la sección 6 a presentar las diferentes técnicas de generación de recomendaciones. En la sección 7 analizamos la fase de realimentación o *feedback*, en su término inglés, en la que los usuarios proporcionan al sistema con decisiones sobre la relevancia de las recomendaciones recibidas. Después, en la Sección 8 estudiamos las diferentes formas de evaluación que podemos aplicar a un sistema de recomendaciones para conocer su calidad o precisión. A continuación, en la sección 9 veremos los aspectos a tener en cuenta en el diseño de sistemas de recomendaciones. Por último, en la sección 10 estudiaremos los problemas asociados a los sistemas de recomendaciones.

## 2.2. Definición

El crecimiento de Internet en los últimos años ha puesto a disposición de los usuarios gran cantidad de información, servicios y productos a través de la red. Este hecho que *a priori* es positivo, implica también algunos problemas desde el punto de vista del usuario, tales como, la dificultad de gestionar la excesiva cantidad de información a la que diariamente nos enfrentamos, complicando el acceso a la información que deseamos, o la incapacidad para decidir de entre los ítems encontrados los que mejor se adecuan a nuestras necesidades, etc. Por

---

lo tanto, muchas actividades que realizamos en la Web a lo largo del día son cada vez menos exitosas debido a la cantidad de información que obtenemos al consultar, cuando en realidad solo nos interesa algo en concreto. Muchas de esas veces necesitamos que las búsquedas que realizamos sean personalizadas para no dejar pasar información que puede ser valiosa para nosotros. Esto es así porque entre tanta información somos incapaces de distinguir la información valiosa, ya que frecuentemente no lo tenemos claro de antemano.

Los usuarios tienen distintas formas de acceder a la gran cantidad de información disponible a través de la Web relacionadas con el propósito de su búsqueda. La forma de búsqueda más inmediata es directamente navegar a través de los sitios Web usando los enlaces que se van encontrando en las páginas visitadas; en este caso, no se necesita ninguna expresión formal acerca de las necesidades de información. Sin embargo, cuando se busca alguna información específica, el paradigma anterior no es práctico y la eficiencia de los resultados que obtenemos depende fuertemente de la página de la que partimos dicha búsqueda. En este caso, la forma más extendida es el uso de motores de búsqueda basados en palabras clave, tales como Google<sup>6</sup>, Yahoo<sup>7</sup> o Bing<sup>8</sup>. Consecuentemente, el rendimiento de estos sistemas sufre diversos problemas tales como:

- Problema del Web crawling: los motores de búsqueda pueden cubrir sólo una pequeña porción de la totalidad de la Web, debido a su tamaño, estructura y rápido crecimiento [106, 108].
- Problema del spamming: los algoritmos para la ordenación de resultados usados por los motores de búsqueda, pueden ser fácilmente manipulados para promover ciertas páginas subiéndolas a la parte más alta del con-

---

<sup>6</sup> <http://www.google.com/>

<sup>7</sup> <http://www.yahoo.com/>

<sup>8</sup> <http://www.bing.com/>

---

junto de resultados o simplemente pagando por las primeras posiciones.

- Problema de sobrecarga de información: usualmente, cuando un usuario busca información a través de la Web, recibe cientos de miles de documentos.

Filtrar la gran cantidad de información disponible permite mejorar el acceso a la información solucionando los problemas anteriores. Los sistemas de recomendaciones se han ido consolidando como potentes herramientas para ayudar a los usuarios a reducir la sobrecarga de información a la que nos enfrentamos en los procesos de acceso a la información. Ayudan a filtrar los ítems de información recuperados, usando distintas técnicas para identificar aquellos ítems que mejor casan con las preferencias o necesidades de los usuarios ayudándolos a decidir o a encontrar lo que buscan [137].

El objetivo de un sistema de recomendaciones es el de recomendar a los usuarios  $C = \{c_1, \dots, c_n\}$ , ítems de un conjunto  $S = \{s_1, \dots, s_n\}$  de tal forma que los ítems recomendados sean de la mayor utilidad posible a los usuarios [82, 171].

Los ítems serán el objeto a recomendar que variará dependiendo del objetivo del SR, en unos casos pueden ser libros o documentos de una biblioteca, así como cualquier tipo de artículo que venda una tienda, así como películas, como es el caso de sistemas de recomendaciones tales como MovieLens<sup>9</sup>, Filmaffinity<sup>10</sup>, IMDb<sup>11</sup> entre otros.

La información que conozcamos de los ítems es crucial para el desarrollo del proceso de generación de recomendaciones, así como el contexto en el que

---

<sup>9</sup> <http://www.movielens.org/>

<sup>10</sup> <http://www.filmaffinity.com/>

<sup>11</sup> <http://www.IMDb.com/>

---

se van a usar. Aun así, a la hora de diseñar un sistema de recomendaciones también hay que tener en cuenta diversos aspectos como son la representación de las recomendaciones, la identificación de la fuente de la que provienen, el uso de las recomendaciones y la forma de agregar las distintas evaluaciones de los usuarios [137].

### 2.3. Uso de los Sistemas de Recomendaciones

Los sistemas de recomendaciones hoy día son ampliamente usados en casi cualquier ámbito que tengan que ver como la toma de decisiones acerca de un campo en el que la cantidad de información existente es muy grande. Uno de los usos más extendidos de los sistemas de recomendaciones se da en los portales Web de comercio electrónico donde se suelen usar estas herramientas para sugerir productos y proporcionar a los clientes servicios de valor añadido para de esta forma ayudarles en sus decisiones de compra [149, 151]. Las recomendaciones podrían estar basadas en los ítems más vendidos o preferidos, en decisiones demográficas o en el análisis del comportamiento anterior de los clientes, así como en el perfil y el comportamiento de los usuarios con la intención de predecir comportamientos futuros [121]. La forma de las recomendaciones varía según los casos, pudiendo tratarse de sugerencias, información personalizada, o bien de resúmenes o críticas del resto de usuarios del sistema. La intención de estos sistemas es la de proporcionar al usuario una sensación de personalización, en la que se sienta en un entorno totalmente adecuado a él. Además, recomendando productos que interesen al usuario, es posible incrementar el número de ventas realizadas.

Los sistemas de recomendaciones son herramientas muy útiles también en el campo del marketing o la publicidad donde ayudan a distribuir la publicidad

---

adecuada al público adecuado causando un impacto directo en la tasa de conversión [53]. Esto permite ayudar a una empresa a tomar decisiones sobre a quién realizar una oferta o a quién dirigir ciertas promociones publicitarias. Sugieren a motores de búsqueda y compañías publicitarias qué anuncios u ofertas visualizar en función del comportamiento del cliente, ofreciendo de este modo un alto grado de personalización [61, 66].

Teniendo en cuenta esos aspectos, los sistemas de recomendaciones ayudan a mejorar las ventas de los portales Web de comercio electrónico de tres formas distintas [149, 151]:

- Los sistemas de recomendaciones ayudan a los clientes a encontrar ítems interesantes que en muchos casos podrían comprar vía Internet.
- Incrementando las ventas cruzadas: sugiriendo productos adicionales basados en los productos que estamos dispuestos a comprar.
- Creando fidelidad: investigando el comportamiento de los clientes y personalizando el sitio de venta según sus necesidades.

En el ámbito de la salud, el uso de sistemas de recomendaciones se está extendiendo de la misma forma, puesto que se cumplen las bases que se dan en otros campos así como otras de valor añadido. Aplicar los sistemas de recomendaciones en el ámbito de la salud permite una reducción de costes, haciendo más asequible el acceso a la sanidad por parte de la sociedad, una salud universalizada, alcanzando puntos que de forma física son imposibles de alcanzar, así como una medicina personalizada para aumentar la calidad de vida [52, 60, 100]. Todos estos factores contribuyen a una mejora en la calidad de vida de los usuarios.

---

## 2.4. Estructura de los Sistemas de Recomendaciones

A continuación presentamos los elementos fundamentales que intervienen en el esquema de funcionamiento de un sistema de recomendaciones. Como podemos ver en la Figura 2.2 [93], en el esquema de funcionamiento podemos distinguir tres elementos diferenciados[61], como son: *las entradas y salidas en el proceso, el grado de personalización y las técnicas que se usan para generar las recomendaciones.*

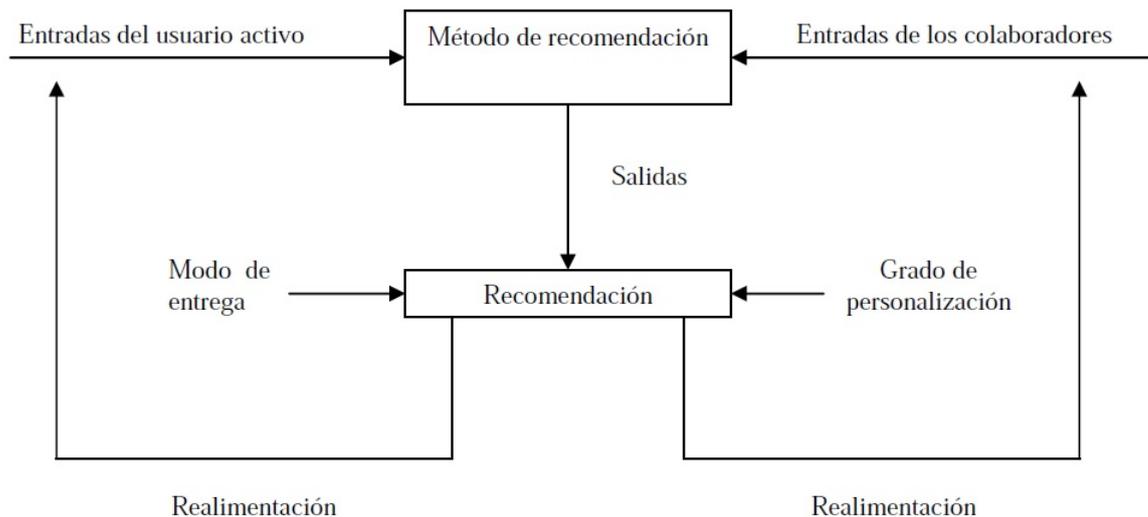


Figure 2.2: Esquema del proceso de generación de una recomendación

Dependiendo del tipo de sistema necesitaremos conocer las preferencias de los usuarios que los usan, así como de los ítem a recomendar, todo esto constituirá las **entradas** del sistema. Podemos diferenciar tres tipos de entradas [171]:

- Las del *usuario activo*, el cual es el destinatario de las recomendaciones, ya sea por extensión, es decir, información obtenida de las experiencias pasadas, o extraídas de un seguimiento al usuario del que él no es consciente.

- Las *expresadas intencionalmente*, es decir el usuario expresa los ítem deseados o da información de sus preferencias.
- Las *entradas de los colaboradores*, se clasifican los ítem mediante las experiencias o las sentencias de los demás usuarios acerca de los ítem.

Las **salidas** del sistema son las recomendaciones dadas a los usuarios, que pueden venir en forma de sugerencias a los usuarios, de predicciones del grado de satisfacción que se obtendrá, o incluso mostrando el grado de satisfacción de otros usuarios en caso de no ser muchos.

El **grado de personalización** viene dado por la precisión y la utilidad que tiene un sistema de recomendaciones [66]. Esto nos ayuda a clasificar los sistemas de recomendaciones en tres grupos:

- *No personalizados*. Los sistemas proporcionan las mismas recomendaciones a todos los usuarios, basadas en selecciones manuales o resúmenes estadísticos.
- *Personalización efímera*. Solo se basan en el comportamiento del usuario en la sesión en la que se produce la recomendación.
- *Personalización persistente*. Recomendaciones distintas para cada usuario y basadas en su perfil, teniendo en cuenta el histórico de dicho usuario. Estos son los más potentes y los que serán objeto de estudio.

## 2.5. Información sobre la Preferencias de los Usuarios

Los sistemas de recomendaciones son sistemas de procesamiento de información que activamente reúnen distintos tipos de información para generar

---

sus recomendaciones. Como ya hemos dicho, el objetivo es recomendar a un determinado usuario (conocido como *usuario activo*) de un conjunto de usuarios, ítems de un conjunto de ítems. La información sobre las preferencias de los usuarios es usada para definir perfiles de usuario que se aplican como filtros sobre los conjuntos de ítems. Por tanto, la construcción de perfiles precisos es una tarea clave, hasta el punto que el éxito y buen funcionamiento del sistema dependerá en gran medida de la habilidad de los perfiles adquiridos para representar las preferencias de los usuarios [134]. Por ello es fundamental disponer de suficiente información sobre los ítems a sugerir, así como de los usuarios que van a recibir las recomendaciones. Se debe recopilar información sobre las preferencias personales de cada usuario, por ejemplo, a través de su historial de compra, datos de navegación, información demográfica, etc.

Cuando un usuario  $u$  expresa sus preferencias sobre un ítem  $o_k$ , se denomina *valoración* (o *rating* en inglés) y se representa  $r_u(o_k)$ . Los usuarios pueden expresar sus valoraciones de dos formas distintas:

- De forma *explícita*. El usuario especifica explícitamente sus preferencias sobre un ítem particular, de diversas formas, tales como [150]:
  - Valoraciones numéricas, normalmente en escalas de 5 o 7 puntos. Es habitual encontrar sitios Web donde proporcionan una escala con 5 estrellas (como por ejemplo Amazon <sup>12</sup>) o 10 estrellas (como IMDb <sup>13</sup>) en la que cuantas más estrellas brillen significa que más se valora ese ítem.
  - Valoraciones ordinales, tales como “completamente de acuerdo, de acuerdo, indiferente, desacuerdo, fuertemente en desacuerdo”, don-

---

<sup>12</sup> <http://www.amazon.es/>

<sup>13</sup> <http://www.imdb.com/>

---

de se le pide al usuario que seleccione el término que mejor indica su opinión respecto del ítem.

- Valoraciones binarias, en las que simplemente se le pide al usuario que decida si un cierto ítem es bueno o malo.
  - Valoraciones unarias, que básicamente indican que un usuario ha analizado o comprado un ítem. En este caso la ausencia de valoración indica que no se dispone de información al respecto.
- 
- De forma *implícita*. El sistema intenta inferir la opinión de los usuarios observando su comportamiento, lo cual evita el posible esfuerzo que podría imponer el esquema explícito. Por ejemplo, se podría considerar la información de una compra, tiempo invertido en leer algún artículo, o el comportamiento de navegación que se haya tenido. Aunque este tipo de valoraciones son fáciles de recopilar, tienen algunos inconvenientes. Por ejemplo, cuando el usuario realiza una compra, pero es para un regalo de manera que no refleja realmente sus preferencias. Además, inferir que la compra implica que algo no guste, tampoco se puede mantener siempre.

Debido a las ventajas e inconvenientes de uno y otro, algunos sistemas adoptan un enfoque que combina ambos. Por ejemplo, Amazon genera recomendaciones basándose en valoraciones explícitas siempre que sea posible. Pero si no lo es, adopta el enfoque implícito. Por ejemplo, si un usuario busca “Programación” se le mostrará un gran listado de libros, del que el usuario podría seleccionar alguno en concreto para obtener información adicional. Ello permitiría al sistema inferir que el usuario está interesado en dicho libro.

---

## 2.6. Técnicas de Recomendación

Debido a que la información y fuentes de conocimiento disponibles pueden ser muy diversos, el que puedan ser explotados o no, depende de la técnica de recomendación que adoptemos. Consideraremos tan solo en las técnicas basadas en personalización, puesto que las técnicas tales como la *recuperación pura*, las *recomendaciones seleccionadas manualmente* o los *resúmenes estadísticos* no serán tenidas en cuenta como sistemas de recomendaciones aunque en algunos casos sean presentados como tales. En general, hay algunas técnicas que no requieren de mucho conocimiento, es decir, usan información simple y básica, tal como valoraciones o evaluaciones de los usuarios respecto de los ítems. Otras técnicas son mucho más dependientes del conocimiento disponible como las que usan descripciones ontológicas de los usuarios o ítems, o las que se basan en relaciones sociales y determinadas actividades de los usuarios.

En la literatura podemos encontrar una gran variedad de técnicas propuestas como motor para generar las recomendaciones. Sin embargo, basándonos en la fuente de conocimiento, podríamos considerar que se agrupan en cuatro clases [27, 61, 137]:

- *Sistemas basados en contenidos.* Generan las recomendaciones teniendo en cuenta los términos usados en la representación de los ítems y las evaluaciones que un usuario ha proporcionado sobre dichos ítems [17, 33]. Estos sistemas de recomendaciones tienden a fallar cuando se dispone de poca información sobre las necesidades de información que tienen los usuarios.
  - *Sistemas colaborativos.* El sistema genera las recomendaciones usando información explícita o implícita sobre las preferencias de muchos usuarios, ignorando la representación de los ítems. Los sistemas colaborativos
-

localizan pares de usuarios con un historial similar en lo que se refiere a las evaluaciones proporcionadas, y generan las recomendaciones usando estas "vecindades" que se van constituyendo [59, 138].

- *Sistemas demográficos*. Un sistema de recomendaciones demográfico genera las recomendaciones basándose en información demográfica recogida acerca de los usuarios, tal como conclusiones de estudios, poder adquisitivo, origen étnico, etc. Los ítems recomendados pueden ser generados a partir de distintos nichos demográficos, combinando las evaluaciones de los usuarios en dichos nichos [128].
- *Sistemas basados en conocimiento*. Estos sistemas generan las recomendaciones basándose en algún tipo de inferencia sobre qué ítems satisfacen a los usuarios, a partir de información suministrada por cada usuario respecto a su conocimiento sobre los ítems que pueden ser recomendados [26].

Todas estas técnicas tienen sus ventajas e inconvenientes. Sin embargo, en numerosas ocasiones se adopta un *enfoque híbrido*, que combina de distintas formas otros enfoques, para suavizar las desventajas de cada técnica y sacar provecho de sus beneficios [17, 26, 27, 33, 59].

### **Cálculo de la similitud.**

Como veremos a continuación, tanto en un esquema basado en contenidos, como en uno colaborativo o cualquier otro, se necesita calcular la similitud entre usuarios o ítems. Para ello, se suelen usar coeficientes de correlación estadística comunes, como son la medida de similitud del coseno, la correlación de Pearson o el índice de Jaccard, bien conocidos en el ámbito de la Recuperación de Información [14]:

---

- *Medida del coseno*: cuantifica la similitud entre dos vectores según el coseno que formen sus ángulos. Devuelve un valor entre 0 y 1, donde 1 indica la máxima similitud y 0 la mínima. Para aplicarla en un enfoque cualquiera suponemos que dos usuarios o ítems,  $i$  y  $j$ , se representan mediante vectores en el espacio  $v_i$  y  $v_j$ . Se calcula mediante la siguiente expresión:

$$\text{sim}(\vec{v}_i, \vec{v}_j) = \frac{\sum_{k=1}^n v_{ik} \cdot v_{jk}}{\sqrt{\sum_{k=1}^n v_{ik}^2 \cdot \sum_{k=1}^n v_{jk}^2}} \quad (2.1)$$

- *Correlación de Pearson*: se trata de un índice que mide la relación lineal entre dos variables, siendo independiente de la escala de medidas de dichas variables. Está acotado en el intervalo  $[-1, 1]$ , de manera que cuando vale 1 indica que existe una correlación positiva perfecta, 0 indica que no existe relación lineal alguna y  $-1$  indica una relación inversa entre las variables. Se calcula mediante la siguiente expresión:

$$\text{sim}(\vec{v}_i, \vec{v}_j) = \frac{\sum_{k=1}^n (v_{ik} - \bar{v}_i) \cdot (v_{jk} - \bar{v}_j)}{\sqrt{\sum_{k=1}^n (v_{ik} - \bar{v}_i)^2 \cdot \sum_{k=1}^n (v_{jk} - \bar{v}_j)^2}} \quad (2.2)$$

- *Índice de Jaccard*: es una estadística que se usa para comparar la similitud y la diversidad entre dos conjuntos. El coeficiente de Jaccard mide la similitud entre conjuntos de muestras finitas, y se define como el tamaño de la intersección dividido por el tamaño de la unión de los conjuntos de muestra. Devuelve un valor entre 0 y 1, donde 1 indica la máxima similitud y 0 la mínima. Se calcula mediante la siguiente expresión:

$$\text{sim}(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (2.3)$$

Los esquemas de recomendación que más han destacado son los basados en contenidos y los colaborativos, que habitualmente se tienden a combinar a la

---

hora de implantar un sistema de recomendaciones. A continuación describiremos ambas técnicas con algo más de detalle puesto que son los enfoques en los que nos centramos en la presente tesis.

### 2.6.1. Enfoque Basado en Contenidos

El sistema recomienda ítems con características similares a las preferidas por el usuario indicadas en su perfil. Es decir, extraen características de los ítems y las comparan con el perfil del usuario. Dicho perfil estará representado en función de los ítems que previamente el usuario ha probado y valorado, así como cualquier característica que pueda indicar interés o preferencia. Por ejemplo, si un usuario ha valorado positivamente una película de “ciencia ficción”, entonces el sistema puede aprender de eso y así recomendará a ese usuario otras películas de este género.

Las preferencias e intereses de los usuarios son proporcionadas por los propios usuarios directamente o mediante los ítems que previamente dicho usuario ha probado y valorado, o también a adquiridas por la observación de los ítems en los que el usuario se interesa.

Un sistema que implementa este enfoque, analiza un conjunto de descripciones de ítems previamente valorados por un usuario y construye un modelo o perfil de intereses del usuario, basándose en las características de los ítems. El proceso de recomendación se desarrolla en 3 pasos, cada uno de los cuales se realiza por un componente independiente [112]:

1. *Analizador de contenidos.* Cuando la información no está estructurada (por ejemplo, cuando se trabaja con texto), se necesita algún tipo de pre-procesamiento, para extraer información relevante de forma estructurada. Los ítems (documentos, páginas Web, noticias, descripciones de
-

productos, etc.) son, pues, analizados mediante alguna técnica de extracción de características que permita la representación del ítem según la estructura deseada (por ejemplo, páginas Web representadas como vectores de palabras clave).

2. *Establecimiento de perfiles.* Este módulo recopila datos representativos de las preferencias del usuario e intenta generalizar esta información, de cara a construir el perfil del usuario. Esta generalización habitualmente se realiza mediante técnicas de aprendizaje automático, que son capaces de inferir un modelo sobre los intereses del usuario a partir de su valoración sobre ítems que ya ha analizado.
3. *Generación de recomendaciones.* El proceso para recomendar a los usuarios nuevos ítems (aún desconocidos para ellos) que le puedan ser de interés, consiste básicamente en calcular la similitud entre los atributos que constituyen el perfil del usuario y los atributos que representan el contenido de los ítem, de manera que cuando se obtenga una alta similitud, se le recomienda el ítem. El resultado es una estimación sobre la relevancia que el ítem tendrá para el usuario.

En la Figura 2.3 tenemos una representación de un sistema de recomendaciones basado en contenidos. Cuando se pretende estimar la relevancia de un ítem  $i$  para un usuario  $x$ , se calculará la similitud entre dicho ítem  $i$ , representado por sus atributos de forma vectorial, esto es  $VR_i$ , y el perfil del usuario  $x$ , representando sus anteriores valoraciones y otras características que puedan ser de ayuda también de forma vectorial, mediante  $VU_x$ .

Viendo la forma de trabajar del enfoque basado en contenidos, podemos observar que únicamente funciona bien cuando es posible extraer información de

---

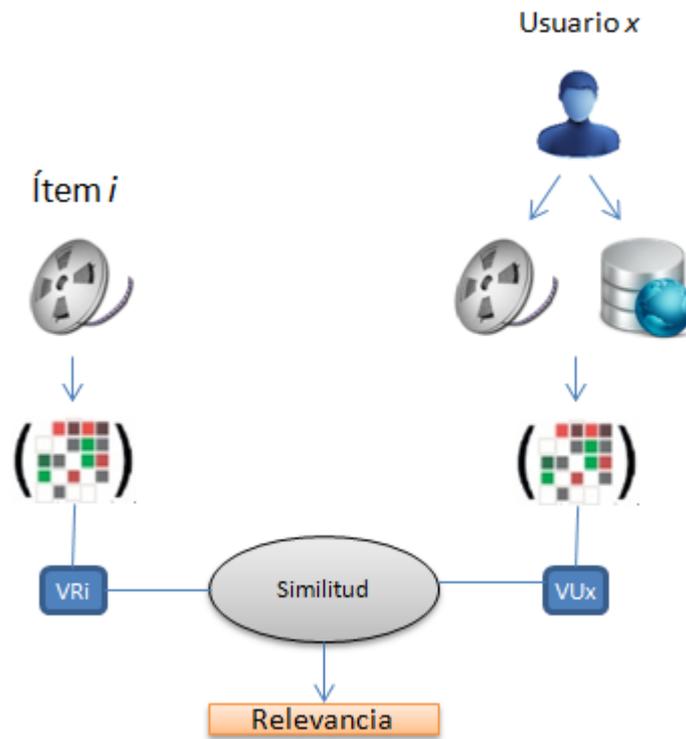


Figure 2.3: Esquema de recomendaciones basado en contenidos.

forma estructurada sobre los ítems, de manera que obtengamos una serie de características que representan al ítem. Otro problema que presentan es la conocida sobre-especialización, que se produce por reducir las recomendaciones siempre a contenidos similares a los que nos han satisfecho, pero sin tener en cuenta la posible arbitrariedad de los gustos o preferencias que puedan tener los usuarios. Por último, estos esquemas también presentan problemas cuando se dispone de poca información sobre los usuarios; es el conocido como problema de arranque en frío para nuevos usuarios (*new user cold-starting problem*) [101].

### Ejemplo de funcionamiento del esquema basado en contenidos.

Un ejemplo de funcionamiento de dicho sistema basado en un hipotético sistema que recomendase películas a usuarios basándose en sus perfiles, podría ser

el siguiente:

Supongamos que tenemos un perfil de usuario, donde por simplificar diremos que 0 significa que no le gusta, y 1 que sí le gusta, que contiene las preferencias de un usuario sobre 5 actores y 5 géneros como se muestra en la Tabla 2.1.

	Bruce Willis	Wesley Snipes	Nicolas Cage	Sean Connery	Ed Harris	Acción	Terrorismo	Ciencia Ficción	Romántica	Comedia
Juan	0	0	0	1	1	1	1	1	0	0
Alberto	1	1	0	0	0	0	0	0	1	1
Álvaro	0	0	0	1	1	1	1	1	1	0

Table 2.1: Ejemplo de perfil de usuario

A continuación tenemos los siguientes perfiles para unas película mostrados en la Tabla 2.2.

Calcular como de buena podría ser la película *The Rock* para el usuario Juan

	Bruce Willis	Wesley Snipes	Nicolas Cage	Sean Connery	Ed Harris	Acción	Terrorismo	Ciencia Ficción	Romántica	Comedia
The Rock	0	0	1	1	1	1	1	0	0	0
Blade	0	1	0	0	0	1	0	1	0	0
Die Hard	1	0	0	0	0	1	0	0	0	1

Table 2.2: Ejemplo de perfiles de películas

usando la similaridad del coseno:

$$\begin{aligned}
 \text{sim}(\overrightarrow{\text{TheRock}}, \overrightarrow{\text{Juan}}) &= \frac{0 \times 0 + 0 \times 0 + 1 \times 0 + 1 \times 1 + 1 \times 1 + 1 \times 1 + 1 \times 1 + 1 \times 0 + 0 \times 0 + 0 \times 0}{\sqrt{5} \times \sqrt{3}} \\
 &= \frac{3}{\sqrt{5} \times \sqrt{3}} = 0.77460
 \end{aligned}$$

### 2.6.2. Enfoque Colaborativo

Los sistemas de recomendaciones basados en el enfoque colaborativo usan representaciones que no están basadas en el contenido, sino que basan su funcionamiento en las valoraciones que los usuarios asignan a los ítems que han analizado. Recomiendan ítems que sean del agrado de los usuarios con intereses similares al usuario activo. Es decir, que se basan en el concepto del *boca a boca*, que habitualmente usamos en nuestras vidas cotidianas: si un amigo, el cual sabemos que tiene gustos similares a los nuestros, nos recomienda una película, seguramente esa película también nos guste a nosotros. Los sistemas colaborativos quieren modelar esta idea intentando reflejar a los usuarios con sus perfiles y que en el caso de que éstos se parezcan, aunque no se conozcan, eso signifique que los dos usuarios comparten gustos y se puedan generar recomendaciones automáticamente sin necesidad de vínculo alguno entre ellos. Estos sistemas identifican usuarios cuyas preferencias sean similares a las de otros usuarios dados y recomiendan a los primeros los elementos que hayan satisfecho a los otros. Por ello, la definición de medidas de similitud entre preferencias es un aspecto clave en estos sistemas.

Entonces este enfoque trabaja sobre un conjunto de usuarios  $U = \{u_1, u_2, \dots, u_n\}$ , un conjunto de ítems  $O = \{o_1, o_2, \dots, o_n\}$  y funciones de valoración parciales  $r_i : U \times O \rightarrow R$ , para cada usuario  $u_i \in U$  y  $R$  un conjunto ordenado. Estas funciones miden la utilidad que un ítem tenga para un usuario, y al ser  $R$  un conjunto ordenado, los valores mayores indican valoraciones positivas, mientras que los valores más pequeños indican valoraciones negativas. Esta información se representa internamente mediante una matriz de usuarios e ítems,  $R_{U \times O}$  donde cada celda  $R_{ij}$  almacena la valoración que el usuario  $u_i$  haya asignado al ítem  $o_j$ .

---

Así visto, el problema podría consistir en predecir valores para las celdas que estén vacías. En el esquema colaborativo, la matriz es por regla general muy dispersa, puesto que cada usuario únicamente habrá valorado un pequeño porcentaje del total de ítems. En la Tabla 2.3 podemos ver un ejemplo de matriz que representa valoraciones de usuarios con respecto a una serie de películas.

	<b>Matrix</b>	<b>Out of Africa</b>	<b>Sim City</b>	<b>Blade</b>
<i>Álvaro</i>	8	2	7	8
<i>María</i>	5	8	2	3
<i>Juan</i>	8	1		7

Table 2.3: Ejemplo de matriz de valoraciones

Debido a la calidad de los resultados obtenidos y la escasa información que se necesita sobre los usuarios, hacen que sea el enfoque más utilizado y extendido.

Este tipo de sistemas también funcionan en tres pasos [150]:

1. *Establecimiento de perfiles*. El sistema guarda un perfil de cada usuario, consistente en las valoraciones asignadas a ítems conocidos (analizados) por él y pertenecientes a la base de datos de ítems con la que se esté trabajando (conjunto  $O$ ).
2. *Identificar grupos de usuarios afines*. Se mide el grado de similitud entre los usuarios del sistema (conjunto  $u$ ) atendiendo a sus perfiles, es decir, a las valoraciones proporcionadas, de manera que se crean grupos de usuarios con características afines (conocidos como *vecinos* o *vecindad*). Este proceso habitualmente se realiza aplicando el sistema de clasificación  $kNN$  (*k Nearest Neighbors*) [38], que calcula los  $K$  vecinos más cercanos a un usuario, a partir de un conjunto de entrenamiento.

3. *Generación de recomendaciones.* El sistema utiliza toda esta información para generar las recomendaciones. A cada usuario le recomienda ítems desconocidos, que hayan sido valorados de forma positiva por otros usuarios con un perfil afín, o bien ítems similares a otros que el usuario ha valorado positivamente. En este punto se pueden usar distintas técnicas (algunas de las cuales veremos a continuación) pero partiendo de la base de que no existen algoritmos mejores o peores, sino que existen algoritmos que se ajustan mejor o peor al contexto concreto en el que estamos trabajando.

En la Figura 2.4 tenemos una representación de un sistema de recomendaciones colaborativo. Cuando se pretenden generar recomendaciones para un usuario  $x$ , se calcularán los usuarios más afines a  $x$ , es decir su vecindad. Este grupo de usuarios afines  $C$ , cumplirá que cada usuario  $C_i$  tendrá un grado de similitud  $\lambda > \alpha$ , donde  $\alpha$  será un umbral establecido previamente que establece cuando dos usuarios son afines. Una vez obtenidos, un ítem  $i$  será recomendado a  $x$  si la agregación de las valoraciones dadas a ese objeto por los usuarios afines a  $x$  pertenecientes a  $C$  es positiva.

Como ejemplo, consideremos de nuevo la Tabla 2.3. Podemos predecir que a Juan le gustará la película *Sim City*. Observamos que Álvaro es el vecino más cercano a Juan, puesto que ambos tienen unas valoraciones muy similares de las películas que ya han visto. Por tanto, la valoración de Álvaro sobre la película *Sim City* tendrá gran influencia en la predicción que hagamos a Juan sobre dicha película. Por el contrario, María tiene opiniones más dispares con respecto a Juan, por lo que tendrán una influencia mucho menor o nula en las recomendaciones que se hagan a dicho usuario.

---

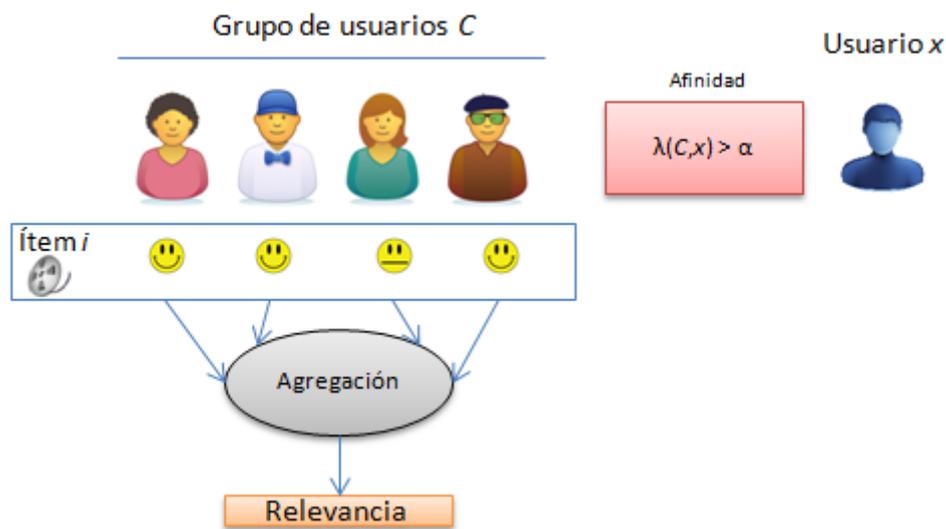


Figure 2.4: Esquema de recomendaciones basado en contenidos.

Sin embargo, este enfoque tampoco está exento de problemas, como son [33]:

- Escasez. Necesitan gran cantidad de información para obtener un buen rendimiento, es decir, necesitan muchos usuarios valorando ítems, para así poder calcular grupos de usuarios con perfiles afines. Si la matriz  $R$  apenas está completada, el proceso de identificar los grupos de usuarios con intereses afines, así como de generación de recomendaciones, no pueden realizarse de forma precisa, obteniendo recomendaciones de baja calidad.
- Escalabilidad. Como hemos visto, el proceso de identificación de grupos de usuarios con intereses afines usado en los esquemas colaborativos utiliza algoritmos específicos que son costosos computacionalmente, coste que crece linealmente cuanto mayor es el número de usuarios e ítems. Por ello, cuando se trabaja con bases de datos demasiado grandes, el sistema sufrirá problemas de escalabilidad.
- Problema de arranque en frío para nuevos ítems (*new item cold-starting*)

*problem*) [27]. Este esquema presenta problemas cuando se inserta un ítem nuevo, o en general, cuando un ítem tiene muy pocas valoraciones, porque no se dispone de información sobre dicho ítem y por tanto no se va a seleccionar para ser recomendado. De igual forma, los nuevos usuarios también recibirán predicciones de baja calidad debido a que al ser nuevos han proporcionado pocas valoraciones y se hace difícil calcular su vecindad. Es por ello que estos sistemas de recomendación requieren de cierto tiempo antes de empezar a generar recomendaciones relevantes y acertadas.

### Generación de recomendaciones.

Estos sistemas pueden hacer uso de numerosas técnicas para conseguir el objetivo de recomendar ítems de interés, pero son dos las que más han destacado y conseguido aceptación:

**Enfoque colaborativo basado en usuarios o memoria.** Este método hace uso de técnicas estadísticas para encontrar un conjunto de vecinos con un perfil similar al usuario activo y posteriormente utilizan algoritmos para combinar las preferencias de esa vecindad y de esta forma poder realizar las predicciones y recomendaciones [63, 148, 157]. Se usa la medida del coseno o correlación de Pearson para calcular la similitud  $s(u_i, u_j)$  entre cada pareja de usuarios  $(u_i, u_j) \in U \times U$ , de manera que obtenemos el conjunto de usuarios más similares a  $u_i$ ,  $prox(u_i)$ . A continuación, se calculan las predicciones sobre las valoraciones de  $u_i$  para todos los ítems  $o_k$  que los vecinos próximos a  $u_i$  hayan valorado, pero que todavía son desconocidos para  $u_i$ , mediante la siguiente expresión:

---

	Ítem1	Ítem2	ítem3	ítem4	ítem5	ítem6
Usuario activo	4	2	3	3	5	?
Usuario1	5	2	2	4	5	3
Usuario2	1	4	2	4	2	2
Usuario3	2	5	5	5	2	4
Usuario4	5	2	4	3	4	4

Figure 2.5: Enfoque colaborativo basado en usuarios o memoria.

$$p_i(o_k) = \bar{r}_i + \frac{\sum_{u_j \in \text{prox}(u_i)} (r_j(o_k) - \bar{r}_j) \cdot s(u_i, u_j)}{\sum_{u_j \in \text{prox}(u_i)} s(u_i, u_j)} \quad (2.4)$$

Las predicciones están basadas por tanto, en los promedios ponderados de las desviaciones de las medias de los vecinos próximos a  $u_i$ .

Siguiendo el ejemplo de una matriz de valoraciones dado anteriormente, en la Figura 2.5 podemos ver como el enfoque colaborativo basado en usuarios considera a los usuarios con patrones de evaluación similares.

**Enfoque colaborativo basado en ítems o modelos** Al igual que el enfoque basado en usuarios, las recomendaciones se calculan según las valoraciones que los usuarios hayan asignado a los ítems. Sin embargo, y a diferencia del anterior enfoque, los valores de similitud son calculados entre ítems y no entre usuarios, de manera que se tienen en cuenta las valoraciones que el usuario activo ha realizado sobre ítems similares al ítem cuya valoración queremos predecir [16, 45, 147]. La idea es que dos ítems  $o_k$  y  $o_l$  serán similares, es decir,  $s(o_k, o_l)$  será elevado, si los usuarios que han valorado uno de ellos tienden a valorar el otro, y si los usuarios tienden a asignarles valoraciones idénticas o similares. A continuación, para cada ítem  $o_k$  se define su conjunto de ítems más similares  $\text{prox}(o_k)$ .

	Ítem1	Ítem2	ítem3	ítem4	ítem5	ítem6
Usuario activo	4	2	3	3	5	?
Usuario1	5	2	2	4	5	3
Usuario2	1	4	2	4	2	2
Usuario3	2	5	5	5	2	4
Usuario4	5	2	4	3	4	4

Figure 2.6: Enfoque colaborativo basado en ítems o modelos.

La predicción sobre la valoración que el usuario  $u_i$  tendrá sobre un determinado ítem  $o_k$ , se calcula mediante la agregación ponderada de las valoraciones que dicho usuario  $u_i$  ha asignado a los ítems similares a  $o_k$ , de la siguiente manera:

$$p_i(o_k) = \frac{\sum_{o_l \in \text{prox}(o_k)} (s(o_k, o_l) \cdot r_i(o_l))}{\sum_{o_l \in \text{prox}(o_k)} |s(o_k, o_l)|} \quad (2.5)$$

Comparado con el enfoque colaborativo basado en usuarios, podemos ver en la Figura 2.6, que la diferencia radica, en que el enfoque colaborativo basado en ítems considera los ítems con patrones de evaluación similares en vez de los usuarios.

### Ejemplo de funcionamiento del enfoque colaborativo basado en ítems.

Un ejemplo de funcionamiento de dicho sistema basado en un hipotético sistema que recomendase películas a usuarios basándose en sus valoraciones, podría ser el siguiente:

Supongamos que tenemos un sistema muy simple en el que tan solo indicamos si nos gusta una película o no, por simplificar mostraremos los usuarios y aquellas películas que le han gustado.

**Juan:** *The Rock, Ace Ventura*

**Alberto:** *The Rock, Superman, Batman*

**Antonio:** *Superman, Ace Ventura*

**Raquel:** *Batman*

Si queremos hacer una recomendación para algún usuario, primero debemos verlo desde la perspectiva de los ítems. Para ello creamos un índice invertido para los ítems y tenemos:

**The Rock:** *Juan, Alberto*

**Ace Ventura:** *Juan, Antonio*

**Superman:** *Alberto, Antonio*

**Batman:** *Alberto, Raquel*

Como hemos considerado el sistema binario, es decir, basado solo en me gusta o no me gusta, para comprobar la similaridad entre las películas *The Rock* y *Ace Ventura*, podemos usar la medida de similitud de *Jaccard*.

$$\text{sim}(\textit{TheRock}, \textit{AceVentura}) = \frac{|\textit{Juan}|}{|\textit{Juan}, \textit{Alberto}, \textit{Antonio}|} = \frac{1}{3}$$

En el numerador tenemos a *Juan*, que es el único usuario al que le gustan las dos películas. En el denominador tenemos que la unión entre las dos películas nos deja 3 usuarios distintos: *Juan, Alberto* y *Antonio*, donde  $||$  nos indica el tamaño del conjunto. Por lo tanto sabemos que la similaridad

---

dad entre *The Rock* y *Ace Ventura* es de  $1/3$  en nuestro caso. Suponemos la misma operación para todos los pares de películas  $(i, j)$ .

Después de tener la similitud estimada para todos los pares, si necesitamos hacerle una recomendación a *Raquel* buscaremos  $sim(Batman, x)$ , donde  $x$  será cualquier otra película y compararemos los valores.

### 2.6.3. Enfoque Híbrido

Es importante observar que los enfoques de recomendaciones basados en contenidos y colaborativos, así como los otros comentados anteriormente, no son mutuamente exclusivos, sino que pueden ser integrados en un mismo sistema para proporcionar sistemas híbridos más potentes. Por lo tanto, un enfoque híbrido combina dos o más técnicas de recomendaciones para aumentar el rendimiento de un sistema de recomendaciones disminuyendo el número o el impacto de los inconvenientes de cada uno de ellos [26].

Basándonos en los dos enfoques más usados, el esquema colaborativo es bastante potente para generar las recomendaciones. Sin embargo, dados los problemas descritos en cada una de las secciones anteriores para que su efectividad se vea aumentada reduciendo al mínimo dichos problemas, es necesario combinarlos con los enfoques basados en contenidos, así como cualquier otro enfoque que pueda incrementar la precisión de las recomendaciones. Por ejemplo, los sistemas colaborativos realizan buenas predicciones de ítems que concuerdan con las preferencias e intereses de los usuarios, pero no trabajan tan bien a la hora de proporcionar información para las necesidades de contenido específicas que pueden ser cubiertas por los otros enfoques.

Otro aspecto a resaltar, es que los sistemas colaborativos, como ya hemos apun-

---

tado previamente, generan recomendaciones a partir de opiniones y preferencias de otros usuarios por lo que para un óptimo funcionamiento del sistema, se hace necesario contar con un cierto número de usuarios y de valoraciones. Cuando un sistema ya se ha diseñado e implantado y empieza a funcionar, normalmente el número de usuarios con los que se cuenta es muy bajo y el problema del arranque en frío se presenta con fuerza, por lo que en este caso, se podría empezar trabajando con un enfoque basado en contenidos y cuando se llegue a un número de usuarios ya aceptable, pasar o combinar con el enfoque colaborativo.

La forma en la que combinar de los diferentes enfoques es objeto de estudio [26]. Desde que cada enfoque proporciona ciertas ventajas y desventajas dependiendo del ámbito en el que se aplique, la forma en que se combinan los diferentes enfoques sigue diferentes estrategias. En la literatura podemos encontrar las diferentes técnicas [26]:

- *Ponderada*. La puntuación de un ítem recomendado se calcula como resultado de todas las técnicas de recomendación presentes en el sistema, cada una de ellas ponderada con la importancia que esta tenga.
  - *Mixto*. La puntuación del ítem a recomendar se presenta como el resultado de la técnica que haya sido encargada de estimarlo, es decir, cada ítem será estimado por la técnica adecuada en cada caso.
  - *Cambiante*. El sistema alternará entre las diferentes técnicas basándose en algún criterio a tener en cuenta.
  - *Combinación de características*. Para tratar con información colaborativa de una forma que sea una simple característica más de los datos asociada con cada ejemplo y usar las técnicas de recomendación basadas en contenido para que coincidan los ítems.
-

- *Incremento de características.* Una técnica será la encargada de producir una calificación o una clasificación para un ítem y esa información será usada por la siguiente técnica de recomendación.
- *Cascada.* El sistema empleará primero una de las técnicas de recomendaciones para producir un *ranking* o lista previa de candidatos que usará la siguiente técnica.
- *Meta-level.* Esta última estrategia usa la salida de una de las técnicas como entrada de de otra.

Expuesto lo anterior, podemos concluir que en la mayoría de las ocasiones la mejor opción es adoptar un enfoque híbrido entre colaborativo y cualquier otra técnica, el más común es el basado en contenidos, y de esta forma disfrutar de las ventajas de ambos. En la literatura se pueden encontrar gran cantidad ejemplos de sistemas que usan un enfoque híbrido para abordar la solución a un problema, que van desde periódicos on-line, recomendaciones acerca de programas de televisión, hasta las propias bibliotecas digitales que abordamos en esta tesis [16, 17, 33, 128, 132, 133, 159].

## 2.7. Fase de Realimentación

La actividad de generación de recomendaciones es seguida por una fase de realimentación de relevancia, también conocida como *feedback* (su nombre en inglés). La realimentación es un proceso cíclico en el que los usuarios realimentan al sistema con decisiones sobre la relevancia que tienen para ellos los documentos recuperados y suministrados. Entonces, el sistema usa estas evaluaciones para actualizar automáticamente los perfiles de los usuarios [61, 137].

---

De nuevo se pueden adoptar dos técnicas para registrar la realimentación por parte de los usuarios. Se habla de *realimentación explícita* cuando el sistema requiere que el usuario evalúe los ítems explícitamente. La otra técnica, denominada *realimentación implícita*, no requiere de participación alguna por parte del usuario activo, sino que se va monitorizando y analizando el comportamiento del usuario.

La realimentación se considera una etapa fundamental en un sistema de recomendaciones, ya que es la manera de comprobar, si las salidas o recomendaciones proporcionadas por el sistema cumplen lo esperado o no. Además, la realimentación forma parte del perfil del usuario, ya sea en forma de lista negra, marcando los errores a evitar en un futuro o reforzando el funcionamiento del sistema en una dirección u otra, ya que se dan altas valoraciones en los casos en los que los usuarios están satisfechos así como bajas valoraciones cuando no lo están.

## 2.8. Evaluación de un Sistema de Recomendaciones

Cuando se propone y diseña un sistema de recomendaciones es indispensable evaluarlo de cara a cuantificar su rendimiento, es decir, cómo de útiles son las recomendaciones generadas por el sistema. Además, en el ámbito científico, ello permitirá comparar distintos esquemas de recomendación. En este sentido, podemos desarrollar dos tipos de evaluaciones:

- Evaluación *online*: se les pregunta directamente a los usuarios sus opiniones sobre la relevancia de las recomendaciones generadas por el sistema.
  - Evaluación *offline*: es la utilizada habitualmente porque con la evaluación online normalmente es difícil conseguir un gran número de usuarios,
-

ítems y valoraciones. Consiste en generar recomendaciones para bases de datos ya conocidas y comprobar el resultado. Explicamos este tipo de evaluación con más detalle en el siguiente apartado.

### 2.8.1. Métodos de Evaluación *Offline*

En este tipo de métodos se utilizan grandes conjuntos de datos que contienen valoraciones que los usuarios han proporcionado sobre los ítems. Uno de los conjuntos de datos más conocido y extendido es el denominado MovieLens [63]. Está disponible públicamente<sup>14</sup> y al ser tan extendido, es el conjunto que se suele utilizar para comparar distintos esquemas de recomendación. Este conjunto de datos está centrado en el ámbito cinematográfico y toda la información fue recopilada desde el 19 de septiembre de 1997 hasta el 22 de abril de 1998, dentro del proyecto de investigación *GroupLens* de la Universidad de Minnesota. Se proporcionan 3 conjuntos de datos:

1. *MovieLens 100K* que consta de 100000 valoraciones proporcionadas por 1000 usuarios sobre un total de 1700 películas.
2. *MovieLens 1M* que consta de 1 millón de valoraciones proporcionadas por 6000 usuarios sobre un total de 4000 películas.
3. *MovieLens 10M* que consta de 10 millones de valoraciones y 100000 aplicaciones de etiquetas a 10000 películas por 72000 usuarios.

Las valoraciones se realizan sobre una escala numérica de 1 a 5, donde  $1 = \text{Horrible}$ ,  $2 = \text{Bastante mala}$ ,  $3 = \text{Está bien}$ ,  $4 = \text{Disfrutarás}$ ,  $5 = \text{Debes verla}$ . Además, cada usuario debe valorar al menos 20 películas.

Una vez seleccionado el conjunto de datos, se usa la técnica de aprendizaje

---

<sup>14</sup> <http://www.grouplens.org/node/73>

automático conocida como **validación cruzada** (*cross validation*) para estimar la precisión que un modelo predictivo tendrá en la práctica [136]. El conjunto de datos se divide en conjuntos complementarios, analizando uno de los subconjuntos, llamado de entrenamiento, y validando el análisis sobre los otros conjuntos, denominados de test. Para reducir posibles variaciones, se repite el proceso varias veces pero usando distintas particiones. Es lo que se denomina *k-fold cross validation* [136], en el que la muestra original se divide aleatoriamente en  $k$  partes y el proceso se repite  $k$  veces, usando cada parte al menos una vez como conjunto de test. En cada iteración se selecciona la parte correspondiente como conjunto de test, que usaremos para estimar el error obtenido con el modelo, y las restantes  $k - 1$  partes constituyen el conjunto de entrenamiento. Al final se calcula el error medio cometido en cada iteración, que nos da una idea sobre la desviación entre las predicciones efectuadas por el modelo y las valoraciones reales. Los valores para  $k$  que habitualmente se usan son 4, 5, ... 10.

### 2.8.2. Métricas de Evaluación

Las medidas usadas habitualmente para evaluar la calidad de las recomendaciones son la **precisión**, **exhaustividad** (*recall*) y **F1** [34, 148]. Para calcular estas métricas necesitamos una tabla de contingencia para clasificar los ítems con respecto a las necesidades de información. Los ítems son clasificados como relevantes e irrelevantes y como seleccionados (recomendados a los usuarios) o no seleccionados. Tal y como vemos en la Tabla 2.4, la tabla de contingencia se crea usando estas cuatro categorías. Las medidas se definen de la siguiente forma:

**Definición 2.1. Precisión** se define como la proporción de ítems relevantes seleccionados del total de ítems seleccionados, es decir, mide la probabilidad

---

	Seleccionado	No seleccionado	Total
Relevante	$N_{rs}$	$N_{rn}$	$N_r$
Irrelevante	$N_{is}$	$N_{in}$	$N_i$
Total	$N_s$	$N_n$	$N$

Table 2.4: Tabla de contingencia.

de que un ítem seleccionado sea relevante:

$$P = \frac{N_{rs}}{N_s} \quad (2.6)$$

**Definición 2.2.** **Recall** se calcula como la proporción de ítems relevantes seleccionados del total de ítems relevantes, es decir, representa la probabilidad de que un ítem relevante sea seleccionado:

$$R = \frac{N_{rs}}{N_r} \quad (2.7)$$

**Definición 2.3.** **F1** es una combinación de métricas que da igual importancia a la precisión y al recall [148]:

$$F1 = \frac{2 \times R \times P}{R + P} \quad (2.8)$$

Además, de cara a validar el rendimiento de un modelo y compararlo con otros enfoques, también se estudia la precisión del sistema en cuestión, es decir, su capacidad para predecir correctamente las valoraciones de los usuarios. Por ello se suele utilizar la métrica de precisión conocida como **Error Medio Absoluto** (*Mean Absolute Error - MAE*) [65, 153], que se define como:

**Definición 2.4.** El **Error Medio Absoluto** (*Mean Absolute Error - MAE*) considera la desviación absoluta media entre las valoraciones predichas por el sistema y las reales suministradas por el usuario. Se calcula mediante la siguiente expresión:

$$MAE = \frac{\sum_{i=1}^n abs(p_i - r_i)}{n}, \quad (2.9)$$

donde  $n$  es el número de casos en el conjunto de test,  $p_i$  la valoración predicha para un ítem y  $r_i$  su valoración real.

## 2.9. Aspectos a Considerar en el Diseño de Sistemas de Recomendaciones

Algunos aspectos que debemos considerar sobre las recomendaciones en el diseño de sistemas de recomendaciones son [137]:

- **Representación de las recomendaciones.** Los contenidos de una evaluación o recomendación pueden venir dados por un valor cuantificable o por comentarios de texto sin estructurar, como por ejemplo una crítica.
- **Expresión de las recomendaciones.** Las recomendaciones pueden ser introducidas de forma explícita o bien de forma implícita.
- **Aspectos de identificación de la fuente.** Las recomendaciones pueden realizarse de forma anónima, identificando la fuente, o bien usando un seudónimo.
- **Forma de agregar las evaluaciones.** La forma de agregación de las evaluaciones disponibles sobre los ítems de cara a generar las recomendaciones. Estas agregaciones pueden ser por ejemplo una suma ponderada de la evaluación concedida por parte de los usuarios con respecto a los ítems.
- **Contenido de las recomendaciones.** Las recomendaciones se pueden mostrar de distintas formas. Por ejemplo, se podrían mostrar los ítems en forma de lista ordenada según las recomendaciones de cada uno.

A continuación describimos algunas sugerencias que nos pueden ayudar a la hora de plantearnos el diseño de un sistema de recomendaciones [121, 137]:

---

- Los diseñadores de sistemas de recomendaciones a menudo se encuentran con el problema de elegir entre facilidad de uso o precisión de los esquemas de recomendación. Esto es, recogiendo poca información sobre las preferencias de los usuarios con respecto a los ítems o requiriendo una mayor participación por parte de los usuarios. Podemos sugerir que merece la pena recoger más información sobre los usuarios aunque se pierda en facilidad de uso, si ello va a significar un aumento considerable de la precisión. La forma de realizar esta tarea ha de ir enmascarada o ligada a recompensas que hagan que el usuario no se canse del sistema.
  - La satisfacción de los usuarios, así como su disposición a valorar los ítems serán más altas en aquellos sistemas que incluyen algún tipo de valor añadido a la hora de realizar la valoración. Por ejemplo, en un sistema de recomendación de películas, sería útil incluir la portada, pero por ejemplo, mejor si se añade algo más de información como puede ser la sinopsis, la valoración de otros usuarios o la recaudación de la película en los cines, datos curiosos que pueden dar la sensación al usuario de estar contribuyendo a construir la opinión generalizada acerca de esa película.
  - Definir la escala de las valoraciones es algo complicado, por lo que se aconseja en la medida de lo posible estudiarlo conjuntamente con los futuros usuarios del sistema. Es por ello que uso de un modelado lingüístico adecuado o un sistema de puntuación sencillo es crucial para el éxito del sistema.
  - Algo realmente atractivo de un sistema de recomendaciones es que proporcione recomendaciones de ítems que no se esperaban, por ejemplo ítems nuevos o ítems poco conocidos, pero en muchos casos igualmente válidos. Saber graduar la diversidad que cada usuario espera obtener es difícil, se puede considerar añadirlo como parámetro ajustable por el
-

usuario.

- Otro aspecto a tener en cuenta es detallar claramente la información característica de los ítems a la hora de recomendarlos, y considerar incluso la posibilidad de incluir opiniones que sobre los ítems tengan el resto de usuarios. El perfil de los ítem es tan importante como el perfil de los usuarios o más.
- Sin embargo, la mejor receta para que un sistema de recomendaciones sea efectivo es utilizar diferentes estrategias para diferentes personas, es decir, adaptar las técnicas y métodos de diseño según el tipo de usuarios y de ítems con los que vaya a trabajar el sistema.

## 2.10. Problemas Asociados a los Sistemas de Recomendaciones

Los sistemas de recomendaciones introducen una serie de problemas que habrá que considerar en su diseño [15, 137].

- En primer lugar, una vez que se ha establecido un perfil de intereses, es fácil considerar libremente las evaluaciones suministradas por otros. Sin embargo, como comentamos anteriormente, no solo es un aspecto a tener en cuenta al diseñar un sistema de recomendaciones, sino también un problema asociado a éste, tanto en cuanto los usuarios son altamente reacios a introducir datos en el sistema. En algunos casos se hace necesario recurrir a incentivos para la provisión de recomendaciones, puesto que los usuarios no suelen estar muy dispuestos a colaborar proporcionando información personal sobre sus preferencias y de esta forma definir su perfil. Estos incentivos podrían consistir, en que a cambio de recibir reco-
-

recomendaciones o puntos canjeables por cualquier otra característica, ya sea externa o interna al sistema, el usuario debe introducir obligatoriamente datos sobre sus preferencias.

- Un segundo problema a solucionar es mantener una total independencia en el ciclo de las recomendaciones, si ha de intervenir algún experto en la valoración de algún ítem, este experto ha de ser totalmente neutral y no incidir en la valoración de ningún ítem por algún motivo no relacionado con el sistema.
  - En los sistemas de recomendaciones también habrá que tener en cuenta aspectos de privacidad y debido a que algunas personas no quieren que se conozcan sus hábitos o preferencias, hay que considerar la participación anónima o bajo un seudónimo, así como la protección de los datos personales incluidos bajo las leyes de protección de datos que rijan en cada momento.
  - El mantenimiento de un sistema de recomendaciones es costoso, por lo que se hace necesario pensar en modelos de negocio que se podrían usar para generar ingresos suficientes para cubrir dichos costes. A veces esos modelos de negocio influyen directamente en la calidad de esas recomendaciones, el balance entre calidad de las recomendaciones y el modelo de negocio puede ser un punto que necesite de un estudio concienzudo.
  - Aunque se ha demostrado que los sistemas de recomendaciones pueden llegar a ser suficientemente precisos en determinados dominios, hay otros dominios en los que existe un gran riesgo en aceptar las recomendaciones proporcionadas por el sistema debido a que el conocimiento de los usuarios sobre el dominio es nulo y solo se tiene la información proporcionada por el sistema.
-

Hay dos razones fundamentales por las que no se tiene confianza en estos sistemas en dominios de alto riesgo. Primera, estos sistemas son procesos que calculan predicciones basándose en modelos que son aproximaciones heurísticas de procesos humanos. Segunda, y quizá más importante, la mayoría de las veces basan sus cálculos en datos incompletos y dispersos. Estas razones hacen que estos sistemas ocasionalmente generen recomendaciones incorrectas, o imprecisas. Sin embargo los usuarios no reciben ningún tipo de indicador que les permita determinar la confianza o fiabilidad de una recomendación cuando estén dudosos. En este sentido, una solución consistiría en incluir **explicaciones** con las recomendaciones o un indicador del grado de fiabilidad, que en cualquier caso nos ayudaría a mejorar el rendimiento del sistema. Estas explicaciones añadirían transparencia al proceso y los usuarios estarían más dispuestos a confiar en las recomendaciones cuando conocieran las razones que hay detrás de una recomendación [61, 121, 151]. Por ejemplo, en Twitter<sup>15</sup>, cuando se nos recomiendan ciertos usuarios a los que seguir, aclara que es debido a que usuario se te ha hecho esa recomendación.

Otro ejemplo sería cuando un amigo nos hace una sugerencia, un aspecto a tener en cuenta es cómo han funcionado anteriormente las recomendaciones de dicho amigo o también comparar los intereses generales o preferencias de nuestro amigo con las nuestras en el ámbito concreto en que se realiza la recomendación. Sin embargo, si aún tuviéramos dudas, preguntaríamos para que nuestro amigo nos explicara las razones que le han llevado a realizar esa sugerencia. Con esta información adicional podremos analizar la lógica de la sugerencia y determinar si es suficiente

---

<sup>15</sup> <https://twitter.com/>

---

o no.

Por tanto, incluir las explicaciones de forma automática en un sistema de recomendaciones tiene las siguientes ventajas:

1. El usuario comprende el razonamiento que hay detrás de una recomendación, de forma que puede decidir qué credibilidad conceder a dicha recomendación.
2. El usuario se involucra en el proceso de recomendación, permitiéndose el uso de su conocimiento para completar el proceso de decisión.
3. El usuario se va familiarizando con el proceso de generación de recomendaciones de forma que puede ir reconociendo las fortalezas y debilidades del sistema, disminuyendo la desconfianza en él.

En definitiva, las explicaciones nos aportan una mayor aceptación del sistema como ayuda de confianza en los procesos de toma de decisiones, puesto que sus limitaciones y potencialidades son visibles, y sus sugerencias se nos muestran justificadas, potenciando así la confianza en él.

- Un último problema es dotar a los sistemas de recomendaciones de mejores técnicas de representación de las preferencias o recomendaciones de los usuarios que nos permitan captar verdaderamente su concepto del objeto recomendado y así mejorar la interacción entre el sistema y los usuarios. En este sentido la incorporación de las más avanzadas técnicas semánticas podrán solucionar los problemas asociados a la representación de opiniones, valoraciones y características de difícil representación.
-

# Chapter 3

## Modelado Lingüístico Difuso

En este capítulo vamos a estudiar las distintas técnicas de modelado lingüístico difuso para el manejo de información lingüística. Estas técnicas nos van a proporcionar una mayor flexibilidad en el tratamiento de la información, especialmente en los casos en que se produce una interacción con los usuarios puesto que se les permitirá operar con información lingüística facilitando su participación e interacción con el sistema.

### 3.1. Introducción

La lógica difusa se plantea como alternativa a la lógica tradicional, con el objetivo de introducir grados de incertidumbre en las sentencias que califica [174]. Hay numerosas situaciones en las que la lógica tradicional funciona perfectamente. Por ejemplo, supongamos que partimos de las mediciones obtenidas en un radar de tráfico destinado al control de la velocidad y queremos agrupar a los infractores (aquellos que hayan sobrepasado el límite establecido, para nuestro ejemplo 130 km/h). El proceso de razonamiento que se seguiría mediante la lógica tradicional sería ir comparando cada medición con 130 hasta obtener cuáles serán sancionados y cuáles no:

*Es cierto que  $155 > 130$ ? SI: Sancionado*  
*Es cierto que  $100 > 130$ ? NO: No sancionado*

*Es cierto que  $130 > 130$ ? NO: No sancionado*

Sin embargo, la información que manejamos en el mundo real puede tener diferentes rangos de valoración y los valores pueden tener distinta naturaleza. En ocasiones, puede que no sea fácil valorarla de forma precisa mediante un valor cuantitativo, sin embargo puede que sí sea factible hacerlo de forma cualitativa. En este caso, adoptar un enfoque lingüístico suele ofrecer mejores resultados que si aplicamos uno numérico. Por ejemplo, cuando evaluamos determinados aspectos relacionados con la percepción subjetiva (*diseño, gusto, diversión, etc.*), solemos utilizar palabras en lenguaje natural en lugar de valores numéricos (*bonito, feo, dulce, salado, mucha, poca, etc.*). Esto hecho se puede deber a diversas causas:

- Hay situaciones en las que la información, por su propia naturaleza, no puede ser cuantificada y por tanto únicamente puede ser valorada mediante el uso de términos lingüísticos, como sucede cuando realizamos una valoración sobre una canción que hayamos escuchado, que solemos usar términos como *bueno, regular o malo*.
- En otros casos, trabajar con información precisa de forma cuantitativa no es posible, o bien porque no están disponibles los elementos necesarios para llevar a cabo una medición exacta de esa información, o bien porque el coste computacional es demasiado alto y nos basta con la aplicación de un valor aproximado. Por ejemplo, cuando evaluamos la velocidad de conexión a Internet, en lugar de usar valores numéricos, solemos usar términos tales como *rápido, muy rápido o lento*.

En este sentido, el uso de la teoría de conjuntos difusos ha dado muy buenos

---

---

resultados para el tratamiento de información de forma cualitativa [173, 174], así como en numerosos campos, como por ejemplo en la toma de decisiones [72, 162, 170], la evaluación de la calidad informativa de documentos Web [80], modelos de recuperación de información [23, 76, 77], diagnósticos clínicos o sanidad [42, 154], *social media* [158], etc. El *modelado lingüístico difuso* (**MLD**) es una herramienta que permite representar aspectos cualitativos y que está basada en el concepto de *variables lingüísticas*, es decir, variables cuyo valores no son números, sino palabras o sentencias expresadas en lenguaje natural o artificial [174]. Cada valor lingüístico se caracteriza por un valor sintáctico o *etiqueta* y un valor semántico o *significado*. La etiqueta es una palabra o sentencia perteneciente a un conjunto de términos lingüísticos y el significado es un subconjunto difuso en un universo de discurso.

En este capítulo, vamos a revisar los principales enfoques de modelado lingüístico difuso que podemos usar para el manejo de información lingüística. En la Sección 2 vamos a revisar los conceptos básicos para el manejo de información lingüística. En la Sección 3 vamos a tratar el modelo tradicional, el modelado lingüístico difuso clásico. En la Sección 4 veremos el modelado lingüístico difuso ordinal definido para eliminar la excesiva complejidad del enfoque lingüístico tradicional. En la Sección 5 nos centraremos en el enfoque de las 2-tupla, definido como una mejora del anterior. En la Sección 6 estudiaremos el enfoque lingüístico difuso multi-granular que al permitir trabajar con distintos conjuntos de etiquetas nos será muy útil en aquellos casos en los que no sea eficiente valorar la información usando un mismo sistema de valores. Después, en la Sección 7 veremos el enfoque lingüístico difuso no balanceado para aplicar en aquellas situaciones en las la información necesite ser valorada sobre un conjunto de etiquetas no uniforme, es decir, asimétrico. En la Sección 8 veremos en enfoque lingüístico difuso vacilante para aquellas situaciones en las que la

---

información lingüística puede ser evaluada de diferentes formas, es decir cuando te hace dudar entre cual será la más adecuada. Para finalizar, en la Sección 9 veremos diferentes aplicaciones del modelado lingüístico difuso en sistemas de acceso a la información y en la Sección 10, unos ejemplos de sistemas de recomendaciones basados en el modelado lingüístico difuso.

## 3.2. Conceptos Básicos

Comenzaremos presentando una revisión de los conceptos básicos de la Teoría de Conjuntos Difusos que van a ser utilizados en el resto de enfoques.

### 3.2.1. Conjuntos Difusos y Definiciones básicas

El interés de la teoría de conjuntos difusos se centra esencialmente en modelar aquellos problemas donde los enfoques clásicos de la teoría de conjuntos y la teoría de la probabilidad resultan insuficientes o no operativos. Por ello, generaliza la noción clásica de conjunto e introduce el concepto de *ambigüedad*, de manera que los conjuntos difusos nos proporcionan una nueva forma de representar la imprecisión e incertidumbre presentes en determinados problemas.

La lógica difusa se fundamenta en el concepto de *conjunto difuso* [173] que suaviza el requerimiento de estrictamente pertenecer o no a un conjunto y admite valores intermedios en la función característica, que se denomina *función de pertenencia*. Esto permite una interpretación más realista de la información, puesto que la mayoría de las categorías que describen los objetos del mundo real, no tienen unos límites claros y bien definidos.

Un conjunto difuso puede definirse como una colección de objetos con valores de pertenencia entre 0 (exclusión total) y 1 (pertenencia total). Los valores de

---

pertenencia expresan los grados con los que cada objeto es compatible con las propiedades o características distintivas de la colección. Formalmente podemos definir un conjunto difuso como sigue.

**Definición 3.1.** Un *conjunto difuso*  $\tilde{A}$  sobre un dominio o universo de discurso  $U$  está caracterizado por una función de pertenencia que asocia a cada elemento del conjunto el grado con que pertenece a dicho conjunto, asignándole un valor en el intervalo  $[0,1]$ :

$$\mu_{\tilde{A}} : U \rightarrow [0, 1]$$

Así, un conjunto difuso  $\tilde{A}$  sobre  $U$  puede representarse como un conjunto de pares ordenados de un elemento perteneciente a  $U$  y su grado de pertenencia,  $\tilde{A} = \{(x, \mu_{\tilde{A}}(x)) / x \in U, \mu_{\tilde{A}}(x) \in [0, 1]\}$ . Por ejemplo, consideremos el concepto *coche potente*, en un contexto donde la potencia oscila entre 50 CV y 300 CV. Como es de suponer, un coche que tenga 75 CV no se puede considerar como *coche potente* por lo que su grado de pertenencia al conjunto de coches potentes será de 0. Por el contrario, un coche que tenga 270 CV sí lo consideramos potente por lo que su grado de pertenencia al conjunto es de 1.

Las gráficas que representan una función de pertenencia pueden adoptar cualquier forma, cumpliendo propiedades específicas, pero es el contexto de la aplicación lo que determina la representación más adecuada en cada caso. Puesto que las valoraciones lingüísticas dadas por los usuarios son únicamente aproximaciones, algunos autores consideran que las funciones de pertenencia trapezoidales lineales son suficientemente buenas para capturar la imprecisión de tales valoraciones lingüísticas. La representación paramétrica es obtenida a partir de una 4-tupla  $(a, b, \alpha, \beta)$ , donde  $a$  y  $b$  indican el intervalo en que el valor de pertenencia es 1, con  $\alpha$  y  $\beta$  indicando los límites izquierdo y derecho del dominio de definición de la función de pertenencia trapezoidal. A continuación se muestra la descripción de la forma general de una función trapezoidal y

---

la representación gráfica de un ejemplo de función de pertenencia trapezoidal (Figura 3.1):

$$\mu_A(x, a, b, \alpha, \beta) = \begin{cases} 0 & \text{si } x < \alpha \text{ o } x > \beta \\ \frac{x-\alpha}{a-\alpha} & \text{si } \alpha \leq x \leq a \\ 1 & \text{si } a \leq x \leq b \\ \frac{\beta-x}{\beta-b} & \text{si } b \leq x \leq \beta \end{cases} \quad (3.1)$$

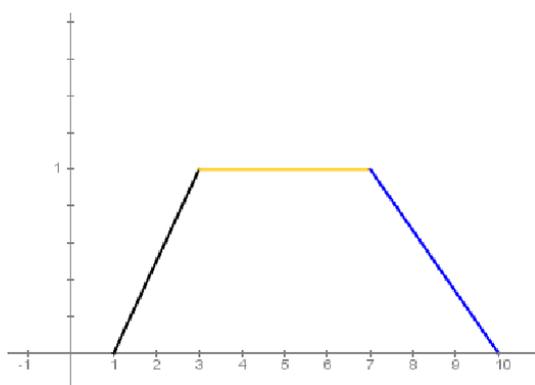


Figure 3.1: Ejemplo de función de pertenencia.

Un caso particular de este tipo de representación son las valoraciones lingüísticas cuyas funciones de pertenencia son triangulares, es decir,  $a = b$ , por lo que se representan por medio de una 3-tupla  $(a, \alpha, \beta)$ .

### 3.2.2. Definiciones Básicas

El modelado lingüístico representa los aspectos cualitativos como valores lingüísticos mediante lo que se conoce como *variables lingüísticas* [174]. Una variable lingüística se caracteriza por un *valor sintáctico* o *etiqueta* que es una palabra o frase perteneciente a un conjunto de términos lingüísticos, y por un *valor semántico* o *significado* de dicha etiqueta que viene dado por un subconjunto difuso en un universo de discurso. Formalmente es definida de la siguiente manera.

**Definición 3.2.** [174] Una *variable lingüística* está caracterizada por una 5-tupla  $(H, T(H), U, G, M)$ , donde:

- $H$  es el nombre de la variable;
- $T(H)$  (o sólo  $T$ ) simboliza el conjunto de términos lingüísticos de  $H$ , es decir, el conjunto de nombres de valores lingüísticos de  $H$ , donde cada valor es una variable difusa denotada genéricamente como  $X$  que toma valores en el universo de discurso;
- $U$  el universo de discurso que está asociado con una variable base denominada  $u$ ;
- $G$  es una regla sintáctica (que normalmente toma forma de gramática) para generar los nombre de los valores de  $H$ ;
- $M$  es una regla semántica para asociar significado a cada elemento de  $H$ , que será un subconjunto difuso de  $U$ .

Por ejemplo, consideremos la variable lingüística  $H = Edad$ , con  $U = [0, 100]$  y la variable base  $u \in U$ . El conjunto de términos asociados con la velocidad podría ser  $H(L) = \{joven, maduro, viejo\}$  donde cada término en  $H(edad)$  es el nombre de un valor lingüístico de *edad*. El significado  $M(X)$  de una etiqueta  $H \in H(edad)$  se define como la restricción  $H(u)$  sobre la variable base  $u$  impuesta según el nombre de  $H$ . Por lo tanto  $M(X)$  es un conjunto difuso de  $U$  cuya función de pertenencia  $H(u)$  representa la semántica del nombre  $H$ . En la Figura 3.2 podemos ver una representación gráfica del ejemplo.

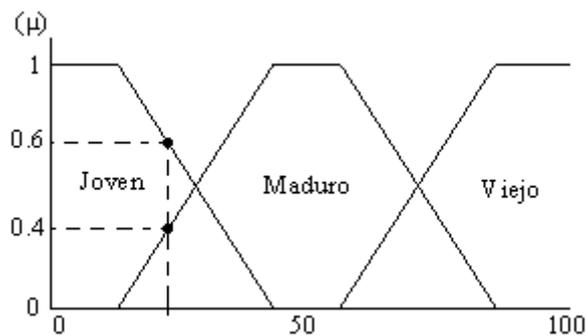


Figure 3.2: Ejemplo de una variable lingüística.

**Definición 3.3.** Se define el *soporte* de un conjunto difuso  $\tilde{A}$  en el universo  $U$ , como el conjunto formado por todos los elementos de  $U$  cuyo grado de pertenencia a  $\tilde{A}$  sea mayor que 0:

$$\text{supp}(\tilde{A}) = \{x \in U / \mu_{\tilde{A}}(x) > 0\}$$

**Definición 3.4.** La *altura* de un conjunto difuso  $\tilde{A}$  se define como el mayor grado de pertenencia de todos los elementos de dicho conjunto:

$$h(\tilde{A}) = \max\{\mu_{\tilde{A}}(x) / x \in U\}$$

**Definición 3.5.** El  $\alpha$ -*corte* de un conjunto difuso  $\tilde{A}$  es el conjunto formado por todos los elementos del universo  $U$  cuyos grados de pertenencia en  $\tilde{A}$  son mayores o iguales que el valor de corte  $\alpha \in [0, 1]$ :

$$\alpha_{\tilde{A}} = \{x \in U / \mu_{\tilde{A}}(x) \geq \alpha\}$$

**Definición 3.6.** Se denomina *conjunto de niveles* de un conjunto difuso  $\tilde{A}$ , al conjunto de grados de pertenencia de sus elementos:

$$L(\tilde{A}) = \{a / \mu_{\tilde{A}}(x) = a, x \in U\}$$

### 3.2.3. Operaciones con Conjuntos Difusos

Las operaciones lógicas que se pueden establecer entre conjuntos difusos son la intersección, la unión y el complemento, al igual que en la lógica tradicional. Así como el resultado de operar dos conjuntos clásicos es un nuevo conjunto clásico, en el caso de los conjuntos difusos, las mismas operaciones con conjuntos difusos también nos darán como resultado otros conjuntos difusos.

Cualquier operación que cumpla las propiedades de una *t-norma* puede ser usada para hacer la intersección, de igual manera que cualquier operación que cumpla las propiedades de una *t-conorma* puede ser empleada para la unión. La Tabla 3.1 muestra las propiedades que deben cumplir las dos familias de funciones y algunos ejemplos.

	<i>Propiedades</i>	<i>Ejemplos</i>
<p><b>T-Normas</b>  <math>T:[0,1] \times [0,1] \rightarrow [0,1]</math>  <math>\mu_{A \cap B}(x) = T[\mu_A(x), \mu_B(x)]</math></p>	<p><b>Conmutativa</b>  <math>T(a,b) = T(b,a)</math>  <b>Asociativa</b>  <math>T(a, T(b,c)) = T(T(b,a), c)</math>  <b>Monotonía</b>  <math>T(a,b) \geq T(c,d)</math> si <math>a \geq c</math> y <math>b \geq d</math>  <b>Condiciones de frontera</b>  <math>T(a,1) = a</math></p>	<p><b>Intersección estándar</b>  <math>T(a,b) = \min(a,b)</math>  <b>Producto algebraico</b>  <math>T(a,b) = a \cdot b</math>  <b>Intersección drástica</b>  <math>T(a,b) = \begin{cases} a &amp; \text{si } b = 1 \\ b &amp; \text{si } a = 1 \\ 0 &amp; \text{Otro caso} \end{cases}</math></p>
<p><b>T-Conormas</b>  <math>S:[0,1] \times [0,1] \rightarrow [0,1]</math>  <math>\mu_{A \cup B}(x) = S[\mu_A(x), \mu_B(x)]</math></p>	<p><b>Conmutativa</b>  <math>S(a,b) = S(b,a)</math>  <b>Asociativa</b>  <math>S(a, S(b,c)) = S(S(b,a), c)</math>  <b>Monotonía</b>  <math>S(a,b) \geq S(c,d)</math> si <math>a \geq c</math> y <math>b \geq d</math>  <b>Condiciones de frontera</b>  <math>S(a,0) = a</math></p>	<p><b>Unión estándar</b>  <math>S(a,b) = \max(a,b)</math>  <b>Suma algebraico</b>  <math>S(a,b) = a + b - a \cdot b</math>  <b>Unión drástica</b>  <math>S(a,b) = \begin{cases} a &amp; \text{si } b = 0 \\ b &amp; \text{si } a = 0 \\ 1 &amp; \text{Otro caso} \end{cases}</math></p>

Table 3.1: T-normas y T-conormas

Las operaciones se definen de la siguiente manera:

- Intersección:  $\tilde{A} \cap \tilde{B} = \{(x, \mu_{\tilde{A} \cap \tilde{B}}) / \mu_{\tilde{A} \cap \tilde{B}}(x) = T[\mu_{\tilde{A}}(x), \mu_{\tilde{B}}(x)]\}$
- Unión:  $\tilde{A} \cup \tilde{B} = \{(x, \mu_{\tilde{A} \cup \tilde{B}}) / \mu_{\tilde{A} \cup \tilde{B}}(x) = S[\mu_{\tilde{A}}(x), \mu_{\tilde{B}}(x)]\}$
- Complemento:  $\mu_{\sim \tilde{A}}(x) = 1 - \mu_{\tilde{A}}(x)$

En la Figura 3.3 podemos ver una representación gráfica de dichas operaciones.

### 3.2.4. Pasos para la Aplicación de un Enfoque Lingüístico Difuso

En cualquier ámbito en el que deseemos aplicar un enfoque lingüístico para la resolución de algún problema, debemos tomar dos decisiones:

- *Modelo computacional*: definir el modelo computacional seleccionando los correspondientes operadores de comparación y de agregación necesarios.
- *Modelo de representación*: elección del conjunto de términos lingüísticos junto con su semántica para así proporcionar a una fuente de información un número reducido de términos con los que poder expresar sus valores.

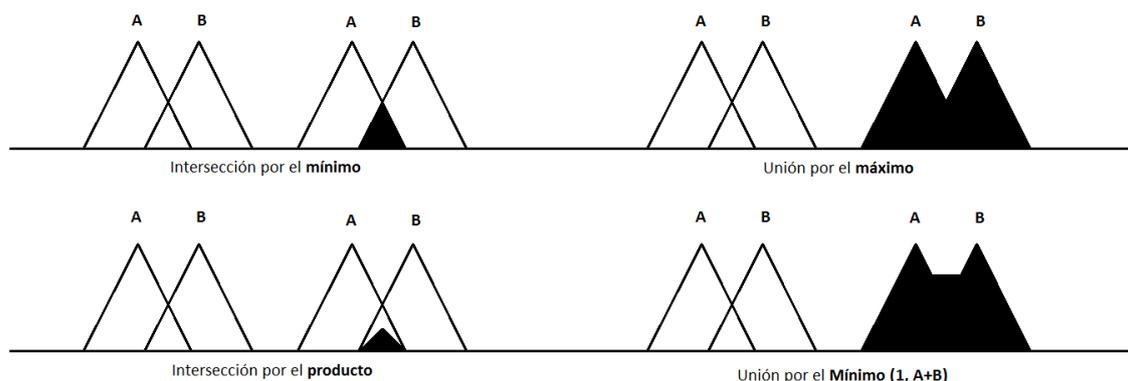


Figure 3.3: Intersección y Unión en conjuntos difusos

Un aspecto importante el cual es necesario analizar con el fin de establecer la descripción de una variable lingüística es la *granularidad de la incertidumbre* [19], es decir, la cardinalidad del conjunto de términos lingüísticos usado para expresar y representar la información. La cardinalidad debe ser suficientemente alta como para conseguir una discriminación de las valoraciones en un número limitado de grados y suficientemente baja como para no imponer una precisión excesiva en la información que se quiera expresar. Habitualmente la cardinalidad usada en los modelos lingüísticos suele ser un valor impar, como 5 o 7, no superando las 11 o 13 etiquetas. El término medio representa una valoración de *aproximadamente 0.5*, y el resto de términos se sitúan simétricamente alrededor de este punto medio [19].

Una vez establecida la cardinalidad del conjunto de términos lingüísticos, hay que definir dicho conjunto, es decir, cuáles van a ser las etiquetas lingüísticas y su semántica asociada.

### 3.3. Modelado Lingüístico Difuso Clásico

El modelado lingüístico difuso clásico adopta un *enfoque basado en una gramática libre de contexto*  $G$ , donde el conjunto de términos pertenece al lenguaje generado por  $G$  [19, 22, 174]. Una gramática generadora  $G$ , es una 4-tupla  $(V_N, V_T, I, P)$  siendo  $V_N$  el conjunto de símbolos no terminales,  $V_T$  el conjunto de símbolos terminales,  $I$  el símbolo inicial y  $P$  el conjunto de reglas de producción. La elección de estos cuatro elementos determinará la cardinalidad y forma del conjunto de términos lingüísticos. Entre los símbolos terminales y no terminales de  $G$  podemos encontrar términos primarios (por ejemplo *joven, maduro, viejo*), modificadores (por ejemplo *nada, mucho, muy, más o menos*), relaciones (por ejemplo *mayor que, menor que*) y conectivos (por ejemplo *y, o, pero*). Siendo  $I$  cualquier término primario y usando  $P$ , construimos el conjunto de términos lingüísticos  $H = \{muy\ joven, joven, maduro, \dots\}$ . La semántica del conjunto de términos lingüísticos se define utilizando números difusos en el intervalo  $[0,1]$ , dónde cada número difuso es descrito por una función de pertenencia basada en ciertos parámetros o reglas semánticas.

En lo que respecta a la definición de operadores de agregación de información lingüística, el modelo clásico extiende las operaciones de la lógica tradicional para aplicarlas sobre las funciones de pertenencia. Pero este enfoque tiene un inconveniente, ya que como resultado obtendremos otro conjunto difuso que no se corresponde con ninguna etiqueta del conjunto de términos originalmente considerado. Así que, si finalmente deseamos obtener una etiqueta de dicho conjunto, es necesario realizar un proceso de aproximación lingüística que consiste en encontrar una etiqueta cuyo significado sea lo más parecido posible al significado del conjunto difuso no etiquetado obtenido como resultado de alguna operación de acuerdo a alguna métrica.

---

### 3.4. Modelado Lingüístico Difuso Ordinal

El modelado lingüístico difuso ordinal [44, 67, 72] fue propuesto como una herramienta alternativa al modelado clásico que simplifica la computación con palabras eliminando la complejidad de tener que definir una gramática.

También, el modelado lingüístico difuso clásico al trabajar con números difusos presenta el inconveniente de que no suelen coincidir con etiquetas del conjunto de términos lingüísticos, por lo que si se desea obtener una etiqueta se hace necesaria una aproximación lingüística. El modelado lingüístico difuso ordinal trabaja directamente con las etiquetas previamente definidas por lo que evita tener que recurrir a aproximaciones lingüísticas complejas facilitando el trabajo al disminuir la complejidad del modelo tradicional.

#### 3.4.1. Modelo de Representación en el Enfoque Lingüístico Ordinal

Un enfoque lingüístico difuso ordinal se define considerando un conjunto de etiquetas finito y totalmente ordenado  $\mathcal{S} = \{s_i\}, i \in \{0, \dots, g\}$  con  $s_i \geq s_j$  si  $i \geq j$ , y con una cardinalidad impar (la cardinalidad de  $\mathcal{S}$  es  $g + 1$ ). La semántica del conjunto de etiquetas es establecida según la estructura ordenada del conjunto de etiquetas [21], considerando que cada etiqueta del par  $(s_i, s_{g-i})$  es igualmente informativa. Por ejemplo, podríamos usar el siguiente conjunto de 9 etiquetas para representar la información lingüística:

$$\mathcal{S} = \{N, VL, L, M, H, VH, P\}$$

$$s_0 = Nulo = N \quad s_1 = Muy bajo = VL$$

$$s_2 = Bajo = L \quad s_3 = Medio = M$$

$$s_4 = Alto = H \quad s_5 = Muy alto = VH$$

$$s_6 = Perfecto = P.$$

donde  $s_a < s_b$  si y sólo si  $a < b$ .

Después, tenemos que dar significado al conjunto de etiquetas lingüísticas asociando con cada término lingüístico un conjunto difuso definido en el intervalo  $[0, 1]$ . Para ello y para capturar la imprecisión de las evaluaciones lingüísticas, podemos hacer uso de una representación trapezoidal de la función de pertenencia, la cual es considerada en algunos casos suficiente. La representación paramétrica es realizada por medio de una 3-tupla  $(a, \alpha, \beta)$ , donde  $a = b$  y  $a$  indica el punto donde el valor de pertenencia vale 1 y  $\alpha$  y  $\beta$  los límites izquierdo y derecho respectivamente. Como ejemplo, podemos considerar el anterior conjunto de etiquetas con las siguientes funciones de pertenencia siendo representadas por medio de 3-tupla. (ver Figura 3.4):

$$\begin{aligned}
 s_0 = Nulo(N) &= (0, 0, 0.17) & s_1 = Muy\ bajo(VL) &= (0.17, 0, 0.33) \\
 s_2 = Bajo(L) &= (0.33, 0.17, 0.5) & s_3 = Medio(M) &= (0.5, 0.33, 0.67) \\
 s_4 = Alto(H) &= (0.67, 0.5, 0.83) & s_5 = Muy\ alto(VH) &= (0.83, 0.67, 1) \\
 s_6 = Perfecto(P) &= (1, 0.83, 1).
 \end{aligned}$$

### 3.4.2. Modelo Computacional en el Enfoque Lingüístico Ordinal

En todo enfoque lingüístico necesitamos operadores para el manejo de la información lingüística. Una ventaja del enfoque lingüístico difuso ordinal es la simplicidad y agilidad de su modelo computacional. Está basado en el cálculo simbólico [67, 72] y actúa operando directamente sobre las etiquetas, teniendo en cuenta el orden de las valoraciones lingüísticas en la estructura ordenada de

---

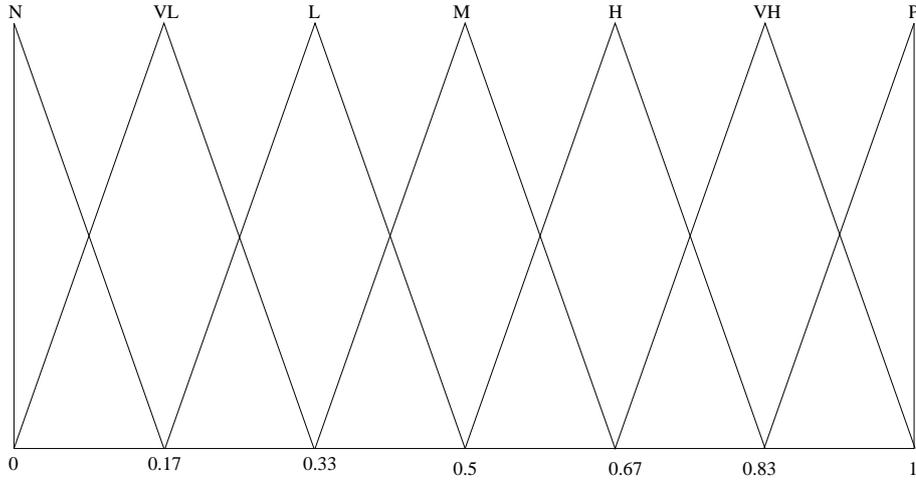


Figure 3.4: Un conjunto de 7 términos lingüísticos y su semántica.

las etiquetas. Como norma general, el modelo lingüístico difuso ordinal para la computación con palabras se define estableciendo:

1. Un operador de negación.
2. Operadores de comparación basados en la estructura ordenada de los términos lingüísticos.
3. Operadores apropiados para la agregación de información lingüística difusa ordinal.

Habitualmente, en los enfoques lingüísticos difusos ordinales, a partir de la semántica asociada a los términos lingüísticos el operador de negación se define como:

$$NEG(s_i) = s_j / j = g - i;$$

Los operadores de comparación de términos lingüísticos son definidos como:

1. *Operador de maximización:*  $MAX(s_i, s_j) = s_i$  si  $s_i \geq s_j$ .
2. *Operador de minimización:*  $MIN(s_i, s_j) = s_i$  si  $s_i \leq s_j$ .

A partir de estos operadores es posible definir operadores automáticos y simbólicos de agregación de información lingüística, como por ejemplo el operador de agregación de información lingüística no ponderada LOWA (*Linguistic Ordered Weighted Averaging*) [72] y el operador de información lingüística ponderada LWA (*Linguistic Weighted Averaging*) [67], que están basados en el operador OWA (*Ordered Weighted Averaging*) definido en [170]. El OWA es un operador de agregación de información numérica que tiene en cuenta el orden de las valoraciones que van a ser agregadas.

**Definición 3.7.** *Operador OWA.* Sea  $A = \{a_1, \dots, a_n\}$  con  $a_i \in [0, 1]$  el conjunto de valoraciones que se quieren agregar y  $W = (w_1, \dots, w_n)$  su vector de pesos asociado, tal que (i)  $w_i \in [0, 1]$  y (ii)  $\sum_{i=1}^n w_i = 1$ . El operador OWA,  $f$ , se define como:

$$f(a_1, \dots, a_n) = \sum_{j=1}^n w_j \cdot b_j$$

donde  $b_j$  es el  $j$ -ésimo mayor valor del conjunto  $A$ . Por tanto, a partir de los elementos de  $A$  podemos obtener un conjunto  $B$  ordenando dichos elementos en orden decreciente, es decir,

$$B = \{b_1, \dots, b_n\} / b_i \geq b_j \text{ si } i < j$$

y definir el operador OWA de la siguiente forma:

$$f(a_1, \dots, a_n) = W \cdot B$$

**Ejemplo de aplicación del operador OWA.**

Supongamos que tenemos el siguiente conjunto de valoraciones  $A = \{0.5, 1.0, 0.4, 0.3\}$  con el siguiente vector de pesos  $W = (0.5, 0.1, 0.1, 0.3)$ .

---

En este caso, el vector ordenado  $B$  es

$$B = \begin{bmatrix} 1.0 \\ 0.5 \\ 0.4 \\ 0.3 \end{bmatrix},$$

por lo que:

$$\begin{aligned} f(0.5, 1.0, 0.5, 0.3) &= W \cdot B = [0.5, 0.1, 0.1, 0.3] \begin{bmatrix} 1.0 \\ 0.5 \\ 0.4 \\ 0.3 \end{bmatrix} \\ &= (0.5 \cdot 1.0) + (0.1 \cdot 0.5) + (0.1 \cdot 0.4) + (0.3 \cdot 0.3) = 0.68 \end{aligned}$$

**Definición 3.8.** *Operador LOWA.* Sea  $A = \{a_1, \dots, a_m\}$  un conjunto de etiquetas a agregar,  $a_i \in \mathcal{S}$ , entonces el operador LOWA,  $\phi$ , se define como:

$$\begin{aligned} \phi(a_1, \dots, a_m) &= W \cdot B = \mathcal{C}^m\{w_k, b_k, k = 1, \dots, m\} = \\ &= w_1 \odot b_1 \oplus (1 - w_1) \odot \mathcal{C}^{m-1}\{\beta_h, b_h, h = 2, \dots, m\} \end{aligned}$$

donde  $W = [w_1, \dots, w_m]$ , es un vector de ponderación, tal que,

1.  $w_i \in [0, 1]$ ,
2.  $\sum_{i=1}^n w_i = 1$ ,

y  $\beta_h = w_h / \sum_2^m w_k$ ,  $h = 2, \dots, m$ , siendo  $B = (b_1, \dots, b_m)$  un vector asociado a  $A$ , tal que,

$$B = \sigma(A) = (a_{\sigma(1)}, \dots, a_{\sigma(n)})$$

donde,  $a_{\sigma(j)} \leq a_{\sigma(i)} \forall i \leq j$ , siendo  $\sigma$  una permutación definida sobre el conjunto de etiquetas  $A$ .  $\mathcal{C}^m$  es el operador de combinación convexa de  $m$  etiquetas [43], de modo que si  $m = 2$ , entonces se define como

$$\begin{aligned} \mathcal{C}^2\{w_i, b_i, i = 1, 2\} &= w_1 \odot s_j \oplus (1 - w_1) \odot s_i = s_k, \quad s_j, s_i \in \mathcal{S}, (j \geq i), \\ k &= \text{MIN}\{g, i + \text{round}(w_1 \cdot (j - i))\}, \end{aligned}$$

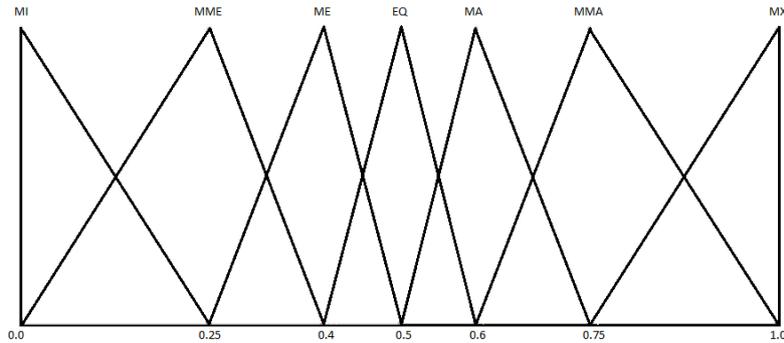


Figure 3.5: Semántica asociada al conjunto de términos lingüísticos.

”round” simboliza el operador de redondeo usual, y  $b_1 = s_j$ ,  $b_2 = s_i$ . Por otro lado, si  $w_j = 1$  y  $w_i = 0$  con  $i \neq j \forall i$ , entonces el operador de combinación se define como:

$$C^m\{w_i, b_i, i = 1, \dots, m\} = b_j.$$

#### ***Ejemplo de aplicación del operador LOWA.***

Supongamos  $m = 2$ ,  $W = [0.4, 0.6]$  y que usamos el siguiente conjunto de siete etiquetas:

$$S = \{s_0 = MI, s_1 = MME, s_2 = ME, s_3 = EQ, s_4 = MA, s_5 = MMA, s_6 = MX\},$$

donde

$$MI = \text{Mínimo} \quad MME = \text{Mucho\_Menor} \quad ME = \text{Menor}$$

$$EQ = \text{Equivalente} \quad MA = \text{Mayor} \quad MMA = \text{Mucho\_Mayor}$$

$$MX = \text{Máximo}$$

con los siguiente valores de representación (ver Figura 3.5):

$$MI = (0, 0, 0, 0.25) \quad MME = (0.25, 0.25, 0, 0.4) \quad ME = (0.4, 0.4, 0.25, 0.5)$$

$$EQ = (0.5, 0.5, 0.4, 0.6) \quad MA = (0.6, 0.6, 0.5, 0.75) \quad MMA = (0.75, 0.75, 0.6, 1)$$

$$MX = (1, 1, 0.75, 1)$$

		$1 - w_1 = 0.6$			
		<b>MME</b>	<b>MMA</b>	<b>MX</b>	<b>MME</b>
$w_1 = 0.4$	<b>MX</b>	EQ	MMA	MX	EQ
	<b>MI</b>	MME	EQ	MA	MME
	<b>ME</b>	MME	EQ	MA	MME
	<b>EQ</b>	ME	MA	MMA	ME

Table 3.2: LOWA con  $m = 2$ 

Los resultados se muestran en la Tabla 3.2, donde por ejemplo:

$$k_{11} = \text{MIN}\{6, 1 + \text{round}(0.4 * (6 - 1))\} = 3 \Rightarrow l_{k_{11}} = \text{EQ}$$

$$k_{21} = \text{MIN}\{6, 0 + \text{round}(0.6 * (1 - 0))\} = 1 \Rightarrow l_{k_{21}} = \text{MME}$$

Para concluir, indicar que existen otras opciones de modelado lingüístico difuso ordinal, como generar la semántica de las etiquetas lingüísticas utilizando funciones de negación que inducen una semántica para cada etiqueta [161], estando éstas definidas como intervalos en  $[0,1]$ .

### 3.5. Modelado Lingüístico Difuso 2-tupla

El *modelado lingüístico difuso 2-tupla* [73] es un tipo de modelado lingüístico difuso que nos permite reducir la pérdida de información que habitualmente se produce en otros enfoques como el modelado lingüístico difuso clásico u ordinal [67, 174]. Esta pérdida de información, que provoca una falta de precisión en los resultados, se debe al propio modelo de representación puesto que opera con valores discretos sobre un universo de discurso continuo. La principal ventaja del modelo lingüístico 2-tupla es que permite realizar procesos de cálculo con palabras de forma más sencilla y sin pérdida de información. Esto es debido a que utiliza un modelo continuo de representación de la información. Para definirlo, tenemos que establecer el modelo de representación y el mo-

delo computacional de las 2-tupla para representar y agregar la información lingüística respectivamente.

### 3.5.1. Modelo de Representación Lingüística 2-tupla

Consideremos que  $\mathcal{S} = \{s_0, \dots, s_g\}$  es un conjunto de términos lingüísticos con cardinalidad impar, donde el término intermedio representa una valoración de aproximadamente 0.5 y con el resto de términos del conjunto distribuidos simétricamente alrededor de ese punto intermedio. Asumimos que la semántica asociada con cada una de las etiquetas viene dada por medio de funciones de pertenencia triangulares a las que hacíamos alusión en la sección 3.4.1, representadas por 3-tupla  $(a, \alpha, \beta)$  y consideramos todos los términos distribuidos sobre una escala sobre la que hay establecida una relación de orden total, es decir,  $s_i \leq s_j \iff i \leq j$ . En este contexto lingüístico difuso, si mediante un método simbólico de agregación de información lingüística [67, 72] obtenemos un valor  $\beta \in [0, g]$ , y  $\beta \notin \{0, \dots, g\}$ , podemos usar una función de aproximación para expresar el resultado obtenido como un valor de  $\mathcal{S}$ .

**Definición 3.9.** [73] Sea  $\beta$  el resultado de una agregación de los índices de un conjunto de etiquetas valoradas sobre un conjunto de términos lingüísticos  $\mathcal{S}$ , es decir, el resultado de una operación de agregación simbólica,  $\beta \in [0, g]$ . Dados  $i = \text{round}(\beta)$  y  $\alpha = \beta - i$  dos valores, tales que,  $i \in [0, g]$  y  $\alpha \in [-0.5, 0.5]$  entonces  $\alpha$  es lo que denominamos **Traslación Simbólica**, que expresa la diferencia de información entre la información expresada por  $\beta$  y la etiqueta lingüística  $s_i$  más cercana a  $\mathcal{S}$ .

El enfoque lingüístico difuso 2-tupla es desarrollado a partir del concepto de traslación simbólica, representando la información lingüística por medio de 2-tupla  $(s_i, \alpha_i)$ ,  $s_i \in \mathcal{S}$  y  $\alpha_i \in [-0.5, 0.5]$ :

- $s_i$  representa la etiqueta lingüística, y
- $\alpha_i$  es un valor numérico que expresa la traslación de  $\beta$  al índice de la etiqueta más cercana,  $i$ , en el conjunto de términos lingüísticos ( $s_i \in \mathcal{S}$ ).

Este modelo define un conjunto de funciones de transformación entre valores numéricos y 2-tupla.

**Definición 3.10.** Sea  $s_i \in \mathcal{S}$  un término lingüístico, su representación mediante una 2-tupla se obtiene mediante la función  $\theta$ :

$$\theta : [0, g] \longrightarrow \mathcal{S} \times [-0.5, 0.5)$$

$$\theta(s_i) = (s_i, 0) / s_i \in \mathcal{S}$$

**Definición 3.11.** [73] Siendo  $\mathcal{S} = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos y  $\beta \in [0, g]$  un valor que representa el resultado de una operación de agregación simbólica, la 2-tupla que expresa la información equivalente a  $\beta$  se obtiene mediante la siguiente función:

$$\Delta : [0, g] \longrightarrow \mathcal{S} \times [-0.5, 0.5)$$

$$\Delta(\beta) = (s_i, \alpha), \text{ con } \begin{cases} s_i & i = \text{round}(\beta) \\ \alpha = \beta - i & \alpha \in [-0.5, 0.5) \end{cases}$$

donde  $\text{round}(\cdot)$  es el típico operador de redondeo,  $s_i$  es la etiqueta cuyo índice es el más cercano a  $\beta$  y  $\alpha$  es el valor de la traslación simbólica.

**Definición 3.12.** [73] Sea  $\mathcal{S} = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos y  $(s_i, \alpha)$  una 2-tupla. Se define la función  $\Delta^{-1}$ , tal que aplicada sobre una 2-tupla  $(s_i, \alpha)$  devuelve su valor numérico  $\beta \in [0, g]$ .

$$\Delta^{-1} : \mathcal{S} \times [-0.5, 0.5) \longrightarrow [0, g]$$

$$\Delta^{-1}(s_i, \alpha) = i + \alpha = \beta$$

### 3.5.2. Modelo Computacional Lingüístico 2-tupla

A continuación presentamos el modelo computacional que nos permite operar sobre la representación lingüística 2-tupla, basándonos en los operadores de comparación, negación y agregación de 2-tupla:

1. *Operador de comparación de 2-tupla.* La comparación de información lingüística representada por medio de 2-tupla se realiza de acuerdo a un orden lexicográfico normal y corriente. Consideremos dos 2-tupla  $(s_k, \alpha_1)$  y  $(s_l, \alpha_2)$  que representan cálculos de información:

- si  $k < l$  entonces  $(s_k, \alpha_1)$  es menor que  $(s_l, \alpha_2)$ .
  - si  $k = l$  entonces
    - a) si  $\alpha_1 = \alpha_2$  entonces  $(s_k, \alpha_1)$  y  $(s_l, \alpha_2)$  representan la misma información,
    - b) si  $\alpha_1 < \alpha_2$  entonces  $(s_k, \alpha_1)$  es menor que  $(s_l, \alpha_2)$ ,
    - c) si  $\alpha_1 > \alpha_2$  entonces  $(s_k, \alpha_1)$  es mayor que  $(s_l, \alpha_2)$ .
2. *Operador de negación de 2-tupla.* El operador de negación sobre una 2-tupla se define como:

$$Neg((s_i, \alpha)) = \Delta(g - (\Delta^{-1}(s_i, \alpha))).$$

siendo  $g + 1$  la cardinalidad del conjunto de etiquetas  $\mathcal{S}$ .

3. *Operador de agregación de 2-tupla.* La agregación de información consiste en obtener un valor que resuma un conjunto de valores, por lo que el resultado de la agregación de un conjunto de 2-tupla debe ser una 2-tupla. En la literatura podemos encontrar numerosos operadores de agregación que nos permiten combinar la información de acuerdo a distintos criterios. Cualquiera de estos operadores ya existentes puede ser fácilmente extendido para trabajar con 2-tupla, usando funciones  $\Delta$  y  $\Delta^{-1}$  que transforman valores numéricos en 2-tupla y viceversa sin pérdida de información. Algunos ejemplos de estos operadores son los siguientes:

**Definición 3.13.** *Media aritmética.* Siendo  $x = \{(r_1, \alpha_1), \dots, (r_n, \alpha_n)\}$  un conjunto de 2-tupla lingüísticas, la 2-tupla que simboliza la media aritmética,  $\bar{x}^e$ , se calcula de la siguiente forma:

$$\bar{x}^e[(r_1, \alpha_1), \dots, (r_n, \alpha_n)] = \Delta\left(\sum_{i=1}^n \frac{1}{n} \Delta^{-1}(r_i, \alpha_i)\right) = \Delta\left(\frac{1}{n} \sum_{i=1}^n \beta_i\right).$$

**Definición 3.14.** *Operador de media ponderada.* Siendo  $x = \{(r_1, \alpha_1), \dots, (r_n, \alpha_n)\}$  un conjunto de 2-tupla lingüísticas y  $W = \{w_1, \dots, w_n\}$  un vector numérico con sus pesos asociados, la 2-tupla que simboliza la media ponderada,

$\bar{x}^w$ , es:

$$\bar{x}^w[(r_1, \alpha_1), \dots, (r_n, \alpha_n)] = \Delta\left(\frac{\sum_{i=1}^n \Delta^{-1}(r_i, \alpha_i) \cdot w_i}{\sum_{i=1}^n w_i}\right) = \Delta\left(\frac{\sum_{i=1}^n \beta_i \cdot w_i}{\sum_{i=1}^n w_i}\right).$$

**Definición 3.15.** *Operador de media ponderada lingüística.* Siendo  $x = \{(r_1, \alpha_1), \dots, (r_n, \alpha_n)\}$  un conjunto de 2-tupla y  $W = \{(w_1, \alpha_1^w), \dots, (w_n, \alpha_n^w)\}$  sus pesos asociados representados mediante 2-tupla lingüísticas, la 2-tupla que representa la media ponderada lingüística,  $\bar{x}_l^w$ , se calcula de la siguiente manera:

$$\bar{x}_l^w[((r_1, \alpha_1), (w_1, \alpha_1^w)) \dots ((r_n, \alpha_n), (w_n, \alpha_n^w))] = \Delta\left(\frac{\sum_{i=1}^n \beta_i \cdot \beta_{W_i}}{\sum_{i=1}^n \beta_{W_i}}\right),$$

con  $\beta_i = \Delta^{-1}(r_i, \alpha_i)$  y  $\beta_{W_i} = \Delta^{-1}(w_i, \alpha_i^w)$ .

## 3.6. Modelado Lingüístico Difuso Multi-granular

En cualquier enfoque lingüístico difuso, uno de los parámetros más importantes que hay que determinar es la *granularidad de la incertidumbre*, es decir, la cardinalidad del conjunto de términos lingüísticos  $\mathcal{S}$  usado para expresar la información lingüística. En función del grado de incertidumbre que un experto encargado de cualificar un fenómeno tenga sobre el mismo, el conjunto de términos lingüísticos elegido para proporcionar ese conocimiento tendrá más o menos términos dependiendo de su criterio. En el caso de que sean varios expertos los encargados de cualificar el fenómeno, si éstos tienen diferentes grados de incertidumbre sobre él, es conveniente que cada uno trabaje con conjuntos de términos lingüísticos de diferente granularidad de incertidumbre [75, 88]. Esto es a lo que se le llama trabajar con información lingüística multi-granular. El uso de diferentes conjuntos de etiquetas es también necesario cuando un experto tiene que valorar conceptos diferentes. Un ejemplo de diferentes conceptos lo tenemos con los problemas de recuperación de información, en los cuales al evaluar la importancia de los términos de la consulta y la relevancia de los documentos recuperados [80], son conceptos distintos.

En ese tipo de situaciones necesitamos herramientas que nos permitan gestionar la información lingüística multi-granular, y para ello necesitamos definir un *modelado lingüístico difuso multi-granular*. Por lo tanto vamos a seguir el modelo propuesto en [75] que hace uso del concepto de jerarquías lingüísticas.

Una *Jerarquía Lingüística* es un conjunto de niveles, donde cada nivel es un conjunto de términos lingüísticos con una granularidad diferente del resto de niveles de la jerarquía. A cada uno de los niveles de una jerarquía lingüística los vamos a denotar como  $l(t, n(t))$ , siendo  $t$  un número que indica el nivel de la jerarquía y  $n(t)$  la granularidad del conjunto de términos lingüísticos del nivel  $t$ .

Los niveles de una jerarquía lingüística están ordenados en función de su granularidad, esto nos deja, que para dos niveles consecutivos  $t$  y  $t+1$ ,  $n(t+1) > n(t)$ . Por lo tanto, cada nivel  $t + 1$  proporciona un refinamiento lingüístico con respecto al nivel anterior  $t$ .

Vamos a definir una jerarquía lingüística,  $LH$ , como la unión de todos los niveles  $t$  que la conforman:

$$LH = \bigcup_t l(t, n(t))$$

De forma genérica, podemos establecer que el conjunto de términos lingüísticos de nivel  $t + 1$ ,  $\mathcal{S}^{n(t+1)}$ , puede ser obtenido a partir del nivel anterior  $t$ ,  $\mathcal{S}^{n(t)}$ , de la siguiente manera:

$$l(t, n(t)) \rightarrow l(t + 1, 2 \cdot n(t) - 1)$$

En la Tabla 3.3 mostramos la granularidad necesaria en cada conjunto de

---

	Nivel 1	Nivel 2	Nivel 3
$l(t,n(t))$	$l(1,3)$	$l(2,5)$	$l(3,9)$
$l(t,n(t))$	$l(1,7)$	$l(2,13)$	

Table 3.3: Granularidad en Jerarquías Lingüísticas.

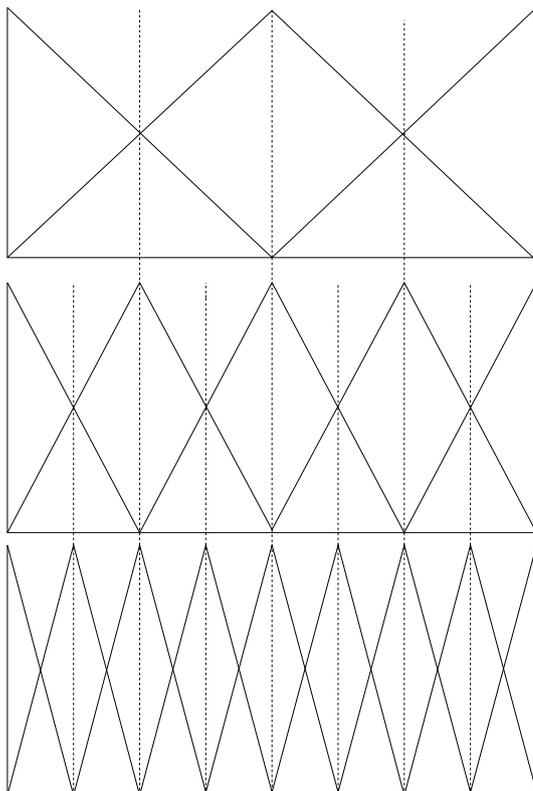


Figure 3.6: Jerarquía lingüística de 3, 5 y 9 etiquetas.

términos lingüísticos de nivel  $t$ , dependiendo del valor  $n(t)$  definido en el primer nivel, en este caso, para valores de 3 y 7 respectivamente.

En la Figura 3.6 se muestra un ejemplo gráfico de jerarquías lingüísticas. En ella se representa una jerarquía compuesta de 3 niveles, de 3, 5 y 9 etiquetas cada uno de ellos.

Para poder representar la información lingüística multi-granular en [75] fue definida una familia de funciones de transformación entre etiquetas de niveles.

Con ello se demostró que las jerarquías lingüísticas son útiles para representar información lingüística multi-granular y por tanto permiten trabajar con información lingüística sin pérdida de información.

**Definición 3.16.** Sea  $LH = \bigcup_t l(t, n(t))$  una jerarquía lingüística cuyos conjuntos de términos lingüísticos son expresados como  $\mathcal{S}^{n(t)} = \{s_0^{n(t)}, \dots, s_{n(t)-1}^{n(t)}\}$ . La **función de transformación** de una etiqueta lingüística (representada mediante una 2-tupla) de un nivel  $t$  a una etiqueta de un nivel consecutivo  $t + c$ , con  $c \in (-1, 1)$ , se define como:

$$TF_{t+c}^t : l(t, n(t)) \longrightarrow l(t + c, n(t + c))$$

$$TF_{t+c}^t(s_i^{n(t)}, \alpha^{n(t)}) = \Delta\left(\frac{\Delta^{-1}(s_i^{n(t)}, \alpha^{n(t)}) \cdot (n(t + c) - 1)}{n(t) - 1}\right)$$

Esta función de transformación se usa para transformar términos lingüísticos entre cualquier nivel dentro de la jerarquía lingüística.

**Definición 3.17.** Sea  $LH = \bigcup_t l(t, n(t))$  una jerarquía lingüística cuyos conjuntos de términos lingüísticos son expresados como  $\mathcal{S}^{n(t)} = \{s_0^{n(t)}, \dots, s_{n(t)-1}^{n(t)}\}$ . La **función de transformación** entre una etiqueta lingüística, la cual es representada mediante una 2-tupla, perteneciente a un nivel  $t$  y una etiqueta perteneciente a otro nivel  $t' \neq t$ , se define como:

$$TF_{t'}^t : l(t, n(t)) \longrightarrow l(t', n(t'))$$

$$TF_{t'}^t(s_i^{n(t)}, \alpha^{n(t)}) = \Delta\left(\frac{\Delta^{-1}(s_i^{n(t)}, \alpha^{n(t)}) \cdot (n(t') - 1)}{n(t) - 1}\right)$$

Como se indica en [75], esta familia de funciones de transformación es biyectiva. Este resultado garantiza que las transformaciones entre niveles de una jerarquía lingüística se pueden llevar a cabo sin pérdida de información.

Para definir el modelo computacional, seleccionamos un nivel para mantener uniforme la información (por ejemplo el nivel de mayor granularidad) y entonces usamos los mismos operadores definidos en el MLD 2-tupla.

---

### 3.7. Modelado Lingüístico Difuso no Balanceado

Hasta ahora, cuando nos enfrentábamos ante un problema en el que se hacía uso de información lingüística, el primer objetivo que satisfacíamos era el de la elección de los términos lingüísticos con sus correspondientes semánticas, para así establecer el conjunto de etiquetas que se va a usar. En la literatura encontramos dos posibilidades distintas para la elección de los términos lingüísticos y sus correspondientes semánticas:

- Una de las posibilidades es asumir que todos los términos del conjunto de etiquetas son igualmente informativos, esto es, que están distribuidos simétricamente tal y como sucede en los modelados lingüísticos difusos que hemos visto en las secciones anteriores.
- Otra posibilidad es asumir que no todos los términos del conjunto de etiquetas son igualmente informativos, por lo tanto esto quiere decir que las etiquetas no están distribuidas simétricamente.

En el caso en el que las etiquetas no estén distribuidas simétricamente necesitamos un *enfoque lingüístico difuso no balanceado* [70, 71]. Con él gestionaremos los conjuntos de términos lingüísticos con distintos niveles de discriminación a ambos lados del término medio. Por ejemplo supongamos el siguiente conjunto de etiquetas, distribuidas tal y como se muestra en la Figura 3.7:

$$\mathcal{S} = \{N, L, M, H, QH, VH, T\}$$

$N = Nulo$

$L = Bajo$

$M = Medio$

$H = Alto$

$QH = Bastante alto$

$VH = Muy alto$

$T = Total$

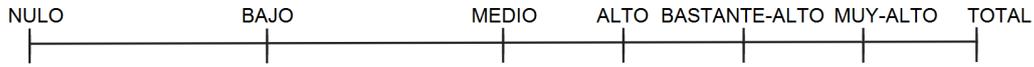


Figure 3.7: Conjunto de términos lingüísticos de 7 etiquetas no balanceado.

En [70] vemos que en sistemas de recuperación de información es más apropiado el uso de conjuntos de términos lingüísticos no balanceados que el uso de conjuntos de términos lingüísticos simétricos, tanto para expresar los grados de relevancia de los documentos como para representar los pesos de importancia en las consultas.

Cuando se trata de gestionar los conjuntos de términos lingüísticos no balanceados es común el uso del modelado lingüístico difuso basado en 2-tupla [70]. Básicamente, el método consiste en representar los términos lingüísticos no balanceados usando distintos niveles de una jerarquía lingüística  $LH$ , llevando a cabo todas las operaciones mediante el uso del modelo computacional definido para la representación 2-tupla. Para aplicar este método, realizaríamos de los siguientes pasos [70]:

1. Representar el conjunto de términos lingüísticos no balanceados  $\mathcal{S}$  mediante una jerarquía lingüística,  $LH$ .
  - a) Seleccionar un nivel  $t^-$  con una granularidad apropiada para representar, usando el modelo de representación de las 2-tupla, el subconjunto de términos lingüísticos de  $\mathcal{S}$  que hay a la izquierda del término medio.
  - b) Seleccionar un nivel  $t^+$  con una granularidad apropiada para representar, usando el modelo de representación de las 2-tupla, el

subconjunto de términos lingüísticos de  $\mathcal{S}$  que hay a la derecha del término medio.

2. Definir un modelo computacional para trabajar con la información lingüística no balanceada.

a) Seleccionar el nivel  $t' \in \{t^-, t^+\}$ , de tal forma que  $n(t') = \max\{n(t^-), n(t^+)\}$ , es decir, el de mayor granularidad.

b) Definir la operación de comparación entre dos 2-tupla  $(s_k^{n(t)}, \alpha_1)$ ,  $t \in \{t^-, t^+\}$  y  $(s_l^{n(t)}, \alpha_2)$ ,  $t \in \{t^-, t^+\}$ , cada una representando un cálculo de información no balanceada. Su expresión es similar a la comparación de dos 2-tupla, pero actuando sobre los valores  $TF_{t'}^t(s_k^{n(t)}, \alpha_1)$  y  $TF_{t'}^t(s_l^{n(t)}, \alpha_2)$ . Otros operadores como *Max* o *Min* pueden ser fácilmente definidos.

c) Definir el operador de negación de información lingüística no balanceada. Siendo  $(s_k^{n(t)}, \alpha)$ ,  $t \in \{t^-, t^+\}$  una 2-tupla que representa información lingüística no balanceada, su negación se define como:

$$\mathcal{NEG}(s_k^{n(t)}, \alpha) = Neg(TF_{t''}^t(s_k^{n(t)}, \alpha)), \quad t \neq t'', \quad t'' \in \{t^-, t^+\}.$$

d) Definir operadores de agregación de información lingüística no balanceada. Para ello se usan los procesos de agregación definidos en el modelo computacional de las 2-tupla, pero actuando sobre valores lingüísticos no balanceados previamente transformados mediante la función de transformación  $TF_{t'}^t$ . Una vez que se obtiene un resultado, éste es transformado al correspondiente nivel  $t$ , para expresar el resultado obtenido en el conjunto de términos lingüísticos no balanceado por medio de  $TF_t^{t'}$ .

En la Figura 3.8 mostramos cómo seleccionar los diferentes niveles para repre-

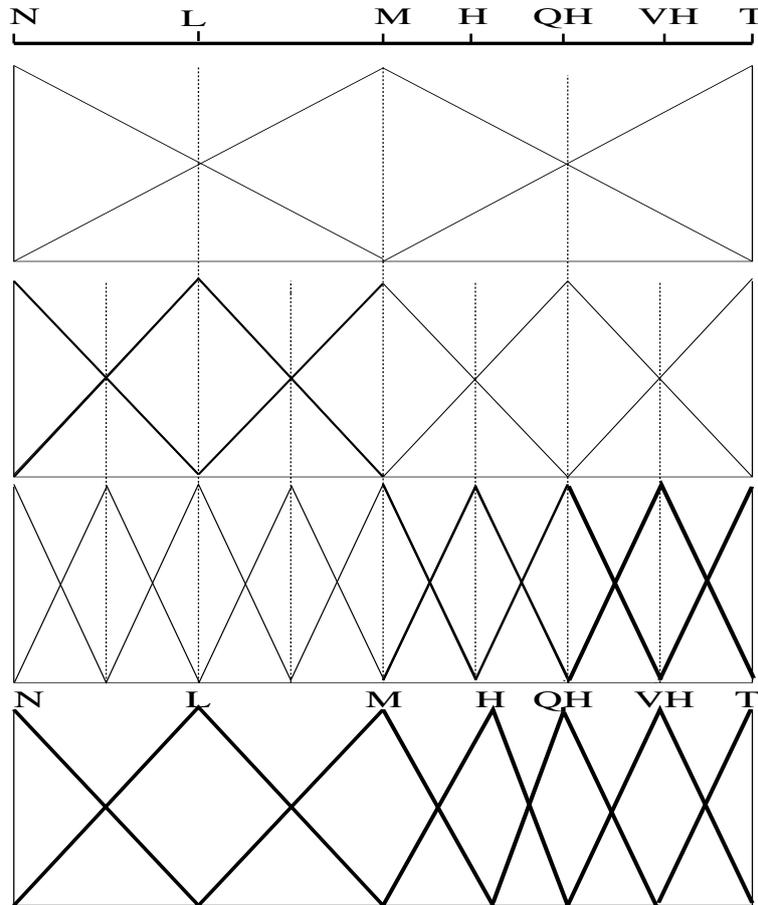


Figure 3.8: Representación de un conjunto de términos lingüísticos no balanceado.

sentar el conjunto de términos lingüísticos no balanceado a partir del conjunto de términos lingüísticos mostrado en la Figura 3.7 y la jerarquía lingüística mostrada en la Figura 3.6.

### 3.8. Modelado Lingüístico Difuso Vacilante

Otra situación a la que se pretende hacer frente mediante el uso de información lingüística, es la de tratar con situaciones de indecisión. Puede ocurrir que los expertos duden acerca de diferentes valores que pueden asignar a una variable lingüística. En este caso, la dificultad general que frecuentemente surge al establecer el grado de pertenencia de un elemento no viene dada por un margen de error o por alguna posible distribución, sino porque hay diferentes

posibles valores que hacen vacilar en la decisión de cual sería el más indicado. En este caso, necesitamos un *enfoque lingüístico difuso vacilante* [143] para gestionar los conjuntos de términos lingüísticos en los que hay un grupo de valores posibles en el proceso de definición de pertenencia de un elemento.

Un conjunto difuso vacilante es definido como una función que devuelve un conjunto de valores por cada elemento en el dominio [142]. Siendo  $X$  un conjunto de referencia, un conjunto difuso vacilante de  $X$  se define mediante una función  $\delta$ ,

$$\delta : X \rightarrow \wp([0, 1])$$

Por lo que podemos decir que un conjunto difuso vacilante es un conjunto de conjuntos difusos definidos sobre  $[0, 1]$ .

Sea  $M = \mu_1, \dots, \mu_n$  un conjunto de  $n$  funciones de pertenencia. El conjunto difuso vacilante asociado con  $M$ , se define como:

$$\delta_M : X \rightarrow \wp([0, 1])$$

$$\delta_M(c) = \bigcup_{\mu \in M} \{\mu(x)\}$$

donde  $x \in X$ .

Teniendo en cuenta la idea de conjunto difuso vacilante, si consideramos que  $\mathcal{S} = \{s_0, \dots, s_g\}$  es un conjunto de términos lingüísticos, un Conjunto Lingüístico Difuso Vacilante (CLDV),  $H_S$ , es un subconjunto finito y ordenado de términos lingüísticos consecutivos de  $S$ .

Supongamos que  $\mathcal{S} = \{s_0, \dots, s_g\}$  es un conjunto de términos lingüísticos, entonces definimos un conjunto vacío lingüístico difuso vacilante y un conjunto

---

completo lingüístico difuso vacilante como:

$$\text{vacío CLDV: } H_S(\vartheta) = \{\},$$

$$\text{completo CLDV: } H_S(\vartheta) = S.$$

A continuación mostramos algunas de las operaciones que pueden ser llevadas a cabo en los conjuntos lingüísticos difusos vacilantes. Para ello, tenemos  $\mathcal{S} = \{s_0, \dots, s_g\}$ , un conjunto de términos lingüísticos y tres conjuntos lingüísticos difusos vacilantes diferentes  $H_s$ ,  $H_s^1$  y  $H_s^2$ .

**Definición 3.18.** El límite superior  $H_{s+}$  y el límite inferior  $H_{s-}$  de un conjunto lingüístico difuso vacilante se definen como:

$$H_{s+} = \max(s_i) = s_j, s_i \in H_s \text{ y } s_i \leq S_j \forall i.$$

$$H_{s-} = \min(s_i) = s_j, s_i \in H_s \text{ y } s_i \geq S_j \forall i.$$

**Definición 3.19.** El complemento  $H_s^c$  de un conjunto lingüístico difuso vacilante se define como:

$$H_s^c = S - H_s = \{s_i/S_i \in S \text{ y } s_i \notin H_s\}.$$

**Definición 3.20.** La unión de dos conjuntos lingüísticos difusos vacilantes,  $H_s^1$  y  $H_s^2$ , se define como:

$$H_s^1 \cup H_s^2 = \{s_i/S_i \in H_s^1 \text{ o } s_i \in H_s^2\}.$$

Y el resultado será otro conjunto lingüístico difuso vacilante.

**Definición 3.21.** La intersección de dos conjuntos lingüísticos difusos vacilantes,  $H_s^1$  y  $H_s^2$ , se define como:

$$H_s^1 \cap H_s^2 = \{s_i/S_i \in H_s^1 \text{ and } s_i \in H_s^2\}.$$

Y el resultado será otro conjunto lingüístico difuso vacilante.

La comparación de dos subconjuntos de términos lingüísticos difusos vacilantes no es simple. Para ello introduciremos el concepto *envoltura* para un conjunto lingüístico difuso vacilante con el objetivo de simplificar las operaciones que se mostrarán a continuación.

**Definición 3.22.** La envoltura de un conjunto lingüístico difuso vacilante  $env(H_s)$  es un intervalo lingüístico cuyos límites son obtenidos como la media de los límites superiores e inferiores. Por lo tanto:

## 9.9. Aplicaciones del MLD en Sistemas de Acceso a la Información

$$\text{env}(H_s) = [H_{s-}, H_{s+}], H_{s-}H_{s+}.$$

**Definición 3.23.** La comparación entre dos conjuntos lingüísticos difusos vacilantes se basa en el concepto de envoltura descrito anteriormente. Por lo que la comparación entre  $H_s^1$  y  $H_s^2$  se define como:

$$H_s^1(\vartheta) > H_s^2(\vartheta) \text{ si } \text{env}(H_s^1(\vartheta)) > \text{env}(H_s^2(\vartheta)).$$
$$H_s^1(\vartheta) = H_s^2(\vartheta) \text{ si } \text{env}(H_s^1(\vartheta)) = \text{env}(H_s^2(\vartheta)).$$

## 3.9. Aplicaciones del MLD en Sistemas de Acceso a la Información

Centrándonos en los SAIs, uno de los ámbitos de aplicación que vamos a destacar es el de los modelos de recuperación de información, donde el MLD se ha usado de cara a conseguir una formalización matemática del uso de pesos para manejar información imprecisa en todos los niveles de representación de información de estos sistemas [105]. En la literatura podemos encontrar algunos sistemas de recuperación de información enriquecidos con lenguajes de consulta ponderados, lo que incrementa la expresividad de los tradicionales lenguajes de consulta booleanos [166], permitiendo a los usuarios representar mejor en la consulta sus conceptos de relevancia y mejorando la eficacia del sistema de recuperación de información [20]. Además, permite trabajar con diferentes semánticas asociadas con los pesos de las consultas:

1. Semántica de importancia, considerando los pesos como medidas de la importancia de un elemento específico en la representación de la consulta.
  2. Semántica de umbral, considerando los pesos como un umbral a la hora de realizar el matching entre un documento y la consulta.
  3. Semántica de perfección, considerando los pesos como descripciones de un documento ideal.
-

Sin embargo estos sistemas de recuperación de información difusos usan normalmente pesos numéricos (valores del intervalo  $[0,1]$ ), lo cual limita la expresividad de los usuarios, por lo que una solución sería incorporar la posibilidad de usar valores cualitativos usados habitualmente en la comunicación entre usuarios. Parece más natural caracterizar los contenidos de los documentos deseados indicando explícitamente un descriptor lingüístico a los términos de la consulta, como por ejemplo “importante” o “muy importante”, en lugar de un valor numérico. Además, parecen más amigables de cara al usuario si la relevancia calculada de los documentos se expresa mediante un valor lingüístico, como “relevante” o “muy relevante”. Siguiendo este razonamientos encontramos varias propuesta de aplicación del MLD en sistemas de recuperación de información, permitiendo definir nuevos lenguajes de consulta con pesos lingüísticos [22, 76, 77, 80, 84, 86, 87, 104].

Por otro lado, la teoría de conjuntos difusos [173] también se ha aplicado con éxito en sistemas de recomendaciones, para gestionar la incertidumbre presente en la representación de los perfiles de los usuarios y en el proceso de generación de recomendaciones [129, 171]. Pero al ser éste un ámbito directamente relacionado con la propuesta desarrollada en esta tesis, se trata con más detalle en la sección siguiente.

### 3.10. Sistemas de Recomendaciones Basados en el MLD

Los sistemas de recomendaciones intentan responder a las necesidades de información de los usuarios, así como predecir futuras necesidades mediante la recomendación de ítems no esperados pero útiles y de relevancia. Como vimos

---

en el capítulo anterior, el éxito de un sistema de recomendaciones dependerá en gran medida de las técnicas que se usen para representar y actualizar los perfiles de los usuarios, así como las usadas para generar las recomendaciones. En este sentido, la teoría de conjuntos difusos [173] también ha sido aplicada con éxito para gestionar la incertidumbre presente en la representación de los perfiles de usuario, así como en el proceso de generación de recomendaciones [129, 171]. En esta sección analizamos diferentes esquemas de recomendaciones que han adoptado el MLD, en concreto:

- Sistemas de recomendaciones lingüísticos difusos basados en el MLD 2-tupla.
- Sistemas de recomendaciones lingüísticos difusos basados en el MLD multi-granular.

### **3.10.1. Sistemas de Recomendaciones Basados en el MLD 2-tupla**

Nos fijamos en dos enfoques [94, 122] basados en MLD 2-tupas que resultan interesantes.

En el primer trabajo [94] se presenta un modelo de sistema de recomendaciones lingüístico difuso que incorpora posibilidades de filtrado de información en un modelo multi-agente, aprovechando las ventajas que presenta el MLD 2-tupla en cuanto a reducción de pérdida de información se refiere. Este sistema de recomendaciones que se centra en el acceso a la información en la Web, implementa el filtrado basado en contenidos y colaborativo para mejorar el acceso a la información. Los usuarios especifican sus necesidades de información por medio de consultas lingüísticas multi ponderadas y seleccionando categorías. En las consultas se pueden usar simultáneamente 2 pesos. Por una parte, los

---

pesos de umbral se usan por los agentes de filtrado basado en contenidos para llevar a cabo un primer filtrado de los documentos a recuperar, y por otro lado, los pesos de importancia relativa se usan por el agente de tareas para determinar el número de documentos que van a ser recuperados del agente de filtrado basado en contenidos. El modelo multi-agente incorpora en su arquitectura un agente de filtrado colaborativo que filtra y recomienda documentos relacionados con la categoría de necesidad de información, de acuerdo a juicios de valoración lingüísticos previamente expresados por otros usuarios.

En [122] los autores presentan un nuevo sistema de recomendaciones lingüístico difuso, llamado *D-Fusion*, basado en el MLD 2-tupla. El sistema multi-agente incorpora un enfoque de recomendación para satisfacer requerimientos de información específicos de los investigadores y genera dos tipos de recomendaciones, de especialización bibliográfica (de cara a profundizar en las áreas de especialización de cada usuario) y multidisciplinarias (que permite a los usuarios descubrir nuevos recursos relacionados con sus preferencias).

### **3.10.2. Sistemas de Recomendaciones Basados en el MLD Multi-granular**

En este apartado se describen las propuestas de sistemas de recomendaciones basados en el MLD multi-granular, que conforman el grueso principal de los modelos usados en los sistemas de recomendaciones en los que se centra esta tesis.

#### **Un sistema de recomendaciones basado en el MLD multi-granular aplicado en una OTRI**

La Oficina de Transferencia de Resultados de Investigación (OTRI) es responsable de promover y gestionar las actividades de generación de conoci-

---

miento y colaboración científica y técnica, fomentando la interrelación entre investigadores de la universidad y el mundo empresarial, así como su participación en diversos programas diseñados para llevar a cabo actividades de I+D+I (Investigación, Desarrollo e Innovación). Uno de sus objetivos fundamentales es fomentar y ayudar en la generación de conocimiento, así como en su difusión y transferencia a la sociedad, con el propósito de identificar las demandas y necesidades del entorno productivo.

Para llevar a cabo este objetivo, la OTRI se compone de un equipo de técnicos en transferencia de tecnología, que difunden información sobre recursos de investigación (convocatorias de proyectos, eventos, congresos, cursos, etc.) entre los investigadores de la universidad y las empresas del entorno, para que puedan surgir colaboraciones entre ellos. Esto implica la selección por parte de los técnicos, de los investigadores o empresas a los que más les podría interesar cada una de las convocatorias que vayan surgiendo. Sin embargo, la gran cantidad de información y recursos de investigación a los que los técnicos de OTRI pueden acceder, provoca que no sean capaces de difundir la información a los usuarios adecuados de forma rápida y sencilla.

En [131] se propone SIRE2IN, un sistema de recomendaciones para ayudar a investigadores y empresas a colaborar entre sí, recomendándoles proyectos en los que podrían cooperar. SIRE2IN fue diseñado incorporando un enfoque de recomendaciones híbrido [27] junto con un MLD multi-granular para representar y gestionar información flexible por medio de etiquetas lingüísticas.

El sistema representan tanto los ítems (recursos a recomendar por la OTRI) como los usuarios (investigadores y empresas) mediante un modelo vectorial [102], en el que son tenidas en cuenta las mismas características para unos y

---

otros (clasificación UNESCO que proporciona 248 categorías), base ésta del esquema basado en contenidos. El sistema valora la importancia de cada una de estas características para el recurso o para el usuario mediante una etiqueta lingüística.

Para representar los distintos conceptos que tienen que ser valorados en la actividad del sistema, se usan distintos conjuntos de etiquetas ( $S_1, S_2, \dots$ ) seleccionados de una jerarquía lingüística. En concreto, se distinguen tres conceptos que tienen que ser valorados:

- *Grado de importancia* ( $S_1$ ) de un código UNESCO con respecto al ámbito de una convocatoria o respecto a los temas de interés de un usuario.
- *Grado de relevancia* ( $S_2$ ) de una convocatoria para un usuario.
- *Grado de compatibilidad* ( $S_3$ ) entre dos usuarios.

SIRE2IN es un sistema de recomendaciones que usa un esquema de recomendación híbrido, en el que se combinan las recomendaciones basadas en contenidos y las colaborativas. Por último, si los usuarios desean colaborar con otros de cara a establecer grupos de trabajo, el sistema analiza las posibles colaboraciones y se recomiendan aquéllas para las que se haya obtenido grado de compatibilidad adecuado. En este caso se devuelve al usuario el grado de compatibilidad estimado mediante una etiqueta lingüística de manera que sea más fácil de entender.

### **TPLUFIB-WEB: Un sistema Web lingüístico difuso para ayudar en el tratamiento de los problemas de lumbaliga**

La lumbalgia es un problema que afecta a una gran proporción de la población adulta en algún momento de sus vidas y tiene un impacto social y

---

económico muy elevado [51]. Para solucionar este impacto, una posible solución es hacer uso de las Tecnologías de la Información y las Comunicaciones. Los ejercicios físicos han probado su efectividad en la protección contra la lumbalgia y proporcionan una recuperación de procesos, que se pueden convertir en crónicos, reduciendo así el número de días de las bajas laborales producidas por este problema como también ayudando en el tratamiento psicológico de esta condición [36].

El número de fisioterapeutas en España por cada 100.000 habitantes es bajo en comparación con otros países europeos<sup>1</sup>, lo que es un argumento para apoyar una tele-rehabilitación complementaria para enfrentar la lumbalgia. El excesivo número de recomendaciones en el ámbito de la salud que podemos encontrar en Internet es una causa de preocupación para el usuario, el cual necesita estar seguro de la proveniencia y de la fiabilidad de esas recomendaciones.

En [52] se propone TPLUFIBWEB, un sistema de recomendaciones Web lingüístico difuso para ayudar en el tratamiento de los problemas de lumbalgia. TPLFIBWEB fue diseñado incorporando un enfoque de recomendaciones híbrido [27] junto con un MLD multi-granular para representar y gestionar información flexible por medio de etiquetas lingüísticas y para ayudar a los fisioterapeutas a llegar a más clientes a través de la tele-rehabilitación.

Para representar los distintos conceptos que tienen que ser valorados en la actividad del sistema, se usan distintos conjuntos de etiquetas ( $S_1, S_2, \dots$ ) seleccionados de una jerarquía lingüística. En concreto, se distinguen tres conceptos que tienen que ser valorados:

---

<sup>1</sup> Ver el informe listado en: <http://www.pordata.pt/en/Europe/-Physiotherapists+per+100+thousand+inhabitants-1925>

---

- *Grado de importancia* de cada subgrupo de diagnóstico para la aplicación de un tratamiento o para establecer el perfil de un paciente en función de la patología ( $S_1$ ).
- *Grado de relevancia* de un tratamiento para un paciente ( $S_2$ ).
- *Grado de similitud* entre las patologías de dos pacientes ( $S_3$ ).
- *Grado de satisfacción* de un paciente acerca de un tratamiento ( $S_4$ ).

TPLUFIBWEB es un sistema de recomendaciones que usa un esquema de recomendación híbrido, en el que se combinan las recomendaciones basadas en contenidos y las colaborativas. Por último, basándose en las valoraciones de los pacientes, los tratamientos de los pacientes con diagnósticos similar se verán afectados por éstas.

### **3.10.3. Sistemas de recomendaciones basados en el MLD multi-granular aplicados en bibliotecas digitales universitarias**

La importancia de la biblioteca dentro de la universidad es incuestionable ya que constituye un servicio clave para el buen desarrollo de los procesos de enseñanza y de investigación [32]. De hecho, es conocido que las universidades más prestigiosas del mundo en términos de docencia e investigación son las que disponen de las mejores bibliotecas.

Tradicionalmente, el objetivo de una biblioteca ha sido el de almacenar la información que la sociedad ha ido generando, permitiendo su acceso a los usuarios. Esta información estaba organizada de forma que se facilitara su uso lo máximo posible para los usuarios. Sin embargo la función de una biblioteca en nuestra sociedad está cambiando. Desde los años 90, cuando hizo aparición Internet, la Web se ha convertido en la principal plataforma para que bibliotecas

---

almacenen, creen y distribuyan documentos (usaremos el termino “documento” en el más amplio significado posible, en el que están incluidos todos los registros comunicativos, incluyendo material en papel, archivos electrónicos, vídeos, etc.), servicios e instrucciones.

Hoy día, podemos encontrar dos tipos de servicios de información para usuarios de bibliotecas [18]: *servicios de información tradicionales* y *servicios de información electrónicos*. Los primeros están basados en una comunicación cara a cara y son los que se desarrollan en la propia biblioteca. Mientras que los segundos se basan en la Web, pueden ser desarrollados en el lugar o fuera y son accesibles sin ninguna limitación geográfica o temporal. Como ejemplos de estos últimos, podemos citar los sistemas integrados de bibliotecas, sistemas de aprendizaje a distancia, servicios de bases de datos, catálogos de bibliotecas Web, revistas *open source*, motores de búsqueda Web, etc.

Los dos tipos de servicios comentados son necesarios y llegado el caso, complementarios para desarrollar las actividades propias de una biblioteca. Sin embargo, los servicios electrónicos nos permiten mejorar la eficiencia de una biblioteca como tal. Por lo tanto, encontramos que las bibliotecas híbridas van en aumento. Éstas mantienen algunos de los servicios tradicionales pero con una gran tendencia a crear nuevos servicios digitales usando todas las posibilidades proporcionadas por la Web y el mundo digital [146]. Sin embargo, dada su importancia en la actualidad y porque es uno de los aspectos a tratar en esta tesis, nos centraremos únicamente en las bibliotecas digitales.

### **Definición de Biblioteca Digital**

Las bibliotecas digitales son las extensiones lógicas de las bibliotecas físicas en la sociedad de la información electrónica. Estas extensiones amplifican los

---

recursos y servicios existentes. No hay consenso acerca de un concepto adecuado de *biblioteca digital*. Ésta puede ser considerada como una colección de versiones digitales de documentos publicados en bibliotecas físicas o bien puede ser una poligamia de documentos, tecnología y trabajo [110]. Una biblioteca digital vista como un sistema automático de acceso a información relevante nos lleva a una situación en la que la información es generada mucho más rápido que los usuarios pueden procesar [58, 83, 115, 144]. Las bibliotecas digitales son colecciones de información que tienen asociados servicios de distribución para las comunidades de usuarios usando cualquier variedad de tecnología disponible.

Las colecciones de información pueden ser de cualquier ámbito, por ejemplo pueden ser científicas, de negocios o incluso de datos personales y pueden ser representadas en cualquier formato digital, ya sea texto, imagen, audio, vídeo o cualquier otro medio. La información puede ser un documento digitalizado o ser creado directamente en formato digital. Los servicios ofrecidos puede ser variados y podrán ser ofertados de forma individual o en grupo a comunidades de usuarios [30, 58, 138]. Las bibliotecas ofrecen diferentes tipos de servicios:

- Servicio de referencia y derivación. Por ejemplo: referencia rápida, búsqueda exhaustiva o difusión selectiva de la información entre otros.
  - Servicios de enseñanza. Por ejemplo: formación de usuarios, de búsqueda de base de datos.
  - Servicios de valor añadido. Por ejemplo: la preparación de bibliografía, traducción de idiomas.
  - Promoción servicios. Por ejemplo, la alfabetización, la libertad de expresión.
-

Las bibliotecas digitales disponen de recursos humanos, personal de la biblioteca, que se encargan de gestionar la información y permitir que los usuarios puedan acceder a los documentos que sean más interesantes para ellos, teniendo en cuenta sus necesidades o áreas de interés. El personal de la biblioteca busca, evalúa, selecciona, cataloga, clasifica, preserva y gestiona el acceso a los documentos digitales [58]. Algunas de las funciones principales que se desarrollan en una biblioteca digital son las que se enumeran a continuación:

- Evaluar y seleccionar material digital para añadirlo en el repositorio.
- Preservar y mantener la seguridad y conservación de los materiales.
- Describir e indexar los nuevos materiales digitales (catalogar y clasificar).
- Difundir entre los usuarios el material almacenado en la biblioteca.
- Otras tareas directivas, administrativas y de gestión.

Las bibliotecas digitales han sido usadas en un amplio abanico de contextos, pero en esta tesis nos centraremos en un tipo ámbito más exclusivo, el académico. En nuestro caso prestaremos atención a dos tipos diferentes de bibliotecas digitales.

- Por un lado, las *Bibliotecas Digitales Universitarias (BDU)* proporcionan recursos de información a estudiantes y personal universitario en un ambiente que apoya el aprendizaje, la enseñanza y la investigación [32].
  - Por otro lado nos centramos en las bibliotecas digitales orientadas a un ambiente académico, más enfocado a la investigación, como pueden ser las colecciones digitales proporcionadas por Thomsom Reuters, Web Of
-

Science (WOS)<sup>2</sup> ; Elsevier, Scopus<sup>3</sup> o ScienceDirect <sup>4</sup> ; IEEE, IEEEExplore<sup>5</sup> ; Association for Computer Machinery, ACM Digital library<sup>6</sup> .

Una de las mayores prioridades de una biblioteca, ya sea digital o de cualquier otro tipo, es proveer las necesidades de investigación necesarias de sus constituyentes [110]. Un servicio que es particularmente importante en una biblioteca digital universitaria y donde nosotros centraremos nuestra atención, es en el filtrado o distribución selectiva de información. Los usuarios desarrollan ciertos perfiles de intereses y de la misma forma que los nuevos documentos añadidos son agregados a las colecciones, éstos son comparados con otros perfiles de forma que la biblioteca digital pueda alertar a los usuarios cuando haya documentos que les puedan ser de interés. [115]. Sin embargo, en este entorno, y debido al problema de la sobrecarga de información, los usuarios encuentran serias dificultades para acceder a información de interés, lo que provoca que en muchas ocasiones, lo que realmente obtengan sea información irrelevante o innecesaria. Por lo tanto, los usuarios necesitan un acceso más sencillo a los miles de documentos que están disponibles pero que le son difíciles de encontrar [119].

Pues bien, en este contexto de las BDU, presentamos tres ejemplos de la temática tratada en esta tesis, sobre la aplicación de sistemas de recomendaciones basados en el MLD. Estos ejemplos son los trabajos previos de los que parte esta tesis y los que desarrollamos en nuestras propuestas las cuales veremos en los siguientes capítulos.

---

<sup>2</sup> <http://wokinfo.com/>

<sup>3</sup> [www.scopus.com/scopus/home.url](http://www.scopus.com/scopus/home.url)

<sup>4</sup> <http://www.sciencedirect.com/>

<sup>5</sup> [IEEEExplorehttp://ieeexplore.ieee.org/Xplore/home.jsp](http://ieeexplore.ieee.org/Xplore/home.jsp)

<sup>6</sup> <http://dl.acm.org/>

---

### Dealing with Incomplete Information in a Fuzzy Linguistic Recommender System to Disseminate Information in University Digital Libraries

En este punto analizamos la propuesta presentada en [130] la cual se centra en la idea de que un sistema de recomendaciones se puede considerar como un sistema de ayuda a la decisión (Decision Support System - DSS) [111, 114, 127], donde las soluciones alternativas son los recursos digitales insertados en la BDU, y los criterios a satisfacer son los perfiles de los usuarios. El uso apropiado de los sistemas de recomendaciones es esencial para proporcionar servicios realmente personalizados e incrementar la satisfacción de los usuarios. Por tanto, la actividad de un sistema de recomendaciones se puede ver como un problema de toma de decisión en grupo (Group Decision Making - GDM), de manera que podemos adoptar los formatos de representación usados habitualmente en este tipo de problemas, como por ejemplo, las relaciones de preferencia difusas [68, 72, 81, 117]. Este formato de representación presenta una gran expresividad y otras propiedades interesantes que nos permiten trabajar de una forma cómoda. Sin embargo, en problema reales es común encontrar situaciones en las que los usuarios no son capaces de proporcionar todos los valores requeridos sobre las preferencias de unos ítems respecto a otros, y por tanto, se hizo necesario trabajar con *relaciones de preferencia incompletas* [7, 10, 11, 78, 79, 117].

El objetivo del trabajo es presentar un nuevo sistema de recomendaciones lingüístico difuso definido en el marco de una BDU, pero solucionando los problemas de caracterización de perfiles de usuario observados en esquemas previos, que requerían mucha participación por parte de los usuarios. En este trabajo se propone una forma alternativa de obtener conocimiento preciso y útil sobre las preferencias de los usuarios. El nuevo sistema de recomendaciones permite a los usuarios indicar sus preferencias por medio de relaciones

---

de preferencia lingüísticas difusas incompletas [7], facilitando la expresión de dichas preferencias, y por tanto mejorando el proceso de determinación de los perfiles de los usuarios. Partiendo de estas relaciones de preferencia incompletas, el sistema es capaz de completarlas usando las herramientas y algoritmos propuestos en [7, 10, 79]. Cada perfil de usuario se compone de sus preferencias sobre los temas tratados en los recursos, así como de sus preferencias sobre posibilidades de colaboración con otros usuarios. Y es que el sistema recomienda tanto recursos de la BDU como posibilidades de colaboración con otros usuarios, de cara a formar grupos de trabajo multidisciplinares.

Para facilitar la representación de la información, en esta propuesta también incorpora el MLD multi-granular, en el se usan distintos conjuntos de etiquetas para valorar los distintos conceptos que tienen que ser valorados, que en este caso son los siguientes:

- *Grado de importancia* de una disciplina respecto del ámbito de un recurso o de las preferencias de un usuario valorado en  $S_1$ .
- *Grado de relevancia* de un recurso para un usuario valorado en  $S_2$ .
- *Grado de compatibilidad* entre dos usuarios valorado en  $S_3$ .
- *Grado de preferencia* de un recurso respecto a otro valorado en  $S_4$ .

### **Using memory to reduce the information overload in a university digital library**

En [130, 132] ya se aplicaban con éxito los sistemas de recomendaciones en una BDU. Sin embargo, el número de recursos electrónicos disponibles en una BDU continúa creciendo continuamente y el problema de sobrecarga de información, previamente descrito, aparece de nuevo. Por tanto, encontramos un problema persistente de sobrecarga de información.

---

Por ello en [159] proponemos un nuevo sistema de recomendaciones mejorado basado en la memoria para evitar ese problema persistente de sobrecarga de información presente en los esquemas previos. El enfoque adoptado en esta propuesta es similar al presentado en [130], pero en este caso usamos una memoria para recordar recursos seleccionados pero no recomendados y de esta forma, el sistema podría incorporarlos en futuras rondas de recomendaciones para completar el panel de recursos recomendados. Como en [130, 132], el sistema recomienda tanto recursos como posibilidades de colaboración con otros usuarios, lo que permite conocer a investigadores de áreas relacionadas con los que se podría colaborar para acceder a proyectos conjuntos.

De nuevo, se define el sistema en un contexto lingüístico difuso multi-granular. De manera que de cara a conseguir una mayor flexibilidad en los procesos de comunicación entre los usuarios y el sistema de recomendaciones, se usan distintos conjuntos de etiquetas para representar los distintos conceptos que tienen que ser valorados durante la actividad de filtrado. En este trabajo son 5 los conceptos con los que trabajamos:

- *Grado de importancia* de una disciplina respecto del ámbito de un recurso o de las preferencias de un usuario valorado en  $S_1$ .
  - *Grado de relevancia* de un recurso para un usuario valorado en  $S_2$ .
  - *Grado de compatibilidad* entre dos usuarios valorado en  $S_3$ .
  - *Grado de preferencia* de un recurso respecto a otro valorado en  $S_4$ .
  - *Número cualitativo de recursos*. Los usuarios pueden especificar el número de recursos que desean recibir mediante una etiqueta que representa un valor aproximado valorado en  $S_5$ .
-

## Chapter 4

# A quality based recommender system to disseminate information in a University Digital Library

In the previous chapters we have presented a study about the recommender systems and their different approaches (Chapter 2), as well as a study about the fuzzy linguistic modeling to represent the information to model the subjectivity and uncertainty involved in the activities of information access (Chapter 3). We also have introduced the concept of University digital library (Section 3.10.3).

In this chapter we propose the design and implementation of a recommender system to disseminate information between researchers in an university digital library that is based on quality. The aim of the system is to aid researchers in their process of personalized information access over resources in their research areas. The system has been designed integrating content-based and collaborative approach together with a multi-granular fuzzy linguistic modeling.

The chapter is set out as follows. In Section 4.1 an introduction explaining the purpose of the system is presented. Next, section 4.2 describes the system

architecture together with the new recommendation approach based on quality of the items. Then, in Section 4.3 the evaluation of the system and the experimental results are presented. Finally, a discussion of the system is pointed out in Section 4.4

## 4.1. Introduction

Nowadays we live in the Information Society and we are constantly receiving many information in all scopes of our lives. Although the problem of information overload has existed for many years, in recent years the problem has become more widely recognized and experienced because of the rapid advances made in Information and Communication Technologies [48]. So the problem resides in the fact that technology are producing, manipulating and disseminating information faster than individuals can use.

World Wide Web (called Web) is a popular and interactive medium to collect, disseminate and access an increasingly huge amount of information. Due to its spectacular growth, related to both resources (pages, sites, and services) and visitors, the Web is nowadays the main information repository. In a few short years, the Web has become our most compelling technological accomplishment. This great amount of information introduces noise in our information accesses and this makes difficult to find relevant information and affects too to our decisions. It can mean several things, such as having more relevant information than one can process or it might mean being overwhelmed with a large amount of unsolicited information, some of which may be relevant. For example, on the one hand, everyday we receive in our accounts a huge amount of emails. Most of them are qualified as spam, but we also receive a big number of emails containing useful or relevant information. The problem is that this fact

---

could provoke we may pay inadequate attention to what we think is of minor importance and so misinterpret the message, or we could lose some information thinking that it isn't of key importance. While on the other hand, we can be looking for something with a search engine in a so big repository of data that the answer to our query cannot be process to extract the information we are looking for [119]. This explosive growth of the Web stimulates the development of fast and effective automated systems that support an easy and effective access to the information relevant [106].

The information overload problem appears specially in the environment of digital libraries where the information is generated much faster than the users can process it. Users develop interest profiles and as new materials are added to the collection, they are compared to the profiles and the UDL alerts the users with relevant items [115].

As we have seen, because of information overload problem, although there is an abundance of information available. When the users of a UDL try to receive useful information, they often obtain irrelevant information. With the increase in the amount of information, users need easier and appropriate access to obtain relevant information. In order to reduce information overload, there is a very widespread solution, the use of *recommender systems* [61, 137].

As we have seen in previous chapter, in previous proposals it has been applied recommender systems in the UDL scope [132, 130]. But, despite that the use of these techniques to avoid the information overload problem was successful, we have found different aspects that may limit their performance. They act as an information retrieval system based on matching functions which acts among the resources representation and user profiles. In fact, we do not use

---

a pure collaborative approach and this limits their performance. If the level of collaboration in the digital library environment is high, then the tools we provide must not make unwarranted assumptions about a single user browsing and access. Tools will be needed to support a range of collaborative activities [110]. Furthermore, as it happens in the Web, the number of electronic resources daily generated grows continuously, so the problem appears again and the system performance is decreased. Therefore, we find a persistent problem of information overload.

Hence, a first step to improve these systems is to adapt the recommendation approach to the new circumstances. If we analyze the UDL scope, we find that the collaborative approach would be very useful because it allows users to share their experiences, that is, users can rate or add value to information objects and these ratings can be shared with the community, so that popular items can be easily located or people could receive information items found useful by others with similar profiles. But the collaborative approaches tend to fail when little is known about items, i.e., when the system has few ratings, what is known as *cold-start* problem. For this reason, we propose to combine both the content-based and collaborative approaches to obtain a hybrid recommendation scheme that improves the performance of those systems proposed in [130, 132]. Moreover, in the real life, people usually buy widely known products or products of popular brands. These products are popular because they are considered to have good quality in order to satisfy the users' needs. What we do is to move this idea to the UDL scope. Generated recommendations could be more interesting for the users if we consider the quality of items themselves. That is, to compute the relevance of an item using its quality.

In this chapter, we present a recommender system whose main features are the

---

following:

- The system implements a *hybrid recommendation strategy* based on a switching hybrid approach [26], which switches between a content-based recommendation approach and a collaborative one to share the user individual experience and social wisdom [152].
- The system implements a richer *feedback process*. In [130, 132] the user participation in the feedback process is small because it consists in adding or eliminating topics in the user profile, but users could not provide satisfaction degrees. However, to improve the recommendations in this new system, when researchers analyze a recommended resource they provide a satisfaction degree. In such a way, we guarantee that user experiences are taken into account to generate the recommendations done by the system.
- We face the recommendations generation process about research resources as a task with two distinct elements: On the one hand, finding research resources that are relevant to the users and on the other hand, finding valid research resources from the standpoint of the *quality of the items*.
- The system incorporates a module which performs a *re-ranking* process which takes into account the estimated relevance of an item along with the item quality.

But the problem is how to obtain the research resource quality without much interaction from users. We cannot use previous proposals like the presented in [28, 32, 91, 92] because they require intensive user's feedback to evaluate the quality. So, we propose a way to evaluate the quality of research resources based on the idea that if a research resource is usually preferred to others, indicate us that such item has a certain quality. To do that, we work from

---

the method presented in [130], where we proposed an alternative way to obtain accurate and useful knowledge about the user preferences: The system allows users to provide their preferences by means of incomplete fuzzy linguistic preference relations [7, 117], and in such a way, it facilitates users the expression of their preferences and, consequently, the determination of user profiles. The system completes the incomplete preference relations using the tools proposed in [7, 10], and it calculates the resources quality using this preference relation. Then, in this chapter we present a hybrid fuzzy linguistic recommender system based on items' quality and we apply it in a UDL to help the users to access relevant research resources. The system measures the items' quality and it takes into account this measure like a new factor to be considered in the recommendation process. This system improves the generated recommendations by increasing its information discovering properties in an academic environment and by including more useful and accurate recommendations.

## 4.2. System architecture

In the introduction we have described the problem we are facing with the design and implementation of this system. In this section we face architecture of the system as well as the recommendations generation process about research resources as a task with two elements to consider: on the one hand, finding research resources that are relevant to the UDL users and, on the other hand, finding valid research resources from the standpoint of the item quality. We propose an approach to combine the estimated relevance of an item along with the item quality.

We work from the method presented in [130], where an alternative way to obtain accurate and useful knowledge about the user preferences is presented.

---

The system allows users to provide their preferences by means of incomplete fuzzy linguistic preference relations [7, 117], and in such a way, we facilitate users the expression of their preferences and, consequently, the determination of user profiles. The system completes the incomplete preference relations using the tools proposed in [7, 10]. However, the recommendation strategy applied in [130] is a simple content-based approach. Now we improve that recommender system by implementing a hybrid recommendation strategy based on a switching hybrid approach [26], which switches between a content-based recommendation approach and a collaborative one to share user experiences by generating social recommendations. With this dual perspective, we get minimize the cold-start problem because our system switch from one approach to another, depending on the circumstances. Furthermore, users do not need to provide their preferences about all resources, but the system presents them only a selection of the most representative resources, and the users only provide their preferences about that reduced number of resources.

Moreover, we incorporate a module which performs a *re-ranking*, combining the estimated relevance of an item along with the item quality. The idea is that resources usually preferred to other are considered to have good quality in order to satisfy the users' needs. In such a way, the recommender system generates more useful and accurate recommendations. But these improvements don't affect the complexity of the recommendation process because we simply substitute the previous recommendation scheme with other with similar complexity. Furthermore, this proposal affects only the selected resources, which is a reduced number of items, and thus, it does not affect the overall complexity.

The proposed model is applied in a UDL to improve the recommendations generated by the system and help users to access relevant research resources.

---

In Figure 4.1 we show the basic operating scheme of this recommender system which is based on the following components:

1. *Resources representation.* The system obtains an internal representation of the resources based on their scopes.
2. *User profiles representation.* The system obtains an internal representation of the user based on their preferred research resources and topics of interest.
3. *Hybrid recommendation approach.* The system generates the recommendations according to the hybrid filtering approach.
4. *Computing quality of items.* From the preference matrix about research resources, the system obtains a quality score for each item.
5. *Re-ranking.* The system aggregates the estimated relevance of a research resource and its quality score in a single score.
6. *Feedback phase.* The users provides the system their opinions about the received recommendations.

The recommender system follows an hybrid approach, based on the multi-granular fuzzy linguistic approach presented in chapter 3 to model the user-system communication in order to allow a higher flexibility in the communication processes of the system. The system uses different label sets ( $S_1, S_2, \dots$ ) to represent the different concepts to be assessed in its filtering activity. These label sets,  $S_i$ , are chosen from those label sets that compose a  $LH$ , i.e.,  $S_i \in LH$ . We should point out that the number of different label sets that we can use is limited by the number of levels of  $LH$ , and therefore, in many cases the label sets  $S_i$  and  $S_j$  can be associated to a same label set of  $LH$  but with different interpretations, depending on the concept to be modeled. We

---

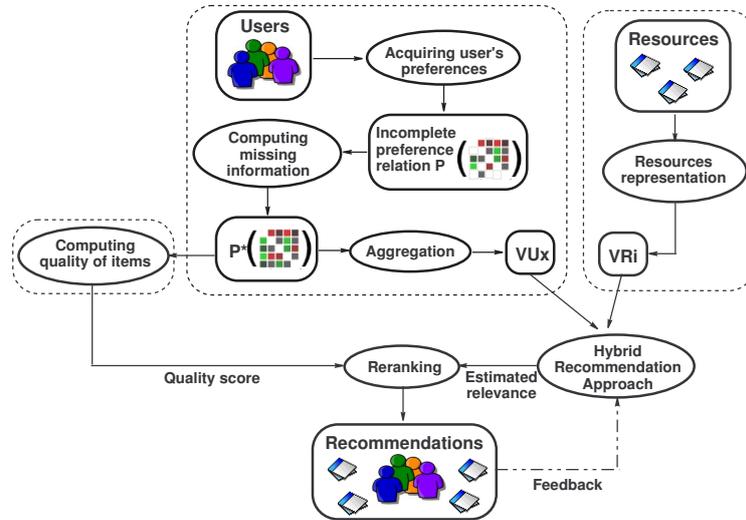


Figure 4.1: Basic operating scheme.

consider five concepts that can be assessed in the activity of this recommender system::

- **Importance degree** of a discipline with respect to a resource scope, which is assessed in  $S_1$ . This degree is used to obtain an internal representation about the research resources.
- **Similarity degree** among resources or among users, which is assessed in  $S_2$ .
- Predicted **relevance degree** of a resource for a user, which is assessed in  $S_3$ .
- **Satisfaction degree** expressed by a user to evaluate a recommended resource, which is assessed in  $S_4$ .
- **Preference degree** of a resource regarding another one, which is assessed in  $S_5$ .

The selected granularity must be sufficiently low as not to impose an excessive

---

precision in the information you want to express and high enough to get a discrimination of the assessments in a limited number of degrees. Usually, the cardinality used in the linguistic models is an odd value, such as 7 or 9, not exceeding 11 labels. These classical values are based on Miller's observation line about human capacity [120], which indicated that can be handled reasonably and remember about 7 or 9 terms.

Following the linguistic hierarchy shown in Figure 3.6, we use the level 2 (5 labels) to represent the importance degrees and preference degrees ( $S_1 = S^5$  and  $S_5 = S^5$ ), and the level 3 (9 labels) to represent the similarity degrees ( $S_2 = S^9$ ), predicted relevance degrees ( $S_3 = S^9$ ) and satisfaction degrees ( $S_4 = S^9$ ). As the importance degrees are provided initially by UDL staff, we use a set of 5 labels to facilitate them the characterization of resource scopes or user interest topics. On the other hand, as the similarity and relevance degrees are computed automatically by the system, we use the set of 9 labels which presents an adequate granularity level to represent the results. Similarly, to provide users with a label set with an adequate granularity level we use the set of 9 labels to express the satisfaction degrees. Using this *LH*, the linguistic terms in each level are the following:

- $S^5 = \{b_0 = \text{None} = N, b_1 = \text{Low} = L, b_2 = \text{Medium} = M, b_3 = \text{High} = H, b_4 = \text{Total} = T\}$
- $S^9 = \{c_0 = \text{None} = N, c_1 = \text{Very-Low} = VL, c_2 = \text{Low} = L, c_3 = \text{More-Less-Low} = MLL, c_4 = \text{Medium} = M, c_5 = \text{More-Less-High} = MLH, c_6 = \text{High} = H, c_7 = \text{Very-High} = VH, c_8 = \text{Total} = T\}$

In the following subsections we explain all components in detail.

---

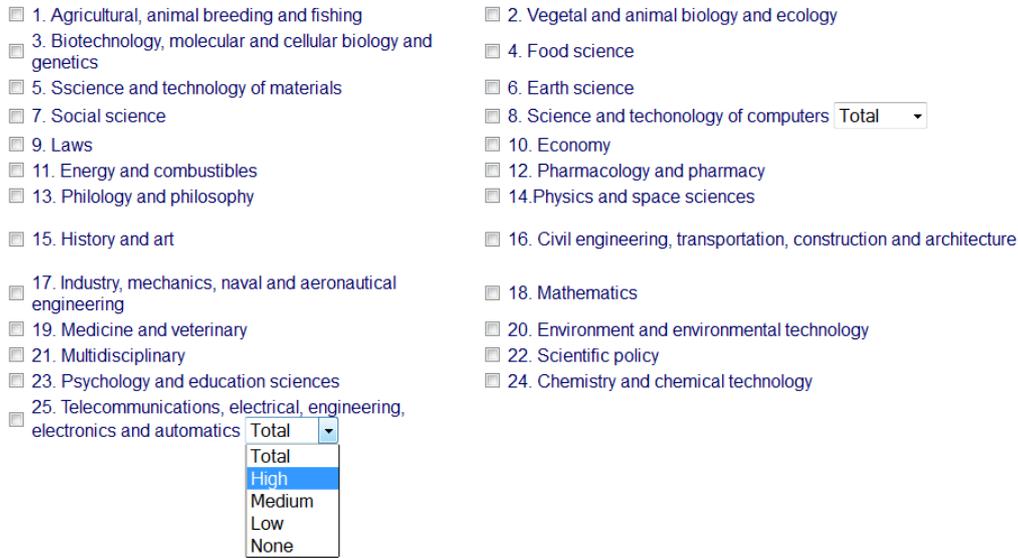


Figure 4.2: Interface to define the disciplines of the resource scope.

#### 4.2.1. Resources representation

The considered resources are journal articles, conference contributions, book chapters, books or edited books. The library staff is on charge of inserting all the available information about a new resource, the system obtains an internal representation mainly based in the resource scope of each resource inserted. We use the *vector model* [102] to represent the resource scope and a classification composed by 25 disciplines (see Figure 4.2), i.e., a research resource  $i$  is represented as

$$VR_i = (VR_{i1}, VR_{i2}, \dots, VR_{i25}),$$

where each component  $VR_{ij} \in S_1$  is a linguistic assessment that represents the importance degree of the discipline  $j$  with regard to the scope of  $i$ . These importance degrees are assigned by the UDL staff when they add new resources.

**Example.** We suppose that the UDL staff receive information about a paper about Computer Science. Then, one of the experts accesses to the application and inserts the new research resource. He/she fills all the fields of the form and

---

he/she uses the interface shown in Figure 4.2 to select the disciplines of the resource scope. We assume that the expert selects the discipline titled “Science and technology of computers” with an importance degree “Total” and the discipline titled “Telecommunications, electrical engineering, electronics and automatics” with an importance degree “High”. These disciplines are in the positions 8 and 25 respectively of the used classification. The rest of disciplines have an importance degree with a value of “None”. So, the scope of the new resource is represented in the following way:

$$VR_i = (VR_{i1}, VR_{i2}, \dots, VR_{i25}),$$

where  $VR_{i8} = (b_4, 0)$ ,  $VR_{i25} = (b_3, 0)$  and the rest of positions have the value  $(b_0, 0)$ .

### 4.2.2. User profiles representation

Normally, users have to perform a great effort to provide their preferences, which the system uses to obtain the user profile. To reduce this effort and make easier the process for acquiring the user preferences, we use the method proposed in [130] where we presented an alternative method to obtain the user preferences.

The system asks users to provide their preferences on some research resources, usually a limited number of resources; in our case we use five research resources. The choice of these research resources is made by the UDL staff taking into account the relevance supplied by the users and the research resource scope. We propose users to represent their preferences by means of incomplete fuzzy linguistic preference relations. Then, the system presents users only a selection of the most representative resources, and the users provide their preferences about these resources by means of an incomplete fuzzy preference

---

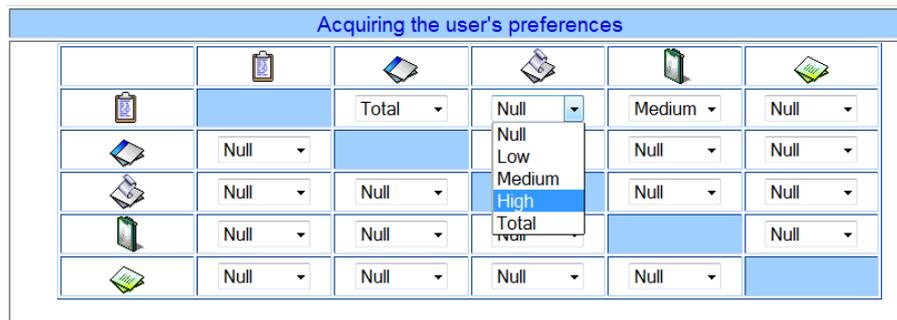


Figure 4.3: Interface to define the user preferences about the five most relevant resources.

relation. Furthermore, according to results presented in [10], it is enough that the users provide only a row of the preference relation. Then, we use the method proposed in [10] to complete the relation. Once the system completes the fuzzy linguistic preference relation provided by the user, it is possible to obtain a vector representing the user preferences on the topics of interest. Next, we explain this process in detail:

1. **Acquiring the user preferences on a limited number of research resources.** At the beginning, the main goal is to help the users to provide their preferences assuring that these preferences are as consistent as possible. The system shows users the five most representative resources,  $R = \{r_1, \dots, r_5\}$ , and asks them to express their preferences by means of an incomplete fuzzy linguistic preference relation (see Figure 4.3). The users only fill those preferences that they wish, assigning labels of  $S_5$ . In the preference relation, each preference value  $p_{ij}$  represents the linguistic preference degree of resource  $i$  over the resource  $j$  according to the user opinion. As aforementioned, the simplest case would be to provide a relation with only one row of preference values:

$$P = \begin{pmatrix} - & p_{12} & p_{13} & p_{14} & p_{15} \\ x & - & x & x & x \\ x & x & - & x & x \\ x & x & x & - & x \\ x & x & x & x & - \end{pmatrix} \quad (4.1)$$

Then, the system completes the preference relation  $P$  using the method proposed in [10], and obtains the relation  $P^*$ :

$$P^* = \begin{pmatrix} - & p_{12} & p_{13} & p_{14} & p_{15} \\ p_{21}^* & - & p_{23}^* & p_{24}^* & p_{25}^* \\ p_{31}^* & p_{32}^* & - & p_{34}^* & p_{35}^* \\ p_{41}^* & p_{42}^* & p_{43}^* & - & p_{45}^* \\ p_{51}^* & p_{52}^* & p_{53}^* & p_{54}^* & - \end{pmatrix} \quad (4.2)$$

where  $p_{1j} \in S_5$  are the degrees inserted by the user about the preferences of the resource  $x_1$  with respect to  $x_j$ ,  $p_{ii}$  represents indifference, and each  $p_{ij}^*$  is the estimated degree for the user about his/her preference of the resource  $x_i$  with respect to  $x_j$ .

2. In order to obtain **user preferences on topic of interest**, i.e., **user preference vector**, firstly we calculate the user preference degrees on each considered resource according to the preference relation  $P^*$ , and secondly, we use these preference degrees together with the vectors that represent each research resource to obtain the user preference vector. To obtain them we propose the application of the arithmetic mean  $\bar{x}^e$  (definition 3.13). Then, the preference degree of the resource  $i$  for the expert called  $DG_i$ , is computed as follows:

$$DG_i = \bar{x}^e[p_{i1}^*, \dots, p_{i5}^*] \quad (4.3)$$

Then, to obtain the user preference vector  $x$ , i.e.  $VU_x = (VU_{x1}, VU_{x2}, \dots, VU_{x25})$ , from the aggregation of the vectors that represents the characteristics of the chosen research resources, i.e.,  $\{VR_1, \dots, VR_5\}$ , weighted by mean of the user preference degrees  $\{DG_1, \dots, DG_5\}$ . To do that, we use the linguistic weighted average operator defined in definition 3.15, and then each position  $k = \{1, \dots, 25\}$  of the vector  $VU_x$ , is computed as follows:

$$VU_{xk} = \bar{x}_l^w[(VR_{1k}, DG_1), \dots, (VR_{5k}, DG_5)] \quad (4.4)$$

### 4.2.3. Hybrid recommendation approach

In this phase the system filters the incoming information to deliver it to the fitting users. As aforementioned, we implement a *hybrid recommendation* strategy, which switches between a content-based recommendation approach and a collaborative one. Burke [26] proposes a classification composed by different strategies according to the method of combining any two (or more) pure techniques to build a hybrid recommender system. In this sense, our proposal is based on a *switching hybrid approach*, which uses one technique or another, depending on some criterion. A system may try one technique and if the confidence of the results is not satisfactory, it may switch to another technique. In our system, depending on the case, a content-based recommendation approach or a collaborative one is applied. The former is applied when a new item is inserted and the latter is applied when a new researcher is registered.

This process is based on a matching process developed by similarity measures, such as Euclidean Distance or Cosine Measure [102].

The **Cosine measure** is an angular measure to estimate similarity between vectors, it is defined by the cosine of the angle formed between two vectors representing two documents, two users or a document and a user. (See equation 2.1)

The angular measurements are characterized by representing a view of the documents space from a fixed point, the origin. In addition, an angular measurement does not consider the distance of each document with respect to the origin, but only considers its direction. Therefore, two documents following the same vector from the origin will be found to be identical, despite they were separated in the documents space.

***Example: Cosine measure.***

Suppose we have three resources represented by the same to terms through the following vectors:

$$VR_1 = \langle 1, 5 \rangle,$$

$$VR_2 = \langle 100, 500 \rangle, y$$

$$VR_3 = \langle 5, 1 \rangle .$$

We apply the cosine measure,  $\sigma(VR_1, VR_2) = 1.0$  and  $\sigma(VR_1, VR_3) = 0.38$ , whereby  $R_2$  and  $R_1$  are more similar than  $R_3$  and  $R_1$ . This is because in  $R_1$  and  $R_2$  the two terms have the same relative importance, that is, they are conceptually in the same topic.

In particular, we use the standard cosine measure but defined in a linguistic framework:

---

$$\sigma_l(V_1, V_2) = \Delta\left(g \times \frac{\sum_{k=1}^n (\Delta^{-1}(v_{1k}, \alpha_{v1k}) \times \Delta^{-1}(v_{2k}, \alpha_{v2k}))}{\sqrt{\sum_{k=1}^n (\Delta^{-1}(v_{1k}, \alpha_{v1k}))^2} \times \sqrt{\sum_{k=1}^n (\Delta^{-1}(v_{2k}, \alpha_{v2k}))^2}}\right) \quad (4.5)$$

with  $\sigma_l(V_1, V_2) \in S_2 \times [-0.5, 0.5]$ , and where  $g$  is the granularity of the term set used to express the relevance degree, i.e.  $S_3$ ,  $n$  is the the number of disciplines and  $(v_{ik}, \alpha_{vik})$  is the 2-tuple linguistic value of discipline  $k$  in the vector  $V_i$  representing the resource scope or user interest topics, depending of the used filtering strategy.

In the following sections, we explain the proposed recommendation strategies.

### Content-Based Recommendations

When a new resource  $i$  arrives to the system, the system calculates the content-based recommendations to be sent to a researcher  $e$  as follows:

1. Compute the linguistic similarity degree between  $VR_i$  and  $VU_e$ :  $\sigma_l(VR_i, VU_e) \in S_2$ .
  2. Assuming that  $S_2 = S^9$ , we consider that a resource  $i$  is related with the researcher's profile  $e$  if  $\sigma_l(VR_i, VU_e) > (s_4^9, 0)$ , i.e., if the linguistic similarity degree is higher than the mid linguistic label.
  3. If  $i$  is considered a related resource for  $e$ , then the system recommends this resource  $i$  to  $e$  with a predicted relevance degree  $i(e) \in S_3 \times [-0.5, 0.5]$  which is obtained as follows:
    - a) Look for all research resources stored in the system that were previously assessed by  $e$ , i.e., the set of resources  $K = \{1, \dots, k\}$  such that there exists the linguistic satisfaction assessment  $e(j) \in S_4$ ,  $j \in K$  and  $\sigma_l(VU_e, VR_j) \geq (s_4^9, 0)$ .
-

b) Then,

$$i(e) = \bar{x}_l^w((TF_{S_3}^{S_4}(e(1), 0), TF_{S_3}^{S_2}(\sigma_l(VR_i, VR_1))), \quad (4.6)$$

$$\dots, (TF_{S_3}^{S_4}(e(k), 0), TF_{S_3}^{S_2}(\sigma_l(VR_i, VR_k)))).$$

where  $\bar{x}_l^w$  is the linguistic weighted average operator (Definition 3.15) and  $TF_{S_3}^t$  is the transformation function between a 2-tuple that belongs to level  $t$  and another 2-tuple in level  $t' \neq t$  (Definition 3.17).

### Collaborative Recommendations

When new users are inserted into the system, they receive recommendations about resources already inserted, which may be interesting for them. Usually, new users provide little information about the items that satisfy their topics of interest, so the collaborative approach is used to generate their recommendations. Exactly, we follow a memory-based algorithm or nearest-neighbor algorithm, which generates the recommendations according to the preferences of nearest neighbors. This algorithm has proven good performance [64]. In the following we describe the process in detail.

Given a new researcher  $e$ , the recommendations to be sent to  $e$  are obtained in the following steps:

1. Identify the set of users  $\aleph_e$  most similar to that new user  $e$ . To do so, we calculate the linguistic similarity degree between the topics of interest vector of the new user ( $VU_e$ ) against the vectors of all users already inserted into the system ( $VU_y$ ,  $y = 1..n$  where  $n$  is the number of users), that is, we calculate  $\sigma_l(V_e, V_y) \in S_2$ . As  $S_2 = S^9$ , we consider that the user  $y$  is near neighbor to  $e$  if  $\sigma_l(VU_e, VU_y) > (s_4^9, 0)$ , i.e., if the linguistic similarity degree is higher than the mid linguistic label.

2. Look for the resources stored in the system that were previously well assessed by the near neighbors of  $e$ , i.e., the set of resources  $K = \{1, \dots, k\}$  such that there exists a linguistic satisfaction assessment  $y(j) \in S_4$ ,  $y \in \aleph_e$ ,  $j \in K$ , and  $y(j) \geq (s_6^9, 0)$ .
3. All the resources  $j \in K$ , are recommended to  $e$  with a predicted relevance degree  $j(e) \in S_3 \times [-0.5, 0.5]$  which is calculated as follows:
  - a) To look for all linguistic satisfaction assessments about resources that were well assessed by the nearest neighbors of  $e$ . That is, we recovery  $y(j)$  with  $j \in K$  and  $y \in \aleph_e$ .
  - b) Then,

$$\begin{aligned}
 j(e) = \bar{x}_l^w &(((TF_{S_3}^{S_4}(y_1(j), 0), TF_{S_3}^{S_2}(\sigma_l(VU_e, VU_{y_1}))), \\
 &\dots, (TF_{S_3}^{S_4}(y_n(j), 0), TF_{S_3}^{S_2}(\sigma_l(VU_e, VU_{y_n}))))), \tag{4.7}
 \end{aligned}$$

where  $y_1, \dots, y_n \in \aleph_e$ ,  $\bar{x}_l^w$  is the linguistic weighted average operator (see Definition 3.15) and  $TF_t^t$  is the transformation function between a 2-tuple that belongs to level  $t$  and another 2-tuple in level  $t' \neq t$  (Definition 3.17)..

#### 4.2.4. Computing the quality of research resources

In the literature we can find some approaches which allow us to evaluate the information quality in different scopes [28, 32, 91]. But, very few studies actually apply all the digital evaluation criteria to assess not the digital library, but the resources, that is, the documents. However, our goal is to assess that resources quality according to the user satisfaction but avoiding an intensive user's feedback. To do that, we could use several measures or concepts, but we are focused on a generalist academic environment, so we are dealing with non specific research resources. Then we evaluate the quality of research resources

---

as the popularity of the resources, that is, from the users' perceptions on the research resources recommended by the system. If the resources of our system were more specific, such as scientific articles, we could use the author or journal reputation, such as the H-index of the author [8] or the impact factor of the journal. So, we propose to estimate the quality of a research resource based on its popularity. The main reason for adopting this approach is that we already have available the information about the preferred research resources such that we don't need more user interaction neither additional information about the resources to fix the quality of the resources.

As aforementioned, the system asks users to provide their preferences on five research resources, by means of an incomplete fuzzy preference relation. Then, the system uses the method proposed in [10] to complete this preference relation. We use this method to obtain the user profiles, but we also use this information about the preferred research resources to estimate the quality of these resources. Thus, we avoid further user's feedback that could be harmful regarding the usability of the system. We assume that research resources usually preferred over others have a higher quality. Then, the system asks users to provide their preferences on five research resources selected by the UDL staff taking into account the relevance supplied by the users and research resource scope. Then, the users provide their preferences about these resources by means of an incomplete fuzzy preference relation. Once the system completes the incomplete preference relation  $P$  and it obtains the relation  $P^*$  (see section 4.2.2), we can count the times that each resource has been selected to be shown as well as the times that each resource has been preferred over other. The displayed resources will vary over time, so the system must record each time a resource is selected and each time a resource is preferred to other. So, we estimate the quality of a item  $i$  as the probability that the item  $i$  be

---

preferred over other having been selected, that is:

$$q(i) = p_i/s_i \quad (4.8)$$

where  $p_i$  is the total of times the resource  $i$  has been preferred to another one and  $s_i$  is the total of times the resource  $i$  has been selected.

#### 4.2.5. Re-ranking

Once a research resource  $i$  is considered relevant for a user  $e$ , and both the estimated relevance degree of this resource  $i$  for  $e$ ,  $i(e) \in S_3$ , and the resource quality score,  $q(i) \in [0, 1]$ , have been computed, the last step is to aggregate both in a single score. To do this, first we need to translate the research resource quality score to the values range in which the estimated relevance degree is defined, i.e.,  $S_3$ . We obtain this translated quality score,  $tq(i)$ , as follows:

$$tq(i) = q(i) \times g \quad (4.9)$$

where  $g$  is the granularity of  $S_3$ , assuming  $S_3 = S^9$  and  $g = 8$ .

Then, due to the ease of use and the proven performance of the results we use a multiplicative aggregation in which the estimated relevance is multiplied by the translated quality score, as follows:

$$FinalRelevance(i) = \Delta\left(\frac{\Delta^{-1}(i(e) \times tq(i))}{g}\right) \quad (4.10)$$

where  $\Delta$  and  $\Delta^{-1}$  are the transformation functions between 2-tuples values and symbolic values defined in section 3.5. To obtain the final relevance degree in  $S_3$ , we translate the final relevance value to the interval  $[0, g]$ .

---

### 4.2.6. Feedback phase

In this phase the recommender system recalculates and updates the ratings of the recommended resources. When the system sends recommendations to the users, then they provide a feedback by assessing the relevance of the recommendations, i.e., they supply their opinions about the recommendations received from the system. If they are satisfied with the received recommendation, they shall provide high values and viceversa. The idea is to improve the generated recommendations taking into account the users' ratings, so it is very important the user provides this information which doesn't require too much interaction. This feedback activity is developed in the following steps:

1. The system recommends the user  $U$  a resource  $R$ , and then the system asks him/her his/her opinion or evaluation judgements about this recommended resource.
2. The user communicates his/her linguistic evaluation judgments to the system,  $rc_y \in S_4$ .
3. This evaluation is registered in the system for future recommendations. The system recalculates the linguistic recommendation of  $R$  by aggregating the opinions about  $R$  provided by all users. In such a way, the opinion supplied by  $U$  is considered. This can be done using the 2-tuple aggregation operator as  $\bar{x}^e$  given in Definition 3.13.

## 4.3. Experiments and evaluation

In this section we present the evaluation of the proposed recommender system. As we have seen in the Chapter 2, to evaluate the performance of a recommender system, off-line and online experiments could be applied [153]. With an off-line setting, we could compare a method with other approaches

---

without user interaction, using a standard data set. However, in this case we cannot use any standard data set, because we have proposed a new way to evaluate the quality of research resources and any standard data set has not this information about the preferred research resources. Consequently, in this study we only perform online experiments, i.e., practical studies where a group of users interact with the system and report us their experiences. When the users receive a recommendation, they provide a feedback to the system rating the relevance of the recommended resource, i.e., they provide their opinions about the recommendation supplied by the system. If they are satisfied with the recommendation, they provide a higher value.

In this sense we perform two kind of experiments. We begin our study by considering whether the system properly recommends research resources interesting for the users; to do this, we compare the recommendations generated by the system with the recommendations generated by a group of experts (library staff). Afterward we focus on whether the system properly predicts the ratings of the research resources, by taking into account the ratings provided by the user in the previous experiment.

#### **4.3.1. Data set**

For the online evaluation, we have considered a data set with 200 research resources related with different areas, which were included into the system following the indications described in section 4.2.3. We limited these experiments to 30 users who completed the registration process and they inserted their preferences about the five most relevant resources presented by the system (like in Figure 4.3). From this information provided by the users, the system builds the user profiles. These user profiles obtained from the provided preferences and the resources previously inserted, constituted our training data set.

---

Then, we added 100 new research resources that conform the test data set. The system filtered these 100 resources and it recommended them to the suitable users. To obtain data to compare, these 100 new research resources also were recommended using the advices of the library staff. On the other hand, when the system recommended these 100 resource, it requested the user rates such resources. We registered the ratings provided for the users about the recommended resources to compare with the predictions generated by our system.

### 4.3.2. Assessing the capacity of recommendations

In the scope of recommender systems, precision, recall and F1 (definitions 2.1, 2.2, 2.3 in Chapter 2) are widely used measures to evaluate whether a recommender system properly recommends items that the user will consider relevant [153].

#### Results of online experiments

In this section we show the results obtained with the online experiments. We used the online experiment data set outlined in previous subsection. By comparing the recommendations generated by the system with the recommendations provided by the library staff, we obtained the experimental confusion matrix shown in Table 4.1 and the contingency table shown in Table 4.2, in which the items are classified both as relevant or irrelevant and recommended to the user or not recommended. From the confusion matrix we can see that the system made 2807 correct predictions and 193 incorrect predictions, so that the error rate is 6.43% and the overall accuracy rate is 93.57%. For more detail, in Table 4.2 we can see the results obtained for each user. For example, for the user 1, the system selected 7 resources as relevant. However, from the information provided by the library staff, we could see that the system didn't

---

select 3 resources that library staff considered relevant for the user 1, and it selected 2 irrelevant resource for user 1. From this contingency table (Table 4.2), we obtained the corresponding precision, recall and F1 which are shown in Table 4.3. With this values the average of precision, recall and F1 metrics are 69.13 %, 66.63 % and 0.6765, respectively, which reveal a good performance of the proposed system, and therefore, a good user satisfaction.

	Recommended	Not recommended
Relevant	200	102
Irrelevant	91	2607

Table 4.1: Confusion matrix.

User	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Nrr	7	9	6	7	6	8	9	5	8	7	5	6	9	6	5
Nrn	3	5	3	4	3	4	4	3	5	3	2	3	5	3	3
Nir	2	3	2	5	2	3	4	2	4	4	3	2	4	4	4
User	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Nrr	8	9	6	4	7	6	7	7	6	5	5	6	8	6	7
Nrn	6	4	4	2	4	2	4	4	2	3	2	2	4	3	3
Nir	3	3	3	1	3	3	2	3	3	2	2	3	5	3	4

Table 4.2: Experimental contingency table.

User	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Precision	0.78	0.75	0.75	0.58	0.75	0.73	0.69	0.71	0.67	0.64	0.63	0.75	0.69	0.60	0.56
Recall	0.70	0.64	0.67	0.64	0.67	0.67	0.69	0.63	0.62	0.70	0.71	0.67	0.64	0.67	0.63
F1	0.74	0.69	0.71	0.61	0.71	0.70	0.69	0.67	0.64	0.67	0.67	0.71	0.67	0.63	0.59
User	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Precision	0.73	0.75	0.67	0.80	0.70	0.67	0.78	0.70	0.67	0.71	0.71	0.67	0.62	0.67	0.64
Recall	0.57	0.69	0.60	0.67	0.64	0.75	0.64	0.64	0.75	0.63	0.71	0.75	0.67	0.67	0.70
F1	0.64	0.72	0.63	0.73	0.67	0.71	0.70	0.67	0.71	0.67	0.71	0.71	0.64	0.67	0.67

Table 4.3: Precision, recall and F1 values for all the users.

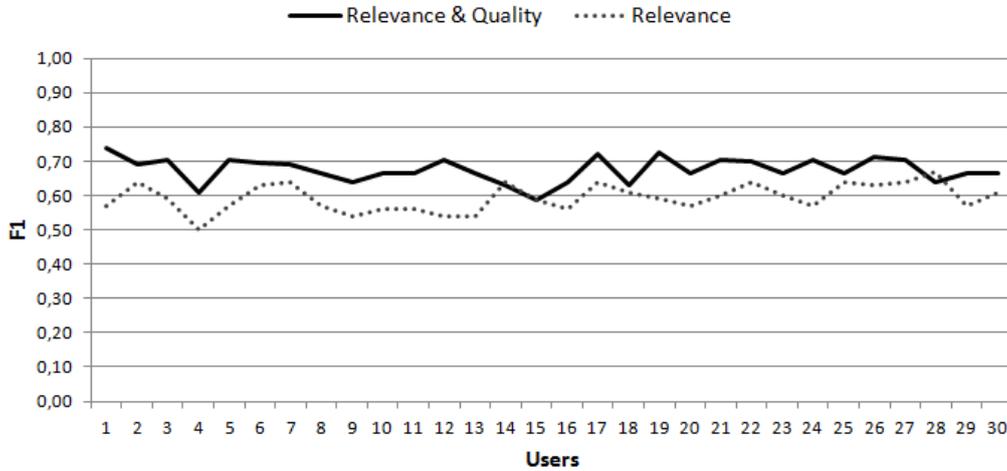


Figure 4.4: F1 values for all the users.

### A comparative study

In order to obtain data to compare the new approach with some previous approaches, we performed a new study by analyzing the results obtained without considering the resources quality. We use the same data set and the same experimental design outlined in previous subsection but applied over the system proposed in [130]. In this case, we obtained a F1 measure of 0.5939, i.e., a smaller value than the obtained with our new approach. Therefore, by considering the resources quality the system performance is better than whether we consider only the relevance. Comparative results of both approaches are graphically displayed in Figure 4.4.

#### 4.3.3. Assessing the capacity of ratings predictions

To complete our experimental study, we wish to measure the accuracy of our system to predict the ratings a user would give to a resource. We use the previously defined measure, **Mean Absolute Error (MAE)** (definition 2.4) in Chapter 2, a commonly used accuracy metric which considers the average absolute deviation between a predicted rating and the user’s true rating [65, 153].

---

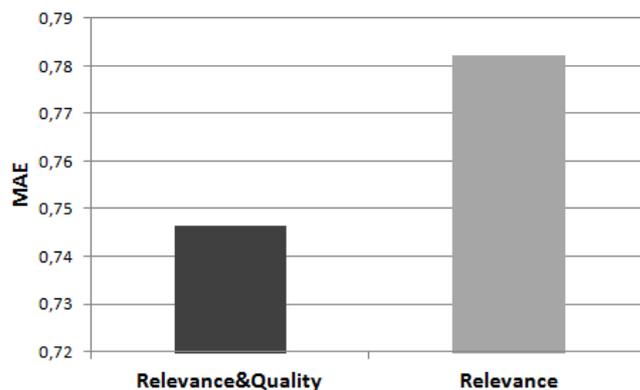


Figure 4.5: Comparison of MAE.

As we have said, during the online study we registered the ratings provided for the users about the recommended resources to compare with the predictions generated by our system, and to calculate the MAE. Taking into account the average MAE for all the users, we obtained a final MAE of 0.7565.

We also have studied the approach proposed in [130], that is, without considering the resources quality. In order to compare the results predicting the ratings, we also calculate the MAE for this approach. In this case we obtained a MAE of 0.7823.

As we can see in the Figure 4.5, the predictions obtained by using the quality of resources are better than the predictions obtained only with the relevance. Specifically we achieved an improvement of 4.80%. That is, the predictions generated with the new system are more close to the users' preferences.

## 4.4. Discussion

In a UDL the selective dissemination of information about research resources is a service particularly important. The UDL staff and researchers need tools to assist them in their processes of information discovering because of the

large amount of information available on these systems. Recommender systems have been successfully applied in academic environments to help users in their access processes to relevant information. But these proposals don't take into account the quality of the resources. Now we face the recommendations generation process about research resources as a task with two distinct elements: On the one hand, finding research resources that are relevant to the users and on the other hand, finding valid research resources from the standpoint of the quality of items.

So, in this chapter we have presented a hybrid fuzzy linguistic recommender system based on quality of the items and we apply it in a UDL to help the users to access relevant research resources. The system measures the item quality and it takes into account this measure like a new factor to be considered in the recommendation process. Thus, the system incorporates a module which performs a re-ranking process which takes into account the estimated relevance of an item along with the item quality. Besides, the system improves the feedback process using satisfaction degrees. We have performed online studies with the proposed system and the experimental results show us significant improvements over previous proposals.

Analyzing our system, we could conclude that its main limitation is the need for interaction with UDL staff to establish the internal representations for the research resources. Therefore, we consider that that system could be improved adding new features, we believe that a promising direction is to study automatic techniques to establish the representation resources. Moreover, we want to explore new improvements of the recommendation approach, exploring new methodologies for the generation of recommendations, as for example, bibliometric tools to enrich the information on the researchers and research resour-

---

ces. In this sense, we will study to include new measures aiming at evaluating other aspects than accuracy of recommendation approaches, such as novelty, coverage, trust, serendipity, diversity, utility or other aspects.

---

## Chapter 5

# REFORE: A recommender system for researchers based on bibliometrics

In the previous chapter we have presented an information resources recommender system to disseminate information between researchers in an university digital library based on quality. As it was pointed in the Section 4.4 the automation of the process of the resources representation and the use of bibliometrics measures to help the generation of recommendations could be used as interesting improvements in the system. Hence, the system presented in this Chapter is based on this idea.

In this Chapter we propose the design and implementation of the system called REFORE<sup>1</sup>, a quality based fuzzy linguistic REcommender system FOR REsearchers. We propose the use of some bibliometrics measures as the way of quantify the quality of both items and users without the interaction of experts. The system takes into account the measured quality as the main factor for the re-ranking of the top-N recommendations list in order to point researchers to the latest and the best papers in their domain. To prove the accuracy improvement, we conduct a study involving different recommendation approaches,

---

<sup>1</sup> <http://sci2s.ugr.es/sapluweb/refore>

aiming at measuring their performance. The aim of the system is to aid researchers in their process of personalized information access over resources in their research areas. The system has been designed integrating content-based and collaborative approach together with a multi-granular fuzzy linguistic modeling.

The chapter is structured as follows. In Section 5.1 an introduction explaining the purpose of the system is presented. Next in Section 5.2 we show the design of the system with all its phases. Section 5.3 presents the development process where we will explain the implementation details and a description of the user interface. After that, Section 5.4 presents the evaluation of the system and the experimental results. Finally, a discussion of the system is pointed out in Section 5.5.

## 5.1. Introduction

Research is a key task in today's society. Science is going through difficult times with the actual crisis facing significant budget cuts in modern economies [123]. However research has a direct impact on society, countries that support research could achieve higher GDP [41], e.g 73% of the papers cited by U.S. industry patents are public science, authored at academic, governmental, and other public institutions [124]. Therefore, the use of scientific knowledge by setting up a sustainable industry/science cooperative environment positively affects innovation performance [113].

Nowadays, where the amount of information available is exponentially growing, the information overload represent a real challenge [48] which spreads over the

---

academic world [130, 160]. The spectacular grow of sources providing new information introduces noise in our way of finding relevant information for researching, but what certain users consider noise could be relevant for others. For example we can not be interested in a particular sub gender of publications but other person can be very interested on them, and both belongs to the same area of research. This fact can make users let through suitable information thinking that is not relevant [119]. In the academic world, research is a field of key importance in society, where the knowledge on one single area is vast and quite specific. At present, tools such as Web of Science (WOS) [5], Scopus [4], Sciencedirect [3], IEEEExplore [2] or Google Scholar [1], support the research in fields where the volume of publications is vast. However, the ever increasing number of resources in a simple area might make the information consumers misunderstand the relevance of certain research resources, at the risk of missing important information.

The number of different journals in Web of Knowledge is more than 12.000 (120.000 if we speak about conference proceedings) [5]. A researcher is typically focused in more than one category, which might include up to 700 journals potentially harboring valuable information, e.g. a combination of relevant sub-categories of Computer Science, Engineer and Maths. To stay in the loop of all new papers being published in all the new journals could be troublesome.

The research process has five elements [167], which are shown in the Figure 5.1 where we can highlight two phases, *situation* or ideas and *research topic*. Without a proper work of keeping ourselves up to date on new trends in our main topics and other topics of our interest, as well as the ones related with our work would be impossible to develop them in a proper way. Nowadays we have a wide set of tools to stay aware of the latest trends, such as the above

---



Figure 5.1: The research process

mentioned scientific repositories or tools like SciMAT to assess the impact of a topic and its relation to the rest [35].

In this sense, it is essential to have tools that allow us to meet this objective: to access to updated and personalized information according to our interests. When a researcher tries to obtain useful information related to his/her research through a searching tool, the retrieved results might be irrelevant and contain unnecessary information even after applying the different embedded filters available. In the Figure 5.2 we try to look for information about *decision making* with the tool ScienceDirect. The results obtained before filtering the information are very non-specific, showing us results from different areas of knowledge that share the search term. To disambiguate the results showed, the use of the filters provides results that are far away of a personalization. Hence, users need easier access to the large amount of resources that are available hidden among the rest [119].

In the previous Chapter we presented a quality based recommender system to disseminate information in an University Digital Library (UDL) where we combined the quality of an item with the user preferences to predict which ones

The screenshot shows the ScienceDirect search interface. At the top, the search term 'decision making' is entered in the search bar. The page displays 'Search results: 688,643 results found.' and includes options to 'Download PDFs' and 'Export'. On the left, there are 'Refine filters' for Year, Publication title, Topic, and Content type. The main area lists several search results, each with a checkbox, title, journal information, authors, and options for Abstract, Research highlights, and PDF. The results include articles from journals like *Neuroeconomics*, *Organizational Behavior and Human Decision Processes*, *Neuroscience*, *Fuzzy Sets and Systems*, *International Journal of Approximate Reasoning*, and *Journal of Vocational Behavior*.

Figure 5.2: Results obtained looking for articles about the topic “decision making” in ScienceDirect

are relevant for the user generating more useful and accurate recommendations [160]. Capitalizing on the improvement we reached with our system in the scope of UDL to tackle the information overload issue, we want to expand the scope to the *much larger research domain*. The heterogeneity of information sources from elements coming from a much larger set of database is going to be a bigger challenge compared with the work done for the UDL.

Hence, a first step to expand the recommendations in research based on quality is to change not the scope but the database. Instead of using a UDL we are going to use the papers indexed by the digital library *WOS*, which could be considered as the most important bibliographic database in a UDL. A second step, is to change the old concept of quality applied in [160] and how to evaluate it. With that, we will test a recommender system for researchers and the use of a way of measure the items' quality to increase the accuracy of the recommendations and to deal with the cold start problem. The use of a hybrid recommendation scheme proved positive in the previous chapter combining two different approaches. For this reason, we propose a combination of both. On the one hand, *content-based* where we are going to deal with the quality of items and on the other hand, the quality of authors according to the *collaborative* approach. That is, we are going to compute the relevance of an item and of a user to do a re-ranking of the recommendations. As test users we are going to engage with some members of the departments of Computer Science and Artificial Intelligence, and Civil Engineer at the University of Granada and Computer Science from TU Delft.

In this Chapter, we present a new recommender system which incorporates methods, algorithms and filters for all the steps in the recommendation process focused on the re-ranking stage. REFORE allows the user to be up to date

---

regarding all articles that might be relevant for him related to the topics the user manifested interest in a particular moment in a real time window. In addition to the articles that are identified to be of interest for the user, a set of high-quality articles with certain overlapping with the researcher's topic are also provided to open up new possibilities and enrich therefore the on-going research. Furthermore, the main novelties of the system are listed below:

- The system implements a *hybrid recommendation strategy* based on a switching hybrid approach [26], which combine a content-based recommendation approach and a collaborative one to share the user individual experience and social wisdom [152] and to present the best last papers in each area for each user.
  - The system implements a two phases *feedback process*. They can say if a paper is relevant or not, that means evaluate the recommendation, and then when they have read the paper they can evaluate their quality giving it different relevance for the collaboration step.
  - The resources recommended in our system are now the *last research papers* from one of the most important international science database, WOS by Thomson Reuters, where we can find the best journal and conference essentials for the daily work of a researcher. The items recommended fulfill the necessities of the users since the quality and novelty of the items are guaranteed by the system.
  - The system incorporates a *re-ranking* process which takes into account the estimated relevance of an item along with the item quality as well as the users' quality to re-order the list of possible items to be recommended. This is done, taking into account not only these factors but also others to ensure the items are interesting for the researcher but also with a small
-

newfangled percentage allowing to see the different application of one singular topic.

- The way of measure quality in previous proposals [28, 32, 91, 92, 160] implies users interaction and is based of the feedback given by them. So, we propose a new way to evaluate the quality of research resources and researchers based on the different rankings provides in the international community by experts. In our case we use the Journal Citation Report(JCR) provided by Thomson Reuters<sup>2</sup> for the items, and also the h-index [97] for the quality of the users given that the system is developed for researcher.

This system improves the generated recommendations, by including more quality papers and accurate recommendations, increasing its information discovering properties in the recommendations and maintaining update the users with the newest papers of each topic being the most relevant for the users.

## 5.2. REFORE architecture

In the introduction we have described the problem we are facing with the design and implementation of this system. In this section we face the architecture of the system as well as the recommendations generation process about research papers. This is done, taking into account the papers' quality and authors' quality that will be use in the re-ranking phase as well as some filter to provide the correct paper for the correct researcher together with the feedback phase. We propose a new way of estimating quality that will be explained later.

REFORE is a new platform which combines a hybrid recommender system

---

<sup>2</sup> <http://thomsonreuters.com/journal-citation-reports/>

---

which takes into account users' and items' quality when it comes to the re-ranking stage with a Web page so that users are able to manage their information and recommendations. The system delivers personalized emails monthly to each user with a selection of the best latest papers for him. It can be used by the research community to facilitate the management of information overload at the routine investigation, the registration and use is for free.

Although this approach was originally developed to deal with UDL, we extended it in REFORE managing bigger databases and focusing more on the relevance of the quality of the items and users when working with a recommender system.

Now, we change our focus to researchers specifically and we move from UDL to an open world where all researchers can use the system based on the international databases of the best and ranked resources. We change the main idea of the system to create awareness of the newer elements amongst users, not only the items that are already stored in the database. For this purpose we set an alert system which send emails each time period with the best items in the system since the last round, keeping all users up to date with the last trends in their interest topics.

The basics steps to build REFORE are shown in Figure 5.3 which represents the structure of the system and are the following:

1. Build an administrative and informative Web for users and administrator to manage the information in an easy way.
  2. Acquire items' database from WOS monthly. We obtained the meta data offered by WOS when you download a paper, to do that we used
-

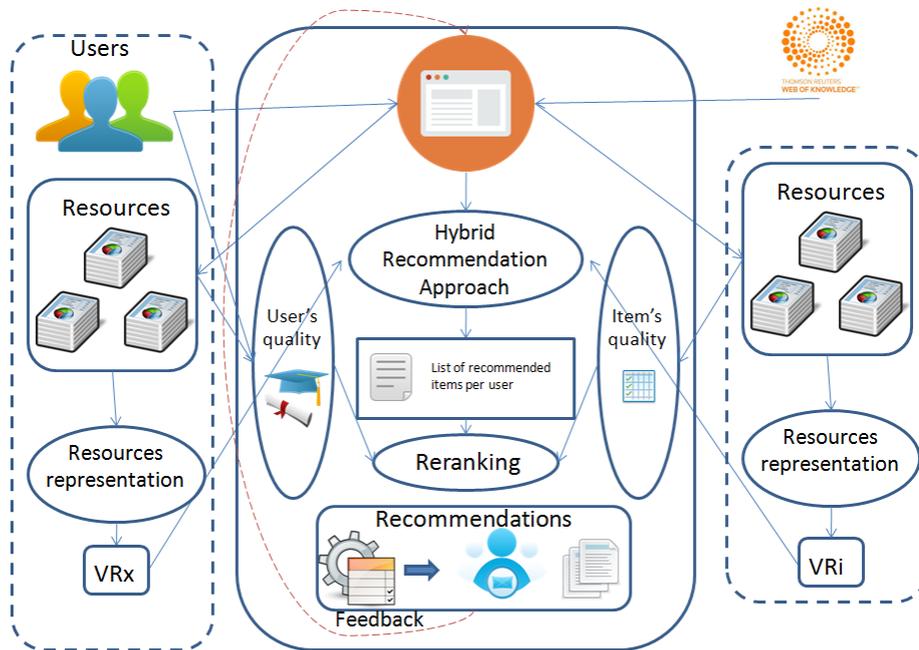


Figure 5.3: Structure of the system

the tool presented in [12]. We can highlight the following data: *Title, abstract, authors, keywords, number of cites, journal, bibliography, type, topic* or information about a journal: *quartil, impact factor, cites, topic*. The system represents internally the items based on the built database.

3. Acquire users' profile. We obtained the profile for users in two steps. On the one hand the system selected all user's papers, considered user's paper as a paper where user  $X$  is author or coauthor of it, and put it in his/her profile. Then select the keywords of these papers as part of the profile with the linguistic label *Normal*. On the other hand the system sent an email to the users asking them to complete their profiles: Users can upload new articles of their own to REFORE Web that have not been published yet or articles from other authors but which topic is similar to the main or the actual interest of a researcher. Also they can add, delete and modify the linguistic label of keywords in their profile, as well as add

new words. The system obtains an internal representation of the users based on their preferred papers and keywords.

4. Build the hybrid recommendation process combining the content-based and collaborative approach.
5. Build the re-ranking process focus on the quality measure established. The system aggregates the estimated relevance of an item and a user and its quality score in a single score as well as different filter to improve the accuracy of recommendations.
6. Send emails to users with their recommendations each month asking for their feedback.

As aforementioned, we work with a multi-granular fuzzy linguistic approach [69, 75] to model the user-system communication in order to allow a higher flexibility in the communication processes of the system. The system uses different label sets ( $S_1, S_2, \dots$ ) to represent the different concepts to be assessed in its filtering activity. These label sets,  $S_i$ , are chosen from those label sets that compose a  $LH$ , i.e.,  $S_i \in LH$ . The number of different label sets that we can use is limited by the number of levels of  $LH$ , and therefore, in many cases the label sets  $S_i$  and  $S_j$  can be associated to a same label set of  $LH$  but with different interpretations, depending on the concept to be modeled. We take into account the following concepts that can be assessed in the system:

- **Importance degree** of a discipline with respect to a resource scope, based on the paper's keywords, which is assessed in  $S_1$ .
  - **Similarity degree** among resources or among users, which is assessed in  $S_2$ .
-

- Predicted **relevance degree** of a resource for a user, which is assessed in  $S_3$ .
- **Satisfaction degree** expressed by a user to evaluate the recommendation of one resource, which is assessed in  $S_4$ .
- **Quality degree** expressed by a user to evaluate a recommended resource, which is assessed in  $S_5$ .

As we saw in the previous Chapter, the selected granularity must be sufficiently low as not to impose an excessive precision in the information you want to express and high enough to get a discrimination of the assessments in a limited number of degrees. Usually, the cardinality used in the linguistic models is an odd value, such as 7 or 9, not exceeding 11 labels [120]. We make an exception to represent if a recommendation is relevant or not for a user, using 2 terms.

Following the linguistic hierarchy shown in Figure 5.4, we use the level 4 (9 labels) to represent the similarity degrees and predicted relevance degrees ( $S_2 = S^9$  and  $S_3 = S^9$ ), the level 3 (5 labels) are used for the importance degrees ( $S_1 = S^5$ ), the level 2 (3 labels) to represent the quality degree given by a user over a paper ( $S_5 = S^3$ ) and for the satisfaction degree we use the level 1 ( $S_4 = S^2$ ). As the importance degrees are extracted automatically from a paper, all of them take the intermediate label of  $S^5$  to facilitate them the characterization of papers. The similarity and relevance degrees are computed automatically by the system, we use the set of 9 labels which presents an adequate granularity level to represent the results. Using this *LH*, the linguistic terms in each level are the following:

- $S^2 = \{a_0 = \text{Null} = N, a_1 = \text{Total} = T\}$ .

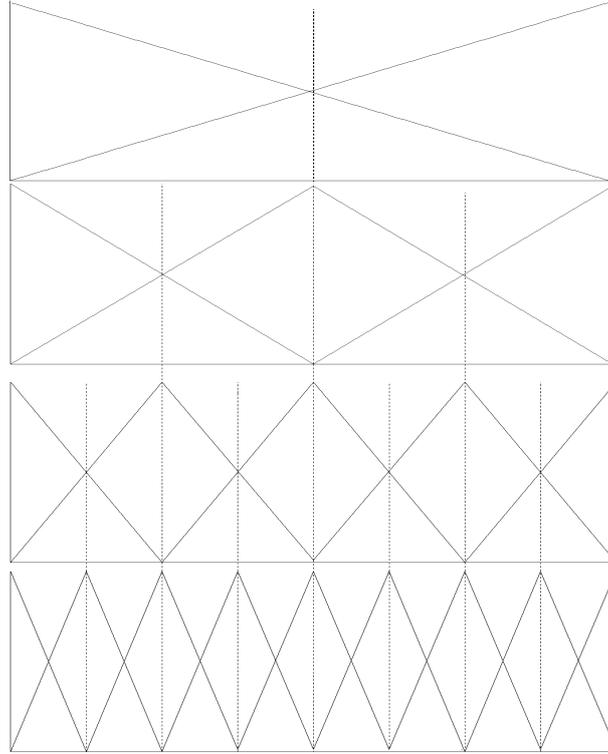


Figure 5.4: Linguistic Hierarchy of 2, 3, 5 and 9 labels

- $S^3 = \{b_0 = \textit{None} = N, b_1 = \textit{Medium} = M, b_2 = \textit{Total} = T\}$
  
- $S^5 = \{c_0 = \textit{Lowest} = LE, c_1 = \textit{Low} = L, c_2 = \textit{Normal} = N, c_3 = \textit{High} = H, c_4 = \textit{Highest} = HE\}$
  
- $S^9 = \{d_0 = \textit{None} = N, d_1 = \textit{Very\_Low} = VL, d_2 = \textit{Low} = L, d_3 = \textit{More\_Less\_Low} = MLL, d_4 = \textit{Medium} = M, d_5 = \textit{More\_Less\_High} = MLH, d_6 = \textit{High} = H, d_7 = \textit{Very\_High} = VH, d_8 = \textit{Total} = T\}$

In the following subsections, we describe the REFORE recommender system. First, the structure of items and users is analyzed in detail. Second, the architecture of REFORE and the description of the recommendation process with the re-ranking steps are described.

### 5.2.1. Resources representation

The considered resources are papers imported from WOS. The journals are selected from the subcategories of the JCR of ISI WOS. In the Table 5.1 we can see the characteristics we use to represent an item, i.e. a paper (where all the characteristics stored match with the name given to the different properties i.e: *Title, Authors, Journal, Year* and *time cited* among others). Additionally, we consider extra characteristics at journal level, like as the Quartile where the journal is indexed in JCR, the impact factor, eigenfactor or characteristics referred to the authors, such as city, email, university, etc.

Paper	Title	Authors	Journal	Journal metadata	DOI	Authors Data	Scope	Year	Time_cited	Type
-------	-------	---------	---------	------------------	-----	--------------	-------	------	------------	------

Table 5.1: Papers structure

Once the system has imported all available information about a resource, an internal representation based on the keywords of the paper itself is created. We use the *vector model* [102] to represent the resource structure and the classification of keywords; i.e., a paper  $i$  is represented as a vector:

$$VR_i = (VR_{i1}, VR_{i2}, \dots, VR_{in}),$$

where each component  $VR_{ij} \in S_1$  is a linguistic assessment of the importance degree of the keywords. Due to the singularity of the keywords in an article, all the keywords are set with the label  $c_4$  of  $S^5$  that corresponds to the highest importance –being that by the own definition of a keyword–. These importance degrees are assigned automatically by REFORE when new resources are imported. In the event where a paper does not have any keywords, the system takes the internal keywords assigned by WOS.

These vectors will experiment modifications once the re-ranking process is run

based on the quality of each them, as well as the final score of each singular recommendation.

### **5.2.2. User profiles representation**

The *profiles* used in REFORE are based on the characteristics of users' items stored. The properties of items are generated based on the information extracted from WOS, that is, papers from proceedings and international journals. Users' profiles are based on their own papers and papers they are interested in, along with keywords and their importance leading the user' interests.

The introduction of the users' preferences is usually a problem due to the effort required to provide it. To reduce this effort and make easier the process of acquiring the user's preferences, REFORE tries to build an automatic profile based on the users' papers. The idea of this first step is just to facilitate users' following steps about indicating their actual preferences based on their papers inasmuch as the preferences of researchers can be different in each time period.

To do that, REFORE automatically tries to identify the resources where the user appears as author or co-author performing a search in WOS *papers* to then import them into the system. The five most important ones according to the quality estimated are then selected. The way of calculating the quality is explained below. After that, from the 5 selected papers of a user, the *keywords* are extracted and flagged as important keywords for this user with the label  $c_2$  of  $S^5$  pending for the user's revision.

The first time users log into REFORE, they are asked to complete / change / enhance their profiles, showing them their papers in a pre-established order.

---

Users can upload more papers to the system by their DOI or entering manually their preferences in the fields available for this purpose. It's possible for them changing the pre-selected 5 papers, which summarizes their current interest, as we can see in Figure 5.5.

The figure shows two side-by-side panels from the REFORE system. The left panel, titled 'Profile's paper', displays a list of 15 papers. Each row includes the paper title, the number of times it has been cited, and a 'Profile for Recommendation Engine (Only 5)' section with 'Yes' and 'No' radio buttons. The right panel, titled 'Add yours or related publications', contains a form for adding new papers. It includes a text input for DOI, a 'Please insert keywords in English' section with a 'Press save button when you finish!' instruction, and fields for 'Title', 'Authors', 'Keywords (English)', and 'Abstract'.

Title or DOI	Time Cited	Profile for Recommendation Engine (Only 5)
Linguistic decision analysis: steps for solving decision problems under linguistic information	322	Yes (selected), No
A fusion approach for managing multi-granularity linguistic term sets in decision making	164	Yes (selected), No
Integrating three representation models in fuzzy multipurpose decision making based on fuzzy preference relations	241	Yes (selected), No
Direct approach processes in group decision making using linguistic OWA operators	194	Yes (selected), No
A model of consensus in group decision making under linguistic assessments	245	Yes (selected), No
Some issues on consistency of fuzzy preference relations	213	No, Yes (selected)
Aggregation operators for linguistic weighted information	179	No, Yes (selected)
Multiperson decision-making based on multiplicative preference relations	174	No, Yes (selected)
A SEQUENTIAL SELECTION PROCESS IN GROUP DECISION-MAKING WITH A LINGUISTIC ASSESSMENT APPROACH	162	No, Yes (selected)
Integrating multiplicative preference relations in a multipurpose decision-making model based on fuzzy preference relations	158	No, Yes (selected)
Combining numerical and linguistic information in group decision making	131	No, Yes (selected)
A consensus model for multiperson decision making with different preference structures	120	No, Yes (selected)
Choice functions and mechanisms for linguistic preference relations	108	No, Yes (selected)
A rational consensus model in group decision making using linguistic assessments	102	No, Yes (selected)

Figure 5.5: Profile's papers

Furthermore, the most important part of users' profile are the keywords that determine the users' preferences at any time. In Figure 5.6 we see how users can set their actual preferences based on labels of  $S_1$  as well as other personal data.

In order to obtain **user preferences**, i.e., **user preference vector**, we represent a user  $i$  as a vector:

$$VU_i = (VU_{i1}, VU_{i2}, \dots, VU_{in}),$$

where each component  $VU_{ij} \in S_1$  is a linguistic assessment that represents the importance degree of keyword  $j$  for the user  $i$ . Firstly, the system builds the vector with the keywords from the user' profile and their labels,  $\kappa_k$ . Secondly the system aggregates these previous keywords and their labels with

Figure 5.6: Profile's papers

the keywords of the user' profile papers, that is  $\kappa_p$ , going through the five papers selected by the users. Hence, these keywords also represent their preferences. The aggregation consists in an union of both domain of keyword where the labels established by the user prevail in the new set when some one is repeated. If the keyword is already in the keyword list, the system maintain the label given by the user specifically to the keyword. Otherwise that means that the keyword is not yet in the vector, therefore it is added with the label  $c_1$ . Hence, all the keywords in  $\kappa_p$  has  $c_1$  label. So that, the user vector is represented as follows:

$$VU_i = Aggregation(K_{ki}, K_{pi}) \begin{cases} VU_{ij} = K_{kij}, & \text{if } \exists K_{kij} \in K_{pij} \\ VU_{ij} = K_{pij}, & \text{otherwise} \end{cases} \quad (5.1)$$

where  $K_{kij}$  is the keyword  $j$  for a user  $i \in \kappa_k$  and  $K_{pij}$  is the keyword  $j$  for a user  $i \in \kappa_p$ .

### 5.2.3. Hybrid recommendation approach

In this phase the system filters the information stored and applies different steps to fit items and user in the delivery. As stated before, we implement a *hybrid recommendation* strategy, which combines a content-based recom-

mentation approach and a collaborative one. According to the classification composed by different strategies given by Burke [26] on how the different techniques are combined, our proposal is based on a *mixed hybrid approach*. Thus, REFORE relies on recommendations from both recommender approaches following some criteria. The system uses the content-based and the collaborative one cooperating both in different percentage. The combination of both occurs after the re-ranking phase.

The process of filtering is based on a matching process developed by similarity measures, such as Euclidean Distance or Cosine Measure [102]. In particular, we use the standard Cosine measure but defined in a linguistic framework:

$$\sigma_l(V_1, V_2) = \Delta\left(g \times \frac{\sum_{k=1}^n (\Delta^{-1}(v_{1k}, \alpha_{v1k}) \times \Delta^{-1}(v_{2k}, \alpha_{v2k}))}{\sqrt{\sum_{k=1}^n (\Delta^{-1}(v_{1k}, \alpha_{v1k}))^2} \times \sqrt{\sum_{k=1}^n (\Delta^{-1}(v_{2k}, \alpha_{v2k}))^2}}\right)$$

with  $\sigma_l(V_1, V_2) \in S_2 \times [-0.5, 0.5]$ , and where  $g$  is the granularity of the term set used to express the relevance degree, i.e.  $S^g$ ,  $n$  is the the number of keywords and  $(v_{ik}, \alpha_{vik})$  is the 2-tuple linguistic value of keyword  $k$  in the vector  $V_i$  representing the resource scope or user interest topics, depending of the used filtering strategy.

In the following subsections, we explain both recommendation strategies.

### Content-Based Recommendations

When a new resource  $i$  is imported to the system and the time window of recommendations starts, the system computes a first content-based list of candidates to recommendations for a researcher  $e$  as follows:

1. Compute the linguistic similarity degree between  $VR_i$  and  $VU_e$ :  $\sigma_l(VR_i, VU_e) \in S_2$ .

2. Assuming that  $S_2 = S^9$ , we consider that a resource  $i$  is relevant for a researcher  $e$  if  $\sigma_l(VR_i, VU_e) > (d_3, 0)$ , i.e., if the linguistic similarity degree is higher than the label one step under the mid linguistic label.

All the relevant resources for a researcher  $e$  are part of the list of candidates with a relevance degree equal to linguistic similarity degree obtained in the first step.

### **Collaborative Recommendations**

Users in the system have set up their profiles with the information extracted from their papers or the ones they are interested in and the set of keywords which captures the preferences for them. When the system is already operating and there are at least one evaluation from other users, that means after the first round, we follow a memory-based algorithm or nearest-neighbor algorithm [38], to detect similar users. This algorithm generates the recommendations according to the items already evaluated of the nearest neighbors. The reason for choosing it, is because this algorithm has proven good performance [64]. In the following steps we describe the process in detail.

Given a researcher  $e$ , the recommendations to be added to the previous list of  $e$  are obtained in the following steps:

1. Identify the set of users  $\aleph_e$  most similar to the user  $e$  that we are estimating in the round  $t$ , where each round is the established period between recommendations. For doing this, we calculate the linguistic similarity degree between the user preference vector of the user ( $VU_e$ ) upon the vectors of all other users  $VU_y$ ,  $y = 1..n$  where  $n$  is the number of users, that is, we calculate  $\sigma_l(V_e, V_y) \in S_2$ . As  $S_2 = S^9$ , we consider that the
-

user  $y$  is near neighbor to  $e$  if  $\sigma_l(VU_e, VU_y) > (d_4, 0)$ , i.e., if the linguistic similarity degree is higher than the mid linguistic label.

2. Look for the resources stored in the system that were previously relevant to the near neighbors of  $e$  at most, two round before  $(t_{-1}, t_{-2})$ . That is, to not to break the novelty property of the recommended items i.e., the set of resources  $\kappa_y = \{1, \dots, k\}$  such that there is a linguistic satisfaction assessment  $y(j) \in S_4$ ,  $y \in \aleph_e$ ,  $j \in \kappa_y$ , and  $y(j) \geq (a_1, 0)$ .
3. Due to the singularity of the problem we are tackling, researchers can have different lines of investigation. In order to avoid the problem of recommended items which are not valid for the user even if they are relevant from near neighbors, the system calculates the similarity for all the items of the last two round for all the near neighbors as described below:
  - a) Compute the linguistic similarity degree between the relevant resources obtained in the step 2,  $VR_{ij}$  and  $VU_e$ :  $\sigma_l(VR_{ij}, VU_e) \in S_2$ , where  $j \in \aleph_e$  and  $i \in (t_{-1}, t_{-2})$ .
  - b) Assuming that  $S_2 = S^9$ , we consider that a resource  $i$  is relevant for a researcher  $e$  if  $\sigma_l(VR_i, VU_e) > (d_3, 0)$ , i.e., if the linguistic similarity degree is higher than the label one step under the mid linguistic label.

The set of relevant resources for a researcher  $e$  is part of the list of candidates with a relevance degree of  $\sigma_l(VU_e, VU_y)$ .

---

#### **5.2.4. Computing the quality of research resources and users**

As aforementioned, one of the most important components of the problem we are facing in this Chapter is the novelty of the items. The resources we are dealing with in this problem are specific enough to apply the set of different measures existing in the literature for the academic world to estimate the quality of an item. So we propose to split the quality measure in two elements: papers and authors.

The former can be measure by the publishing entity, using the Impact Factor (IF) of the journal as well as the quartile of JCR index they are ranked in. Furthermore, the feedback given by users about papers is also taken into account to estimate the quality of an item. The final measure is the aggregation of both measures. However, as a result of the novelty characteristic of the recommended items and due to constraint we imposed of two rounds as maximum time elapsed between possible recommendable items, the metric which contributes the most to the quality estimation of an item is the IF.

Meanwhile, the latter can be measured by the H-index [8] of authors which quantifies the importance of each author within the research community.

The main reason for adopting this approach revolves around the fact that both the information of the quality of the journal and the impact factor where the paper was published are public and stored in REFORE. The users' H-Index is maintained up to date due to the users' profile are updated each round updating the time their articles have been cited.

---

The problem of estimating the quality of a **resource** based on the IF of a journal is the explained in the lines below:

1. Suppose that an item belong to the best journal in one field. i.e. *Medicine*.
2. This item share some keywords with one user and fulfill the similarity degree i.e. *Decision Making*.
3. The item under analysis deals with decision making problems but in a field where the context of the same keywords is different.
4. The item score is increased due to the quality of the journal and later recommended to the user.

In order to overcome this problem, the quality of each item  $i$  is estimated individually for each user  $j$ .

$$q(i, j) = \left(\frac{1}{Q_i} + IF_i\right) * G_j \quad (5.2)$$

where, we normalize the  $q(i, j)$  to the range  $[0, 1]$ ,  $Q_i$  is the quartile where the journal  $i$  is ranked.  $IF_i$  is its impact factor of the journal  $i$  and  $G_j$  is a constant which measures how appropriate a journal for a user  $j$  is, adopting  $G_j$  the following values:

$$G_j = \begin{cases} 1, & \text{if } \exists j \in Js_i \\ 0.75, & \text{if } \exists T(j) \in Ts_i \\ 0.5, & \text{if } \exists j \in Jns_i \\ 0.25, & \text{if } \exists T(j) \in Tns_i \\ 0.1, & \text{otherwise} \end{cases} \quad (5.3)$$

where  $J_{s_i}$  is the set of journals where the selected papers of the user  $i$  are published,  $T(j)$  is the function which extracts the topics of a journal  $j$ ,  $T_{s_i}$  is the set of topics from selected journals of the user  $i$ ,  $J_{ns_i}$  are the journals non selected but part of the profile of the user  $i$  and  $T_{ns_i}$  is the set of topics from the non selected journal of the user  $i$ .

The quality of an **author** despite is independent from the rest of qualities, is weighted with the qualities of similar authors to the user we are calculating. Before of that, they are normalized to the range  $[0, 1]$ . Therefore, the set of qualities  $\Phi_a$  consist on the weighted qualities of the similar authors to  $j$ . So, the quality of an author  $i$  regarding to the user  $j$  is:

$$q_a(i, j) = H(i) / \max(Q_a(j)) \quad (5.4)$$

where  $H(i)$  is the H-index of the author  $i$  and  $Q_a(j)$  is the set with the H-index values for the authors that are near neighbors to  $j$  and  $\max()$  is a function to obtain the maximum element of a set.

In spite of the before mentioned procedure, REFORE does not recommend authors, just resources. The quality of the authors is used to measure how good a resource for a user is, when we are dealing with the collaborative approach.

In order to measure the quality of a resource, REFORE also leverages the feedback provided by users once they have read the paper. The rating of a resource  $e$  given by a user  $i$  is used as the quality of the resource for the system in the next rounds. The quality  $y$  is expressed in  $S_5$ , assuming that  $S_5 = S^3$ , we consider that a resource  $i$  is rated with the certain quality score  $y$  for the researcher's profile  $e$ .

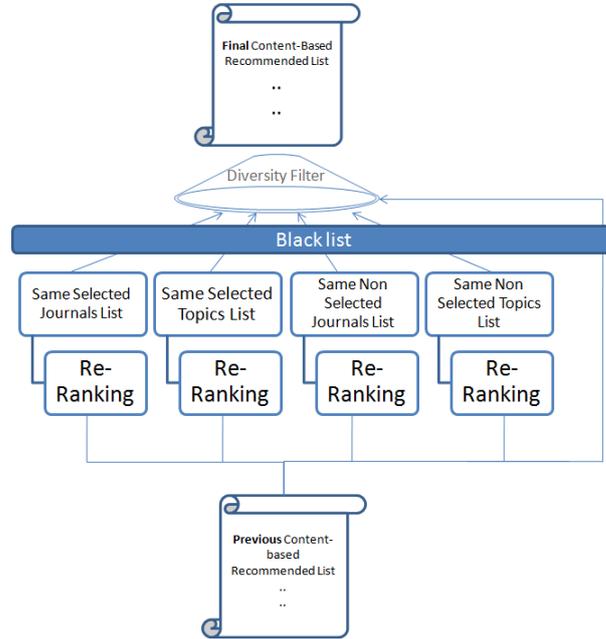


Figure 5.7: Re-Ranking on Content-based previous list

### 5.2.5. Re-ranking

Once the previous lists of resources have been generated we proceed with the re-ranking process. The re-ranking phase in both approaches is independent from each other and consists of the reorganization of the previous lists aggregating the linguistic similarities with the scores of quality as we indicate below.

On the one hand we have the re-ranking of the *content-based* previous list whose process diagram is showed in Figure 5.7. The previous lists of resources  $\aleph_i$  that are considered relevant for a user  $e$  with the estimated relevance degree of each resource  $i$  for  $e$ ,  $i(e) \in S_3$ , where  $S_3 = S^9$  (see section 3.5) are used as input of the re-ranking process.

The computation of the quality for the resources mentioned above is also used to support the classification of each resource  $i$  in different groups based on the

selected papers by the users in their profiles. Hence, we split the previous list into four smaller lists:

1. *Same Selected Journals List.* Papers from the same journals of the group of the selected one for the user  $e$ .
2. *Same Selected Topics List.* Papers from the journals with the same topic of the group of the selected one for the user  $e$ .
3. *Same Non Selected Journals List.* Papers from the rest of the journals for the papers of the group of the non selected one for the user  $e$ .
4. *Same Non Selected Topics List.* Papers from the rest of the journals with the same topic of the group of the non selected one for the user  $e$ .

The aggregation of the quality scores and the relevance degree for each one leave us four candidates lists for the content-based. To do this, first we need to translate the research resource quality score into the values range in which the estimated relevance degree is defined, i.e.,  $S_3$ . Then, we obtain following translated quality score,  $tq(i)$  [160], as follows:

$$tq(i) = q(i) \times g \quad (5.5)$$

where  $g$  is the granularity of  $S_3$ , assuming  $S_3 = S^9$  then  $g = 8$ .

In the next step, we use a multiplicative aggregation in which the estimated relevance is multiplied by the translated quality score, as follows:

$$FinalRelevance(i) = \Delta\left(\frac{\Delta^{-1}(i(e) \times tq(i))}{g}\right) \quad (5.6)$$

where  $\Delta$  and  $\Delta^{-1}$  are the transformation functions between 2-tuples values and symbolic values defined in section 3.5. To obtain the final relevance degree

in  $S_3$ , we map the final relevance value to the interval  $[0, g]$ . The foregoing operation lets us four ordered lists of items with different characteristics.

On the other hand the re-ranking of the *collaborative* previous lists takes place as follows. The previous lists of resources from similar authors  $\mathfrak{S}_i$  that are considered relevant for a user  $e$  with the estimated relevance degree of each resource  $i$  for  $e$ ,  $i(e) \in S_3$ , where  $S_3 = S^9$  (see section 4.2.3) are used as input of the re-ranking process.

The computation of the quality for the resources mentioned above is conditioned by two factors, quality of near neighboring authors and rating of resources relevant for those authors. Therefore, before aggregating quality scores and relevance degree as in the content-based approach, the final quality score must be expressed as an unique one. To do that, we translate the author quality score to values in range in which the estimated degree is defined, i.e.,  $S_3$ . We obtain the translated quality score  $tq(i)$  as before. As the linguistic level of the quality of the author is lower than the relevance of an item, before doing a multiplicative aggregation of all the values we change to the granularity of  $S_3$ .

Then, the multiplicative aggregation in which the estimated relevance is multiplied by the mapped quality score and by the translated author quality, is calculated as follows:

$$FinalRelevance(i) = \Delta\left(\frac{\Delta^{-1}(i(e) \times tq(i)) \times \Delta^{-1}(i_a(e))}{g}\right) \quad (5.7)$$

where  $\Delta$  and  $\Delta^{-1}$  are the transformation functions between 2-tuples values and symbolic values defined in section 3.5. To obtain the final relevance degree in  $S_3$ , we translate the final relevance value to the interval  $[0, g]$ , being  $g$  the

---

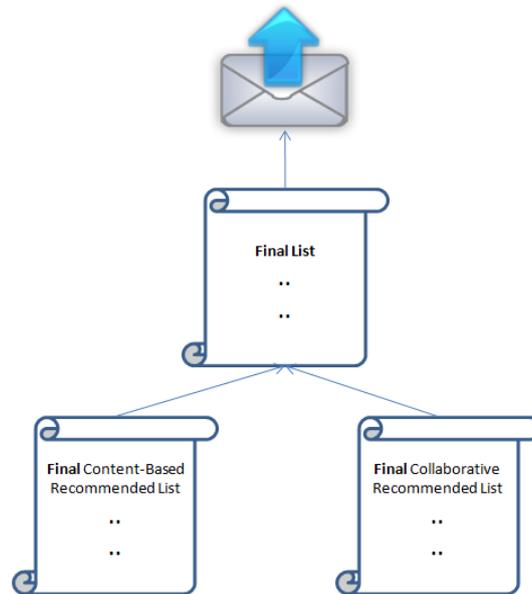


Figure 5.8: Combination of both approach in one final list

granularity of  $S_3$ . The foregoing operation let us a relevance ordered list of items that where previously relevant for other users.

Before obtaining the final list or applying the diversity filter, a last step which affects the final relevance degree is applied. The black list of the combination of keywords of each user where the feedback provided was negative, is compared with the keywords of each list. If the combination is found on one paper, the relevance degree is penalized to half value.

### Diversity filter

In Figure 5.8, we can see that to obtain the final list of recommendations, we previously require the definitive one of each approach, both content-based and collaborative. The first one is composed based on the preferences of the system in the matter of similarity, diversity and quality. In REFORE, the percentage which each list provide to the final list was establish as follow:

1. *Same Selected Journals List*: 40%.

2. *Same Selected Topics List*: 40 %.
3. *Same Non Selected Journals List*: 20 %.
4. *Same Non Selected Topics List*: [10 %]. This last 10 % is only used in case there are not enough relevant resources between the other lists.

With this percentage we intent to maintain the author up to date with the best and more important papers for him but we expose him to papers related with his topic in other areas.

### **Mixed hybrid combination**

The final aggregation of the both lists, content-based and collaborative is made with the following percentage:

1. *Content-based*: 80 %.
2. *Collaborative*: 20 %.

As aforementioned, the novelty property prevails over the rest, that is, due to the peculiarity of the system, the most important resources are the new ones. Hence, we give much greater importance to the content-based approach.

### **5.2.6. Feedback phase**

In this phase the recommender system calculates and updates the ratings of the recommended resources for the users. The system communicates the recommendations by email and registers the feedback of each user as explained below:

---

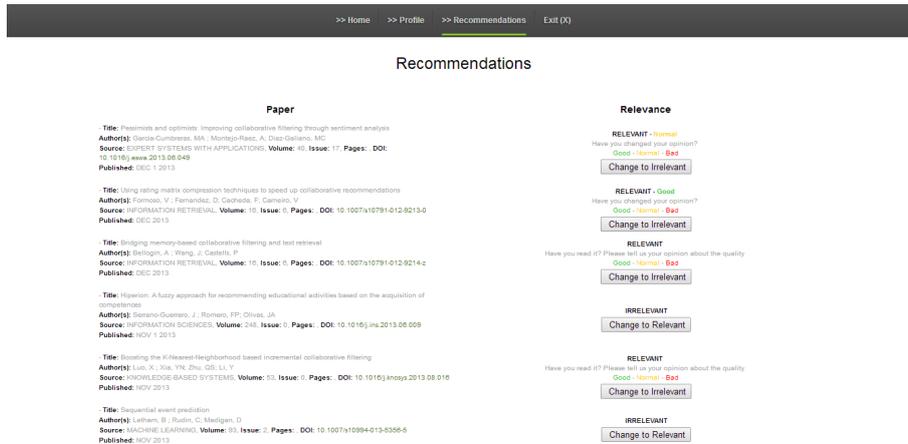


Figure 5.9: Recommendations for a user

1. Interaction with the email content. The system recommends a resource  $r$  to the user  $u$ . In this email, the user  $u$  is asked to tell the system about the resource relevance by clicking on *relevant* or *irrelevant* or by clicking on the link to the resource  $r$  –considered in this case as *relevant*–. If the user does not select any of these options before the round is finished, the recommendation is considered irrelevant.
2. In the REFORE Web page, in their profiles users can mark as relevant or irrelevant the items recommended in the last round, as well as the previous one. The user communicates his/her linguistic evaluation assessment to the system,  $rc_y \in S_4$ .
3. In the REFORE Web page if an item was set as relevant, the user has the possibility of evaluating the quality of the paper as *Good*, *Normal* or *Bad* as is shown in the Figure 5.9.

These evaluations are registered in the system for future recommendations. The idea of the collaborative approach is not only to improve the generated recommendations taking into account the users' ratings, but also to palliate the possible side effect of the use of the diversity filter, where one good paper is left

out of the final recommendations. That is why the interaction of users are very important for both approaches. First, the ratings provided by the user are taken to improve the quality of the next recommendations for himself. Second, the collaborative approach needs the users' ratings to generate recommendations.

## 5.3. System development

### 5.3.1. Implementation

Given the great potential that the system could provide to the research community, we decided to implemented it.

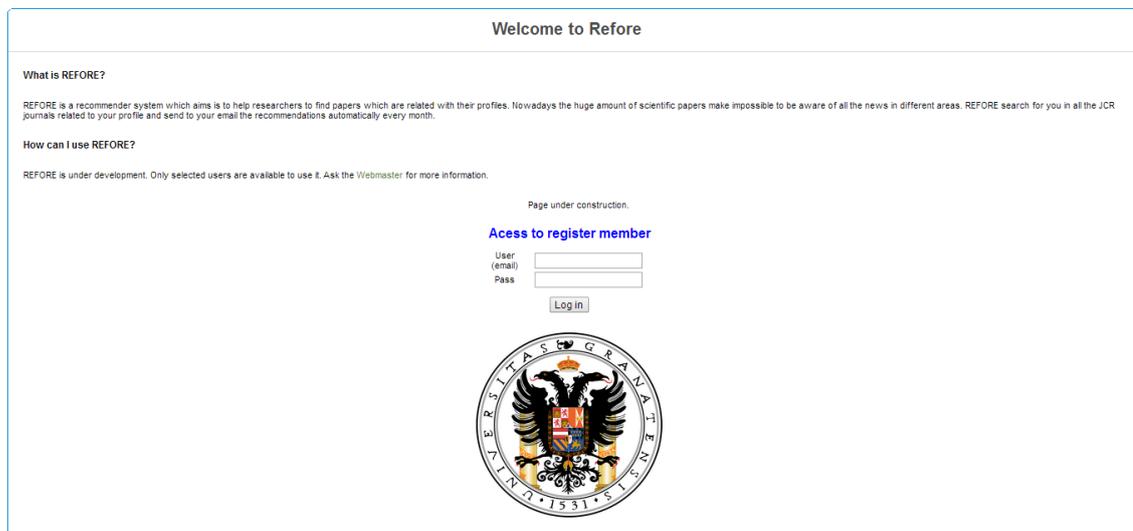
Since the beginning we considered that REFORE works from the point of view of a Web application through a client-server architecture, so that it can be accessed from any place with a simple browser. That implies to add identification modules to the system.

We have implemented the first version of the system using an internal server of the department of Computer Science and Artificial Intelligence at University of Granada. The operative system running in the server is Debian Linux and the application server is Apache. To the storage of the data, the database management system used is MySQL allocated on the same server. The programming language used is PHP and Javascript.

### 5.3.2. Application description

The idea of this subsection is to offer a general view of the application from a user interface point of view. The actual changes, that we are working on, are not going to affect the interface at an early stage in the front-end. We are working on improvements on the back-end of the system focus on the performance and

---



Welcome to Refore

**What is REFORE?**

REFORE is a recommender system which aims is to help researchers to find papers which are related with their profiles. Nowadays the huge amount of scientific papers make impossible to be aware of all the news in different areas. REFORE search for you in all the JCR journals related to your profile and send to your email the recommendations automatically every month.

**How can I use REFORE?**

REFORE is under development. Only selected users are available to use it. Ask the Webmaster for more information.

Page under construction.

[Access to register member](#)

User (email)

Pass



Figure 5.10: Identification screen REFORE.

on applying new techniques of generating recommendations. We can access to the system by the URL: <http://sci2s.ugr.es/sapluweb/refore/> where the log in screen is shown (see Figure 5.10). There is pointed here that to register on the system you have to contact the administrator before, in order to control the number of users that are using the system and the possible interest in the areas they belong. Once we are register and we have our user and password provided by the administrator, we can log in into the system.

The screen we will see once we are log into REFORE will show us the main menu (see Figure 5.11) where we can enter to our profile or to check our recommendations.

If we access to our profile we will see, on the one hand, our personal data and our interest keywords (see Figure 5.12) with the possibility of edit them, and on the other hand, our selected and non selected profile papers and the possibility of add, remove or edit the existing ones (see Figure 5.13).

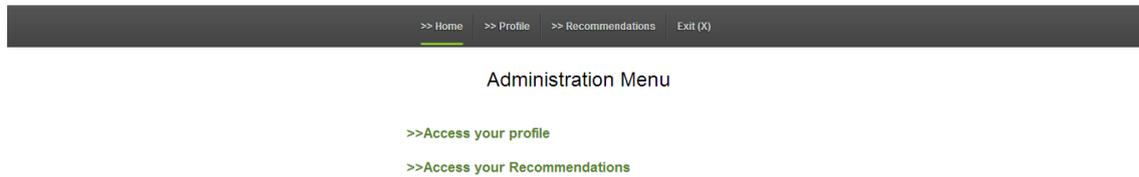


Figure 5.11: Main user menu

The screenshot displays the "Edit User" interface. At the top, there is a dark navigation bar with links: >> Home, >> Profile, >> Recommendations, and Exit (X). The main content area is divided into two sections: "Personal Data" and "Keywords".

**Personal Data:**

- Id Name:** A text input field containing "Enrique".
- Surname:** A text input field containing "Hemera Viedma".
- email:** A text input field containing "viedma@decsai.ugr.es".
- Update Personal Data:** A button located below the email field.

**Keywords:**

- keywords:** A list of 18 keywords, each with a corresponding input field: aggregation operators, bibliometrics, computing with words, data mining, Decision making, digital imaging, digital library, fuzzy integrals, fuzzy sets, index h, information filtering, information retrieval, linguistic modelling, machine learning, mathematical, medicine, quality evaluation, recommender system, and science management.
- Actual Interest:** A column of 18 dropdown menus, each showing "Current value(High)" or "Current value(Lowest)".
- Update Keywords:** A button located at the bottom right of the keywords section.

Figure 5.12: Personal data and user keywords.

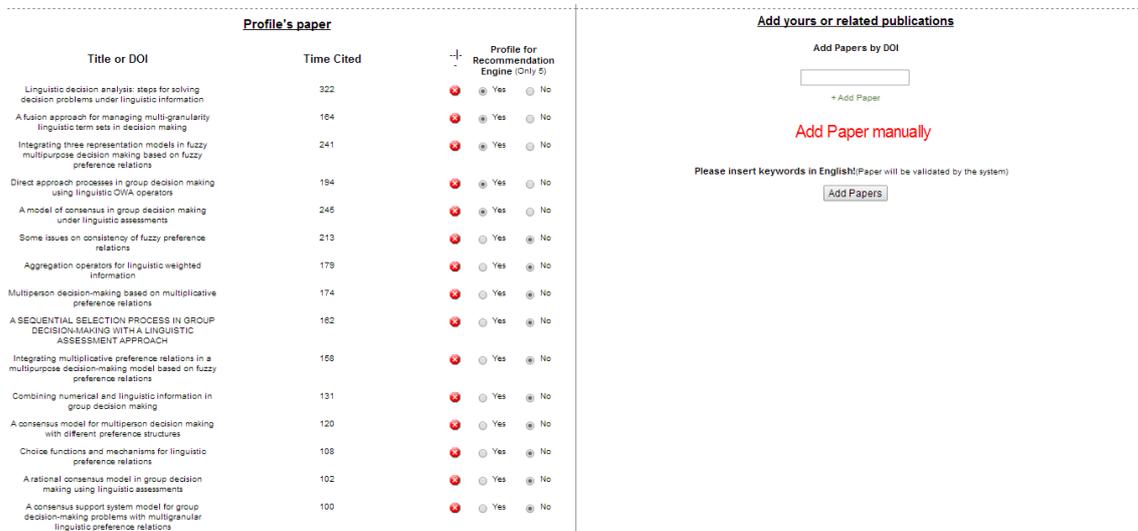


Figure 5.13: Selected, non selected user papers and options.

If we access to our recommendations, the system will show us the last ten recommended papers in the last active round (see Figure 5.14). Here we will have the possibility of edit our answer and we can also evaluate the quality of the paper in the case we have already read it. If we want to access to our old recommendations, in the bottom part of the page we have a link that will show us in the same format and with the same possibilities, all the recommendations since our beginning until the previous round.

But the access to the system is not necessary if we do not want to modify a previous decision or to add extra information since the recommendation are delivered by email each round. The email received have the format described in the Figure 5.15.

## 5.4. Experiments and evaluation

In this section we present the evaluation of the proposed recommender system. To do this, we could perform offline and online experiments [153]. But due to singularity of REFORE, we will only use online experiments based on

[>> Home](#)
[>> Profile](#)
[>> Recommendations](#)
[Exit \(X\)](#)

### Recommendations

Paper	Relevance
<p><b>Title:</b> Pessimists and optimists: Improving collaborative filtering through sentiment analysis  <b>Author(s):</b> Garcia-Cambronero, MA; Monago-Ribas, A; Diaz-Ordaz, MC  <b>Source:</b> EXPERT SYSTEMS WITH APPLICATIONS, Volume: 40, Issue: 11, Pages: DOI: 10.1016/j.eswa.2013.06.049  <b>Published:</b> DEC 1 2013</p> <p><b>Title:</b> Using rating matrix compression techniques to speed up collaborative recommendations  <b>Author(s):</b> Formoso, V.; Fernandez, D.; Caceres, F.; Camais, V.  <b>Source:</b> INFORMATION RETRIEVAL, Volume: 16, Issue: 6, Pages: DOI: 10.1007/s10791-012-9213-0  <b>Published:</b> DEC 2013</p> <p><b>Title:</b> Bridging memory-based collaborative filtering and text retrieval  <b>Author(s):</b> Bellign, A.; Wang, J.; Castells, P.  <b>Source:</b> INFORMATION RETRIEVAL, Volume: 16, Issue: 6, Pages: DOI: 10.1007/s10791-012-9214-z  <b>Published:</b> DEC 2013</p> <p><b>Title:</b> Hyperion: A fuzzy approach for recommending educational activities based on the acquisition of competences  <b>Author(s):</b> Serrano-Guerrero, J.; Romero, FP; Olivas, JB  <b>Source:</b> INFORMATION SCIENCES, Volume: 248, Issue: 0, Pages: DOI: 10.1016/j.ins.2013.06.009  <b>Published:</b> NOV 1 2013</p> <p><b>Title:</b> Boosting the K-Nearest-Neighborhood based incremental collaborative filtering  <b>Author(s):</b> Luo, F.; Xia, YN; Zhu, QS; Li, Y.  <b>Source:</b> KNOWLEDGE-BASED SYSTEMS, Volume: 63, Issue: 0, Pages: DOI: 10.1016/j.knsys.2013.08.016  <b>Published:</b> NOV 2013</p> <p><b>Title:</b> Sequential event prediction  <b>Author(s):</b> Letham, B.; Rudin, C.; Madigan, D.  <b>Source:</b> MACHINE LEARNING, Volume: 63, Issue: 2, Pages: DOI: 10.1007/s10994-013-9356-5  <b>Published:</b> NOV 2013</p> <p><b>Title:</b> A random-walk based recommendation algorithm considering item categories  <b>Author(s):</b> Zhang, LY.; Xu, J.; Li, CP.  <b>Source:</b> NEUROCOMPUTING, Volume: 100, Issue: 0, Pages: DOI: 10.1016/j.neucom.2012.06.002  <b>Published:</b> NOV 23 2013</p> <p><b>Title:</b> Recommending people to people: the nature of reciprocal recommenders with a case study in online dating  <b>Author(s):</b> Ruzals, L.; Rab, T.; Aleksovski, J.; Kopiniska, I.; Vasef, K.; Kary, J.  <b>Source:</b> USER MODELING AND USER-ADAPTED INTERACTION, Volume: 23, Issue: 5, Pages: DOI: 10.1007/s11257-012-9125-0  <b>Published:</b> NOV 2013</p> <p><b>Title:</b> Noisy but non-malicious user detection in social recommender systems  <b>Author(s):</b> Li, B.; Chen, L.; Zhu, YD.; Zhang, QD.  <b>Source:</b> WORLD WIDE WEB-INTERNET AND WEB INFORMATION SYSTEMS, Volume: 16, Issue: 6, Pages: DOI: 10.1007/s11280-012-0161-9  <b>Published:</b> NOV 2013</p> <p><b>Title:</b> Shilling attack detection utilizing semi-supervised learning method for collaborative recommender system  <b>Author(s):</b> Cao, J.; Wu, Z.; Han, B.; Zhang, YC.  <b>Source:</b> WORLD WIDE WEB-INTERNET AND WEB INFORMATION SYSTEMS, Volume: 16, Issue: 6, Pages: DOI: 10.1007/s11280-012-0164-0  <b>Published:</b> NOV 2013</p>	<p><b>RELEVANT - Normal</b>            Have you changed your opinion?            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p> <p><b>RELEVANT - Good</b>            Have you changed your opinion?            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p> <p><b>RELEVANT</b>            Have you read it? Please tell us your opinion about the quality            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p> <p><b>IRRELEVANT</b>  <input type="button" value="Change to Relevant"/></p> <p><b>RELEVANT</b>            Have you read it? Please tell us your opinion about the quality            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p> <p><b>IRRELEVANT</b>  <input type="button" value="Change to Relevant"/></p> <p><b>RELEVANT</b>            Have you read it? Please tell us your opinion about the quality            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p> <p><b>RELEVANT</b>            Have you read it? Please tell us your opinion about the quality            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p> <p><b>RELEVANT</b>            Have you read it? Please tell us your opinion about the quality            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p> <p><b>RELEVANT</b>            Have you read it? Please tell us your opinion about the quality            Good - Normal - Bad  <input type="button" value="Change to Irrelevant"/></p>

**Do you want to see your old recommendations? [Click here](#)**

These are your actual recommendations. The recommendations without feedback at the start of the next round will be considered as Irrelevant recommendations. If you want to see your older recommendations in order to change your opinion or provide information about the quality click here.

Figure 5.14: Recommendations in user profile.

the evaluation of the quality [160].

Moreover, in this case we can not compare our method with other approaches using a standard data set. The reason is any standard data set has not this information about the preferences of users or the important phase of feedback and the adaptation of the existent data sets is not possible. We are not proposing a new recommendation strategy but an approach which combines hybrid recommendation with quality measures as bibliometrics that were widely used in many areas and whose efficiency is proved [103, 169].

Consequently, in this study we only perform online experiments, i.e., practical studies where a group of researchers receive recommendations and report to the system their evaluations. When the users receive the list of recommendations per round, they provide feedback to the system rating if a recommended

Dear Alvaro,

Your recommended papers for December are ready!

We kindly ask you to tell us which ones you find relevant by clicking on "Relevant" or just by opening the article. Likewise, telling us which ones are not relevant (clicking on "Irrelevant") will help us improve the quality of the recommendations for the next round.

Additionally, you can go to [Refore Web](#) and update in the system the quality of the papers we recommended for you for future research.

The recommendation rounds for 2013 are finished, the results for the evaluation of the system will be announced soon. Thank you very much for your cooperation.

1- Title: [Pessimists and optimists: Improving collaborative filtering through sentiment analysis](#)

Author(s): Garcia-Cumbreras, MA ; Montejo-Raez, A; Diaz-Galiano, MC

Source: EXPERT SYSTEMS WITH APPLICATIONS, Volume: 40, Issue: 17, Pages: 6758-6765, DOI: [10.1016/j.eswa.2013.06.049](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

2- Title: [Using rating matrix compression techniques to speed up collaborative recommendations](#)

Author(s): Formoso, V ; Fernandez, D; Cacheda, F; Carneiro, V

Source: INFORMATION RETRIEVAL, Volume: 16, Issue: 6, Pages: 680-696, DOI: [10.1007/s10791-012-9213-0](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

3- Title: [Bridging memory-based collaborative filtering and text retrieval](#)

Author(s): Bellugin, A ; Wang, J; Castells, P

Source: INFORMATION RETRIEVAL, Volume: 16, Issue: 6, Pages: 697-724, DOI: [10.1007/s10791-012-9214-z](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

4- Title: [Hiperion: A fuzzy approach for recommending educational activities based on the acquisition of competences](#)

Author(s): Serrano-Guerrero, J ; Romero, FP; Olivas, JA

Source: INFORMATION SCIENCES, Volume: 248, Issue: 0, Pages: 114-129, DOI: [10.1016/j.ins.2013.06.009](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

5- Title: [Boosting the K-Nearest-Neighborhood based incremental collaborative filtering](#)

Author(s): Luo, X ; Xia, YN; Zhu, QS; Li, Y

Source: KNOWLEDGE-BASED SYSTEMS, Volume: 53, Issue: 0, Pages: 90-99, DOI: [10.1016/j.knosys.2013.08.016](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

6- Title: [Sequential event prediction](#)

Author(s): Letham, B ; Rudin, C; Madigan, D

Source: MACHINE LEARNING, Volume: 93, Issue: 2, Pages: 357-380, DOI: [10.1007/s10994-013-5356-5](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

7- Title: [A random-walk based recommendation algorithm considering item categories](#)

Author(s): Zhang, LY ; Xu, J; Li, CP

Source: NEUROCOMPUTING, Volume: 120, Issue: 0, Pages: 391-396, DOI: [10.1016/j.neucom.2012.06.062](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

8- Title: [Recommending people to people: the nature of reciprocal recommenders with a case study in online dating](#)

Author(s): Pizzato, L ; Rej, T; Akehurst, J; Koprinska, I; Yacef, K; Kay, J

Source: USER MODELING AND USER-ADAPTED INTERACTION, Volume: 23, Issue: 5, Pages: 447-488, DOI: [10.1007/s11257-012-9125-0](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

9- Title: [Noisy but non-malicious user detection in social recommender systems](#)

Author(s): Li, B ; Chen, L; Zhu, XQ; Zhang, CQ

Source: WORLD WIDE WEB-INTERNET AND WEB INFORMATION SYSTEMS, Volume: 16, Issue: 5, Pages: 677-699, DOI: [10.1007/s11280-012-0161-9](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

10- Title: [Shilling attack detection utilizing semi-supervised learning method for collaborative recommender system](#)

Author(s): Cao, J ; Wu, Z; Mao, B; Zhang, YC

Source: WORLD WIDE WEB-INTERNET AND WEB INFORMATION SYSTEMS, Volume: 16, Issue: 5, Pages: 729-748, DOI: [10.1007/s11280-012-0164-6](#)

Published: DEC 2013

[Relevant](#) or [Irrelevant](#)

Thank you!

P.S.: If you didn't receive up to 10 recommendations you might well want to review the keywords in your profile (maybe they are not enough or are not set properly to match your interests). You can go anytime to [Refore Web](#) to enter new keywords or modify the existing ones.

Kind Regards,  
Your Refore Team

This is an auto-generated email. To contact with the administrator write to [atejeda@decsai.ugr.es](mailto:atejeda@decsai.ugr.es)

Figure 5.15: Format used in the email to deliver recommendations.

resource is relevant or not, i.e., they provide their opinions about the recommendation supplied by the system. If they are satisfied with the recommendation, they set as relevant recommendation. After that, they can also set the quality of a resource.

In this sense we carry out following experiment: We select the research members of different departments and introduce their data into the system. The system is tested sending every month during a year the different recommendations based on the new articles appeared in WOS. The users marked every month for each recommendation of the list if is relevant or not, and may also indicate the quality they consider for each paper. This allows us to contrast the functioning of the system and the different approaches followed in it from the analysis of user's feedback.

#### 5.4.1. Data sets

For the evaluation, we made the tests using the collaboration of around 100 researchers of the following research groups: *Soft Computing and Intelligent Information Systems*<sup>3</sup> from University of Granada, *Delft Multimedia Information Retrieval Lab*<sup>4</sup> from TU Delft, some members from *Intelligent System and Data Mining*<sup>5</sup> and *Intelligent System Based on the Fuzzy Decision Analysis*<sup>6</sup> from University of Jaen and *Department of Civil Engineering*<sup>7</sup> from university of Granada. The similarities inside the set of users are stronger. Nevertheless, Figure 5.16 shows a representation of the users from university of Granada (the larger community tested), where we can see the different clusters created where the bubbles represent users, the size of the bubble is proportio-

---

<sup>3</sup> <http://sci2s.ugr.es/>

<sup>4</sup> <http://dmirlab.tudelft.nl/content/members-dmir-lab>

<sup>5</sup> <http://simidat.ujaen.es/>

<sup>6</sup> <http://sinbad2.ujaen.es/>

<sup>7</sup> <http://www.icivil.es/web2.0/>

---

nal to their H-index and the similarity is represented by the line which join them, being the distance proportional to it, and the lack of line the absence of similarity.

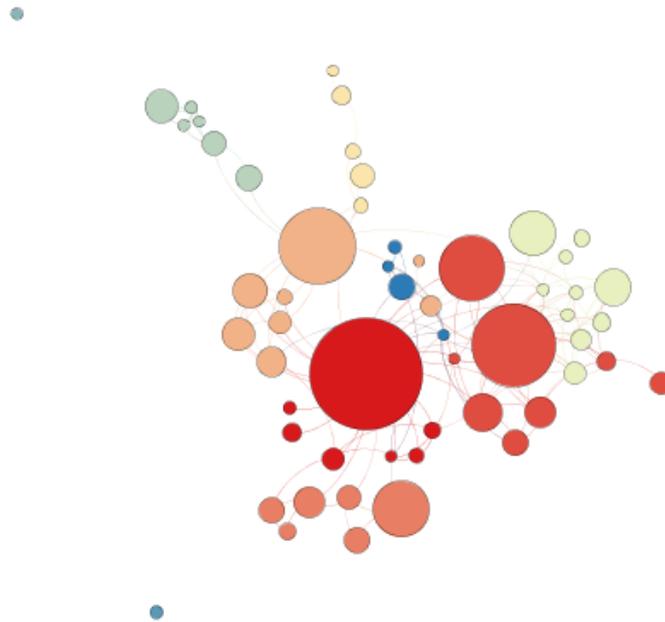


Figure 5.16: Users' similarities from University of Granada, weighted according to topics and quality

To build the set of resources 585000 papers belonging to the year 2013 of 1731 journals related with the areas where the previous group are focused, have been downloaded from WOK using the tool described in [12]. The selected areas are the following:

*Acoustics; Computer Science, Artificial Intelligence; Computer Science, Cybernetics; Computer Science, Hardware & Architecture; Computer Science, Information Systems; Computer Science, Interdisciplinary Applications; Computer Science, Software Engineering; Computer Science, Theory & Methods; Engineering, Civil; Engineering, Electrical & Electronic; Engineering, Multi-disciplinary; Mathematical & Computational Biology; Mathematics; Mathematics, Applied; Mathematics, Interdisciplinary Applications; Medical; Informa-*

*tics; Nanoscience & Nanotechnology; Neurosciences; Statistics & Probability.*

The 585000 resources were progressively added monthly from WOS obtaining the recent papers of journals monthly. The system filtered these resources when the recommendation round was launched and recommended them to the suitable users. To find out whether the recommendations were appropriate we based our study on the feedback given by the users, removing unusual behaviors such inactive users or users that did not update their profiles. We registered the ratings provided by users about the recommended resources to compare them with the predictions generated by our system.

The set of the users into the system is built following the steps described in section 4.2.3. With the information provided by the users, the system sets up the user profiles. As we have mentioned, these profiles are dynamic and could be modified depending on the user preferences and on the feedback provided.

#### **5.4.2. Assessing the capacity of recommendations**

Commonly used measures are precision, recall and F1. They are used to evaluate whether a recommender system properly recommends items that users will consider relevant [153].

We used these measures to quantify the quality of the recommender system [160]. However, in this work we are not relying on experts who can say if the recommendations are relevant or not. Furthermore, we are implementing a temporal window to avoid overwhelming users with a excessive number recommendations. Under these conditions, we have no means to identify which items are relevant but are not recommended due to the limitation in the number of recommendations, so that, we can not build a contingency table. For

---

this reason, the way we measure the accuracy of our system is using the **Mean Absolute Error (MAE)** [65, 153] explained in Section 2.4.

As we have mentioned before, during the online study we record the ratings provided by users on the recommended resources to compare with the predictions generated by our system, and to calculate the MAE. As a rating metric for the system, we use the average of the MAE for all the users resulting into a final MAE of **0.70529**.

In our case, without the intervention of any expert participating in the process, that is, in a fully automated process, we are able to cover the whole number of users and items. That is, the coverage of the system is the 100% for each user based on the coverage definition given in [56]. The predictions generated with the new system are in line with the users' preferences.

To complete our study, we have tested the system with different configurations:

- No re-ranking (NRR), that is, the ten first items of the previous ordered list of items or users similar to the active user, either content-based and collaborative.
  - Similarity measured based in abstract (ABS) instead of keywords, using tf-idf algorithm [141] to estimate the similarity between papers and users, either content-based and collaborative, without the use of re-ranking.
  - Quality filter for the content-based based on the H-index (QH) of the authors of an article instead of the IF of the journal.
  - Same quality filter in journals but without the application of the diversity filter (NDF).
-

---

Configuration	MAE
NRR	0.61
ABS	0.28
QH	0.56
NDF	0.51

---

Table 5.2: MAE for all the different configuration.

Table 5.2 shows the MAE values for each configuration, based on these values we can see the improvement obtained by the application of the quality as index for the re-ranking process. As we can see, the use of the analysis of the abstract based on the tf-idf algorithm produced poorer results than expected. Probably the fact that abstract are all written in a similar manner might explain this poor performance. The absence of re-ranking leaves us with the typical recommender system that we would have obtained in these systems with the hybrid approach. After both approaches without re-ranking we moved on to test differences in the quality criteria plus diversity filter. On the one hand, the quality criteria of the H-index of authors of an article in the content-based approach proves that this criteria distorts the results. The reason of this behavior is that these good authors can be oriented to specific areas similar to user interest but with different approaches. On the other hand, the use of diversity filter resulted to be an essential task to mitigate the own distortion introduced by the quality criteria, as the quality of some items could not be relevant if there's no relation with the actual profile.

In order to analyze the behavior of the system over time, we compare the MAE of the different twelve rounds corresponding with the monthly recommendation of the year 2013. We can see in the Figure 5.17 the evolution of some decimals points in the monthly MAE due to the application of the collaborative filtering and the use of the black list as part of users' profile. We also observe that the

---

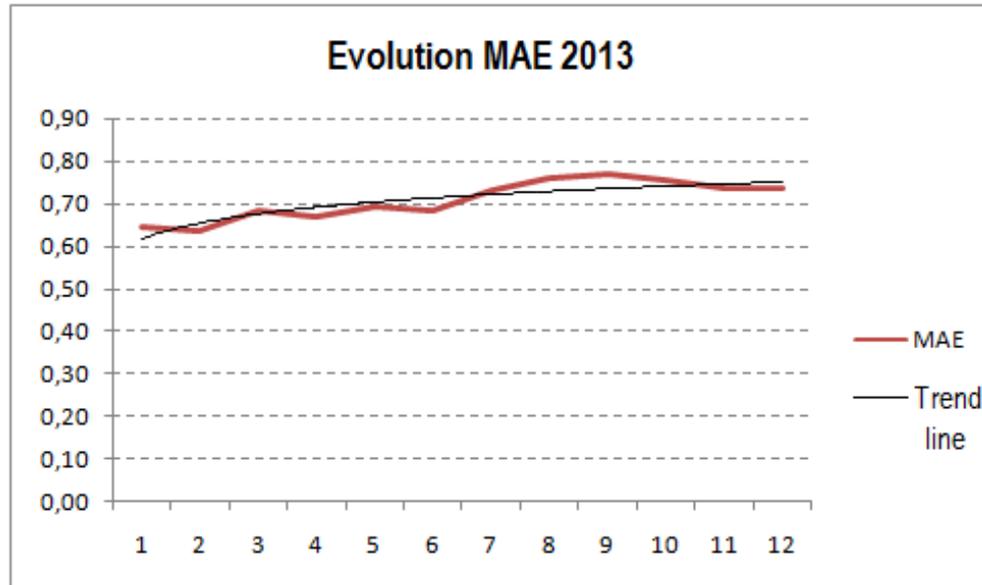


Figure 5.17: Evolution of MAE during the year 2013

accuracy obtained by using combined quality of items and authors with the diversity filter outperforms the predictions computed without them or with a different approach. Specifically we achieved an improvement of 9% against *NRR*, 42% against *ABS*, 14% against *QH* and 19% against *NDF*. According to the results, the predictions generated with the system are more accurate. The users part of the trial showed themselves satisfied with the results.

## 5.5. Discussion

The personalization of information related to research papers deserves a special attention due to the ever growing information overload problem in the research world. Researchers need tools to assist them in their processes of getting the newest and most relevant information recently produced. Recommender systems have been successfully applied in both academic and commercial environments obtaining relevant information. Quality has been taken into account in previous works, but relying on the experts supervision of recommended items. Since the number of items is continuously growing, the human

interaction needs to be reduced to the minimum. In this chapter we approached the recommendation generation process about new research papers as an hybrid recommender system. On the one hand, a content-based approach to obtain the latest papers inserted into the system, non rated by any user, and on the other hand, a collaborative approach to avoid disregarding potentially important papers for a user, rated in the last two rounds by experts on the field.

So, we have developed a hybrid fuzzy linguistic recommender system based on the quality of the items and users, which has been then applied in the database extracted from WOS to assist users to access relevant papers. The system measures both items' and users' quality for the re-ranking process. Beside the quality of items and the quality of the users, REFORE takes into account the users' profiles for the top-N recommendations. In addition, the system improves the regular feedback process in two ways. Firstly evaluating the recommendation as relevant or irrelevant, which then becomes part of the user profile. Secondly, giving the user the possibility to assess the quality of the item recommended. We have performed online studies with the proposed system and the experimental results yielded satisfactory results.

The experimental study performed allowed us to contrast the behavior of these different approaches implemented in the hybrid recommender system. The proposed quality procedure in conjunction with the application of a filter based on the user profile in the re-ranking process has shown better accuracy than the use of different techniques or the absence of any. The results obtained with different methods, supports the drawn conclusion.

As future work, we consider enhancing the paper keywords with the automatic

---

extraction of terms from the article abstracts for the users' vectors to estimate similarity, which we think can provide promising results. One step in this direction is to use Wordnet [54] in the process for the nouns extraction. Moreover, we want to expand the use of REFORE as a tool for user not only to be up to date on the newest trends but also for researchers who wants to enter in a new area, or even to have the best personalized papers for a wider time window.

At this time, REFORE is in a test phase where they are being studied the improvements suggested in this section. We are also trying to improve the performance of the data similarity processing looking into some techniques of Big Data to deal with the increasing number of users and items.



# Chapter 6

## Concluding Remarks and Future Works

### 6.1. Concluding remarks

In this thesis, we have addressed several problems pursuing a common objective: to aid users in their process of accessing information in digital libraries. To achieve this goal, we have relied on two main research lines that have been developed throughout this dissertation: recommender systems and fuzzy linguistic modeling.

In the second Chapter, our initial objective was to present a review of recommender system. Which serves to prevent the information overload problem providing personalized recommendations to users. To achieve that, we carried out a theoretical and empirical study of recommender systems, focused on characterizing of recommendation techniques as well as on the use of quality as key element to obtain better recommendations. The third Chapter of this dissertation has been devoted to the field of *fuzzy linguistic modeling of information* to model the subjectivity and uncertainty involved in the activities of information access. Once again, we performed a study of specialized literature in order to categorize the basis of fuzzy sets with their operations and the

fuzzy linguistic modeling with its different approaches. In the same Chapter, the main purpose and performance of digital libraries was presented as well as some examples which were the basis of this dissertation.

Leveraging all the findings from this study, we proposed two systems to solve the identified problems in digital libraries.

- The first one, “*a quality based recommender system to disseminate information in a University Digital Library*” aimed at generating personalized recommendations of information items in an academic environment. The system uses the quality of the items, based on the popularity of them, to estimate their relevance as well as a multi-granular fuzzy linguistic approach to represent the information. The results of our experimentation proved appropriate results for the participating users. In the experiments conducted, this model has significantly outperformed the accuracy of previous works where no use of quality was done. Thus, the obtained results confirm the use of quality in the re-ranking process for recommendations in academic environments to increase the effectiveness.
  - The second one, “*REFORE: A recommender system for researchers based on bibliometrics*” was also designed to produce personalized recommendations of information items in the context of a digital libraries. In this case, we developed the system called REFORE (REcommender FOR REsearchers) which deals with the information contained in the Thomson Reuters digital library, *Web of Science*, and is intended specifically to keep up to date researchers on new trends in their main fields. To carry out this task, the system relies on a multi-granular fuzzy linguistic approach to represent the information and where the quality of the items is estimated automatically without the interaction of any experts based
-

on bibliometrics. In the experiments conducted over a year of usage, this model proved the effectiveness generating recommendations using quality based on the most extended bibliometrics measures in the research area. The system delivered every month personalized emails with recommendations allowing users to evaluate the recommendation in the same email.

Taking into account these aspects, the results obtained in this dissertation can be summarized in following points:

- We have analyzed and studied recommender systems, highlighting the role of these systems on real world scenarios such as e-commerce, health, advertising, entertainment or digital libraries as useful tools to disseminate information.
  - We have studied, analyzed and presented the fuzzy linguistic modeling to linguistic information management and its application in the design of a recommender system.
  - We have studied the main purpose and operation of digital libraries.
  - We have proposed two recommender systems to information access for digital libraries based on quality and multi-granular fuzzy linguistic modeling.
  - The systems we proposed have been designed and implemented as systems to disseminate information in an academic environment, based on hybrid techniques for the recommendation process and on quality for the re-ranking one, and using a multi-granular fuzzy linguistic modeling to represent the information.
-

## Conclusiones

En esta tesis, hemos abordado varios problemas que persiguen un objetivo común: ayudar a los usuarios en su proceso de acceso a la información en las bibliotecas digitales. Dos líneas de investigación han compuesto esta disertación: sistemas de recomendaciones y el modelado lingüístico difuso.

En el segundo Capítulo nuestro objetivo inicial era presentar una revisión acerca de los sistemas de recomendaciones. El propósito de dichos sistemas, es el de prevenir el problema de la sobrecarga de información proporcionando recomendaciones personalizadas a los usuarios. Para ello, se ha llevado a cabo un estudio teórico y empírico del diseño de los sistemas de recomendaciones, centrándose en la caracterización de los rasgos de las técnicas de recomendación y en el uso de la calidad como elemento clave para obtener mejores recomendaciones. El tercer Capítulo de esta tesis, se ha dedicado al campo del modelado lingüístico difuso de la información para conformar la subjetividad y la incertidumbre inherente a las actividades de acceso a la información. Una vez más, hemos realizado un estudio de la literatura especializada con el fin de clasificar los conceptos básicos de los conjuntos difusos con sus operaciones y el modelado lingüístico difuso con sus diferentes enfoques. En el mismo Capítulo, se han presentado los aspectos fundamentales relacionados con el funcionamiento de las bibliotecas digitales, así como una serie de ejemplos de los que parte esta tesis.

Basándose en las lecciones aprendidas en este estudio, hemos propuesto dos sistemas con el fin de resolver los problemas de sobrecarga de información de las bibliotecas digitales.

- El primero, *“a quality based recommender system to disseminate infor-*
-

---

*mation in a University Digital Library*” tiene como objetivo el generar recomendaciones personalizadas de elementos de información en un ambiente académico en el que el sistema utiliza la calidad de los artículos, basada en la popularidad de éstos, para estimar su relevancia, así como un modelado lingüístico difuso multi-granular para representar la información. Este sistema ha sido capaz de generar las recomendaciones apropiadas para cada usuario. En los experimentos realizados, este modelo ha superado significativamente la precisión de trabajos anteriores donde no se realizó ningún uso de calidad como concepto a tener en cuenta. Por lo tanto, se ha demostrado la eficacia de la utilización de la calidad en un ambiente académico como elemento clave para la fase de reordenación.

- El segundo, “*REFORE: A recommender system for researchers based on bibliometrics*” también ha tenido como objetivo el generar recomendaciones personalizadas de elementos de información en una biblioteca digital. En este caso hemos desarrollado el sistema denominado Refore (*REcommender FOR REsearchers*) que trata con la información contenida en la biblioteca digital *Thomsom Reuters, Web of Science*, y está pensado específicamente para mantener al día los investigadores sobre las nuevas tendencias en sus principales áreas de investigación. Para ello, el sistema utiliza un enfoque lingüístico difuso multi-granular para representar la información y donde la calidad de los artículos se calcula de forma automática y sin la interacción de ningún expertos basándose en las medidas bibliométricas más populares. En los experimentos llevados a cabo durante un año de uso, este modelo ha demostrado la eficacia generando recomendaciones utilizando la calidad como base de la reordenación teniendo en cuenta ciertas medidas bibliométricas que destacan
-

en el ámbito de la investigación. El sistema ha mandado todos los meses emails personalizados con recomendaciones que permitan a los usuarios evaluar la recomendación contenida en el mismo email.

Teniendo en cuenta estos aspectos, los resultados obtenidos en esta tesis pueden resumirse en los siguientes puntos:

- Hemos analizado y estudiado los sistemas de recomendaciones, destacando la funcionalidad de la inclusión de estos sistemas en el mundo real como en el comercio electrónico, sanidad, bibliotecas digitales, publicidad o entretenimiento como herramientas útiles para difundir información.
  - Hemos estudiado, analizado y presentado el modelado lingüístico difuso para la gestión de la información lingüística y su aplicación en el diseño de un sistema de recomendaciones.
  - Hemos estudiado los aspectos fundamentales relacionados con el funcionamiento de las bibliotecas digitales.
  - Hemos propuesto dos sistemas de recomendaciones para el acceso a la información de las bibliotecas digitales basadas en calidad y en un modelado lingüístico difuso multi-granular.
  - Se han diseñado e implementado sistemas de difusión de información en un entorno académico, basado en técnicas híbridas para el proceso de recomendación y en la calidad para el proceso de reordenación, así como el uso de un modelado lingüístico difuso multi-granular para representar la información.
-

## 6.2. Future works

In this section we point some of the trends we consider more interesting in order to our future works in the development of fuzzy linguistic recommender systems in digital libraries:

1. A possible line of research would be related with the study of the credibility of recommendations in the collaborative recommender systems taking into account moods of people at the time of generating the recommendation.
  2. To take into account social networks aspects, such as to build trust networks between collaborators and to consider their trust degrees to generate the recommendations. To do that, it will be necessary to study the propagation and aggregation operators for trust degrees that improve the actual ones.
  3. To go further using different techniques of fuzzy linguistic modeling trying to include the uncertainty doing more natural the interaction user-system.
  4. To apply automatic techniques in the user profiles and item profiles acquisition to reduce the interaction of users in order to avoid the problem of the non cooperation of users and the difficult task of the introduction of each items. These techniques can be the automatic extraction of terms from an article abstract using the Wordnet [54] lexical database in order to process the nouns extraction.
  5. To study how to model in a better way the novelty or the utility of an item in a way that enhance the re-ranking process as a personalized filter for the users based on their preferences.
-

## Associated Publications to the Dissertation Thesis

In this section we list the publications either scientific journals, book chapters and national and international conferences associated to the dissertation thesis.

The international journal publications associated to the dissertation thesis are the following:

- A. Tejeda-Lorente, C. Porcel, E. Peis, R. Sanz, E. Herrera-Viedma, A quality based recommender system to disseminate information in a University Digital Library. *Information Sciences*, 261 (2014) pp. 52-69 DOI: 10.1016/j.ins.2013.10.036.
- A. Tejeda-Lorente, C. Porcel, J. Bernabé-Moreno, E. Herrera-Viedma, REFORE: A recommender system for researchers based on bibliometrics. **Submitted to** *Applied Soft Computing*.
- C. Porcel, A. Tejeda-Lorente, M.A. Martínez, E. Herrera-Viedma, A hybrid recommender system for the selective dissemination of research resources in a technology transfer office. *Information Sciences*, 184:1 (2012) pp. 1-19 DOI: 10.1016/j.ins.2011.08.026.

The book chapter publication associated to the dissertation thesis is the following:

- C. Porcel, A. Tejeda-Lorente, M.A. Martínez, E. Herrera-Viedma, Using a Recommender System to Help the Technology Transfer Office Staff to Disseminate Selective Information. *Intelligence Systems in Industrial Engineering. Atlantis Computational Intelligence Systems* 6 6 (2012) 45-69. Editors: Cengiz Kahraman. ISBN: 978-94-91216-76-3.
-

The national and international conferences publications associated to the dissertation thesis are the following:

- A. Tejeda-Lorente, C. Porcel, J. Bernabé-Moreno, E. Herrera-Viedma, Integrating Quality Criteria in a Fuzzy Linguistic Recommender System for Digital Libraries. 2nd International Conference on Information Technology and Quantitative Management (ITQM 2014), Moscow (Russia), *Procedia Computer Science* 31 pp. 1036–1043, 3-6 June 2014.
  - A. Tejeda-Lorente, C. Porcel, J. Bernabé-Moreno, M.A. Martínez, E. Herrera-Viedma, Aplicación de un sistema de recomendaciones que combina relevancia y calidad en una biblioteca digital universitaria. Proceedings of the XVII Congreso Español Sobre Tecnologías Y Lógicas Fuzzy (ESTYLF 2014), pp. 493-498. ISBN: 978-84-15688-76-1, Zaragoza (Spain), 5-7 February 2014.
  - A. Tejeda-Lorente, C. Porcel, M.A. Martínez, A.G. López-Herrera, E. Herrera-Viedma, Using memory to reduce the information overload in a university digital library. 11th International Conference on Intelligent Systems Design and Applications (ISDA 2011), Córdoba (Spain), pp. 444-449, 22-24 November 2011.
  - A. Tejeda-Lorente, C. Porcel, B. Esteban, E. Herrera-Viedma, Un sistema de recomendaciones para el tratamiento y prevención en fisioterapia. II Jornadas Andaluzas de Informática (JAI2011), Canillas del Aceituno (Spain), pp. 167-173, 16-18 September 2011.
  - C. Porcel, A. Tejeda, E. Herrera-Viedma, Un sistema de recomendaciones mejorado para evitar la sobrecarga de información persistente en una biblioteca digital universitaria. In Proceedings of the III Congreso Español de Informática (CEDI 2010). III Simposio sobre Lógica Fuzzy
-

y Soft Computing, LFSC2010 (EUSFLAT), Valencia (Spain), 361-368,  
7-10 September 2010.

---

# Bibliography

- [1] *Google scholar*, <http://scholar.google.com/intl/en/scholar/about.html>.
- [2] *Ieeexplore*, <http://ieeexplore.ieee.org/Xplore/home.jsp>.
- [3] *Sciencedirect*, <http://info.sciencedirect.com/>.
- [4] *Scopus*, <http://www.elsevier.com/online-tools/scopus>.
- [5] *Web of science, information*, <http://wokinfo.com/>.
- [6] A. Aladwani and P. Palvia, *Developing and Validating an Instrument for Measuring User Perceived Web Quality*, *Information & Management* **39** (2002), 467–476.
- [7] S. Alonso, F. Cabrerizo, F. Chiclana, F. Herrera, and E. Herrera-Viedma, *Group decision-making with incomplete fuzzy linguistic preference relations*, *International Journal of Intelligent Systems* **24** (2009), 201–222.
- [8] S. Alonso, F. Cabrerizo, E. Herrera-Viedma, and F. Herrera, *H-index: A review focused in its variants, computation and standardization for different scientific fields*, *Journal of Informetrics* **3** (2009), 273–289.
- [9] ———, *hg-index: A new index to characterize the scientific output of researchers based on the h- and g- indices*, *Scientometrics* **82** (2010), 391–400.

- [10] S. Alonso, F. Chiclana, F. Herrera, E. Herrera-Viedma, J. Alcalá-Fdez, and C. Porcel, *A consistency-based procedure to estimating missing pairwise preference values*, International Journal of Intelligent Systems **23** (2008), 155–175.
- [11] S. Alonso, E. Herrera-Viedma, F. Chiclana, and F. Herrera, *Individual and social strategies to deal with ignorance situations in multi-person decision making*, International Journal of Information Technology and Decision Making **8** (2009), 313–333.
- [12] S. Alonso, F. J. Cabrerizo, E. Herrera-Viedma, and F. Herrera, *Wos query partitioner: A tool to retrieve very large numbers of items from the web of science using different source-based partitioning approaches*, Journal of the American Society for Information Science and Technology **61** (2010), no. 8, 1582–1597.
- [13] R. Baeza-Yates, *Information retrieval in the web: Beyond current search engines*, International Journal of Approximate Reasoning **37(2-3)** (2003), 97–104.
- [14] R. Baeza-Yates and B. Ribeiro-Neto, *Modern information retrieval*, Addison-Wesley, 1999.
- [15] G. Bafoutsou and G. Mentzas, *Review and functional classification of collaborative systems*, International Journal of Information Management **22** (2002), no. 4, 281 – 305.
- [16] A. Barragáns-Martínez, E. Costa-Montenegro, J. Burguillo, M. Rey-López, F. Mikic-Fonte, and A. Peleteiro, *A hybrid content-based and item-based collaborative filtering approach to recommend tv programs enhanced with singular value decomposition*, Information Sciences **180** (2010), 4290–4311.
-

- 
- [17] C. Basu, H. Hirsh, and W. Cohen, *Recommendation as classification: Using social and content-based information in recommendation*, Proceedings of the Fifteenth National Conference on Artificial Intelligence, 1998, pp. 714–720.
- [18] D. Bawden and P. Vilar, *Digital libraries: to meet or manage user expectations*, Aslib Proceedings, vol. 58, Emerald Group Publishing Limited, 2006, pp. 346–354.
- [19] P. Bonissone and K. Decker, *Uncertainty in artificial intelligence*, ch. Selecting Uncertainty Calculi and Granularity: an experiment in trading-off precision an complexity, pp. 217–247, Kanal, L.H. and Lemmer, J.F. Eds. North-Holland, 1986.
- [20] G. Bordogna, P. Carrara, and G. Pasi, *Query term weights as constraints in fuzzy information retrieval*, Information Processing & Management **27** (1991), no. 1, 15–26.
- [21] G. Bordogna, M. Fedrizzi, and G. Pasi, *A linguistic modeling of consensus in group decision making based on OWA operators*, IEEE Transactions on Systems, Man, and Cybernetics. Part A: Systems and Humans **27** (1997), no. 1, 126–133.
- [22] G. Bordogna and G. Pasi, *A fuzzy linguistic approach generalizing boolean information retrieval: A model and its evaluation*, Journal of the American Society for Information Science **44** (1993), no. 2, 70–82.
- [23] G. Bordogna and G. Pasi, *An ordinal information retrieval model*, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems **9** (2001), no. Supplement 1, 63–75.
-

- [24] G. Bordogna and G. Pasi, *Application of fuzzy set theory to extend boolean information retrieval*, pp. 21–47, Springer, 2000.
- [25] M. Bovee, R. Srivastava, and B. Mak, *A Conceptual Framework and Belief-Function Approach to Assessing Overall Information Quality*, International Journal of Intelligent Systems **18** (2003), 51–74.
- [26] R. Burke, *Hybrid recommender systems: Survey and experiments*, User Modeling and User-Adapted Interaction **12** (2002), 331–370.
- [27] ———, *Hybrid web recommender systems*, P. Brusilovsky, A. Kobsa, and W. Nejdl (Eds.): The Adaptive Web, LNCS **4321** (2007), 377–408.
- [28] F. Cabrerizo, J. López-Gijón, A. Ruíz-Rodríguez, and E. Herrera-Viedma, *A model based on fuzzy linguistic information to evaluate the quality of digital libraries*, International Journal of Information Technology & Decision Making **9(3)** (2010), 455–472.
- [29] F. J. Cabrerizo, S. Alonso, E. Herrera-Viedma, and F. Herrera, *q2-index: Quantitative and qualitative evaluation based on the number and impact of papers in the hirsch core*, Journal of Informetrics **4** (2010), no. 1, 23–28.
- [30] J. Callan and A. Smeaton, *Personalization and recommender systems in digital libraries*, Joint NSF-EU DELOS Working Group Report, 2003.
- [31] J. Callan, A. Smeaton, M. Beaulieu, P. Borlund, P. Brusilovsky, M. Chalmers, C. Lynch, J. Riedl, B. Smyth, U. Straccia, et al., *Personalisation and recommender systems in digital libraries*, (2003).
- [32] H. Chao, *Assessing the quality of academic libraries on the web: The development and testing of criteria*, Library & Information Science Research **24** (2002), 169–194.
-

- 
- [33] M. Claypool, A. Gokhale, and T. Miranda, *Combining content-based and collaborative filters in an online newspaper*, Proceedings of the ACM SIGIR-99 Workshop on Recommender Systems-Implementation and Evaluation, 1999, pp. 714–720.
- [34] C. Cleverdon and E. Keen, *Factors determining the performance of indexing systems*, ASLIB Cranfield Research Project **2** (1966).
- [35] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, *Scimat: A new science mapping analysis software tool*, Journal of the American Society for Information Science and Technology **63** (2012), no. 8, 1609–1630.
- [36] I. Cohen and J. Rainville, *Aggressive exercise as treatment for chronic low back pain*, Sports Medicine **32** (2002), no. 1, 75–82.
- [37] O. Cordón and E. Herrera-Viedma, *Special issue on soft computing applications to intelligent information retrieval on the internet*, International Journal of Approximate Reasoning **34** (2003), no. 2, 89–95.
- [38] T. Cover and P. Hart, *Nearest neighbor pattern classification*, IEEE Transactions on Information Theory **13**(1) (1976), 21–27.
- [39] F. Crestani and G. Pasi, *Soft computing in information retrieval: Techniques and applications*, Physica Verlag, 2000.
- [40] ———, *Handling Vagueness, Subjectivity, and Imprecision in Information Access: An Introduction to the Special Issue*, Information Processing & Management **39** (2003), no. 2, 161–165.
- [41] A. Czarl and M. Belovecz, *Role of research and development in the 21st century*, Proceedings of the Eight International Conference on Informatics in Economy, 2007, pp. 497–502.
-

- [42] R. Degani and G. Bortolan, *The problem of linguistic approximation in clinical decision making*, International Journal of Approximate Reasoning **2** (1988), no. 2, 143–162.
- [43] M. Delgado, J. Verdegay, and M. Vila, *On aggregation operations of linguistic labels*, International Journal of Intelligent Systems **8** (1993), no. 3, 351–370.
- [44] M. Delgado, F. Herrera, E. Herrera-Viedma, and L. Martínez, *Combining numerical and linguistic information in group decision making*, Information Sciences **107** (1998), no. 1, 177–194.
- [45] M. Deshpande and G. Karypis, *Item-based top-n recommendation algorithms*, ACM Transactions on Information Systems **22** (2004), 143–177.
- [46] D. Dhyan, W. Keong, and S. Bhowmick, *A Survey of Web Metrics*, ACM Computing Surveys **34** (2002), no. 4, 469–503.
- [47] V. Durieux and P. A. Gevenois, *Bibliometric indicators: Quality measurements of scientific publication 1*, Radiology **255** (2010), no. 2, 342–351.
- [48] A. Edmunds and A. Morris, *The problem of information overload in business organizations: a review of the literature*, International Journal of Information Management **20** (2000), 17–28.
- [49] L. Egghe, *An improvement of the h-index: the g-index*, ISSI newsletter **2** (2006), no. 1, 8–9.
- [50] ———, *Theory and practise of the g-index*, Scientometrics **69** (2006), no. 1, 131–152.
- [51] G. E. Ehrlich, *Low back pain*, Bulletin of the World Health Organization **81** (2003), no. 9, 671–676.
-

- 
- [52] B. Esteban, A. Tejada-Lorente, C. Porcel, M. Arroyo, and E. Herrera-Viedma, *Tplufib-web: A fuzzy linguistic web system to help in the treatment of low back pain problems*, Knowledge-Based Systems (In Press 2014).
- [53] A. Felfernig, E. Teppan, and B. Gula, *Knowledge-based recommender technologies for marketing and sales*, International Journal of Pattern Recognition and Artificial Intelligence **21** (2007), no. 02, 333–354.
- [54] C. Fellbaum, *Wordnet*, Wiley Online Library, 1999.
- [55] E. A. Fox and G. Marchionini, *Digital libraries: Introduction*, Commun. ACM **44** (2001), no. 5, 30–32.
- [56] M. Ge, C. Delgado-Battenfeld, and D. Jannach, *Beyond accuracy: evaluating recommender systems by coverage and serendipity*, Proceedings of the fourth ACM conference on Recommender systems, ACM, 2010, pp. 257–260.
- [57] M. Gertz, M. Ozsu, G. Saake, and K. Sattler, *Report on the Dagstuhl Seminar “Data Quality on the Web”*, Sigmod Record **31** (2004), no. 1, 127–132.
- [58] M. A. Gonçalves, E. Fox, L. Watson, and N. Kipp, *Streams, structures, spaces, scenarios, societies (5s): A formal model for digital libraries*, ACM Transactions on Information Systems **22(2)** (2004), 270–312.
- [59] N. Good, J. Schafer, J. Konstan, A. Borchers, B. Sarwar, J. Herlocker, and J. Riedl, *Combining collaborative filtering with personal agents for better recommendations*, Proceedings of the Sixteenth National Conference on Artificial Intelligence, 1999, pp. 439–446.
-

- [60] S. Hammer, J. Kim, and E. André, *Med-styler: Metabo diabetes-lifestyle recommender*, Proceedings of the fourth ACM conference on Recommender systems, ACM, 2010, pp. 285–288.
- [61] U. Hanani, B. Shapira, and P. Shoval, *Information filtering: Overview of issues, research and systems*, User Modeling and User-Adapted Interaction **11** (2001), 203–259.
- [62] M. Henderson, S. Shurville, and K. Fernstrom, *The quantitative crunch: the impact of bibliometric research quality assessment exercises on academic development at small conferences*, Campus-Wide Information Systems **26** (2009), no. 3, 149–167.
- [63] J. Herlocker, J. Konstan, A. Borchers, and J. Riedl, *An algorithmic framework for performing collaborative filtering*, Proceedings of the 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval, 1999, pp. 230–237.
- [64] J. Herlocker, J. Konstan, and J. Riedl, *An empirical analysis of design choices in neighborhood-based collaborative filtering algorithms*, Information Retrieval **5** (2002), 287–310.
- [65] J. Herlocker, J. Konstan, L. Terveen, and J. Riedl, *Evaluating collaborative filtering recommender systems*, ACM Transactions on Information Systems **22(1)** (2004), 5–53.
- [66] J. L. Herlocker, *Understanding and improving automated collaborative filtering systems*, Ph.D. thesis, Citeseer, 2000.
- [67] F. Herrera and H.-V. E., *Aggregation operators for linguistic weighted information*, IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems **27** (1997), 646–656.
-

- 
- [68] F. Herrera and E. Herrera-Viedma, *Choice functions and mechanisms for linguistic preference relations*, European Journal of Operational Research **120** (2000), 144–161.
- [69] F. Herrera, E. Herrera-Viedma, and L. Martínez, *A fusion approach for managing multi-granularity linguistic term sets in decision making*, Fuzzy Sets and Systems **114** (2000), 43–58.
- [70] F. Herrera, E. Herrera-Viedma, and L. Martínez, *An information retrieval system with unbalanced linguistic information based on the linguistic 2-tuple model*, 8th International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems (IPMU'02), 2002, pp. 23–29.
- [71] F. Herrera, E. Herrera-Viedma, L. Martínez, and P. Sánchez, *A methodology for generating the semantics of unbalanced term sets*, 9th International Conference on Fuzzy Theory and Technology, 2003, pp. 151–154.
- [72] F. Herrera, E. Herrera-Viedma, and J. Verdegay, *Direct approach processes in group decision making using linguistic owa operators*, Fuzzy Sets and Systems **79** (1996), 175–190.
- [73] F. Herrera and L. Martínez, *A 2-tuple fuzzy linguistic representation model for computing with words*, IEEE Transactions on Fuzzy Systems **8(6)** (2000), 746–752.
- [74] F. Herrera and L. Martínez, *The 2-tuple linguistic computational model. Advantages of its linguistic description, accuracy and consistency*, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems **9** (2001), no. Supplement 1, 33–48.
-

- [75] F. Herrera and L. Martínez, *A model based on linguistic 2-tuples for dealing with multigranularity hierarchical linguistic contexts in multiexpert decision-making*, IEEE Transactions on Systems, Man and Cybernetics, Part B: Cybernetics **31(2)** (2001), 227–234.
- [76] E. Herrera-Viedma, *An information retrieval system with ordinal linguistic weighted queries based on two weighting elements*, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems **9** (2001), 77–88.
- [77] ———, *Modeling the retrieval process of an information retrieval system using an ordinal fuzzy linguistic approach*, Journal of the American Society for Information Science and Technology **52(6)** (2001), 460–475.
- [78] E. Herrera-Viedma, S. Alonso, F. Chiclana, and F. Herrera, *A consensus model for group decision making with incomplete fuzzy preference relations*, IEEE Transactions on Fuzzy Systems **15(5)** (2007), 863–877.
- [79] E. Herrera-Viedma, F. Chiclana, F. Herrera, and S. Alonso, *Group decision making model with incomplete fuzzy preference relations based on additive consistency*, IEEE Transactions on Systems, Man and Cybernetics, Part B **37(1)** (2007), 176–189.
- [80] E. Herrera-Viedma, O. Cordón, M. Luque, A. López, and A. Muñoz, *A model of fuzzy linguistic IRS based on multi-granular linguistic information*, International Journal of Approximate Reasoning **34(3)** (2003), 221–239.
- [81] E. Herrera-Viedma, F. Herrera, and F. Chiclana, *A consensus model for multiperson decision making with different preference structures*, IEEE Transactions on Systems, Man and Cybernetics, Part A **32(3)** (2002), 394–402.
-

- 
- [82] E. Herrera-Viedma, F. Herrera, L. Martínez, J. C. Herrera, and A. G. López, *Incorporating filtering techniques in a fuzzy linguistic multi-agent model for information gathering on the web*, *Fuzzy Sets and Systems* **148** (2004), no. 1, 61 – 83.
- [83] E. Herrera-Viedma and J. López-Gijón, *Libraries’ Social Role in the Information Age*, *Science* **339** (2013), no. 6126, 1382–1382.
- [84] E. Herrera-Viedma and A. López-Herrera, *A model of information retrieval system with unbalanced fuzzy linguistic information*, *International Journal of Intelligent Systems* **22** (2007), no. 11, 1197–1214.
- [85] ———, *A review on information accessing systems based on fuzzy linguistic modelling*, *International Journal of Computational Intelligence Systems* **3** (2010), no. 4, 420–437.
- [86] E. Herrera-Viedma, A. López-Herrera, M. Luque, and C. Porcel, *A fuzzy linguistic irs model based on a 2-tuple fuzzy linguistic approach*, *International Journal of Uncertainty, Fuzziness and Knowledge-based Systems* **15** (2007), no. 2, 225–250.
- [87] E. Herrera-Viedma, A. López-Herrera, and C. Porcel, *Tuning the matching function for a threshold weighting semantics in a linguistic information retrieval system*, *International Journal of Intelligent Systems* **20(9)** (2005), 921–937.
- [88] E. Herrera-Viedma, L. Martínez, F. Mata, and F. Chiclana, *A consensus support system model for group decision-making problems with multi-granular linguistic preference relations*, *IEEE Transactions on Fuzzy Systems* **13(5)** (2005), 644–658.
-

- [89] E. Herrera-Viedma and G. Pasi, *Soft approaches to information retrieval and information access on the web: An introduction to the special issue. special issue on soft approaches to information retrieval and information access on the web*, Journal of the American Society for Information Science and Technology **57** (2006), no. 4, 511–514.
- [90] E. Herrera-Viedma, G. Pasi, and F. Crestani, *Soft computing in web information retrieval: Models and applications. studies in fuzziness and soft computing series, vol. 197*, Physica-Verlag, 2006.
- [91] E. Herrera-Viedma, G. Pasi, A. López-Herrera, and C. Porcel, *Evaluating the information quality of Web sites: A qualitative methodology based on fuzzy computing with words*, Journal of the American Society for Information Science and Technology **57** (2006), no. 4, 538–549.
- [92] E. Herrera-Viedma and E. Peis, *Evaluating the Informative Quality of Documents in SGML Format from Judgements by Means of Fuzzy Linguistic Techniques Based on Computing With Words*, Information Processing & Management **39** (2003), no. 2, 233–249.
- [93] E. Herrera-Viedma, C. Porcel, and L. Hidalgo, *Sistemas de recomendaciones: herramientas para el filtrado de información en internet*, 2004.
- [94] E. Herrera-Viedma, C. Porcel, A. López, M. Olvera, and K. Anaya, *A fuzzy linguistic multi-agent model for information gathering on the web based on collaborative filtering techniques*, Lecture Notes in Artificial Intelligence **3034** (2004), 3–12.
- [95] E. Herrera-Viedma, C. Porcel, A. G. López-Herrera, and S. Alonso, *A fuzzy linguistic recommender system to advice research resources in university digital libraries*, Fuzzy Sets and Their Extensions: Representation, Aggregation and Models, Springer, 2008, pp. 567–585.
-

- 
- [96] W. Hill, L. Stead, M. Rosenstein, and G. Furnas, *Recommending and evaluating choices in a virtual community of use*, Proceedings of the SIGCHI conference on Human factors in computing systems, ACM Press/Addison-Wesley Publishing Co., 1995, pp. 194–201.
- [97] J. E. Hirsch, *An index to quantify an individual's scientific research output*, Proceedings of the National academy of Sciences of the United States of America **102** (2005), no. 46, 16569–16572.
- [98] M. Hsu, *A personalized english learning recommender system for esl students*, Expert Systems with Applications **34** (2008), 377–408.
- [99] K. Huang, Y. Lee, and R. Wang, *Quality Information and Knowledge*, Prentice Hall PTR Upper Saddle River, NJ, USA, 1998.
- [100] W. Husain and L. T. Pheng, *The development of personalized wellness therapy recommender system using hybrid case-based reasoning*, Computer Technology and Development (ICCTD), 2010 2nd International Conference on, IEEE, 2010, pp. 85–89.
- [101] A. Jun, *A new similarity measure for collaborative filtering to alleviate the new user cold-starting problem*, Information Sciences **178(1)** (2008), 37–51.
- [102] R. Korfhage, *Information storage and retrieval*, New York: Wiley Computer Publishing, 1997.
- [103] R. Kostoff, R. Tshiteya, K. Pfeil, J. Humenik, and G. Karypis, *Power source roadmaps using bibliometrics and database tomography*, Energy **30** (2005), no. 5, 709–730.
-

- [104] D. Kraft, G. Bordogna, and G. Pasi, *Extended fuzzy linguistic approach to generalize boolean information retrieval*, Information Sciences **2** (1994), no. 3, 119–134.
- [105] D. Kraft, G. Pasi, and G. Bordogna, *Vagueness and uncertainty in information retrieval: How can fuzzy sets help?*, Proceedings of the 2006 International Workshop on Research Issues in Digital Libraries Table of Contents, ACM New York, NY, USA, 2006.
- [106] S. Lawrence and C. Giles, *Searching the web: General and scientific information access*, Communications Magazine **37(1)** (1999), 116–122.
- [107] S. Lawrence, C. Lee Giles, and K. Bollacker, *Digital libraries and autonomous citation indexing*, Computer **32** (1999), no. 6, 67–71.
- [108] S. Lawrence and C. L. Giles, *Searching the world wide web*, Science **280** (1998), no. 5360, 98–100.
- [109] Y. Lee, D. Strong, B. Kahn, and R. Wang, *AIMQ: A Methodology for Information Quality Assessment*, Information & Management **40** (2002), no. 2, 133–146.
- [110] D. M. Levy and C. C. Marshall, *Going digital: A look at assumptions underlying digital libraries*, Commun. ACM **38** (1995), no. 4, 77–84.
- [111] T. Liang, *Recommendation systems for decision support: An editorial introduction*, Decision Support Systems **45** (2008), 385–386.
- [112] P. Lops, M. Gemmis, and G. Semeraro, *Recommender systems handbook*, ch. Content-based Recommender Systems: State of the Art and Trends, pp. 73–106, Ricci, F. and Rokach, L. and Shapira, B. and Kantor, P.B. Eds. (Springer), 2011.
-

- 
- [113] I. Macho-Stadler, D. Perez-Castrillo, and R. Veugelers, *Licensing of university inventions: The role of a technology transfer office*, International Journal of Industrial Organization **25** (2007), 483–510.
- [114] J. Malinowski, T. Weitzel, and T. Keim, *Decision support for team staffing: An automated relational recommendation approach*, Decision Support Systems **45** (2008), 429–447.
- [115] G. Marchionini, *Research and development in digital libraries*, 2000.
- [116] G. Marchionini, *Research and development in digital libraries*, Encyclopedia of library and information science **63** (1998), 259–279.
- [117] L. Martínez, L. Pérez, M. Barranco, and M. Espinilla, *Improving the effectiveness of knowledge based recommender systems using incomplete linguistic preference relations*, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems **16(2)** (2008), 33–56.
- [118] M. Martínez, M. Herrera, J. López-Gijón, and E. Herrera-Viedma, *H-classics: characterizing the concept of citation classics through h-index*, Scientometrics **98** (2014), 1971–1983.
- [119] G. Meghabghab and A. Kandel, *Search engines, link analysis, and user's web behavior*, Springer-Verlag Berlin Heidelberg, 2008.
- [120] G. Miller, *The magical number seven or minus two: some limits on our capacity of processing information*, Psychological Review **63** (1956), 81–97.
- [121] M. Montaner, B. López, and J. L. De La Rosa, *A taxonomy of recommender agents on the internet*, Artificial intelligence review **19** (2003), no. 4, 285–330.
-

- [122] J. Morales-del Castillo, E. Peis, J. Moreno, and E. Herrera-Viedma, *D-fusion: A semantic selective dissemination of information service for the research community in digital libraries*, Information Research **14** (2009), no. 2, paper 398.
- [123] A. Moro-Martín, *Spanish changes are scientific suicide*, Nature **482** (2012), no. 7385, 277–277.
- [124] F. Narin, K. S. Hamilton, and D. Olivastro, *The increasing linkage between u.s. technology and public science*, Research Policy **26** (1997), no. 3, 317 – 330.
- [125] F. Naumann, *Quality-Driven Query Answering for Integrated Information Systems*, Lectures Notes in Computer Sciences **2261** (2002).
- [126] L. Olsina and G. Rossi, *Measuring Web Application Quality With Web-QEM*, IEEE Multimedia **2002** (2002), 20–29.
- [127] G. Pasi, *Modeling users' preferences in systems for information access*, International Journal of Intelligent Systems **18(7)** (2003), 793–808.
- [128] M. J. Pazzani, *A framework for collaborative, content-based and demographic filtering*, Artificial Intelligence Review **13** (1999), no. 5-6, 393–408.
- [129] P. Perny and J. Zucker, *Collaborative filtering methods based on fuzzy preference relations*, Proceedings of the EUROFUSE-SIC, Kluwer, 1999, pp. 279–285.
- [130] C. Porcel and E. Herrera-Viedma, *Dealing with incomplete information in a fuzzy linguistic recommender system to disseminate information in university digital libraries*, Knowledge-Based Systems **23** (2010), 32–39.
-

- 
- [131] C. Porcel, A. López-Herrera, and E. Herrera-Viedma, *A recommender system for research resources based on fuzzy linguistic modeling*, Expert Systems with Applications **36** (2009), no. 3, 5173–5183.
- [132] C. Porcel, J. Moreno, and E. Herrera-Viedma, *A multi-disciplinary recommender system to advice research resources in university digital libraries*, Expert Systems with Applications **36** (2009), no. 10, 12520–12528.
- [133] C. Porcel, A. Tejada-Lorente, M. Martínez, and E. Herrera-Viedma, *A hybrid recommender system for the selective dissemination of research resources in a technology transfer office*, Information Sciences **184** (2012), no. 1, 1 – 19.
- [134] L. Quiroga and J. Mostafa, *An experiment in building profiles in information filtering: the role of context of user relevance feedback*, Information Processing and Management **38** (2002), 671–694.
- [135] A.-R. Ramos-Rodríguez and J. Ruíz-Navarro, *Changes in the intellectual structure of strategic management research: A bibliometric study of the strategic management journal, 1980–2000*, Strategic Management Journal **25** (2004), no. 10, 981–1004.
- [136] P. Refaeilzadeh, L. Tang, and H. Liu, *Cross-validation*, 2008.
- [137] P. Resnick and H. Varian, *Recommender systems*, Special issue of Communications of the ACM **40(3)** (1997), 56–59.
- [138] M. Renda and U. Straccia, *A personalized collaborative digital library environment: a model and an application*, Information Processing and Management **41** (2005), 5–21.
- [139] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom, and J. Riedl, *GroupLens: An open architecture for collaborative filtering of netnews*, Proc.
-

- 1994 Computer Supported Cooperative Work Conf, ACM Press, 1994, pp. 175–186.
- [140] S. Rieh, *Judgment of Information Quality and Cognitive Authority in the Web.*, Journal of the American Society for Information Science and Technology **53** (2002), no. 2, 145–161.
- [141] S. Robertson, *Understanding inverse document frequency: on theoretical arguments for idf*, Journal of documentation **60** (2004), no. 5, 503–520.
- [142] R. Rodríguez, L. Martínez, V. Torra, Z. Xu, and F. Herrera, *Hesitant fuzzy sets: State of the art and future directions*, International Journal of Intelligent Systems **29** (2014), no. 6, 495–524.
- [143] R. Rodríguez, L. Martínez, and F. Herrera, *Hesitant fuzzy linguistic term sets for decision making*, Fuzzy Systems, IEEE Transactions on **20** (2012), no. 1, 109–119.
- [144] L. Ross and P. Sennyey, *The Library is Dead, Long Live the Library! The Practice of Academic Librarianship and the Digital Revolution*, The Journal of Academic Librarianship **34** (2008), no. 2, 145–152.
- [145] L. Ross and P. Sennyey, *The library is dead, long live the library! the practice of academic librarianship and the digital revolution*, The Journal of Academic Librarianship **34** (2008), no. 2, 145–152.
- [146] C. Rusbridge, *Towards the hybrid library*, (1998).
- [147] B. Sarwar, G. Karypis, J. Konstan, and R. J., *Item-based collaborative filtering recommendation algorithms*, Proceedings of the ACM World Wide Web Conference, 2001, pp. 285–295.
-

- 
- [148] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, *Analysis of recommendation algorithms for e-commerce*, Proceedings of ACM E-Commerce 2000 conference (2000), 158–167.
- [149] J. B. Schafer, J. Konstan, and J. Riedl, *E-commerce recommendation applications*, Applications of Data Mining to Electronic Commerce, Springer, 2001, pp. 115–153.
- [150] J. Schafer, D. Frankowski, J. Herlocker, and S. Sen, *The adaptive web*, ch. Collaborative filtering recommender systems, pp. 291–324, Springer Berlin - Heidelberg, 2007.
- [151] J. Schafer, J. Konstan, and J. Riedl, *Recommender systems in e-commerce*, Proceedings of the 1st ACM conference on Electronic commerce, ACM, 1999, pp. 158–166.
- [152] R. Schenkel, T. Crecelius, M. Kacimi, T. Neumann, J. Parreira, M. Spaniol, and G. Gerhard Weikum, *Social wisdom for search and recommendation*, Data Engineering Bulletin **31(2)** (2008), 40–49.
- [153] G. Shani and A. Gunawardana, *Recommender systems handbook*, ch. Evaluating Recommendation Systems, pp. 257–298, Ricci, F. and Rokach, L. and Shapira, B. and Kantor, P.B. Eds. (Springer), 2011.
- [154] P. Spyridonos, G. Gaitanis, M. Tzaphlidou, and I. D. Bassukas, *Spatial fuzzy c-means algorithm with adaptive fuzzy exponent selection for robust vermilion border detection in healthy and diseased lower lips*, Computer methods and programs in biomedicine **114** (2014), no. 3, 291–301.
- [155] D. Strong, Y. Lee, and R. Wang, *Data Quality in Context*, Communications of the ACM **40** (1997), no. 5, 103–110.
-

- 
- [156] M. Sushmita and H. Larsen, *Special issue on web mining using soft computing*, Fuzzy Sets and Systems **148** (2004), no. 1, 1–3.
- [157] P. Symeonidis, A. Nanopoulos, A. Papadopoulos, and Y. Manolopoulos, *Collaborative recommender systems: Combining effectiveness and efficiency*, Expert Systems with Applications **34(4)** (2008), 2995–3013.
- [158] M. Tavana, E. Momeni, N. Rezaeiniya, S. M. Mirhedayatian, and H. Rezaeiniya, *A novel hybrid social media platform selection model using fuzzy anp and copras-g*, Expert Systems with Applications **40** (2013), no. 14, 5694–5702.
- [159] A. Tejada-Lorente, C. Porcel, M. Martinez, A. López-Herrera, and E. Herrera-Viedma, *Using memory to reduce the information overload in a university digital library*, Intelligent Systems Design and Applications (ISDA), 2011 11th International Conference on, 2011, pp. 444–449.
- [160] A. Tejada-Lorente, C. Porcel, E. Peis, R. Sanz, and E. Herrera-Viedma, *A quality based recommender system to disseminate information in a university digital library*, Information Sciences **261** (2014), no. 0, 52 – 69.
- [161] V. Torra, *Negation functions based semantics for ordered linguistic labels*, International Journal of Intelligent Systems **11** (1996), no. 11, 975–988.
- [162] V. Torra, *Aggregation of linguistic labels when semantics is based on antonyms*, International Journal of Intelligent Systems **16** (2001), no. 4, 513–524.
- [163] ———, *Hesitant fuzzy sets*, International Journal of Intelligent Systems **25** (2010), no. 6, 529–539.
-

- 
- [164] G. Tyburski, *Get Smart About Web Site I.Q.*, 2002, Retrieved April 1, 2010, from <http://searchenginewatch.com/searchday/article.php/2159621>.
- [165] A. F. Van Raan, *Measuring science*, Handbook of quantitative science and technology research, Springer, 2005, pp. 19–50.
- [166] C. Van Rijsbergen, *Information retrieval*, Butterworth, 1979.
- [167] N. Walliman, *Your research project: a step-by-step guide for the first-time researcher*, Sage, 2005.
- [168] R. Wang and D. Strong, *Beyond Accuracy: What Data Quality Means to Data Consumers*, Journal of Management Information Systems **12** (1996), no. 4, 5–34.
- [169] C. J. Williams, M. O'Rourke, S. D. Eigenbrode, I. O'Loughlin, and S. J. Crowley, *Using bibliometrics to support the facilitation of cross-disciplinary communication*, Journal of the American Society for Information Science and Technology **64** (2013), no. 9, 1768–1779.
- [170] R. Yager, *On ordered weighted averaging aggregation operators in multicriteria decision making*, IEEE Transactions on Systems, Man, and Cybernetics **18** (1988), no. 1, 183–190.
- [171] R. Yager, *Fuzzy logic methods in recommender systems*, Fuzzy Sets and Systems **136** (2003), no. 2, 133–149.
- [172] G. Zacharia, A. Moukas, and P. Maes, *Collaborative reputation mechanisms for electronic marketplaces*, Decision Support Systems **29** (2000), no. 4, 371–388.
- [173] L. Zadeh, *Fuzzy Sets*, Information and Control **8** (1965), no. 3, 338–353.
-

- [174] ———, *The concept of a linguistic variable and its applications to approximate reasoning. Part I*, *Information Sciences 8 (1975) 199-249*, *Part II*, *Information Sciences 8 (1975) 301-357*, *Part III*, *Information Sciences 9 (1975) 43-80*, 1975.
- [175] ———, *Fuzzy logic, neural networks, and soft computing*, *Communications of the ACM* **37** (1994), no. 3, 77–84.
- [176] ———, *What is soft computing?*, *Soft Computing* **1** (1997), no. 1, 1.
- [177] L. Zadeh and J. Kacprzyk, *Fuzzy logic for the management of uncertainty*, John Wiley & Sons, Inc., 1992.
-