

# UN MODELO DE RECOMENDACIÓN CON PERFILES DE USUARIO LINGÜÍSTICOS

L.G. Pérez, L. Martínez<sup>0</sup>, F. Mata, M. Barranco

Dept. Informática

Universidad de Jaén

23700 - Jaén, Spain

email: lgonzaga@ujaen.es, martin@ujaen.es, fmata@ujaen.es, barranco@ujaen.es

## Resumen

Hoy en día Internet se caracteriza por la gran cantidad de información que pone a disposición de los usuarios. Esta cantidad de información llega a ser abrumadora e incluso molesta. En algunos ámbitos de internet, principalmente en el comercio electrónico intentan resolver el problema de la sobreinformación con el uso de sistemas de recomendación, un software que ayuda a los usuarios en la compra de productos a través de Internet. En este trabajo proponemos el diseño de un sistema de recomendación basado en contenido que usa perfiles de usuarios lingüísticos y que emplea medidas de similitud y ranking difuso para realizar las recomendaciones.

**Palabras Clave:** sistemas de recomendación, ranking difuso, similitud, perfiles de usuario, teoría de conjuntos difusos

## 1 Introducción

Entre otras muchas cosas Internet se caracteriza por el gran volumen de datos e información disponibles para los usuarios. No es difícil que un usuario se sienta abrumado ante la gran cantidad de información recibida sobre una consulta y tampoco es difícil que mucha de esta información no sea útil y no se corresponda con las verdaderas necesidades del usuario. En el área del comercio electrónico [1] este problema se ha agudizado debido a la gran cantidad de productos que pueden ser devueltos ante una consulta simple aún cuando el

usuario esté buscando un producto en concreto. Dicho usuario puede sentirse frustrado e incluso molesto al recibir como respuesta a su consulta la recomendación de decenas de productos muchos de los cuales no satisfacen sus necesidades. Para evitar este problema, han surgido los sistemas de recomendación que permiten facilitar y personalizar las búsquedas de productos así como aumentar la fidelidad de los clientes y la calidad de las respuestas de los sistemas de comercio electrónico. [1].

Los sistemas de recomendación ayudan a los usuarios en los procesos de búsqueda en la red. Su propósito es recomendar los objetos o productos más adecuados, de un conjunto de éstos, de acuerdo con las necesidades y/o preferencias del usuario o del cliente. Desde este punto de vista, los sistemas de recomendación podrían ser vistos como un tipo de proceso de toma de decisiones, el cuál decide qué productos son los más adecuados para cada usuario.

Las principales estructuras de información que se emplean para la formación de recomendaciones son los perfiles de usuario y las representaciones de los objetos. El propósito de los perfiles de usuario es almacenar información relativa sobre los usuarios como pueden ser sus necesidades, gustos o áreas de interés y el propósito de las representaciones de los objetos es almacenar las descripciones de los productos que se pueden recomendar.

Los sistemas de recomendación actuales se clasifican atendiendo al tipo de información y fuentes que utilicen para sus recomendaciones, distinguiéndose tres tipos:

1. *Los sistemas de filtrado basado en contenido* [13]: filtran y recomiendan los elementos emparejando los términos de la consulta con los términos utilizados en la representación de los elementos, ignorando datos de otros usuarios
2. *Los sistemas de filtrado colaborativo* [9]: utilizan

<sup>0</sup>Soportado parcialmente por los proyectos de Investigación TIC2002-03348

información sobre las preferencias o los gustos de los usuarios, obtenidas de forma explícita y/o implícita, para filtrar y recomendar objetos a un usuario dado, ignorando la representación de los objetos.

3. *Sistemas híbridos basados en contenido y colaborativos* [5]: esta nueva clase de sistemas de recomendación ha surgido entre los sistemas basados en contenido y los colaborativos y su objetivo es minimizar las desventajas de cada uno. Un modo habitual de hibridar ambas clases es construir un algoritmo de filtrado de dos niveles, donde en el primer nivel, utilizamos el algoritmo de filtrado basado en contenido para poder obtener un primer conjunto de elementos y después, usamos el segundo algoritmo, el algoritmo de filtrado colaborativo, para filtrar y recomendar los elementos de este conjunto.

El propósito de este trabajo es presentar un modelo de sistema de recomendación basado en contenido, apoyado en medidas de similaridad y en perfiles de usuario lingüísticos y que utilizará ranking difuso para realizar recomendaciones sobre la compra de productos. Nuestro modelo de recomendación ha sido diseñado para tratar problemas en donde necesitamos recomendar una opción (o varias) de compra de productos de una forma rápida dentro un conjunto de posibles alternativas. En muchos casos la información de partida que proporcionan los usuarios es subjetiva y llena de imprecisión. El uso de la Aproximación Lingüística Difusa [19] ha dado buenos resultados al modelar este tipo de información mediante variables lingüísticas cuyos valores son términos lingüísticos en lugar de valores numéricos. Con lo cual los usuarios podrán expresar sus preferencias mediante etiquetas lingüísticas.

El modelo de sistema de recomendación basado en contenido propuesto en esta contribución seguirá el siguiente esquema de funcionamiento:

1. *Adquisición de perfiles de usuario*: Recogemos las preferencias del usuario y construimos su perfil de usuario utilizamos un vector de utilidades lingüísticas,  $P_u = \{p_1^u, p_2^u, \dots, p_l^u\}$ , donde cada  $p_i^u$  representará una preferencia del atributo  $i$  del usuario  $u$ .
2. *Cálculo del producto más adecuado para cada usuario de acuerdo a sus preferencias mediante el uso de medidas de similaridad* [4] con lo que obtendremos un conjunto difuso  $R_j^u$  que representará la similaridad.
3. *Ordenación los productos*: para ello emplearemos un ranking difuso [8, 14] y devolveremos los  $n$  mejores.

En la sección 2 revisaremos las herramientas utilizadas para la construcción de nuestro modelo de recomendación y en la sección 3 desarrollaremos nuestro modelo. Finalmente en la sección 4 expondremos las conclusiones obtenidas en nuestro estudio.

## 2 Preliminares

En esta sección hacemos un breve repaso a las herramientas utilizadas en el desarrollo de nuestro modelo de recomendación. En primer lugar revisaremos la aproximación lingüística difusa. A continuación explicaremos las medidas de similaridad que utilizaremos en nuestro modelo y finalmente hablaremos del ranking difuso, el cual usaremos para realizar las recomendaciones.

### 2.1 Aproximación lingüística difusa

Muchos aspectos de las actividades del mundo real no pueden ser descritas de forma cuantitativa adecuadamente pero sí de forma cualitativa, por ejemplo, cuando tratamos con información vaga o imprecisa. En estos casos, es mejor emplear valoraciones lingüísticas en vez de numéricas. La Aproximación Lingüística Difusa representa los aspectos cualitativos con valores lingüísticos por medio de variables lingüísticas [18]. Esta aproximación ha sido aplicado con resultados satisfactorios en diferentes problemas.

La elección del conjunto de términos lingüísticos junto a su semántica es el primer punto que debemos realizar para resolver un problema desde el punto de vista del enfoque lingüístico. Uno de los aspectos más importantes que tenemos que analizar en este punto es la “*granularidad de la incertidumbre*”, o lo que es lo mismo, el nivel de discriminación entre los distintos grados de incertidumbre. Los valores de cardinalidad mas utilizados son los impares, tales como el 7 y el 9, donde el término medio representa la valoración de “aproximadamente 0.5” y el resto de términos son colocados simétricamente alrededor de él [2]. Estos valores clásicos de cardinalidad parecen satisfacer las observaciones recogidas por Miller sobre el hecho de que los seres humanos pueden trabajar razonablemente teniendo en cuenta 7 o más objetos [12].

Una vez hemos establecido la cardinalidad del conjunto de términos, debemos proporcionar los términos lingüísticos y la semántica de los mismos. Existen diferentes posibilidades para realizar esta tarea [10]. Una de estas posibilidades implica proporcionar directamente el conjunto de términos considerando a todos los terminos distribuidos en una escala con un orden total definido [11]. Por ejemplo, un conjunto  $S$  de 7 términos, podría ser:

$$S = \{s_0 = Nada, s_1 = Muy bajo, s_2 = Bajo, s_3 = Medio, s_4 = Alto, s_5 = Muy Alto, s_6 = Perfecto\}$$

en donde  $s_a < s_b$  si y solo si  $a < b$ . Normalmente, en estos casos, es necesario que los términos lingüísticos satisfagan las siguientes condiciones adicionales:

1. Debe de existir un operador de negación. Por ejemplo,  $Neg(s_i) = s_j$ ,  $j = g - i$  (donde  $g + 1$  es la cardinalidad de  $S$ ).
2. Un operador de maximización:  $\max(s_i, s_j) = s_i$ , si  $s_i \geq s_j$ .
3. Un operador de minimización:  $\min(s_i, s_j) = s_i$ , si  $s_i \leq s_j$ .

La semántica de los términos se presentan por medio de números difusos, definidos en el intervalo  $[0, 1]$ , descritos por funciones de pertenencia. Una forma de caracterizar un número difuso es utilizar una representación basada en parametros de su función de pertenencia [2]. Las valoraciones lingüísticas dadas a los usuarios son solo aproximaciones, y por lo tanto, las funciones de pertenencia trapezoidales lineales son lo suficientemente buenas para capturar la vaguedad de estas valoraciones lingüísticas, [6]. Esta representación se consigue mediante una 4-tupla  $(a, b, d, c)$ , donde  $b$  y  $d$  indican el intervalo en el cual la función de pertenencia vale 1, con  $a$  y  $d$  indicamos los límites derecho e izquierdo del dominio de definición [2]. Un caso particular de esta representación es la función de pertenencia triangular, donde  $b = d$ , y que representaremos mediante una 3-tupla  $(a, b, c)$ . Por ejemplo, podemos asignar la siguiente semántica al conjunto de siete términos anteriormente visto:

$$\begin{aligned} N = s_0 &= (0, 0, 0.17) & MB = s_1 &= (0, 0.17, 0.33) \\ B = s_2 &= (0.17, 0.33, 0.5) & M = s_3 &= (0.33, 0.5, 0.67) \\ A = s_4 &= (0.5, 0.67, 0.83) & MA = s_5 &= (0.67, 0.83, 1) \\ P = s_6 &= (0.83, 1, 1) \end{aligned}$$

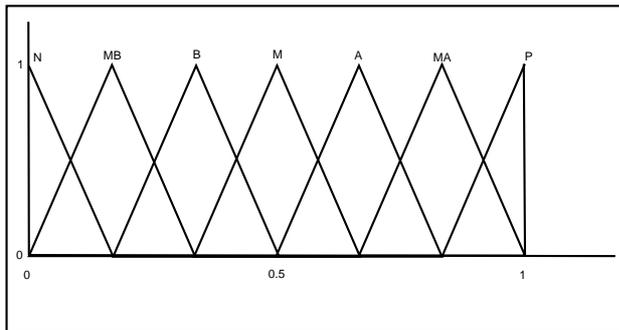


Figura 2. Representación gráfica de las funciones de pertenencia asignadas al conjunto  $S$ .

## 2.2 Medidas de similitud

La comparación de descripciones de objetos es una operación habitual en muchos dominios: psicología, analogía, ciencias físicas, procesado de imágenes, clustering, razonamiento deductivo, razonamiento basado en casos. Estas comparaciones frecuentemente se basan en medidas que intentan determinar que puntos tienen en común ambos objetos y en cuales difieren. Las medidas de comparación tiene varias formas dependiendo del propósito de su utilización. En [4] se consideran cuatro tipos de medidas de comparación:

1. Medidas de satisfiabilidad: La satisfiabilidad se corresponde a una situación en la cual consideraremos un objeto referencia y una clase y decidiremos si el nuevo objeto es compatible o satisface la referencia.
2. Medidas de semejanza: Se utilizan para realizar una comparación entre las descripciones de dos objetos del mismo nivel de generalidad para decidir si tienen muchas características comunes.
3. Medidas de inclusión: también se ocupa de situaciones en donde tenemos un objeto referencia, en este caso, medimos si los puntos en común entre  $A$  y  $B$  son importantes con respecto a  $A$ .
4. Medidas de disimilaridad: la disimilaridad entre objetos evalúa hasta que punto son diferentes.

Como hemos indicado anteriormente trabajaremos en un entorno difuso con valores imprecisos e inexactos. Las tres primeras medidas de comparación son medidas de similitud. En nuestro modelo de recomendación utilizaremos una medida de semejanza para medir la similitud entre las preferencias de los clientes y las características de los productos a recomendar. La medida que utilizaremos es la siguiente:

$$D(A, B) = \sup_x \min(f_A(x), f_B(x))$$

Ya que cumple las propiedades definidas en [3] para ser medida de semejanza y es ampliamente utilizada en la literatura para llevar a cabo estos procesos de medida de similitud.

## 2.3 Ranking difuso

En nuestro modelo de recomendación una vez se aplique una medida de similitud a los distintos productos con respecto a las preferencias de los clientes

se obtendrán conjuntos difusos que nos indicarán el grado de similaridad

Para poder establecer un orden entre varios elementos definidos por conjuntos difusos debemos poder establecer relaciones entre ellos. Para establecer estas relaciones utilizaremos las siguientes definiciones [8, 14]:

**Definición 1.** Dadas dos alternativas **a** y **b**, la sentencia “*a* es preferida a *b*” refleja la presencia de argumentos suficientes para apoyar la sentencia de que “*a* es preferida a *b*” pero no “*b* es preferida a *a*”. La credibilidad de que **a** es preferida a **b** se define como:

$$P(a, b) = \max \{S(a, b) - S(b, a), 0\}$$

Donde la función  $S$  representa el concepto de cuando **a** domina a **b**, ocurriendo esto solo si hay suficientes evidencias para creer que el concepto **a** es mejor que **b** o al menos **a** es tan bueno como **b**.

**Definición 2.** Dadas dos alternativas **a** y **b**, la sentencia “**a** y **b** son indiferentes” reflejan la presencia de argumentos suficientemente fuertes como para apoyar que “**a** domina a **b**” y “**b** domina a **a**”. La credibilidad de que **a** y **b** son indiferentes se define:

$$I(a, b) = \min \{S(a, b), S(b, a)\}$$

**Definición 3.** Dadas dos alternativas **a** y **b**, la sentencia “**a** y **b** son incomparables” refleja la ausencia de argumentos suficientemente fuertes para apoyar la afirmación de que “**a** domina a **b**” y “**b** domina a **a**”. La credibilidad de que **a** y **b** son incomparables se define:

$$J(a, b) = \min \{1 - S(a, b), 1 - S(b, a)\}$$

Gracias a estos tres índices podemos establecer un ranking de alternativas, de forma que:

- **a** es preferido a **b**  $\Leftrightarrow P(a, b) > I(a, b)$  y  $P(a, b) > J(a, b)$
- en otro caso, **a** es indiferente o incompatible con **b**.

**Definición 4.** Dada dos alternativas **a** y **b**, la sentencia “**a** domina a **b**” significa que el decisor tiene suficientes razones para admitir que **a** es al menos tan buena como **b**. Una relación de dominación indica el grado de dominación, denotado por  $S(a, b)$ , asociado con cada par de alternativas **a** y **b**, donde  $S(a, b) \in [0, 1]$ .

Si  $S(a, b) = 1$  sabemos que **a** domina a **b** con certeza. En el caso contrario,  $S(a, b) = 0$  implica que no hay

ninguna evidencia de que **b** sea dominada por **a**. Si  $S(a, b) \in (0, 1)$  entonces tenemos un índice de credibilidad de que **a** domina a **b**.

Nosotros emplearemos un enfoque de dominación difusa que es capaz de manejar las valoraciones representadas con conjuntos difusos de forma que podamos construir relaciones de dominación difusa entre las distintas alternativas. Para realizar esto nos basaremos en los trabajos de Dubois y Prade [7] que desarrollaron un conjunto de cuatro índices de dominancia,  $PG, PSG, NG$  y  $NSG$  dentro del marco de la teoría de la posibilidad de Zadeh [19].

Los cuatro índices pueden no obtener el mismo orden por lo que obligaría al decisor a realizar una última elección. Para solucionar este defecto del método de ranking y obtener una conclusión sin la necesidad de la colaboración de un decisor externo hemos empleado una función de agregación, el operador OWA (ordered weighted averaging) [17].

Para determinar el grado de dominancia entre dos conceptos necesitamos definir dos índices: *el índice de concordancia y el índice de discordancia*. Para dos conceptos **a** y **b**, el índice de discordancia,  $DI_k$ , expresa la credibilidad de la hipótesis de que **a** es al menos tan bueno como **b** con respecto a cierto criterio  $k$ . El índice de discordancia es utilizado para expresar dudas sobre la hipótesis de que **a** no es al menos tan bueno como **b** con respecto a algún criterio. El índice de concordancia,  $CI_k$ , se utiliza para construir el índice de concordancia global. Ambos índices, el índice de concordancia global  $GCI$  y el índice de discordancia los podemos encontrar definidos en [16].

Ahora, a partir de estos índices podemos construir el grado de dominancia  $S(a, b)$  [15]:

$$S(a, b) = \begin{cases} GCI(a, b) & \text{si } GCI(a, b) \geq DI_k(a, b), \\ \forall c_k \in C, \\ \prod_{k^*} [1 - DI_{k^*}(a, b)] \frac{GCI(a, b)}{1 - GCI(a, b)} & \text{para} \\ \{k^* | GCI(a, b) < DI_{k^*}(a, b)\} \end{cases}$$

donde  $c_k$  es el criterio  $k$ -ésimo del conjunto de criterios  $C$ .

### 3 Modelo de recomendación

A continuación mostraremos en detalle el modelo de recomendación que proponemos en esta contribución. Debemos recordar que el contexto en el que trabajaremos es un modelo de sistema de recomendación basado en contenido con perfiles de usuario lingüísticos y donde la información sobre los objetos está almacenada mediante información lingüística o números difusos. Nuestro modelo lleva a cabo 3 fases para realizar las recomendaciones (figura 2):

1. Adquisición de preferencias, en donde construiremos el perfil de usuario.
2. Cálculo del producto más adecuado al usuario de acuerdo a sus preferencias mediante el uso de medidas de similitud.
3. Ordenación de productos y recomendación de los  $n$  mejores teniendo en cuenta que la similitud de cada producto con el perfil de usuario estará representada mediante un conjunto difuso.

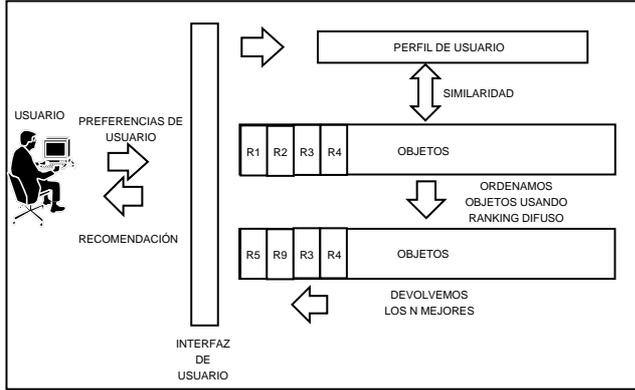


Figura 2. Funcionamiento del modelo de sistema de recomendación

En el diagrama anterior podemos ver el funcionamiento del modelo propuesto. A continuación plantearemos el problema a resolver y explicaremos más detenidamente cada una de estas fases.

### 3.1 Adquisición de los perfiles de usuario

Sea  $u$  el usuario que está interactuando con el sistema y desea obtener una recomendación. Sea  $C = \{c_1, \dots, c_k, \dots, c_l\}$  el conjunto de criterios/atributos que emplearemos a la hora de describir un objeto y la hora de describir las preferencias del usuario. Sea  $A = \{a_1, \dots, a_j, \dots, a_n\}$  el conjunto de alternativas o productos que pueden ser recomendados por el sistema, donde  $a_j = \{v_1^j, \dots, v_k^j, \dots, v_l^j\}$  y  $v_k^j$  será el valor que se le asigne al objetivo  $a_j$  en el criterio  $c_k$ . Este valor podrá ser una etiqueta y/o un número difuso que no tienen por qué coincidir con los utilizados en el perfil de usuario. Sea  $P_u = \{p_1^u, \dots, p_i^u, \dots, p_l^u\}$  el perfil del usuario  $u$  donde  $p_i^u$  es el valor que le asigna el usuario  $u$  al criterio  $c_i$ . Este valor será una etiqueta cualquiera de las propuestas por el sistema para dicho criterio.

El objetivo de nuestro modelo es: Dado un conjunto de productos  $A = \{a_1, \dots, a_n\}$  y un perfil de usuario  $P_u$  queremos recomendar aquel(los) producto(s)  $a_j$  que más se asemeje(n) a las necesidades del usuario expresadas por medio de su perfil  $P_u$ .

En primer lugar obtendremos la información del perfil de usuario  $P_u$  del usuario  $u$  al que queremos realizar una recomendación. El usuario podrá expresar sus opiniones o preferencias o necesidades sobre el conjunto de criterios/atributos  $C = \{c_1, \dots, c_k, \dots, c_l\}$  y al final de este proceso obtenemos su perfil  $P_u = \{p_1^u, \dots, p_i^u, \dots, p_l^u\}$ .

### 3.2 Cálculo del producto más adecuado.

Llegados a este punto, tenemos un perfil de usuario  $P_u$  con las preferencias del usuario descritas mediante etiquetas lingüísticas y un conjunto de productos  $A = \{a_1, \dots, a_n\}$  valorados por medio de números difusos y/o etiquetas lingüísticas en una serie de criterios/atributos  $C = \{c_1, \dots, c_k, \dots, c_l\}$ :

	$c_1$	$\dots$	$c_k$	$\dots$	$c_l$
$a_1$	$(v_1^1, \dots, v_k^1, \dots, v_l^1)$				
$\vdots$	$\vdots$		$\vdots$		$\vdots$
$a_j$	$(v_1^j, \dots, v_k^j, \dots, v_l^j)$				
$\vdots$	$\vdots$		$\vdots$		$\vdots$
$a_n$	$(v_1^n, \dots, v_k^n, \dots, v_l^n)$				

Tabla 1. Descripción del conjunto de productos  $A$ .

Para obtener una medida de cual es el producto más adecuado usaremos una medida de similitud [4], mas exactamente las de semejanza, entre el perfil de usuario  $P_u$  y cada alternativa  $a_i$ ,  $i = 1, \dots, l$ . De este cálculo obtendremos un conjunto difuso  $R_i^u = (r_1^i, \dots, r_k^i, \dots, r_l^i)$  en donde cada componente  $r_k^i$  será un grado de semejanza que mide la similitud (semejanza) entre las etiquetas que describe la valoración del usuario del criterio  $c_k$ ,  $p_k^u$ , y la etiqueta o número difuso que describe el valor del criterio  $c_k$  en la alternativa  $a_i$ ,  $v_k^j$ . La medida de similitud que hemos empleado ha sido:

$$D(A, B) = \sup_x \min(f_A(x), f_B(x))$$

Así, para calcular el grado de similitud  $R_j^u$  de la alternativa  $a_j$  con respecto al perfil de usuario  $P_u$  deberemos realizar lo siguiente:

$$R_j^u = D(P_u, a_j) = (r_1^j, \dots, r_l^j) = \left( \sup_x \min(p_1^u, v_1^j), \dots, \sup_x \min(p_l^u, v_l^j) \right)$$

### 3.3 Ordenamos los productos y devolvemos los $n$ mejores.

Una vez calculada la similitud de cada producto  $a_j$  con el perfil de usuario  $P_u$  queremos devolver aquella alternativa más cercana a las necesidades del usuario.

El proceso que tenemos que seguir en este punto para devolver los  $n$  mejores es encontrar algún método de ordenación de forma con si  $R_i^u \leq R_j^u$  quiere decir que la alternativa  $a_j$  satisface mejor las necesidades del usuario expresadas mediante el perfil  $P_u$  que la alternativa  $a_i$ . Para esta tarea emplearemos el método de ranking difuso expuesto en la sección 2.4.

## 4 Trabajos futuros

En el futuro nos proponemos mejorar este modelo de recomendación desde 2 puntos de vista:

- Incorporación de diferentes modelos de preferencias de distinta naturaleza (cuantitativa y cualitativa) y de distintos tipos de estructuras (ordenes, relaciones de preferencias,...).
- Estudiar el comportamiento del modelo cuando empleamos otros mecanismos de ranking difuso.

## Referencias

- [1] A. Ansari, S. Essegaiier, and R. Kohli. Internet recommendation systems. *Journal of Marketing Research*, XXXVII:363–375, August 2000.
- [2] P. Bonissone and K. Decker. *Selecting Uncertainty Calculi and Granularity: An Experiment in Trading-Off Precision and Complexity*. North-Holland, 1986.
- [3] B. Bouchon-Meunier and M. Rifqi. Resemblance in database utilization. *6th IFSA World Congress*, 1995.
- [4] B. Bouchon-Meunier, M. Rifqi, and S. Bothorel. Towards general measures of comparison of objects. *Fuzzy Sets and Systems*, (84):143–153, 1996.
- [5] M. Claypool, A. Gokhale, T. Miranda, P. Murnikov, D. Netes, and M. Sartin. Combining content-based and collaborative filters in an online newspaper. *Proceedings of the ACM SIGIR Workshop on Recommender Systems - Implementations and Evaluations*, 1999.
- [6] M. Delgado, J. Verdegay, and M. Vila. Linguistic decision making model. *International Journal of Intelligent Systems*, (7):479–492, 1992.
- [7] D. Dubois and H. Prade. Ranking fuzzy numbers in the setting of possibility theory. *Information Science*, (30):183–224, 1983.
- [8] J. Fodor and M. Roubens. *Fuzzy Preference Modelling and Multicriteria Decision Support*. Kluwer Academic Publisher, Dordrecht, 1994.
- [9] D. Golberg, D. Nichols, B.M. Oki, and D. Terry. Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, 35(12):61–70, 1992.
- [10] 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):43–58, 2000.
- [11] F. Herrera, E. Herrera-Viedma, and J. Verdegay. A sequential selection process in group decision making with linguistic assessment. *Information Science*, (85):223–239, 1995.
- [12] G. Miller. The magical number seven or minus two: Some limits on our capacity of processing information. *Psychological Review*, (63):81–97, 1956.
- [13] M. Pazzani, J. Muramatsu, and D. Billsus. Syskill and weber: Identifying interesting web sites. *In Proceedings of the Thirteenth National Conference on Artificial Intelligence AAAI*, 96:54–61, 1996.
- [14] B. Roy. *Partial Preference Analysis and Decision Aid: The Fuzzy Outranking Relation Concept*. O.E. Bell. R.L. Keeny, H. Raiffa, Chichester, New York, 1977.
- [15] J.L. Siskos, J. Lochard, and J. Lombard. *A Multicriteria Decision Making Methodology under Fuzzyness: Applications to the Evaluation of Radiological Protection in Nuclear Power Plants*. H.J. Zimmermann, North-Holland, Amsterdam, 1984.
- [16] J. Wang. Ranking engineering design concepts using a fuzzy outranking preference model. *Fuzzy Sets and Systems*, (119):161–170, 2001.
- [17] R.R. Yager. On ordered weighted averaging aggregation operators in multicriteria decisionmaking. *IEEE Transactions on Systems, Man and Cybernetics*, (18):183–190, 1988.
- [18] L.A. Zadeh. The concept of a linguistic variable and its application to approximate reasoning. *Information Science*, (8 and 9):(Part I and II) 8, pp 199–249 and pp. 301–357, (Part III) 9, pp. 43–80, 1975.
- [19] L.A. Zadeh. Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets and Systems*, (1):3–28, 1978.