# TRABAJANDO CON RELACIONES DE PREFERENCIA LINGÜÍSTICAS DIFUSAS INCOMPLETAS PARA RECOMENDAR RECURSOS DE INVESTIGACIÓN EN UNA BIBLIOTECA DIGITAL UNIVERSITARIA

**Carlos Porcel**[1] **Enrique Herrera-Viedma**[2]

[1] Universidad de Jaén, Dept. Informática, cporcel@ujaen.es
[2] Universidad de Granada, Dept. Ciencias de la Computación e IA, viedma@decsai.ugr.es

## Resumen

En trabajos previos hemos propuesto el uso de sistemas de recomendaciones lingüísticos difusos para difundir recursos de investigación en bibliotecas digitales universitarias. El problema es que el proceso de adquisición de las preferencias de los usuarios es bastante complejo y requiere demasiado esfuerzo por parte de los mismos. En este trabajo presentamos un sistema de recomendaciones lingüístico difuso que facilita ese proceso permitiendo que los usuarios expresen sus preferencias mediante relaciones de preferencia lingüísticas difusas incompletas. Se incluyen herramientas para gestionar la información incompleta cuando los usuarios expresan sus preferencias, mejorando la adquisición de los perfiles de usuario.

**Palabras Clave:** sistemas de recomendaciones, modelado lingüístico difuso, relaciones de preferencia incompletas.

## 1 INTRODUCCIÓN

Las bibliotecas digitales son colecciones de información que tienen asociados una serie de servicios que ofrecen a su comunidad de usuarios [4, 14]. Se han aplicado en numerosos ámbitos, pero nosotros nos vamos a centrar en un contexto académico. El acceso a Internet está motivando el uso cada vez más extendido de estas bibliotecas y que sus contenidos sean más variados, por lo que los usuarios esperan servicios cada vez más sofisticados [4, 14]. Un servicio particularmente importante es la difusión selectiva de información, para ayudar a los usuarios a acceder a información interesante para ellos. Los usuarios desarrollan perfiles de interés, y conforme se añade nuevo material (libros, artículos, informes, etc.) a la colección, los ítems relevantes son recomendados a los usuarios.

Los sistemas de recomendaciones evalúan y filtran la gran cantidad de información disponible y asisten a los usuarios en sus procesos de acceso a la información [3, 13]. En el marco de las Bibliotecas Digitales Universitarias (BDU), los sistemas de recomendaciones se pueden usar para ayudar a sus usuarios (profesores, estudiantes y personal de biblioteca) a encontrar y seleccionar información y fuentes de conocimiento [10].

En un sistema de recomendaciones, se usan las preferencias de los usuarios para definir perfiles de usuarios que son aplicados como filtros sobre el flujo de documentos [3, 13]. En [11, 12] desarrollamos sistemas de recomendaciones en un entorno académico. En [11] propusimos un sistema de recomendaciones lingüístico difuso para una oficina de transferencia de tecnología para ayudar a los investigadores y empresas a obtener automáticamente información sobre recursos de investigación en sus áreas de interés. En [12] propusimos un sistema de recomendaciones lingüístico difuso que recomienda recursos especializados pero también complementarios relacionados con las áreas de investigación. El problema de esos sistemas es que los usuarios deben especificar directamente sus preferencias, lo cual implica demasiado esfuerzo para ellos. En algunos casos son pocas las categorías que tienen que valorar, pero hay casos en los que el número podría ser mucho mayor; por ejemplo en [11] se trabaja con 248 categorías.

Sin embargo, un sistema de recomendaciones se puede ver como un problema de ayuda a la decisión, donde las posibles soluciones son los recursos de la BDU, y los criterios a satisfacer son los perfiles de los usuarios. Podríamos, pues, adoptar los formatos de representación típicos en toma de decisiones, como las relaciones de preferencias difusas que presentan un alto nivel de expresividad [6]. Sin embargo, hay situa-

ciones en las que los usuarios no son capaces de proporcionar todos los valores requeridos, por lo que tenemos que trabajar con *relaciones de preferencia incompletas* [1, 2, 9].

En este trabajo presentamos un nuevo sistema de recomendaciones lingüístico difuso definido en el entorno de una BDU en el que proponemos una forma alternativa de obtener conocimiento preciso y útil sobre las preferencias de los usuarios. El sistema permite a los usuarios expresar sus preferencias por medio de relaciones de preferencia incompletas [1], que se completan estimando los valores ausentes usando los métodos propuestos en [1, 2, 9], que se basan en la propiedad de consistencia aditiva y usando sólo valores de preferencia conocidos. Ello permite reducir la intervención por parte de los usuarios y mejorar el proceso de establecimiento de sus perfiles. El sistema propuesto recomienda recursos de investigación que mejor satisfacen las necesidades de los usuarios, así como posibilidades de colaboración para conocer investigadores de áreas relacionadas con los que podrán colaborar.

Como en [11, 12] aplicamos el Modelado Lingüístico Difuso (MLD) multi-granular [8], que aporta técnicas que permiten representar los distintos conceptos del sistema con diferentes conjuntos de etiquetas lingüísticas.

El trabajo se estructura de la siguiente forma. En la sección 2 se describe el MLD. En la sección 3 presentamos el nuevo modelo para filtrar recursos en una BDU. Por último, analizaremos las conclusiones obtenidas.

# 2 MODELADO LINGÜÍSTICO DIFUSO

El MLD es una herramienta basada en el concepto de variable lingüística [15] que ha dado muy buenos resultados para el modelado de información cualitativa en multitud de problemas.

## 2.1 MODELADO LINGÜÍSTICO DIFUSO 2-TUPLAS

El MLD 2-tuplas [7] es un modelo continuo de representación de la información que permite reducir la pérdida de información típica de otros enfoques lingüísticos (clásico y ordinal [5, 15]). Para definirlo, tenemos que establecer el modelo de representación y el modelo computacional de las 2-tuplas para representar y agregar respectivamente la información lingüística.

Consideremos que $\mathcal{S} = \{s_0, ..., s_g\}$ es un conjunto de términos lingüísticos con cardinalidad impar, donde la semántica asociada con cada una de las etiquetas viene dada por medio de funciones de pertenencia triangulares, y consideramos todos los términos distribuidos sobre una escala sobre la que hay establecida una relación de orden total. Si mediante un método de agregación de información lingüística, obtenemos un valor $\beta \in [0, g]$, y $\beta \notin \{0, ..., g\}$, podemos representar $\beta$ como una 2-tupla $(s_i, \alpha_i)$, donde $s_i$ representa la etiqueta lingüística, y $\alpha_i$ es un valor numérico que expresa la traslación de $\beta$ con respecto 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-tuplas: $\Delta(\beta) = (s_i, \alpha)$ y $\Delta^{-1}(s_i, \alpha) = \beta \in [0, g]$ [7].

Para establecer el modelo computacional, definimos operadores de negación, de comparación y de agregación. Usando las funciones $\Delta$ y $\Delta^{-1}$, podemos extender cualquiera de los operadores de agregación ya definidos para trabajar con 2-tuplas [7]. Algunos ejemplos son:

**Definición 2.1**. *Media aritmética.* Sea $x = \{(r_1, \alpha_1), \ldots, (r_n, \alpha_n)\}$ un conjunto de 2-tuplas, la 2-tupla que representa la media aritmética $\overline{x}^e$ se calcula como:

$$\overline{x}^e[(r_1, \alpha_1), \ldots, (r_n, \alpha_n)] = \Delta(\sum_{i=1}^{n} \frac{1}{n} \Delta^{-1}(r_i, \alpha_i)) =$$

$$\Delta(\frac{1}{n} \sum_{i=1}^{n} \beta_i).$$

**Definición 2.2**. Operador de *media ponderada lingüística.* Sea $x = \{(r_1, \alpha_1), \ldots, (r_n, \alpha_n)\}$ un conjunto de 2-tuplas y $W = \{(w_1, \alpha_1^w), ..., (w_n, \alpha_n^w)\}$ sus pesos asociados con valores 2-tupla. La media ponderada lingüística $\overline{x}_l^w$ es:

$$\overline{x}_l^w[((r_1, \alpha_1), (w_1, \alpha_1^w))...((r_n, \alpha_n), (w_n, \alpha_n^w))] =$$

$$\Delta(\frac{\sum_{i=1}^{n} \beta_i \cdot \beta_{W_i}}{\sum_{i=1}^{n} \beta_{W_i}}),$$

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

## 2.2 MODELADO LINGÜÍSTICO DIFUSO MULTI-GRANULAR

En cualquier enfoque, un parámetro importante que hay que determinar es la "granularidad de incertidumbre", es decir, la cardinalidad del conjunto de términos lingüísticos $S$. Según el 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. Cuando distintos expertos tienen diferentes grados de incertidumbre sobre el fenómeno o cuando un experto tiene que valorar distintos conceptos, se necesitan varios conjuntos de términos lingüísticos de diferente granularidad [8]. En tales situaciones necesitamos herramientas que nos permitan gestionar la información lingüística multi-granular. En [8] se propuso un MLD 2-tuplas multi-granular basado en el concepto de jerarquía lingüística. Una *Jerarquía Lingüística, LH,* es un conjunto de niveles $l(t, n(t))$, donde cada nivel $t$ es un conjunto de términos lingüísticos con una granularidad $n(t)$ diferente [8]. Los niveles están ordenados por granularidad, de manera que podemos definir un nivel a partir del anterior: $l(t, n(t)) \rightarrow l(t+1, 2 \cdot n(t) - 1)$. En [8] se definió una familia de funciones de transformación entre etiquetas de diferentes niveles. Para establecer el modelo computacional seleccionamos un nivel que usamos para uniformizar la información y así podemos usar los operadores definidos en el modelo 2-tuplas.

### 2.3 RELACIONES DE PREFERENCIA LINGÜÍSTICAS DIFUSAS INCOMPLETAS

**Definición 2.3**. Una relación de preferencia difusa $P$ sobre un conjunto de alternativas $X = \{x_1, .., x_n\}$ es un conjunto difuso sobre $X \times X$, es decir, es caracterizado por una función de pertenencia $\mu_P \colon X \times X \longrightarrow [0, 1]$.

Cuando la cardinalidad de $X$ es pequeña, la relación de preferencia puede ser convenientemente representada mediante la matriz $P = (p_{ij})$, con $p_{ij} = \mu_P(x_i, x_j)$ $(\forall i, j \in \{1, \ldots, n\})$ indicando el grado de preferencia de la alternativa $x_i$ sobre $x_j$, donde: $p_{ij} = 1/2$ indica indiferencia entre $x_i$ y $x_j$, $p_{ij} = 1$ indica que $x_i$ es absolutamente preferida a $x_j$, y $p_{ij} > 1/2$ indica que $x_i$ es preferida a $x_j$.

Sin embargo, nuestro sistema integra el MLD multi-granular basado en 2-tuplas, por lo que definimos una relación de preferencia de la siguiente manera.

**Definición 2.4**. Sea $X = \{x_1, .., x_n\}$ un conjunto de alternativas y $S$ un conjunto de términos lingüísticos. Una relación de preferencia lingüística $P = p_{ij} (\forall i, j \in \{1, \ldots, n\})$ sobre $X$ es:

$$\mu_P : X \times X \longrightarrow S \times [0.5, 0.5)$$

donde $p_{ij} = \mu_P(x_i, x_j)$ es una 2-tupla que denota el grado de preferencia de la alternativa $x_i$ respecto $x_j$.

Sin embargo, en problemas reales, los expertos no siempre son capaces de proporcionar todos los valores que son requeridos. Para modelar estas situaciones, definimos el concepto de relación de preferencia difusa incompleta [1, 2].

**Definición 2.5**. Una función $f \colon X \longrightarrow Y$ es *parcial* cuando no ocurre que cada elemento del conjunto $X$ necesariamente se corresponde con un elemento del conjunto $Y$.

**Definición 2.6**. Una *relación de preferencia difusa incompleta* $P$ sobre un conjunto de alternativas $X$ es un conjunto difuso sobre el conjunto $X \times X$ que se caracteriza mediante una función de pertenencia *parcial*.

## 3 DISEÑO DEL SISTEMA

En esta sección presentamos un nuevo sistema de recomendaciones lingüístico difuso en el que los perfiles de los usuarios se obtienen a partir de sus preferencias representadas por medio de relaciones de preferencia lingüísticas difusas incompletas [1]. Este sistema facilita la expresión de las preferencias de los usuarios y reduce el esfuerzo realizado por parte de los mismos. El sistema se usa para recomendar a los usuarios de una BDU sobre los recursos de investigación que mejor satisfacen sus preferencias, así como sugerencias de colaboración con otros investigadores.

En la figura 1 podemos observar el esquema básico de funcionamiento, que será explicado en las siguientes secciones.

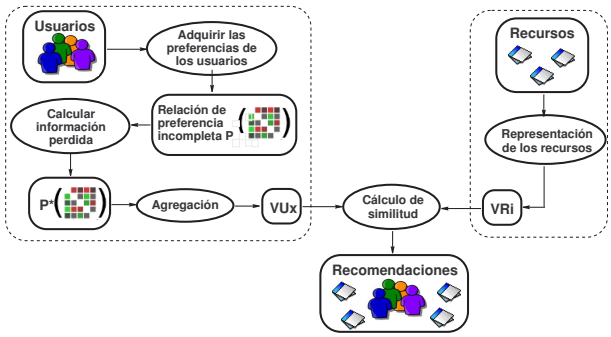


Figura 1: Esquema de funcionamiento.

### 3.1 REPRESENTACIÓN DE LA INFORMACIÓN

Para representar los distintos conceptos que tienen que ser valorados en la actividad del sistema, vamos a usar distintos conjuntos de etiquetas $(S_1, S_2, ...)$ seleccionados de una jerarquía lingüística [8]. Distinguimos cuatro conceptos que tienen que ser valorados:

- **Grado de importancia** ($S_1$) de una disciplina con respecto al ámbito de un recurso o las preferencias de un usuario.
- **Grado de relevancia** ($S_2$) de un recurso para un usuario.
- **Grado de compatibilidad** ($S_3$) entre dos usuarios.
- **Grado de preferencia** ($S_4$) de un recurso respecto de otro.

En nuestro sistema usamos conjuntos de etiquetas seleccionados de 2 niveles de una jerarquía lingüística de 3 niveles de 3, 5 y 7 etiquetas cada uno. En concreto, se usa el segundo nivel para asignar grados de importancia y grados de preferencia ($S_1 = S^5$ y $S_4 = S^5$), y el tercer nivel para asignar grados de relevancia y de compatibilidad ($S_2 = S^9$ y $S_3 = S^9$).

### 3.1.1 Representación de los recursos

Los recursos considerados son artículos de revista, contribuciones a congresos, capítulos de libro, libros o libros editados. El sistema obtiene una representación interna basada principalmente en el ámbito del recurso, para lo cual usamos una clasificación compuesta de 25 disciplinas (ver figura 2). Entonces, para representar un recurso $i$ adoptamos un modelo vectorial, es decir, obtenemos un vector $VR_i = (VR_{i1}, VR_{i2}, ..., VR_{i25})$, donde $VR_{ij} \in S_1$, con $j = \{1, ..., 25\}$, indica el grado de importancia de la disciplina $j$ con respecto al ámbito del recurso $i$.

Figura 2: Disciplinas para definir el ámbito de los recursos.

### 3.1.2 Perfiles de usuario

Los perfiles se componen de dos tipos de preferencias: sobre los tópicos de interés y sobre si desean o no colaborar con otros usuarios. La principal contribución de esta propuesta es la forma en que los usuarios proporcionan estas preferencias. Si usamos el modelo vectorial, como en trabajos previos, los usuarios deben insertar o modificar los valores asignados a las disciplinas, pero puede haber casos en los que el número sea muy elevado. Ello implicaría un esfuerzo aún mayor. En este modelo proponemos un método alternativo para obtener las preferencias de los usuarios sobre los tópicos de interés.

Pedimos a los usuarios que proporcionen sus preferencias sobre 5 recursos, usando una relación de preferencia lingüística difusa incompleta. Además, de acuerdo a los resultados presentados en [2], basta con que los usuarios proporcionen una fila de la relación. A continuación usamos el método propuesto en [2] para completar la relación, y entonces podemos obtener un vector que representa las preferencias de los usuarios sobre sus tópicos de interés. Veámos el proceso en detalle:

1. Adquirir las **preferencias de los usuarios** sobre un número limitado de recursos. El sistema muestra a los usuarios los 5 recursos más representativos, $R = \{r_1, .., r_5\}$ y les pide que expresen sus preferencias mediante una relación de preferencia lingüística difusa incompleta. En la relación de preferencia, cada valor $p_{ij} \in S_4$ representa el grado de preferencia de $i$ sobre $j$. Bastaría con proporcionar una única fila:

$$P = \begin{pmatrix} - & p_{12} & p_{13} & p_{14} & p_{15} \\ x & - & x & x & x \\ x & x & - & x & x \\ x & x & x & - & x \\ x & x & x & x & - \end{pmatrix} \quad (1)$$

Entonces el sistema completa la relación $P$ usando el método propuesto en [2], y obtenemos la relación $P^*$:

$$P^* = \begin{pmatrix} - & p_{12} & p_{13} & p_{14} & p_{15} \\ p^*_{21} & - & p^*_{23} & p^*_{24} & p^*_{25} \\ p^*_{31} & p^*_{32} & - & p^*_{34} & p^*_{35} \\ p^*_{41} & p^*_{42} & p^*_{43} & - & p^*_{45} \\ p^*_{51} & p^*_{52} & p^*_{53} & p^*_{54} & - \end{pmatrix} \quad (2)$$

donde $p_{1j} \in S_4$ son los grados insertados por el usuario sobre las preferencias del recurso $x_1$ con respecto a $x_j$, $p_{ii}$ indica indiferencia, y cada $p^*_{ij}$ es el grado estimado para el usuario sobre sus preferencias del recurso $x_i$ con respecto a $x_j$.

2. Obtener el **vector de preferencias del usuario**. Para calcular los grados de preferencia del recurso $i$ para un experto $DG$, podemos aplicar el operador de media aritmética definido en la definición

2.1 [7]: $DG_i = \overline{x}^e[p^*_{i1}, \ldots, p^*_{i5}]$. Ahora podemos obtener el vector de preferencias del usuario $x$, es decir, $VU_x = (VU_{x1}, VU_{x2}, ..., VU_{x25})$, a partir de la agregación de los vectores que representan las características de los recursos seleccionados ($\{VR_1, ..., VR_5\}$) ponderados por los grados de preferencias $\{DG_1, \ldots, DG_5\}$, usando el operador $\overline{x}^w_l$ definido en la definición 2.2 [7]: $VU_{xk} = \overline{x}^w_l[(VR_{1k}, DG_1), \ldots, (VR_{5k}, DG_5)]$, con $k = \{1, \ldots, 25\}$.

Completamos el perfil del usuario consultando sus preferencias de colaboración, es decir, si desea colaborar o no.

### 3.2 ESQUEMA DE RECOMENDACIÓN

En esta fase se generan las recomendaciones que se envían a los usuarios. Nos basamos en un proceso de cálculo de similitud entre los perfiles de los usuarios y la representación de los recursos. Como los componentes de los vectores son valores lingüísticos, la similitud entre dos vectores ($\sigma_l(V_1, V_2) \in S_1$) la calculamos definiendo la medida del coseno en un entorno lingüístico:

$$\sigma_l(V_1, V_2) = \Delta(g \times \frac{\sum_{k=1}^{n}(\hbar_1 \times \hbar_2)}{\sqrt{\sum_{k=1}^{n}(\hbar_1)^2} \times \sqrt{\sum_{k=1}^{n}(\hbar_2)^2}})$$

donde $g$ es la granularidad de $S_1$, $\hbar_i = \Delta^{-1}(v_{ik}, \alpha_{vik})$ y $(v_{ik}, \alpha_{vik})$ es el 2-tupla del término $k$ en el vector $V_i$.

Cuando se inserta un nuevo recurso $i$, calculamos $\sigma_l(VR_i, VU_j)$, entre el vector que representa este nuevo recurso ($VR_i$) y los vectores de preferencias de todos los usuarios, $\{VU_1, \ldots, VU_m\}$, donde $m$ es el número de usuarios en el sistema.

Si $\sigma_l(VR_i, VU_j) \geq (s^9_6, 0)$ (umbral previamente definido para filtrar la información que se modifica en función de los resultados que se vayan obteniendo), el usuario $j$ es seleccionado para recomendarle el recurso $i$. A continuación el sistema aplica a cada $\sigma_l(VR_i, VU_j)$ la función de transformación definida en [8], para obtener el grado de relevancia del recurso $i$ para el usuario $j$, expresado usando una etiqueta del conjunto $S_2$.

Las preferencias de colaboración se usan para clasificar a los usuarios en colaboradores $\mathcal{U}_\mathcal{C}$ y no colaboradores $\mathcal{U}_\mathcal{N}$. Para los usuarios de $\mathcal{U}_\mathcal{N}$ el sistema les envía la información del recurso junto con su grado estimado de relevancia.

Para los usuarios de $\mathcal{U}_\mathcal{C}$ el sistema calcula las posibilidades de colaboración. Para ello, entre cada dos usuarios $x, y \in \mathcal{U}_\mathcal{C}$:

1. Calcular $\sigma_l(VU_x, VU_y)$.
2. Obtener el grado de compatibilidad lingüístico entre ambos usuarios, que será expresado como etiqueta de $S_3$.

Por último se envía a los usuarios de $\mathcal{U}_\mathcal{C}$ la información sobre el recurso, su grado de relevancia lingüístico estimado y las recomendaciones sobre colaboraciones junto con su grado de compatibilidad lingüístico.

### 3.3 EVALUACIÓN DEL SISTEMA

Actualmente tenemos implementada una versión de pruebas, en la que el sistema funciona sólo con unos pocos investigadores. Esta versión ha sido usada para probar la funcionalidad, pero estamos trabajando para obtener una versión más completa. Cuando los usuarios reciben recomendaciones, valoran la relevancia de dichas recomendaciones y usamos estas opiniones para evaluar el sistema, comparándolas con las sugerencias del personal de biblioteca.

Para este primer estudio consideramos un conjunto de datos con 30 recursos de distintas áreas que fueron insertados en el sistema. Inicialmente limitamos estos experimentos a 6 usuarios que completaron el proceso de registro e insertaron sus preferencias acerca de los 5 recursos más relevantes presentados por el sistema. Los perfiles obtenidos a partir de dicha información junto con los recursos previamente insertados, constituyeron el conjunto de entrenamiento. Entonces, añadimos 20 nuevos recursos que constituyeron el conjunto de datos de pruebas. El sistema filtró estos 20 recursos y los recomendó a los usuarios apropiados. Para obtener datos con los que comparar, los 20 recursos también fueron recomendados usando las sugerencias del personal de biblioteca.

Con esta información podemos calcular la precisión (proporción de ítems relevantes seleccionados con respecto al total de ítems seleccionados), recall (proporción de ítems relevantes seleccionados con respecto al total de ítems relevantes) y F1 (combinación de ambas: $F1 = \frac{2 \times recall \times precision}{recall + precision}$), que son las métricas habitualmente usadas para evaluar la calidad de las recomendaciones [10]. Las medias para la precisión, recall y F1 son de 67.50%, 61.39% y 63.51%, respectivamente. Aunque se apliquen en ámbitos ligeramente distintos, y con distintos experimentos, si comparamos este valor F1 con los obtenidos en sistemas anteriores [11, 12], 54.49% y 65.05% respectivamente, observamos un buen rendimiento del sistema propuesto, a falta, eso sí, de una comparación más precisa con algún sistema que aplique un esquema similar, usando datos reales y planteando los mismos experimentos. Pero a pesar de estos resultados, destacamos que ahora la ob-

tención de perfiles de usuario requiere menor esfuerzo por parte de los mismos.

## 4 CONCLUSIONES

Hemos presentado un sistema de recomendaciones lingüístico difuso multi-granular para la difusión de recursos de investigación pero integrando un nuevo método para facilitar la adquisición de las preferencias de los usuarios. Éstos no proporcionan directamente sus vectores de preferencias, sino que proporcionan dichas preferencias por medio de relaciones de preferencia lingüísticas difusas incompletas. Los perfiles de los usuarios son completados con sus preferencias sobre si desean colaborar o no con otros usuarios. Así, este sistema de recomendaciones actúa como un sistema de ayuda a la decisión que toma decisiones sobre los recursos que más podrían interesar a un investigador, así como sobre posibilidades de colaboración con otros investigadores para formar grupos de trabajo. Los resultados experimentales obtenidos muestran la satisfacción de los usuarios con las recomendaciones recibidas. Como principal trabajo futuro, nos planteamos estudiar la viabilidad sobre la obtención de las preferencias de los usuarios de forma automática, lo cual facilitaría aún más dicho proceso a pesar del coste computacional que ello supondría.

**Agradecimientos**

Este trabajo ha sido desarrollado con la financiación de los proyectos Proyecto de Excelencia Andaluz TIC05299, FUZZYLING (TIN2007-61079) y PETRI (PET2007-0460).

## Referencias

[1] S. Alonso, F.J. Cabrerizo, F. Chiclana, F. Herrera, E. Herrera-Viedma. Group decision-making with incomplete fuzzy linguistic preference relations. *International Journal of Intelligent Systems*, 24(2), 201-222, 2009.

[2] S. Alonso, F. Chiclana, F. Herrera, E. Herrera-Viedma, J. Alcalá-Fdez, C. Porcel. A Consistency-Based Procedure to Estimating Missing Pairwise Preference Values. *International Journal of Intelligent Systems*, 23, 155-175, 2008.

[3] R. Burke. Hybrid Web Recommender System. *P. Brusilovsky, A. Kobsa, and W. Nejdl (Eds.): The Adaptive Web, LNCS* 4321, 377-408, 2007.

[4] M. A. Gonçalves, E. A. Fox, L. T. Watson, N. A. Kipp. Streams, structures, spaces, scenarios, societies (5s): A formal model for digital libraries. *ACM Transactions on Information Systems*, 22(2), 270-312, 2004.

[5] F. Herrera, E. Herrera-Viedma. Aggregation operators for linguistic weighted information. *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems*, 27, 646-656, 1997.

[6] F. Herrera, E. Herrera-Viedma. Choice functions and mechanisms for linguistic preference relations. *European Journal of Operational Research*, 120, 144-161, 2000.

[7] F. Herrera, L. Martínez. A 2-tuple fuzzy linguistic representation model for computing with words. *IEEE Transactions on Fuzzy Systems*, 8(6), 746-752, 2000.

[8] F. Herrera, 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), 227-234, 2001.

[9] E. Herrera-Viedma, F. Chiclana, F. Herrera, 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), 176-189, 2007.

[10] A.W. Neumann. Recommender Systems for Information Providers: Designing Customer Centric Paths to Information. *Heidelberg: Physica-Verlag*, 2009.

[11] C. Porcel, A.G. López-Herrera, E. Herrera-Viedma. A recommender system for research resources based on fuzzy linguistic modeling. *Expert Systems with Applications*, 36, 5173-5183, 2009.

[12] C. Porcel, J.M. Moreno, E. Herrera-Viedma. A Multi-disciplinar Recommender System to Advice Research Resources in University Digital Libraries. *Expert Systems with Applications*, 36(10), 12520-12528, 2009.

[13] P. Reisnick, H.R. Varian. Recommender Systems. *Special issue of Communications of the ACM*, 40(3), 56-59, 1997.

[14] L. Ross, 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(2), 145-152, 2008.

[15] L.A. Zadeh. The concept of a linguistic variable and its applications to approximate reasoning. *Part I. Information Sciences*, 8, 199-249, 1975. *Part II, Information Sciences*, 8, 301-357, 1975. *Part III, Information Sciences*, 9, 43-80, 1975.