

Recomendação de Objetos de Aprendizagem utilizando Filtragem Colaborativa: Uma comparação entre abordagens de pré-processamento por meio de clusterização

Henrique L. dos Santos¹, Cristian Cechinel¹, Ricardo M. Araújo¹, Daniela Brauner¹

¹Centro de Desenvolvimento Tecnológico
(CDTec) - Universidade Federal de Pelotas
Caixa Postal: 354 – 96010-900 - Pelotas, RS, Brasil

hldsantos@inf.ufpel.edu.br, contato@crisiancechinel.pro.br

ricardo@inf.ufpel.edu.br, danibrauner@gmail.com

Abstract. Collaborative Filtering can be used in the context of e-learning to recommend learning objects to students and teachers involved with the teaching and learning process. Even though such technique presents a great potential for e-learning, studies related to this application in this field are still limited, mostly because the inexistence of available datasets for testing and evaluating. The present work evaluates two pre-processing methods through clustering for future use of collaborative filtering algorithms. For that we use a large data set collected from the MERLOT repository. The initial results point out that clustering learning objects before the use of collaborative filtering techniques can improve the recommender performance.

Resumo. No contexto de e-learning a filtragem colaborativa pode servir para a recomendação de objetos de aprendizagem aos estudantes e professores envolvidos no processo de ensino-aprendizagem. Ainda que tal técnica apresente grande potencial no contexto educacional, os estudos existentes sobre sua utilização nesse domínio são bastante limitados, sobretudo pelas barreiras encontradas na disponibilização de conjuntos de dados para teste e avaliação. O presente trabalho avalia dois métodos de pré-processamento por meio de clusterização para a posterior utilização por um algoritmo de filtragem colaborativa utilizando uma base de dados de ratings de objetos de aprendizagem coletada do tradicional repositório MERLOT. Os resultados iniciais encontrados apontam que o agrupamento de objetos de aprendizagem melhora o desempenho do algoritmo de filtragem colaborativa.

1. Introdução

Objetos de aprendizagem (OAs) são unidades auto-contidas de aprendizado importantes na composição de programas de educação a distância (EaD). Dependendo de como este tipo de recurso de aprendizagem é fornecido, cursos online podem permitir que seus alunos tenham a liberdade de construir um caminho de aprendizagem próprio, que se encaixe em suas preferências, habilidades e conhecimentos prévios.

Coleções de objetos de aprendizagem são normalmente armazenadas e organizadas em Repositórios de Objetos de Aprendizagem (ROAs). Alunos, educadores e outras

partes interessadas podem disponibilizar ou consumir estes objetos de diferentes formas através dos repositórios ou de outras plataformas de EaD, como os Ambientes Virtuais de Aprendizagem (AVAs). Os repositórios existentes podem apresentar diferenças em vários aspectos (localização do objeto, especificidade da área de cobertura do repositório, padrão de metadados adotado) e atender diferentes comunidades, países ou níveis de educação.

Grandes repositórios podem conter dezenas de milhares de objetos de aprendizagem diferentes, tornando difícil a tarefa de encontrar objetos de interesse. Como os repositórios são naturalmente organizados em torno de comunidades de interesse, as avaliações e os comentários adicionados pelos usuários aos objetos podem contribuir na busca e recuperação de informação [Cechinel et al. 2011]. Assim, os resultados de uma busca podem ser ordenados com base nos objetos melhor avaliados, por exemplo.

O uso de sistemas de recomendação tem sido amplamente investigado com o objetivo de aprimorar a descoberta de objetos de aprendizagem. Estes sistemas podem fornecer recomendação de novos objetos com base no histórico de consumo e avaliações de um usuário (por exemplo, usando a abordagem de filtragem colaborativa). Estes sistemas são amplamente utilizados em comércio eletrônico, em sites como Amazon, e na distribuição de produtos digitais como filmes, jogos e livros. Eles também podem recomendar objetos com base em seu conteúdo – por exemplo, se um usuário assiste muitos filmes do gênero Drama, então um filme ainda não assistido deste gênero pode ser uma boa recomendação.

Apesar dos benefícios que a adoção de algoritmos de filtragem colaborativa (FC) pode trazer para a área de sistemas de recomendação em Aprendizagem Aprimorada por Tecnologia, do termo em inglês *Technology Enhanced Learning* (TEL), ainda existe uma carência de trabalhos reportando resultados obtidos especificamente da aplicação de FC em grandes amostragens de dados. Isto está relacionado a falta de coleções de dados disponíveis para teste de soluções de forma que possam ser generalizadas [Drachsler et al. 2010]. Os experimentos existentes são normalmente conduzidos em pequenos cenários ou em ambientes controlados, sendo que poucos pesquisadores conseguem testar e validar seus sistemas de recomendação usando dados reais [Manouselis et al. 2011].

Este artigo dá continuidade a um experimento anteriormente conduzido por [Cechinel et al. 2013] com um grande conjunto de dados (quase 5 mil objetos) coletado do repositório Merlot¹. No presente trabalho, são testadas duas diferentes abordagens de pré-processamento dos dados utilizando técnicas de clusterização com o objetivo de reduzir a taxa de erro das recomendações em comparação com a abordagem de FC pura anteriormente testada. O trabalho está organizado da seguinte maneira. A seção 2 descreve os trabalhos relacionados. Na seção 3 são apresentados os objetivos, a metodologia utilizada e as características da coleção de dados utilizada. Os resultados são discutidos na seção 4. Por fim, a seção 5 conclui o artigo, apresentando algumas possibilidades de trabalhos futuros.

¹<http://www.merlot.org>

2. Trabalhos relacionados

2.1. Sistemas de recomendação em aprendizagem aprimorada por tecnologia

O trabalho apresentado neste artigo está no escopo do amplo domínio de TEL. TEL é um domínio concentrado em investigar como diferentes tecnologias podem suportar o processo educacional. Os trabalhos relacionados são apresentados agrupados em três seções distintas. Em primeiro lugar, os estudos sobre como os sistemas de recomendação são úteis para os cenários educacionais e as avaliações de algoritmos de recomendação aplicados a uma variedade de coleções de dados, o segundo grupo inclui os trabalhos preocupados em aprimorar os sistemas de recomendação aplicados a aprendizagem, utilizando características específicas que emergem de processos de aprendizagem. Finalmente, no terceiro grupo, os estudos que focam em métodos de clusterização aplicados a sistemas de recomendação, mostrando os benefícios desta técnica em outros domínios de aplicação.

Em [Wang and Yang 2012], um algoritmo de filtragem colaborativa baseada no usuário é aplicado a um fórum online para aprendizado de Língua Inglesa. Com isso, foi possível recomendar tópicos do fórum aos estudantes. Como resultado, o uso do recomendador demonstrou melhoras no engajamento e na performance dos estudantes em testes de habilidade do idioma. Em [Sicilia et al. 2010], um algoritmo de filtragem colaborativa baseada no usuário é avaliado usando o repositório Merlot. O objetivo foi analisar o uso de diferentes parâmetros e seu impacto no desempenho da recomendação. Os parâmetros com melhor performance, bem como a base de dados e o algoritmo, são os adotados no presente artigo.

Diversos esforços são apresentados a fim de aprimorar as recomendações no contexto de aprendizagem. [Carvalho et al. 2014], propõe a personalização do processo de ensino baseada no mapeamento automático de características de estilos de aprendizagem de estudantes em metadados de objetos de aprendizagem usando um modelo computacional e probabilístico. *TF-IDF* é usado em [Ghauth and Abdullah 2010] para computar a similaridade entre itens de aprendizagem e recomendá-los de acordo com as avaliações de bons alunos. No presente artigo, a clusterização de objetos de aprendizagem ocorre de forma semelhante, também utilizando vetores *TF-IDF* para representar cada OA. Entretanto, além de utilizarmos a mesma técnica também para usuários, a recomendação final não é exclusivamente dependente da avaliação de um determinado grupo de usuários. Em [Klašnja-Milićević et al. 2011], as recomendações são aprimoradas através da classificação dos estudantes de acordo com seus estilos de aprendizado e o uso desta informação juntamente com uma matriz de *ratings* tradicional.

A filtragem colaborativa e a recomendação baseada em conteúdo são avaliadas em [Drachler et al. 2008]. Mais recentemente, [Manouselis 2012] observou que o mesmo algoritmo de filtragem colaborativa pode apresentar desempenho diferente quando aplicado a diferentes coleções de dados e propõe o uso de algoritmos multi-critérios. Finalmente, [Verbert et al. 2012] argumenta que a informação contextual pode aprimorar os sistemas de recomendação, desde que uma resposta adaptativa seja possível e que uma resposta personalizada para cada usuário possa ser construída pelo recomendador. No mesmo artigo, a informação contextual é definida e é apresentada uma análise de sistemas de recomendação em TEL, baseada no uso destas informações. Uma revisão maior da literatura sobre recomendadores de objetos de aprendizagem no contexto brasileiro pode ser vista em [Pontes et al. 2014].

2.2. Sistemas de recomendação e métodos de clusterização

Um dos principais desafios no desenvolvimento de sistemas de recomendação é quanto a escalabilidade, quando existe um grande número de usuários ou itens no conjunto de dados [Ochoa and Carrillo 2013]. A clusterização é uma técnica geralmente aplicada para aumentar a escalabilidade de sistemas de recomendação, onde usuários ou itens são agrupados de acordo com alguma métrica de similaridade e a recomendação é aplicada por grupo de base ao invés da população inteira. Além disso, também é utilizada para reduzir a esparsidade em matrizes de *ratings* (ou, avaliações) de usuários.

Por exemplo, [Gong and Ye 2009] defende que clusterizar os usuários pelas suas avaliações antes de aplicar um algoritmo de filtragem colaborativa em um sistema de comércio eletrônico pode melhorar a escalabilidade com poucas perdas no desempenho da recomendação. Uma abordagem similar é apresentada em [Huang 2009], onde um algoritmo de clusterização *k-means* é aplicado a base de dados de usuários do MovieLens² (um sistema de recomendação *online* de filmes) e a vizinhança de usuários é criada com base nos centroides de cada um dos *clusters*.

Em um ambiente TEL, [Tang and McCalla 2005] mapeia as diferenças entre recomendadores no geral e recomendadores para ensino a distância, e também apresenta um sistema de *e-learning* onde os usuários são clusterizados pelos seus interesses de aprendizagem; cada *cluster* tem seu próprio processo de recomendação usando técnicas de filtragem colaborativa. Esta é uma abordagem similar a que apresentamos neste artigo, porém aqui propomos também comparar o desempenho entre a clusterização de usuários com a clusterização de objetos de aprendizagem.

3. Objetivos e metodologia

3.1. Objetivos

O principal objetivo desse artigo é encontrar uma forma de melhorar a aplicação de sistemas de recomendação baseados em filtragem colaborativa dentro de um contexto educacional, nesse caso, a recomendação de objetos de aprendizagem pertencentes a um repositório. Nosso objetivo também consiste em avaliar o impacto que a utilização de técnicas de clusterização, aplicadas a usuários e objetos de aprendizagem, possui na eficácia das recomendações. Tais técnicas são aplicadas inicialmente, fazendo com que as recomendações sejam geradas tendo como base *clusters* específicos. Nossa hipótese é de que essa abordagem não somente melhore a escalabilidade do sistema como um todo, mas também melhore a acurácia das recomendações, já que objetos de aprendizagem similares normalmente são utilizados em conjunto e usuários de mesmas categorias tendem a consumir objetos semelhantes.

3.2. Descrição dos dados

Nesse artigo, utilizamos uma versão atualizada do conjunto de dados apresentado em [Cechinel et al. 2013] e que contém usuários, objetos de aprendizagem e suas relações disponíveis no repositório Merlot (ver figura 1). Esse conjunto contém 9910 avaliações (que variam no intervalo de 1 a 5) de 3659 usuários sobre 4968 objetos de aprendizagem.

²<https://movielens.org>

O conjunto de dados contém diversas informações e metadados sobre os OAs (por exemplo, descrição, categoria, tipo de material, revisões, idioma) e usuários (por exemplo, afiliação, categoria, tipo de membro), juntamente com as relações entre ambos (avaliações, comentários e coleções pessoais). Na abordagem de clusterização de objetos, utilizamos apenas as informações de título e descrição do OA. Já na abordagem de clusterização de usuários foram utilizadas somente as categorias às quais o usuário pertence. A descrição e o título de um OA são informações textuais, já as categorias de um usuário, também textuais, possuem 1394 valores possíveis, além disso, um usuário pode estar cadastrado em diversas categorias. Uma avaliação pode ser vista como uma tupla $\langle id_usuario, id_objeto, nota \rangle$.

The screenshot shows a Merlot learning object page. The main title is "DNA FROM THE BEGINNING". The page is divided into two main sections: "DNA FROM THE BEGINNING" and "QUALITY".

DNA FROM THE BEGINNING

QUALITY

Peer Reviews: ★★★★★
User Rating: ★★★★★
Discussion (50 Comments)
Learning Exercises (11)
Bookmark Collections (411)
Course ePortfolios (23)
Accessibility Info (none)

Editors' Choice **MERLOT Classics**

Rate this material
Create a learning exercise
Add accessibility information
Bookmark this material

Go to material **Discuss this Material**

Material Type: Simulation
Technical Format: Excel
Date Added to MERLOT: Abril 11, 2000
Date Modified in MERLOT: Maio 21, 2015

Author: Cold Spring Harbor Laboratory
Submitter: Jeff Bell
Keywords: genetics, DNA, History about DNA, genes, DNA models

[\[Report Broken Link\]](#) [\[Report as Inappropriate\]](#)

Figura 1. Exemplo de tela de Objeto de Aprendizagem no Merlot

O uso das avaliações se dá na segunda fase do processo. Uma vez que as clusterizações são utilizadas para recortar o conjunto total de avaliações de forma não-aleatória. Em cima desses recortes (*clusters*), são geradas e avaliadas as recomendações.

3.3. Geração de *clusters* e recomendações

Nossa abordagem geral para recomendação é baseada em aplicar um algoritmo de filtragem colaborativa em *clusters* de objetos de aprendizagem e de usuários, ao invés de gerar recomendações considerando todos os dados reunidos. Nesse sentido, inicialmente realizamos uma clusterização baseada em conteúdo de duas maneiras diferentes: sobre itens (OAs) e sobre usuários, e depois geramos as recomendações para cada *cluster*. Analisamos a performance destes recomendadores para diferentes números de *clusters* e diferentes valores de parâmetros do algoritmo utilizado. As implementações utilizadas para as clusterizações, recomendações e suas subsequentes avaliações no presente artigo estão disponíveis no *framework* Apache Mahout³, versão 0.7.

3.3.1. *Clusters* de objetos de aprendizagem

A fim de gerar *clusters* de objetos de aprendizagem, utilizamos suas informações textuais disponíveis (título e descrição). Um modelo saco-de-palavras foi escolhido, onde

³<https://mahout.apache.org/>

cada objeto é representado por um vetor n -dimensional onde cada posição representa uma única palavra. Foi utilizado o cálculo do $TF - IDF$ (frequência do termo - inverso da frequência nos documentos) de cada palavra para preencher sua respectiva posição no vetor. Esse método faz com que palavras muito frequentes e irrelevantes (por exemplo, artigos, preposições) tenham seus valores basicamente zerados, o que gera vetores esparsos como forma de representação de cada registro (nesse caso, objeto de aprendizagem). O mesmo cálculo foi feito para a clusterização de usuários, cujas especificações seguem.

3.3.2. Clusters de Usuários

Na clusterização de usuários foram utilizadas as suas categorias, de modo que um agrupamento direto não foi testado já que um usuário pode pertencer a diversas categorias diferentes. Um usuário, então, é definido pelo conjunto de categorias às quais pertence (por exemplo, um usuário pode ser representado pelas palavras Artes, Música, Ensino de Música, História da Música, Teatro, Dança e Teatro Musical, que são as categorias nas quais ele está cadastrado no repositório). Optamos por utilizá-las como informações textuais para não ter necessidade de escolher apenas uma dentre um conjunto maior. Além disso, do conjunto total de usuários(3659), 293 não possuíam categoria alguma ou possuíam apenas uma categoria. Dessa forma, optamos por manter apenas usuários que possuíam mais do que uma categoria assinalada, o que acarretou num número total de usuários de 3366 (8% a menos que o total inicial). Como consequência, as 532 avaliações feitas por esses 293 usuários também foram perdidas, uma queda de 5,3% do total de avaliações citado anteriormente (9910).

3.3.3. As recomendações

O algoritmo k -means foi então aplicado para a geração de *clusters* sobre os vetores anteriormente gerados pelo cálculo $TF - IDF$. Utilizou-se como medida de similaridade a distância do cosseno, e os centroides foram inicializados de forma aleatória. Foram testados valores de k no intervalo de 2 a 9 (onde k representa o número de *clusters* gerados). Valores maiores que $k=9$ geraram dados muito esparsos e impossibilitaram que o algoritmo de filtragem colaborativa recomendasse itens.

Como pode ser observado na figura 2, para $k=9$ as coberturas do espaço de usuários já se aproximam de valores muito baixos em ambos experimentos (próximos a 15%). Valores ainda mais altos de k geram coberturas que seguem a tendência decrescente da reta da figura. A medida que esses valores aumentam, diminuem os números de usuários, OAs e de avaliações presentes em cada *cluster*, de modo que se torna cada vez mais difícil para o algoritmo de filtragem colaborativa encontrar similaridades entre usuários (cálculo de similaridade entre usuários depende de co-avaliações de itens). Tal situação ocasiona a queda da qualidade na recomendação ou até mesmo a impossibilidade de gerar recomendações para um ou mais *clusters* inteiros.

Após a aplicação do algoritmo k -means, cada objeto de aprendizagem está atribuído a um dos k *clusters*. No caso do segundo experimento, cada usuário está atribuído a um dos *clusters*.

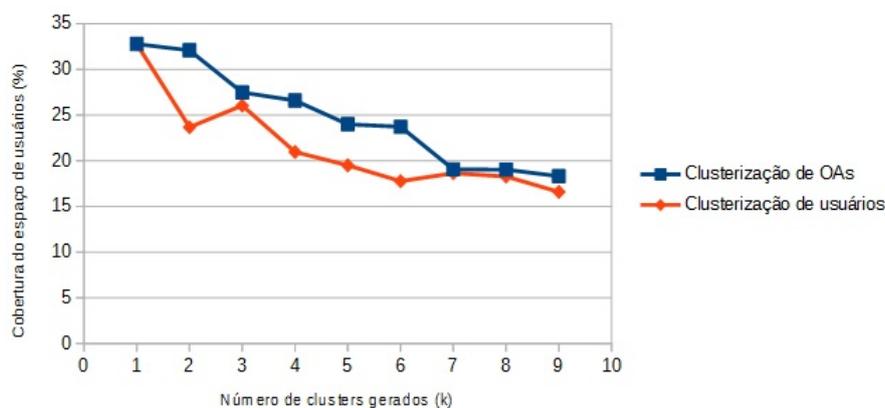


Figura 2. Cobertura do espaço de usuários para cada valor de k em ambas abordagens

Para a geração de recomendações, aplicamos um algoritmo de filtragem colaborativa baseada em usuário, onde a similaridade entre usuários foi calculada a partir da relação *LogLikelihood*. Juntamente com o valor de k , os dois principais parâmetros do algoritmo de filtragem colaborativa baseada em usuário foram sistematicamente variados para a observação de como as taxas de erro das recomendações reagiriam. O tamanho de vizinhança máximo de cada usuário variou de 2 a 20. A similaridade mínima variou entre 0.2 e 0.9. Para cada configuração possível o algoritmo foi executado 50 vezes e os resultados médios são apresentados.

Foram utilizadas duas medidas clássicas de erro [Herlocker et al. 2004] para medir o desempenho da predição das avaliações: Erro Absoluto Médio (MAE, do inglês *mean average error*) e Raiz do Erro Quadrático Médio (RMS, do inglês *root-mean-square error*). Para o cálculo dos erros utilizamos uma abordagem de avaliação de treinamento e teste, sendo que para cada *cluster* foi utilizado 90% para treinamento do recomendador e 10% para teste.

4. Resultados e Discussões

Um teste ANOVA foi realizado para avaliar se as médias dos erros médios MAE e RMS para os diferentes valores de k eram significativamente diferentes em cada abordagem, e um teste de Kruskal-Wallis foi realizado para avaliar as diferenças entre as medianas. Ambos os testes apresentaram diferenças significativas com um nível de confiança de 95%. Os resultados dos erros médios MAE e RMS para cada abordagem são apresentados nas figuras 3 e 4 respectivamente. Como pode ser observado na figura 3, quando consideramos o MAE, a estratégia de clusterizar OAs supera a abordagem pura (sem clusterização, ou $k=1$) para algumas situações ($k=6$, $k=8$, $k=9$). Considerando o MAE, a estratégia de clusterizar usuários perde para a abordagem pura em quase todos os casos, com exceção do caso $k=9$. Ainda assim, para $k=9$ existe uma variação muito grande, ou seja, os erros estão muito espalhados. Com base nas figuras, é possível concluir que a estratégia de clusterização de LOs é melhor.

Quando consideramos o RMS, a estratégia de clusterizar OAs supera a abordagem pura (sem clusterização) para quase todos os valores de k (exceção para $k=3$). No caso do RMS, a clusterização de usuários também supera a abordagem pura em vários cenários

(exceções para $k=2$, $k=3$, $k=4$). Ainda assim, é possível observar que os erros se cruzam com a abordagem pura em vários pontos, o que não ocorre de maneira tão forte para a estratégia de clusterizar OAs. Nesse segundo caso (erro RMS), a estratégia de clusterização de OAs também é melhor do que a de clusterização de usuários.

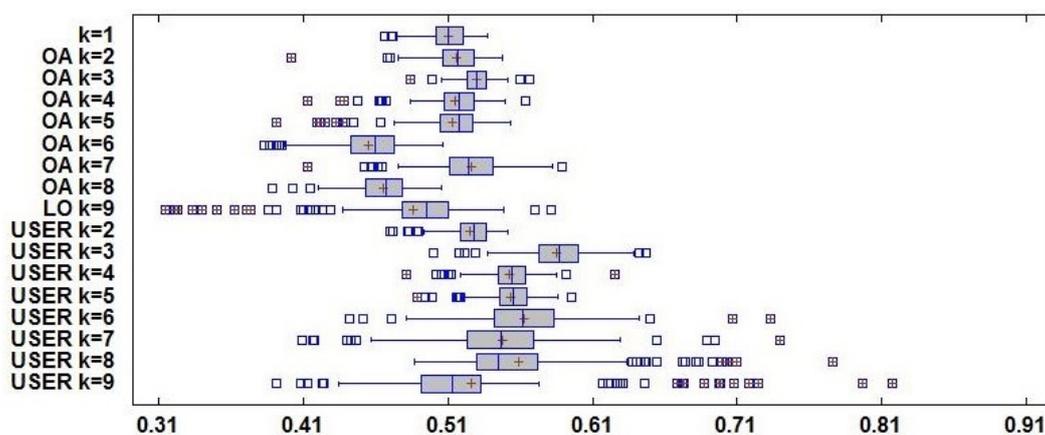


Figura 3. Box-plots dos valores médios de MAE para cada valor de k em ambas abordagens

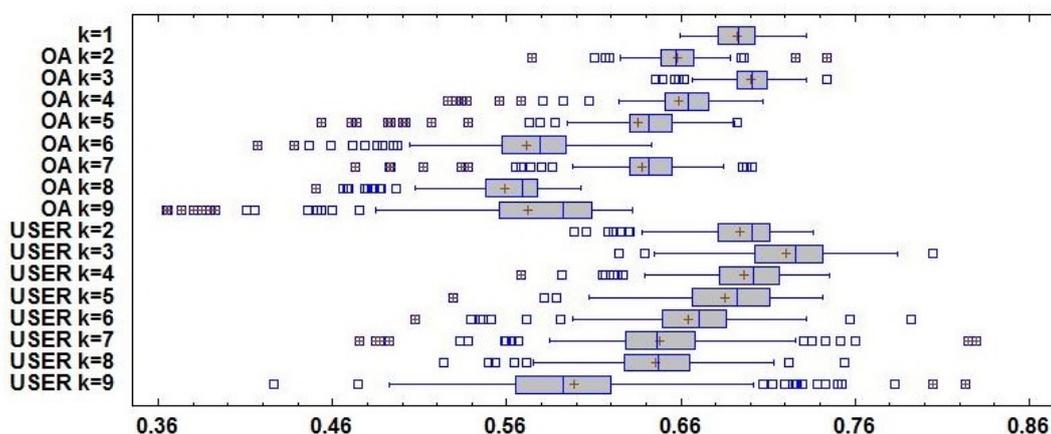


Figura 4. Box-plots dos valores médios de RMS para cada valor de k em ambas abordagens

5. Considerações Finais

O trabalho apresentado neste artigo compara dois tipos de pré-processamentos baseados em clusterização para a posterior utilização por um algoritmo de filtragem colaborativa na recomendação de objetos de aprendizagem. A primeira abordagem foi a clusterização de objetos de aprendizagem pela similaridade de suas descrições e títulos, enquanto a segunda abordagem realizou a clusterização de usuários com base nas categorias em que estão cadastrados.

Os resultados obtidos demonstraram que a clusterização de objetos de aprendizagem antes da aplicação de técnicas de filtragem colaborativa aprimora a qualidade das recomendações. O melhor desempenho da estratégia de clusterização de OAs (em

relação a estratégia de clusterização de usuários) pode ter sido ocasionado pela maior riqueza de informação textual acerca de um objeto de aprendizagem em comparação com a informação textual de um usuário. Enquanto no primeiro caso há um texto descritivo (título e descrição) sobre o conteúdo do OA, no segundo caso o texto fica limitado a um conjunto pré-determinado (pela configuração do repositório) de categorias às quais um usuário pode pertencer.

Ainda, uma melhora na capacidade de recomendação de OAs aos estudantes leva a uma melhor adaptação de materiais às suas necessidades educacionais. Considerando um ambiente onde não há a existência inerente de um tutor (tal qual o Merlot), essa melhora se torna ainda mais importante. É importante ainda ressaltar que a melhora no desempenho da recomendação após a utilização da clusterização apresenta a limitação de diminuir o espaço de cobertura dos usuários, sendo que quanto maior o número de clusters gerados, menor a quantidade de usuários para os quais o algoritmo de FC consegue recomendar objetos.

Agradecimentos

Este trabalho foi financiado pela FAPERGS (Fundação de Amparo à Pesquisa do Rio Grande do Sul) através do seu programa Pesquisador Gaúco - PQG - Edital 02/2014, pelo CYTED (Programa Ibero-Americano para Ciência, Tecnologia e Desenvolvimento) como parte do seu projeto "RIURE - *Ibero-American Network for the Usability of Learning Repositories*" e pela Universidade Federal de Pelotas (UFPel-Brasil).

Referências

- Carvalho, V., Dorca, F., Cattelan, R., and Araujo, R. (2014). Uma abordagem para recomendação automática e dinâmica de objetos de aprendizagem baseada em estilos de aprendizagem. *25º Simpósio Brasileiro de Informática na Educação (SBIE) no 3º Congresso Brasileiro de Informática na Educação (CBIE 2014), Dourados: EaD-UFGD*, 1.
- Cechinel, C., Sánchez-Alonso, S., and García-Barriocanal, E. (2011). Statistical profiles of highly-rated learning objects. *Computers & Education*, 57(1):1255 – 1269.
- Cechinel, C., Sicilia, M.-Á., Sánchez-Alonso, S., and García-Barriocanal, E. (2013). Evaluating collaborative filtering recommendations inside large learning object repositories. *Information Processing & Management*, 49(1):34 – 50.
- Drachsler, H., Bogers, T., Vuorikari, R., Verbert, K., Duval, E., Manouselis, N., Beham, G., Lindstaedt, S., Stern, H., Friedrich, M., and Wolpers, M. (2010). Issues and considerations regarding sharable data sets for recommender systems in technology enhanced learning. *Procedia Computer Science*, 1(2):2849 – 2858. Proceedings of the 1st Workshop on Recommender Systems for Technology Enhanced Learning (RecSysTEL 2010).
- Drachsler, H., Hummel, H. G. K., and Koper, R. (2008). Personal recommender systems for learners in lifelong learning networks; the requirements, techniques and model. *Int. J. Learn. Technol.*, 3(4):404–423.
- Ghauth, K. and Abdullah, N. (2010). Learning materials recommendation using good learners' ratings and content-based filtering. *Educational Technology Research and Development*, 58(6):711–727.

- Gong, S. and Ye, H. (2009). Joining user clustering and item based collaborative filtering in personalized recommendation services. In *Industrial and Information Systems, 2009. IIS '09. International Conference on*, pages 149–151.
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., and Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Trans. Inf. Syst.*, 22(1):5–53.
- Huang, Y. (2009). An item based collaborative filtering using item clustering prediction. In *Computing, Communication, Control, and Management, 2009. CCCM 2009. ISECS International Colloquium on*, volume 4, pages 54–56.
- Klašnja-Milićević, A., Vesin, B., Ivanović, M., and Budimac, Z. (2011). E-learning personalization based on hybrid recommendation strategy and learning style identification. *Computers & Education*, 56(3):885 – 899.
- Manouselis, N., K. G. S. G. (2012). Revisiting the multi-criteria recommender system of a learning portal. In *2nd Workshop on Recommender Systems in Technology Enhanced Learning (RecSysTEL) - 7th European Conference on Technology Enhanced Learning (EC-TEL 2012)*, pages 35–48.
- Manouselis, N., Drachsler, H., Vuorikari, R., Hummel, H., and Koper, R. (2011). Recommender systems in technology enhanced learning. In Ricci, F., Rokach, L., Shapira, B., and Kantor, P. B., editors, *Recommender Systems Handbook*, pages 387–415. Springer US.
- Ochoa, X. and Carrillo, G. (2013). Recomendación de objetos de aprendizaje basado en el perfil del usuario y la información de atención contextualizada. *Conferencias LACLO*, 4(1).
- Pontes, W., Franca, R., Costa, A. P. M., and Behar, P. A. (2014). Filtragens de recomendação de objetos de aprendizagem: uma revisão sistemática do cbie. *25º Simpósio Brasileiro de Informática na Educação (SBIE) no 3º Congresso Brasileiro de Informática na Educação (CBIE 2014), Dourados: EaD-UFGD*, 1:76–86.
- Sicilia, M.-Á., García-Barriocanal, E., Sánchez-Alonso, S., and Cechinel, C. (2010). Exploring user-based recommender results in large learning object repositories: the case of merlot. *Procedia Computer Science*, 1(2):2859 – 2864. Proceedings of the 1st Workshop on Recommender Systems for Technology Enhanced Learning (RecSysTEL 2010).
- Tang, T. and McCalla, G. (2005). Smart recommendation for an evolving e-learning system: Architecture and experiment. *International Journal on E-Learning*, 4(1):105–129.
- Verbert, K., Manouselis, N., Ochoa, X., Wolpers, M., Drachsler, H., Bosnic, I., and Duval, E. (2012). Context-aware recommender systems for learning: A survey and future challenges. *Learning Technologies, IEEE Transactions on*, 5(4):318–335.
- Wang, P.-Y. and Yang, H.-C. (2012). Using collaborative filtering to support college students' use of online forum for english learning. *Computers & Education*, 59(2):628 – 637.