

VI Congreso Iberoamericano de Docencia Universitaria



La **opción** por la **interdisciplinariedad**.
El **estudiante** como **protagonista**.

PÓSTER

4, 5 y 6 de
noviembre
2010 LIMA - PERÚ



PONTIFICIA
**UNIVERSIDAD
CATÓLICA**
DEL PERÚ

www.pucp.edu.pe/vicidu

UTILIZACIÓN DE SISTEMAS DE RECOMENDACIÓN EN ENTORNOS DE E-LEARNING. UN CASO PRÁCTICO

Antonio Hernando, Jorge Tejedor, Jesús Bobadilla
Departamento de Sistemas Inteligentes Aplicados
Universidad Politécnica de Madrid

Resumen

Los Sistemas de Recomendación basados en filtrado colaborativo permiten realizar predicciones y recomendaciones en base a los votos emitidos por los usuarios más similares al que se pretende recomendar. Mientras que en los sistemas de recomendación habituales todos los usuarios tienen la misma importancia en el proceso de recomendación, en el filtrado colaborativo para e-learning, los usuarios más avanzados (profesores, estudiantes de último curso, estudiantes con mejores calificaciones, etc.) tienen un peso mayor en sus recomendaciones que el resto de los usuarios. Basándonos en este principio, se ha llevado a cabo un experimento entre alumnos de cursos de formación, obteniéndose resultados satisfactorios que confirman el buen funcionamiento de los principios matemáticos que sustentan los procesos de recomendación y de evaluación de calidad diseñados específicamente para el ámbito de e-learning. En este paper se presenta los principios metodológicos seguidos y los resultados obtenidos.

Palabras Clave: *Sistemas de Recomendación, e-learning, filtrado colaborativo.*

1. Introducción

La web social está cambiando, para mejor, la manera de enfocar multitud de aspectos cotidianos de nuestras vidas. Ahora solemos tener en cuenta las opiniones, experiencias, gustos compartidos e información proporcionada por otras personas a las que ni siquiera conocemos, pero a la que cada vez tenemos más en cuenta a la hora de hacer nuestras compras, planificar los viajes que hacemos, elegir las películas que vemos, seleccionar las noticias que leemos, etc. Por supuesto no basamos nuestras opiniones, en general, en la información proporcionada por un solo o unos pocos usuarios, sino que nos sumergimos en una serie de búsquedas por uno o varios sitios web 2.0 para ir obteniendo información que desconocíamos y que difícilmente encontraríamos en sitios web no sociales (por ejemplo, las maravillosas charlas nocturnas con el dueño de un casa que alquila habitaciones en un parque nacional de Nueva Zelanda). Nos basta con encontrar varios comentarios coincidentes para tomar la determinación de alojarnos en ese lugar y, en general, acertaremos y reforzaremos con nuestra experiencia y comentarios la elección de ese destino por parte de futuros viajeros.

La web social, por lo tanto, nos ayuda en nuestras vidas al permitirnos acceder a todo tipo de información no necesariamente institucional ni estructurada, proporcionada por cualquier otra persona. Es un avance en las posibilidades existentes respecto a los tradicionales sitios web, pero a lo largo de su rápida expansión se ha encontrado con el mismo problema que sus predecesores no sociales: encontrar la información adecuada entre una enorme y creciente cantidad de opiniones, posts, fotos, vídeos, textos, etc.

Las herramientas más utilizadas para encontrar la información que mejor se adapta a nuestras expectativas siguen siendo los tradicionales buscadores (google, yahoo,...); también se aprecia una tendencia social a aglutinarse en mega-web sociales (cuyo exponente más notorio es Facebook) donde resulta mucho más probable encontrar lo que buscamos. Una potente tecnología adicional y compatible con las anteriores son los sistemas de recomendación (SR);

Tradicionalmente, los trabajos publicados en el área de investigación de SR se han fundamentado en estudios de validez general, aplicables por igual a cualquier tipo de SR y normalmente basados en resultados obtenidos utilizando las bases de datos públicas existentes (que habitualmente contienen valoraciones de películas de cine). Sin embargo, actualmente es posible encontrar

estudios centrados en diferentes tipos específicos de SR, tales como los SR de e-learning [1,2,3,4,5,6,7,8].

La etapa de SR que normalmente tiene una mayor influencia en la calidad de los resultados obtenidos en el filtrado colaborativo (FC) [9,10]. El FC se basa en realizar predicciones acerca de la preferencia de un grupo de usuarios que se consideran similares al usuario al que se pretende recomendar (usuario activo). Una parte importante de la investigación en el área de FC se centra en cómo determinar qué usuarios son similares al usuario activo; para llevar a cabo esta tarea existen fundamentalmente tres enfoques: métodos basados en el contenido, métodos basados en modelos y métodos híbridos.

Los métodos basados en contenidos [11] usan métricas de similaridad [9,12,13] y actúan directamente en la matriz que contiene los votos de todos los usuarios que han expresado sus preferencias usando el servicio colaborativo. Estas métricas expresan la distancia entre dos usuarios basándose en sus votos. Los métodos basados en modelos [14,15] usan la matriz de votos para crear un modelo con el que determinar posteriormente el conjunto de usuarios similares a cada usuario activo.

Independientemente del método utilizado en la etapa de FC, el objetivo que habitualmente se persigue es minimizar los errores de predicción alcanzando la "accuracy" [16,17,18,19,20] del SR tan alta como sea posible; sin embargo, hay otros objetivos que se deben tener en cuenta: evitar sobreespecialización, encontrar ítems adecuados, credibilidad de las recomendaciones, etc.

2. Descripción del trabajo

Para poder probar el método de FC propuesto se ha implementado un SR de e-learning que hemos tenido funcionando durante 2 años. En este periodo de tiempo se han recogido las valoraciones de 243 alumnos acerca de 224 aspectos (44 documentaciones escritas de unidades didácticas + 44 ejercicios propuestos + 44 tests de validación de conocimientos + 88 fuentes de información externas + 4 profesores), todo ello en 9 cursos de formación con los temas: "comunicaciones con lenguaje Java" y "desarrollo de aplicaciones web con Java".

Las fuentes de información externas (libros, documentos on-line, sitios web, etc.) sirven para ofrecer 2 referencias de información complementaria a la propia documentación del curso en cada una de las unidades didácticas.

Las valoraciones de los alumnos se han tomado siempre consultando su opinión, en un rango de 0 a 5, acerca de la idoneidad de cada uno de los aspectos evaluados como medio para asimilar los conocimientos propuestos en cada una de las unidades didácticas o en todo el curso en el caso de la valoración de los profesores.

El perfil de los alumnos ha sido el de ingenieros o estudiantes de últimos cursos de ingeniería con buenos conocimientos de programación en lenguajes diferentes a Java. El nivel técnico de los alumnos en uno de los cursos (el de comunicaciones) por término medio ha sido superior que el de los alumnos del segundo curso. Ningún alumno ha participado en ambos cursos. El plazo máximo permitido para emitir una valoración relativa a una unidad didáctica ha sido el de una semana desde su terminación. La valoración de los profesores se realiza al final del curso.

Aunque la participación en el SR no era obligatoria, debido al interés mostrado por los profesores y por los propios alumnos, el resultado final nos ha llevado a un porcentaje de valoraciones muy superior al que se puede encontrar en cualquier base de datos pública de SR, lo que nos ha obligado a calibrar el impacto de trabajar con una matriz R de valoraciones muy poco dispersa.

Desde el punto de vista de los alumnos, nuestro SR de e-learning les permitía recibir recomendaciones personalizadas acerca de la idoneidad de las fuentes de documentación de las lecciones, con lo que disponían de una indicación acerca de cuál o cuáles de las 3 documentaciones de cada lección se ajustarían mejor a sus preferencias. En el primer curso impartido, los alumnos disponían de recomendaciones basadas en las valoraciones de sus compañeros y de los profesores. En el resto de los cursos, además, la recomendación se procesaba teniendo en cuenta las valoraciones de los alumnos de los cursos anteriores.

La matriz de votos consta de los 224 elementos valorados. La matriz de calificaciones consta de un número de elementos $T=88$ y está formada por las puntuaciones obtenidas por cada alumno en

los 44 ejercicios propuestos más los 44 tests de validación de conocimientos, todo ello correspondiente a las 44 unidades didácticas. A medida que se iban realizando nuevos cursos, el número de filas de las matrices R y C se iba incrementando hasta alcanzar, finalmente, el total de 243 alumnos participantes en este SR.

Una vez finalizados los cursos y completadas las matrices de votos y calificaciones, pasamos a evaluar el clásico factor de "accuracy" del SR calculando the Error Absoluto Medio (MAE).

EL estudio permite ponderar la importancia de los votos frente a los conocimientos; es decir, la importancia que damos a la similitud en las valoraciones de dos usuarios frente a la importancia que se le otorga a cada usuario en función de sus conocimientos. A modo de ejemplo: si existe un estudiante que ha emitido valoraciones de los distintos materiales didácticos muy parecidas al del usuario activo, pero sus conocimientos en la materia son bajos, es posible que no sea seleccionado como usuario similar al activo, ya que otros usuarios con menor similitud podrían ser escogidos en función de sus altos conocimientos en la materia.

Utilizamos un parámetro α para establecer la ponderación entre similitud y conocimientos. Cuando α toma el valor 1 los conocimientos no se valoran, Cuando α toma el valor 0 los conocimientos es lo único que se valora. Lo adecuado será tomar un valor intermedio que pondere adecuadamente similitud y conocimientos.

Los detalles del FC empleado para obtener los resultados del paper se pueden obtener de [5].

3. Resultados

En la figura 1 se presentan los resultados del Mean Absolute Error (MAE) obtenido aplicando las técnicas tradicionales de FC sobre los datos de nuestro SR de e-learning (gráfica negra con cuadrados) y los resultados equivalentes utilizando valores de α 0.3, 0.5 and 0.7. El valor de α 0.3 pondera en mayor medida las recomendaciones de los usuarios que tienen una mejor reputación (conocimientos), mientras que usando el valor de α 0.7 las recomendaciones de los usuarios que tienen mejor reputación pierde gran parte de su importancia; el valor de α 0.5 representa un equilibrio entre ambas tendencias.




Fig. 1 Accuracy obtained

El estudio se realiza utilizando valores de k-neighborhoods: 5, 10, 20 and 40, lo que nos permite incidir en los valores más representativos para una base de datos tan pequeña y también mostrar la tendencia en los resultados cuando el número de k-neighborhoods aumenta.

Como se puede observar en la figura, salvo para $k=5$ & $\alpha = 0.7$, en todos los valores procesados el error (MAE) disminuye al realizar the testing of the accuracy of the recommendations usando diferentes valores de α . Los mejores resultados se obtienen al equilibrar ($\alpha = 0.5$) la importancia de la reputación de los usuarios en el proceso de la recomendación. Este resultado nos indica que, al hacer uso de este SR en concreto, conseguiríamos las mejores estimaciones al ponderar en aproximadamente un 50% las valoraciones de los usuarios con mejores conocimientos.

Este resultado se puede explicar reflexionando sobre el necesario equilibrio que debe existir entre la elección de usuarios (k-neighborhoods) con valoraciones suficientemente similares a las del usuario al que se pretende recomendar respecto a la elección de usuarios que aún no siendo tan similares, sus valoraciones deberían ser más acertadas.

4. Conclusiones

Los resultados obtenidos con nuestro SR de e-learning han sido muy positivos, consiguiéndose mejoras de alrededor del 20% en los niveles de accuracy (MAE).

Los resultados empíricos también han mostrado la conveniencia de utilizar valores equilibrados en la importancia asignada a los usuarios con mayores niveles de conocimientos, de tal manera que se tenga en cuenta esa nueva fuente de conocimientos, pero sin comprometer en exceso la similaridad de los k-neighborhoods escogidos para realizar las recomendaciones de cada usuario.

Resulta posible diseñar sistemas de recomendación de e-learning basados en el concepto de que la importancia de cada usuario para recomendar a los demás depende de sus conocimientos y habilidades en el tema.

Los resultados del experimento realizado con alumnos nos lleva a concluir que el sistema de recomendación diseñado produce los resultados numéricos de calidad esperados y que los alumnos han valorado mayoritariamente la iniciativa como muy positiva para su proceso de aprendizaje.

5. Referencias

1. LOLL, F.; PINKWART, N. "Using Collaborative Filtering Algorithms as eLearning Tools". 2009. *HICSS '09. 42nd Hawaii International Conference on System Sciences*, 5-8 Jan. 2009, pp.1 – 10, Digital Object Identifier 10.1109/HICSS.2009.492
2. DRACHSLER, H.; HUMMEL, H. G. K.; KOPER R. "Recommendations for learners are different: applying memory-based recommender system techniques to lifelong learning". *EC-TEL 2007 Conference*, 2007, pp. 17-20
3. HU J.; ZHANG W.. "Community Collaborative Filtering for E-Learning" *International Conference on Computer and Electrical Engineering ICCEE, 2008*, pp. 593 – 597, Digital Object Identifier 10.1109/ICCEE.2008.144.
4. BALASUNDARAM, S. R.; RAMADOSS, B. "Object Oriented Analysis Learning Tool using Collaborative Learning". *7th International Conference on Information Technology Based Higher Education and Training*, 2006, pp. 811-816
5. BOBADILLA J.; SERRADILLA F.; HERNANDO A. "Collaborative Filtering adapted to Recommender Systems of e-learning". *Knowledge Based Systems*, 2009, pp. 261-265, doi: 10.1016/j.knosys.2009.01.008.

6. DENIS H. "Managing Collaborative Learning Processes in e-Learning Applications". *Proceedings of the 29th International Conference on Information Technology Interfaces*, 2007, pp. 345-350.
7. GANG, C.; RUIMIN, S.; JIAJUN, W.; ZEYU, C. "Collaborative Education Model and Its Application in E-learning". *Proceedings of the the 6th IEEE/ACIS International Conference on Computer and Information Science*, 2007, pp. 856-860.
8. LOLL, F.; PINKWART, N. "Using Collaborative Filtering Algorithms as eLearning Tools". *42nd Hawaii International Conference on System Sciences HICSS '09*, 2009, pp.1-10.
9. ANTONOPOULUS N.; SALTER J. "Cinema screen recommender agent: combining collaborative and content-based filtering". *IEEE Intelligent Systems*, 2006, pp.35–41.
10. ADOMAVICIUS; TUZHILIN, A. "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*, vol. 17, no. 6, 2005, pp. 734-749
11. HERLOCKER, J. L.; KONSTAN, J.A.; RIEDL, J.T.; TERVEEN, L.G. "Evaluating Collaborative Filtering Recommender Systems". *ACM Transactions on Information Systems*, vol. 22, no. 1, 2004, pp. 5-53
12. BOBADILLA, J.; SERRADILLA, F.; BERNAL, J. "A new collaborative filtering metric that improves the behavior of recommender Systems". *Knowledge-Based Systems*, 23 (6), 2010, pp. 520-528. doi:10.1016/j.knosys.2010.03.009.
13. SANCHEZ, J. L.; SERRADILLA, F.; MARTINEZ, E.; BOBADILLA, J. "Choice of Metrics used in Collaborative Filtering and their Impact on Recommender Systems". *IEEE DEST, 2008*, pp. 432–436. doi: 10.1109/DEST.2008.4635147
14. GAO L.Q.; LI C. "Hybrid personalizad recommended model based on genetic algorithm". *Int. Conf. on Wireless Commun. Netw. and Mob. Computing*, 2008, pp. 9215-9218.
15. AL-SHAMRI M.Y.; BHARADWAJ K.K. "Fuzzy-genetic approach to recommender systems based on a novel hybrid user model". *Expert Syst. Appl*, Vol. 35, No. 3, 2008, pp. 1386-1399.
16. BREESE, J.S.; HECKERMAN, D.; KADIE, C. "Empirical Analysis of Predictive Algorithms for Collaborative Filtering". *Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence, Morgan Kaufmann*, 1998, pp. 43-52
17. GIAGLIS, G.M.; LEKAKOS "Improving the Prediction Accuracy of Recommendation Algorithms: Approaches Anchored on Human Factors". *Interacting with Computers*, vol. 18, no. 3, 2006, pp. 410-431
18. LI, Y.; NAYAK, R.; WENG, L.T.; XU, Y. "An Improvement to Collaborative Filtering for Recommender Systems". *Proceedings of the IEEE International Conference on Computational Intelligence for Modelling, Control and Automatitaton*, 2005
19. FUYUKI, I.; QUAN, T.K.; SHINICHI, H. "Improving Accuracy of Recommender Systems by Clustering Items Based on Stability of User Similarity". *Proceedings of the IEEE International Conference on Intelligent Agents, Web Technologies and Internet Commerce*, 2006
20. MANOLOPOULUS, Y.; NANOPOULUS, A.; PAPADOPOULUS, A. N.; SYMEONIDIS, P. "Collaborative Recommender Systems: Combining Effectiveness and Efficiency". *Expert Syst. with Applications*, Vol. 34, No. 4, 2007, pp. 2995-3013. doi:10.1016/j.eswa.2007.05.013