

RECOMENDACIÓN DE PERFILES ACADÉMICOS MEDIANTE ALGORITMOS COLABORATIVOS BASADOS EN EL EXPEDIENTE

Emilio J. Castellano

Universidad de Jaén

Campus de las Lagunillas s/n, 23021. Jaén

Luis Martínez

Universidad de Jaén

Campus de las Lagunillas s/n, 23021. Jaén

Manuel Barranco

Universidad de Jaén

Campus de las Lagunillas s/n, 23021. Jaén

Luis G. Pérez Córdón

Universidad de Jaén

Campus de las Lagunillas s/n, 23021. Jaén

RESUMEN

Los Sistemas de Recomendación Colaborativos resultan ser muy útiles ayudando a seleccionar ítems dentro de grandes espacios de búsqueda, basándose en que individuos con preferencias similares suelen elegir y valorar ítems de forma parecida. Existen numerosas aplicaciones comerciales que avalan esta idea, especialmente en las áreas del comercio electrónico y del ocio; sin embargo, hay ámbitos, como el de la educación, que no aprovechan al máximo su potencial.

La elección de itinerarios académicos y/o materias optativas a cursar no suele ser una decisión fácil, ya que, en la mayoría de los casos, los alumnos carecen de la información, la madurez y el conocimiento necesarios para tomar decisiones acertadas. En esta contribución se evalúa el comportamiento de los Sistemas Colaborativos a la hora de ayudar y orientar al alumnado en este tipo de decisiones, comprobando el comportamiento y el impacto que en estos sistemas pueda tener el uso de unos datos tan distintos a los que usan habitualmente, como son las calificaciones del alumnado.

En base a este estudio se construye OriEB, un sistema encargado de orientar académicamente al alumnado cuando se enfrenta a la complicada decisión de elegir un perfil académico y unas materias a cursar en su siguiente etapa educativa.

PALABRAS CLAVES

Sistemas de Recomendación, Filtrado Colaborativo, Educación, Expediente, Perfil Académico

1. INTRODUCCIÓN

Las personas se enfrentan diariamente a situaciones en las que deben tomar decisiones, más o menos importantes, encontrándose a veces con un amplio volumen de alternativas a considerar. Principalmente son tres los elementos que juegan un papel fundamental en la toma de decisiones: (i) el grado de madurez del individuo, (ii) su nivel de conocimientos y (iii) la información que dispone relacionada con la decisión a tomar. Algunas veces, sobre todo en el caso de individuos con falta de experiencia, y en el ámbito concreto de la educación, los dos primeros pueden no alcanzar el grado deseable, por lo que es interesante

proporcionar herramientas que los asistan, ya sea proporcionando información relevante, o delimitando las opciones a contemplar, en definitiva, orientando en mayor o menor medida a la hora de tomar la decisión.

En la formación educativa de todo individuo existe un momento en el que debe tomar ciertas decisiones con respecto a su futuro: ¿qué tipo de formación me conviene, qué área elegir, qué itinerario académico seguir, que materias escoger...? Este hecho resulta inevitable y se produce en la mayoría de las etapas educativas, empezando por la Enseñanza Secundaria, en la que es cuestionable el grado de responsabilidad, madurez y/o conocimientos que los alumnos presentan a la hora de tomar estas importantes decisiones.

¿Existe entonces alguna forma de ayudar al alumnado en las tareas planteadas, ya sea delimitando el espectro de posibilidades, u orientando hacia qué camino educativo seguir? En esta contribución vamos a tratar de dar respuesta a esta pregunta mediante la propuesta de un Sistema de Recomendación basado en algoritmos de Filtrado Colaborativo (en adelante FC).

Los Sistemas de Recomendación son herramientas de ayuda para la toma de decisiones muy utilizadas en la actualidad, y de las cuales existe un amplio espectro de aplicaciones [Schafer et al. 2001; Resnick and Varian 1997], sobre todo para comercio electrónico y ocio. Existen diversos tipos de sistemas de recomendación que difieren en el método o proceso de obtención de las recomendaciones y/o en las fuentes de información usadas, pudiendo destacar: sistemas de recomendación colaborativos [Herlocker et al. 1999; Sarwar et al. 2001; Adomavicius and Tuzhilin 2005], sistemas basados en contenido [Pazzani 1999; Martínez et al. 2007], en información demográfica [Pazzani 1999], en conocimiento [Burke 2000; Pérez et al. 2007], en utilidad [Barranco et al. 2006], o hibridando alguna de estas técnicas [Burke 2002].

Los sistemas de recomendación colaborativos han sido los que mayor difusión han tenido debido a su simplicidad y buenos resultados. Dichos sistemas usan valoraciones de una comunidad de usuarios sobre una serie de ítems para recomendar a un usuario u un ítem i que aún no ha valorado, estimando el valor que u daría a los ítems candidatos en base al valor que asignaron sobre los i candidatos aquellos usuarios con un parecido historial de preferencias.

En esta contribución nosotros centramos el estudio de estos sistemas en el ámbito de la educación, donde evaluaremos la aplicación del FC en la recomendación asignaturas y/o perfiles estimando las calificaciones que obtendría un alumno, u , en las materias candidatas, basándonos en las calificaciones sobre las materias candidatas que alumnos con el mismo o parecido perfil académico que u obtuvieron en el pasado. Intentamos pues, estudiar la validez del uso del FC como herramienta válida para orientar al alumnado a la hora de tomar decisiones que impliquen alguno de los siguientes puntos: elección individual de materias, elección de perfiles o modalidades académicas, e incluso detección de asignaturas con potenciales problemas y necesidades de refuerzo para el individuo. Si los experimentos realizados aportan resultados satisfactorios se implementará un Sistema de Recomendación Colaborativo sobre el dominio expuesto.

Esta comunicación se estructura del siguiente modo: en la sección 2 se hace una breve descripción del funcionamiento de los sistemas colaborativos; en la sección 3 se expone en detalle nuestra propuesta de FC para la recomendación de perfiles académicos y/o asignaturas; en la sección 4 se presenta un sistema de recomendación para orientar al alumnado en el Bachillerato; en la sección 5 se concluye esta comunicación.

2. SISTEMAS DE RECOMENDACIÓN COLABORATIVOS

En la literatura existente se describen los Sistemas de Recomendación basados en FC como sistemas que trabajan recogiendo juicios humanos, expresados como votaciones, sobre una serie de ítems en un dominio dado, y tratan de emparejar personas que comparten las mismas necesidades o gustos [Herlocker et al. 1999; Pazzani 1999; Adomavicius and Tuzhilin 2005; Breese et al. 1998].

Los usuarios de un sistema colaborativo comparten sus valoraciones y opiniones con respecto a los ítems que conocen de forma que otros usuarios puedan decidir qué elección realizar. A cambio de compartir esta información, el sistema proporciona recomendaciones personalizadas para aquellos elementos que pueden resultar interesantes al usuario.

Es de destacar que en el FC son los usuarios, las personas, quienes determinan la relevancia, calidad e interés de los ítems, por lo que se puede realizar el filtrado sobre elementos difíciles de analizar mediante computación. El FC tiene la capacidad de discernir cómo se adapta un ítem a las necesidades o intereses de los usuarios, basándose en la propia capacidad humana de analizar en términos de calidad o gusto, tarea difícilmente realizable por procesos computacionales.

Los algoritmos FC pueden ser agrupados en dos clases generales [Adomavicius and Tuzhilin 2005; Breese et al. 1998]: los basados en memoria, que se basan en una vecindad completa de usuarios y sus valoraciones para el cálculo de predicciones [Herlocker et al. 1999; Adomavicius and Tuzhilin 2005], y los basados en modelos, que usan esas valoraciones para aprender un modelo que será el usado para predecir [Ungar and Foster 1998; Kim and Yum 2005; Breese et al. 1998].

La información manejada en FC consta de una serie de ítems, usuarios y valoraciones proporcionada por los usuarios sobre esos ítems: el espacio del problema viene definido como una matriz de usuarios frente a ítems, en la que cada celda representa la puntuación de un usuario concreto referida a un ítem específico (Tabla 1). En nuestro caso tal matriz estaría formada por calificaciones de alumnos en materias.

Resolver un problema típico de FC implica predecir qué valores tendría un usuario para aquellos ítems que aún no ha puntuado, basándonos para ello en las valoraciones aportadas anteriormente por la comunidad de usuarios [Adomavicius and Tuzhilin 2005; Herlocker et al. 1999]. En cuanto a la recomendación que se muestra al usuario, puede estar formada por los valores previstos para una serie de ítems, o bien por una lista formada por aquellos ítems que supuestamente al usuario deberían gustarle más, teniendo para ello en cuenta si deben o no mostrarse ítems ya votados.

Tabla 1. Representación del espacio de un problema asociado a FC.

	Superman	Titanic	Spiderman	American Pie	Matrix
Alex	9	1	9	6	10
Ricardo	4		3	10	4
Eva	8	2	9	7	8
Pedro	6	3	?	6	7

Para generar una predicción deben realizarse una serie de tareas [Herlocker et al. 1999]: establecer el valor de similitud entre el usuario activo y el resto, seleccionar un conjunto de usuarios para generar la predicción, y generar una predicción en base a combinaciones ponderadas de las valoraciones que realizaron los vecinos seleccionados.

Para establecer la similitud entre vecinos debemos definir una medida que nos permita evaluar el grado de parecido entre unos y otros. Existen diversas medidas para este cálculo siendo las más usadas de estas medidas son el Coeficiente de Correlación de Pearson y el Vector de Similitud o Coseno [Breese et al. 1998].

Una vez establecidas las similitudes entre el usuario activo y el resto de la comunidad, es necesario elegir cuáles de entre estos últimos se usarán para computar las predicciones, puesto que en términos de eficiencia y exactitud utilizar todos para el cálculo no sería viable. Por ello se suele escoger un número predeterminado K de vecinos, los K con mayor valor de similitud [Herlocker et al. 1999; Pazzani 1999]. Los dos procesos anteriores se realizan mediante la implementación de un algoritmo K -NN (K Nearest Neighbors).

Tras escoger el vecindario resta combinar las valoraciones de éste para producir una predicción [Adomavicius and Tuzhilin 2005; Herlocker et al. 1999]. La forma más sencilla de hacerlo es calcular una media ponderada de las predicciones, sin embargo, una de las aproximaciones más utilizadas y que mejores resultados da es calcular una suma media ajustada de dichas puntuaciones utilizando la media de valoración de cada individuo y las correlaciones como pesos [Adomavicius and Tuzhilin 2005; Herlocker et al. 1999].

Todo el proceso relatado hasta el momento se conoce como *filtrado colaborativo basado en usuario* (en adelante FC-U). Existe otro enfoque de la misma idea que surge para intentar solventar ciertos problemas de *escalabilidad* (conforme crece el número de valoraciones y usuarios, aumenta el tiempo de computación requerido) y *dispersión* (usuarios con valoraciones muy dispares pueden no encontrar recomendaciones al no encontrar vecinos adecuados) se ha propuesto en [Sarwar et al. 2001] una variante de filtrado colaborativo basada en ítems (FC-I) en la que en vez de estudiarse la similitud entre usuarios y proporcionar predicciones en base a sus votaciones se estudia el comportamiento de los propios ítems en sí, estableciendo cuáles presentan valoraciones similares y realizando predicciones en base a los propios ítems, y no a los usuarios. Por ejemplo, si se comprueba que los usuarios que votan *Matrix*, *Superman* y *Spiderman* lo hacen de forma similar, se pueden usar las valoraciones del usuario activo en dos de ellas para estimar la puntuación de la tercera (Tabla 1).

La construcción de estos sistemas se realiza de forma análoga al FC-U, con las mismas medidas, solo que en vez de explorar la matriz de usuarios-ítems por filas para establecer la similitud entre usuarios, se hace por columnas, para obtener similitudes entre ítems.

Por otro lado, los algoritmos FC-U están pensados para trabajar *online*. Esto quiere decir que se espera que en tiempo real el usuario solicite una recomendación y el sistema realice todos los cálculos necesarios

para aportar una recomendación. En FC-I lo que se pretende es buscar datos que sean computables *offline*, es decir, realizar la mayor parte del cálculo (correspondiente a encontrar la similitud entre ítems) antes de que el usuario solicite una recomendación, de forma que el coste computacional después de la solicitud sea mínimo.

Veamos ahora el comportamiento de estas técnicas en el ámbito propuesto y su impacto sobre los datos que pretendemos utilizar.

3. FC PARA RECOMENDAR MATERIAS Y PERFILES ACADÉMICOS

En las enseñanzas regladas que permiten algún grado de elección u optatividad encontramos ciertos patrones comunes en la estructura que presentan: existen alumnos que, matriculados en asignaturas, obtienen en ellas ciertas calificaciones; las asignaturas están asociadas a un curso, nivel o grado, y pueden presentar distintos tipos, según sean obligatorias, optativas, referidas a una modalidad o perfil concreto, habiendo agrupaciones de materias que formen perfiles o itinerarios educativos en caso de cursar todas o un grupo de ellas. Podemos definir un expediente académico como un conjunto de calificaciones obtenidas por un alumno para una serie de materias cursadas a lo largo de cierto periodo de tiempo.

El objetivo principal de esta contribución es responder a la siguiente pregunta: ¿Es posible utilizar el expediente académico de una persona para orientarle a la hora de escoger su futuro? Inicialmente la respuesta no es del todo clara, puesto que entran en juego factores subjetivos, psicológicos y aptitudinales.

Dado que las calificaciones de un individuo aportan información fiable sobre las aptitudes de ese alumno, las áreas en las que mejor se comporta, e incluso sus preferencias. Pretendemos evaluar si un Sistema de Recomendación Colaborativo, estimando la posible calificación que un alumno obtendría en una materia en caso de cursarla, puede proporcionar información relevante que, conjugada debidamente en un futuro con otro tipo de informaciones, termine dando lugar a un sistema capaz de ayudar a los individuos a la hora de tomar decisiones sobre su futuro. Para ello realizamos una serie de experimentos para obtener una respuesta fiable a la pregunta anterior.

3.1 Unos datos Singulares

El conjunto de datos que utilizaremos en los experimentos son las calificaciones de los alumnos en una serie de materias. Normalmente los sistemas de recomendación trabajan o bien con datos explícitos (directamente aportados por el usuario sobre sus propias percepciones), o bien implícitos (obtenidos automáticamente por el sistema en función del comportamiento del usuario) [Herlocker et al. 2004]. En el caso que nos ocupa los datos no se encuadran nítidamente en los tipos anteriores, puesto que las calificaciones son aportadas por una tercera persona experta en la materia, y no dependen directamente del usuario. Por tanto, es interesante comprobar qué funcionamiento puede tener el uso de FC en este tipo de datos tan singular.

El conjunto de datos utilizado está formado por un total de 744 alumnos anónimos de entre 4º de E.S.O. (Educación Secundaria Obligatoria), 1º y 2º de Bachillerato de 9 promociones procedentes de varios centros educativos andaluces, considerando hasta 100 asignaturas y un total de 15752 calificaciones, que contemplan valores enteros comprendidos entre el 0 y el 10. En las etapas educativas contempladas se empiezan a realizar decisiones del tipo de las expuestas anteriormente, existiendo distintos itinerarios educativos a seguir. Este es el motivo por el que se ha considerado interesante basar en ellas nuestro estudio.

3.2 Procedimiento Experimental

Para dar respuesta a la pregunta del inicio de esta sección, se han realizado numerosos experimentos para medidas de similitud y predicciones basadas en memoria, tanto con FC-U como con FC-I.

Indicar que para evaluar el comportamiento de los distintos algoritmos de FC se han utilizado las métricas de evaluación del Error Medio Absoluto (en adelante MAE), que estima la exactitud con la que el sistema realizará las predicciones, y la Cobertura, que calcula el porcentaje de ítems para los que el sistema es capaz de proporcionar una predicción [Herlocker et al. 2004].

En nuestros experimentos hemos estudiado el comportamiento de la mayoría de variantes conocidas de algoritmos FC [Breese et al. 1998; Herlocker et al. 1999], intentando optimizar diferentes parámetros como:

- Porcentajes de conjunto de entrenamiento y prueba

- Número de Vecinos
- Factor de relevancia
- Medidas de predicción

Cada experimento se ha ejecutado un mínimo de 40 veces. Dado el gran número de experimentos realizados sólo mostraremos en la *Tabla 2* los resultados obtenidos para aquellos que mejor comportamiento han mostrado en FC-I/U. Puede obtenerse una información más extensa al respecto de [Castellano 2007].

Tabla 2. Resultados experimentales.

	MAE obtenido para FC-I			MAE obtenido para FC-U			
	K=10	K=15	K=20	K=25	K=30	K=35	
N=20	0,9069	0,9053	0,9067	N=35	0,9319	0,9300	0,9308
N=25	0,9075	0,9036	0,9060	N=40	0,9278	0,9261	0,9271
N=30	0,9097	0,9020	0,9072	N=45	0,9278	0,9261	0,9272
N=35	0,9094	0,9026	0,9095	N=50	0,9249	0,9234	0,9243
N=40	0,9114	0,9045	0,9111	N=55	0,9304	0,9297	0,9292

Los valores de la *Tabla 2*, en el caso de FC-I corresponden al uso del coeficiente de correlación de Pearson como medida de similitud, a la que se aplica un factor de relevancia que parte de la idea de que serán más relevantes aquellas medidas de similitud en las que han participado un mayor número de valoraciones [Herlocker et al. 1999; Pazzani 1999]. Para ello se multiplica el coeficiente de correlación de Pearson por el número de alumnos usados en el cálculo de similitud (recordemos que estamos usando FC-I) dividido entre una constante N , que hemos ajustado a 30 tras haberse variado en los experimentos entre 5 y 60. El número de vecinos K escogidos para el cálculo de predicciones que mejor ha resultado ha sido 15, después de realizar pruebas con valores entre 5 y 50. Las predicciones del sistema se han calculado mediante la suma media ponderada y se le ha aplicado una mejora denominada amplificación de casos [Breese et al. 1998] que enfatiza en las predicciones aquellas valoraciones aportadas por vecinos con mayor similitud, penalizando los más lejanos.

En el caso de FC-U el que mejor resultados aportó es análogo al anterior, pero con ciertas diferencias (*Tabla 2*): para el cálculo del coeficiente de correlación de Pearson se fija la media a 5 para todos los alumnos, de modo que las similitudes se calculen de forma absoluta; N tomará el valor de 50 y K de 30. Los resultados obtenidos se muestran en la *Figura 1*.

En ambos casos los porcentajes de poblaciones de entrenamiento y prueba que mejor se comportan son del 80% y 20% respectivamente.

Como podemos verificar, el MAE en las predicciones es aceptable para las necesidades que pretendemos de nuestro estudio.. Mencionar que en FC-I la cobertura no baja del 99% y en FC-U del 98%. Se ha comprobado el comportamiento de ambos algoritmos agrupando las materias por tipos para corroborar si existía variación. Vemos que el mejor modelo es el basado en ítem, con un MAE global de 0,902 y sin mucha variación en función del tipo.

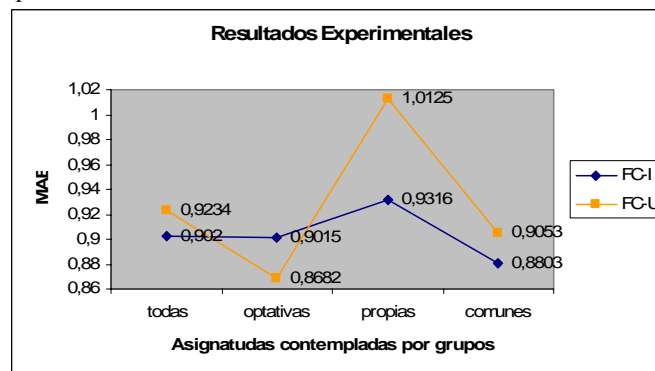


Figura 1. Cálculo del Error Absoluto Medio.

A continuación presentamos OriEB, una aplicación web que pretende orientar al alumnado de E.S.O. y Bachillerato en decisiones tales como escoger modalidad, seleccionar asignaturas, etc.

4. ORIEB – WEB DE ORIENTACIÓN PARA EL BACHILLERATO

Utilizando la información obtenida tras analizar los resultados derivados de los experimentos realizados, se ha querido implementar un pequeño sistema de orientación, OriEB, basado en el algoritmo que mejores resultados ha dado, para ayudar a aquellos alumnos que quieran cursar Bachillerato, partiendo de los datos que hemos usado en los experimentos.

La Figura 2 nos muestra la página de presentación del sistema OriEB, en la que se explica de forma breve y clara el tipo de recomendaciones que se realizan y se da una pequeña noción sobre cómo utilizar el sistema, que queda ampliada en la *ayuda*.



Figura 2. Página de presentación de OriEB.

El sistema realiza 3 tipos de recomendaciones: la modalidad de Bachillerato más adecuada para el individuo (a elegir de entre 4 posibles), las asignaturas de modalidad y optativas más recomendadas, y asignaturas obligatorias en las que el alumno puede requerir refuerzo educativo (Figuras 3, 4, 5 y 6).

(-) Recomendación de perfil	
Confianza	Modalidad
64.22%	Artes
60%	Humanidades y Ciencias Sociales
57%	Ciencias de la Naturaleza y de la Salud
54.5%	Tecnología

Figura 2. Recomendación de perfil o modalidad.

Dado que las recomendaciones se calculan en base a la similitud de los usuarios, y esta puede dar valores sesgados (alta similitud con números bajos de elementos en común), para aumentar la fiabilidad de las recomendaciones, el sistema proporcionará información adicional que expresa no sólo lo adecuada que es una recomendación para el individuo, sino también el grado de confianza que merece, teniendo en cuenta cómo esa recomendación es construida por el sistema basándose en las predicciones.

Teniendo en cuenta esto, construimos el grado de interés que una modalidad puede presentar para un alumno en base a 3 factores: (i) la media de las calificaciones correspondientes a las materias propias de dicha modalidad, (ii) la varianza en las calificaciones de dichas materias, y (iii) la cobertura de tales previsiones, considerando que cuantas más materias de entre todas las propias de la modalidad se contemplen, y cuanto menor sea la diferencia entre las calificaciones de dichas materias, mayor será el grado de confianza que nos puede aportar la media de las predicciones (Figura 2).



Figura 3. Recomendaciones para asignaturas propias de modalidad.



Figura 4. Recomendaciones para materias optativas.



Figura 5. Recomendaciones para refuerzo educativo.

Para el caso de recomendaciones individuales, se presentan listas ordenadas en base al interés calculado para cada ítem, obtenido en base a las predicciones realizadas por el algoritmo FC; además se muestra un porcentaje de confianza para la recomendación que tiene en cuenta dos factores: la varianza para la predicción concreta y el número de elementos que se utilizaron para elaborar la predicción, es decir, el número de materias similares usadas (Figuras 3 y 4). Al recomendar las materias propias de modalidad se muestran todas las modalidades, favoreciendo que el alumno pueda evaluar completamente las posibles alternativas. Con respecto a las materias que requieren refuerzo el cálculo es similar al de las optativas, aunque se muestran únicamente aquellas asignaturas cuya predicción es menor o igual que 4 (Figura 5). Puede obtenerse una información más detallada sobre el funcionamiento del sistema en [Castellano 2007].

5. CONCLUSIONES

Tras analizar los sistemas de recomendación basados en filtrado colaborativo se ha demostrado que su uso puede resultar más que interesante a la hora de realizar recomendaciones personalizadas a alumnos sobre itinerarios educativos y a la hora de escoger asignaturas optativas, e incluso prever qué asignaturas comunes presentarán unas mayores dificultades de aprendizaje o necesidades específicas de refuerzo al alumno.

Además, y tras estudiar las peculiaridades del dominio concreto, hemos observado que posiblemente sea la primera vez que se utilizan datos que no provienen directamente del usuario ni son recogidos

automáticamente por el sistema, sino que son aportados por expertos; sin embargo, el FC se ha comportado de forma adecuada.

En base a estos resultados se ha implementado OriEB, un pequeño sistema basado en FC-I para ayudar/orientar a aquellos alumnos que quieran cursar Bachillerato a elegir tanto la modalidad como las materias propias de modalidad y las optativas.

Los buenos resultados obtenidos nos hacen pensar que se pueden construir sistemas de este tipo para orientar a alumnos de cualquier tipo de enseñanzas en las que el camino académico a recorrer no sea único, como por ejemplo enseñanzas de tipo universitario, y dado que el sistema utiliza únicamente información cuantitativa sobre el alumnado, es viable la inclusión de mejoras que contemplen información de carácter cualitativo, tanto sobre alumnos como sobre asignaturas, de forma que se elaboren recomendaciones más confiables y de mayor calidad.

AGRADECIMIENTOS

Esta contribución está parcialmente financiada por el proyecto de investigación TIN 2006-02121.

REFERENCIAS

- Adomavicius, G., and A. Tuzhilin. 2005. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *Ieee Transactions on Knowledge and Data Engineering* 17 (6):734-749.
- Barranco, M., L. G. Pérez, and L. Martínez. 2006. Un Sistema de Recomendación Basado en Conocimiento con Información Lingüística Multigranular. Paper read at SIGEF XIII - The XIII Congress of International Association for Fuzzy-Set Management and Economy, at Hammamet, Tunisia.
- Breese, J. S., D. Hecherman, and C. Kadie. 1998. Empirical Analysis of Predictive Algorithms for Collaborative Filtering. Paper read at Uncertainty in Artificial Intelligence. Proceedings of the Fourteenth Conference.
- Burke, R. 2000. Knowledge-based Recommender Systems. *Encyclopedia of Library and Information Systems*.
- Burke, R. 2002. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction* 12 (4):331-370.
- Castellano, E. J. 2007. Evaluación del uso de Algoritmos Colaborativos para Orientar Académicamente al Alumnado en Bachillerato. *Memoria de Investigación para la obtención del Diploma de Estudios Avanzados, Lenguajes y Sistemas Informáticos*, Universidad de Jaén.
- Herlocker, J. L., J. A. Konstan, A. Borchers, and J. Riedl. 1999. An algorithmic framework for performing collaborative filtering. In *Sigir'99: Proceedings of 22nd International Conference on Research and Development in Information Retrieval*, edited by M. Hearst, F. Gey and R. Tong. New York: Assoc Computing Machinery, 230-237.
- Herlocker, J. L., J. A. Konstan, K. Terveen, and J. T. Riedl. 2004. Evaluating collaborative filtering recommender systems. *Acm Transactions on Information Systems* 22 (1):5-53.
- Kim, D., and B. J. Yum. 2005. Collaborative filtering based on iterative principal component analysis. *Expert Systems with Applications* 28 (4):823-830.
- Martínez, L., L. G. Pérez, and M. Barranco. 2007. A Multi-granular Linguistic Based-Content Recommendation Model. *International Journal of Intelligent Systems* 22 (5):419-434.
- Pazzani, M. J. 1999. A framework for collaborative, content-based and demographic filtering. *Artificial Intelligence Review* 13 (5-6):393-408.
- Pérez, L. G., M. Barranco, L. Martínez and M. Espinilla. 2007. Exploiting Linguistic Preference Relations in Knowledge Based Recommendation Systems. Paper read at EUROFUSE WORKSHOP 2007, at Jaén, España.
- Resnick, P., and H. R. Varian. 1997. *Recommender systems*. Vol. 40: ACM Press.
- Sarwar, B., G. Karypis, J. Konstan, and J. Reidl. 2001. *Item-based collaborative filtering recommendation algorithms*. Hong Kong: ACM Press.
- Schafer, J. B., J. A. Konstan, and J. Riedl. 2001. *E-Commerce Recommender Applications*. Vol. 5: Kluwer Academic Publishers.
- Ungar, L. H., and D. P. Foster. 1998. Clustering Methods for Collaborative Filtering. Paper read at Proceedings of the Workshop on Recommendation Systems.