

Recomendação de Objetos de Aprendizagem baseada na Popularidade dos Objetos e nos Estilos de Aprendizagem dos Alunos

Janderson J. B. Aguiar¹, Joseana M. Fechine¹, Evandro B. Costa²

¹ Universidade Federal de Campina Grande (UFCG), Campina Grande – PB – Brasil

² Universidade Federal de Alagoas (UFAL), Maceió – AL – Brasil

janderson@copin.ufcg.edu.br, joseana@dsc.ufcg.edu.br, evandro@ic.ufal.br

Abstract. *Students have different Learning Styles (LS), and therefore the characteristics of the materials used for study can impact on their learning. With the increasing number of Learning Objects (LO) in various repositories, it is important to study possibilities for improving the access of the vast amount of LO to students. Thus, it is interesting the use of Recommender Systems for LO, based on LS students. In addition, the popularity of these LO in educational environment can be used as a strategy to improve the recommendations. The objective of this paper is to present a hybrid recommendation model for LO, based on popularity of items and LS. The experiment conducted with 55 students, considering their LS and their ratings for 25 LO variations, indicated the utility of the proposed hybrid model (which proved to be better than other traditional recommendation approaches).*

Resumo. *Os alunos possuem diferentes Estilos de Aprendizagem (EA), e, portanto, as características dos materiais educacionais podem impactar no seu modo de aprender. Com o número crescente de Objetos de Aprendizagem (OA) em vários repositórios, é importante estudar como melhorar o acesso a esses OA. Portanto, é interessante o uso de Sistemas de Recomendação de OA, com base nos EA dos alunos. Além disso, a popularidade desses OA no ambiente educacional pode ser usado como uma estratégia para melhorar as recomendações. O objetivo deste artigo é apresentar um modelo híbrido de recomendação de OA, com base em sua popularidade e nos EA dos alunos. O experimento realizado com 55 estudantes, considerando seus EA e suas avaliações para 25 variações de OA, indicou a utilidade do modelo proposto, que se mostrou melhor que outras abordagens tradicionais de recomendação.*

1. Introdução

Para minimizar o tempo e o esforço despendido ao desenvolver materiais didáticos, e pensando em uma forma de reutilizar esses materiais, surgiu o conceito de Objetos de Aprendizagem (OA) [Resende *et al.* 2014]. Com a consolidação da Web como meio de apoio ao processo de ensino e aprendizagem, há uma tendência crescente na quantidade de OA disponíveis para estudantes e professores, em vários repositórios existentes, a exemplo do ARIADNE (<http://ariadne-eu.org/>), Connexions (<http://cnx.org/>), Learn-Alberta (<http://learnalberta.ca>), MERLOT (<http://merlot.org>) e RIVED (<http://rived.mec.gov.br/>).

Em meio à sobrecarga de informação, surgiram os Sistemas de Recomendação (SR), coletando informações sobre as preferências de seus usuários para um conjunto de

itens (a exemplo de filmes, músicas e materiais educacionais), e visando ao auxílio aos usuários no processo de busca e acesso a informações relevantes [Ricci *et al.* 2011; Bobadilla *et al.*, 2013; Aguiar *et al.*, 2014]. Dentre as técnicas utilizadas em SR, uma das mais conhecidas é a Filtragem Colaborativa (FC). Na FC, com as avaliações dos itens pelos usuários do sistema, é possível sugerir os itens melhor avaliados por usuários com preferências similares, não sendo necessário compreender ou reconhecer as características dos itens [Cazella, Nunes e Reategui 2010; Bobadilla *et al.* 2013; Costa, Aguiar e Magalhães 2013].

As limitações em relação à FC referem-se especialmente à coleta de informações dos usuários, destacando-se os problemas de: (i) primeiro avaliador, uma vez que um novo item não é recomendado até que usuários o avaliem; (ii) pontuações esparsas, em casos de sistemas com pequeno número de usuários e grande número de itens; (iii) usuário com gostos muito diferentes, dado que as recomendações para ele podem ser fracas pela escassez de usuários com gostos similares [Adomavicius e Tuzhilin 2005; Costa, Aguiar e Magalhães 2013].

Além dessas limitações em SR de contexto geral, é ainda mais desafiador quando se pretende recomendar recursos educacionais personalizados baseando-se em necessidades individuais de cada aluno, um vez que, segundo Kolb (1984), o processo de aprendizagem não é vivenciado por todos os indivíduos da mesma forma, sendo desenvolvidos — como resultado da bagagem hereditária, das experiências pessoais e das exigências do ambiente — Estilos de Aprendizagem (EA), que enfatizam algumas habilidades sobre as outras.

Segundo Bobadilla *et al.* (2013), a evolução dos SR mostra a importância de técnicas híbridas, que combinam duas ou mais técnicas de recomendação diferentes, a fim de resolver as limitações e obter as vantagens de cada uma delas.

Embora técnicas de recomendação personalizada demonstrem ser mais eficientes em muitos contextos, a recomendação não personalizada pode ser encontrada em combinação com técnicas de recomendação personalizada em muitos SR. Um algoritmo bastante útil e conhecido que utiliza recomendação não personalizada é o Mais Popular (*Most Popular* — MP) que, como o nome sugere, se baseia na popularidade dos itens, sendo recomendados a todos os usuários do sistema os itens julgados mais interessantes pela maioria.

Considerando todo o contexto discutido até então, percebe-se a importância de criar modelos de recomendação de OA baseada nos EA dos estudantes para melhorar a aprendizagem destes. Os resultados obtidos por meio de um experimento, realizado com alunos de graduação e pós-graduação em Ciência da Computação, indicam a utilidade de um modelo híbrido baseado em popularidade dos OA e as características desses, seguindo o padrão IEEE LOM (*Learning Object Metadata*) [IEEE 2002], associadas à teoria de EA de Felder–Silverman [Felder e Silverman 1988].

2. Trabalhos Relacionados

Dentre as primeiras iniciativas de SR voltadas para a educação, é possível citar o GroupLens, um projeto de pesquisa, desenvolvido pela Universidade de Minnesota, relacionado à FC, cujo sistema auxiliava a busca de artigos, coletando a avaliação dos usuários, referente aos artigos lidos e, a partir da identificação dos usuários com avaliações similares, recomendava novos artigos [Konstan *et al.* 1997].

Recentemente, Drachsler *et al.* (2015) realizaram uma pesquisa analisando a área de SR na Aprendizagem Apoiada por Tecnologia (*Recommender Systems in TEL — Technology Enhanced Learning*), ao longo de 15 anos (2000–2014). Foram investigados 82 trabalhos, de 35 países diferentes. Dentre eles, é possível citar o de Kerkiri, Manitsaris e Mavridis (2009) e o de Casali *et al.* (2012), trabalhos que demonstraram preocupação com as preferências dos aprendizes.

Kerkiri, Manitsaris e Mavridis (2009) propuseram uma metodologia para aplicar algoritmos de recomendação em um sistema *e-learning*, explorando ontologias para personalizar recursos de aprendizagem. Segundo os autores, a personalização é realizada por meio da manipulação de metadados relacionados à reputação e aos EA dos usuários, a partir do modelo de Felder–Silverman. Para receberem as recomendações personalizadas, os alunos inicialmente fornecem algumas informações sobre eles (dados pessoais, preferências etc.), além de preencherem um questionário sobre EA.

Casali *et al.* (2012) apresentam o desenvolvimento de um SR para ajudar os usuários a encontrar OA mais adequados às suas necessidades e preferências. A partir de repositórios de aprendizagem distribuídos, os OA, descritos em metadados, são recomendados seguindo uma abordagem baseada em regras, levando em consideração o perfil dos usuários.

No contexto brasileiro, Aguiar *et al.* (2014) realizaram um mapeamento sobre iniciativas em Sistemas de Recomendação Educacionais (SRE). Dentre os trabalhos retornados nesse mapeamento, é possível destacar o de Zaina *et al.* (2012), que utiliza o padrão de metadados IEEE LOM para OA, sendo relacionado esse padrão com as dimensões de EA de Felder–Silverman. Outro trabalho que utiliza esses conceitos é o de Carvalho *et al.* (2014).

Enquanto Zaina *et al.* (2012) apresentaram uma abordagem não dinâmica, desconsiderando as incertezas relacionadas à modelagem do perfil do estudante, Carvalho *et al.* (2014) consideraram de maneira probabilística as dimensões de EA. Embora o processo de avaliação do trabalho de Carvalho *et al.* (2014) indique sua possível utilidade à personalização em SRE, não é avaliada a acurácia das recomendações.

Apesar dos trabalhos comentados anteriormente serem relacionados ao trabalho proposto neste artigo, este trabalho diferencia-se por expandir o modelo de Carvalho *et al.* (2014) com o aspecto de popularidade, criando um modelo híbrido. Além disso, este trabalho avaliou a acurácia do modelo híbrido proposto comparando-o com o modelo de Carvalho *et al.* (2014) e outros algoritmos tradicionais de recomendação.

3. Conceitos sobre Objetos e Estilos de Aprendizagem

Dentre as definições de OA existentes, Wiley (2000) defende que eles são entidades digitais que podem ser transmitidas pela Web e acessadas simultaneamente por um grande público, de uma maneira mais versátil em comparação à mídia tradicional (livros e outros materiais disponibilizados em mídias físicas). Um dos padrões de OA mais populares é o padrão IEEE LOM (IEEE 1484.12.1), que, como afirmam Vicari *et al.* (2010), é amplamente aceito no meio acadêmico, apresentando um conjunto de metadados organizado em nove categorias. São elas: Geral (informações gerais do OA), Ciclo de vida (características relativas ao histórico e ao estado atual do OA), Meta-metadados (metadados utilizados para descrever os metadados do OA), Técnica

(requisitos e características técnicas do OA), Educacional (características educacionais e pedagógicas do OA), Direitos (direitos de propriedade intelectual e condições de uso do OA), Relação (características que definem o relacionamento entre um OA e outros), Anotação (comentários sobre o uso do OA) e Classificação (descrição do objeto de acordo com algum sistema de classificação pré-definido) [IEEE 2002; Vaz 2009].

Dentre os modelos de EA, é possível destacar o modelo de Felder–Silverman, o mais utilizado no contexto brasileiro e internacional em pesquisas relativas à adaptação e personalização de materiais de aprendizagem [Aguiar, Fachine e Costa 2014; Valaski, Malucelli e Reinehr 2011]. Tal modelo contempla 4 (quatro) dimensões de EA: (1) Processamento (estilos Ativo e Reflexivo); (2) Percepção (estilos Sensorial e Intuitivo); (3) Entrada (estilos Visual e Verbal); e (4) Compreensão (estilos Sequencial e Global) [Felder e Silverman 1988; Felder 2002]. Baseado nas 4 dimensões, foi desenvolvido o Índice de Estilos de Aprendizagem (*Index of Learning Styles* — ILS) [Felder e Soloman 1999], instrumento de mensuração com 44 questões.

Em geral, os alunos Ativos aprendem por meio da experimentação ativa, e compreendem as informações mais eficientemente discutindo e aplicando os conceitos; por outro lado, os Reflexivos necessitam de um tempo sozinhos para pensar/refletir sobre as informações obtidas. Os alunos Sensoriais preferem lidar com situações concretas, dados e experimentos; por outro lado, os Intuitivos são inovadores, gostam de lidar com abstrações, conceitos e teorias. Os indivíduos com estilo Visual aprendem mais facilmente por meio de demonstrações, diagramas, figuras, filmes, fluxogramas; por outro lado, aqueles com estilo Verbal compreendem melhor as informações transmitidas por meio de palavras. Os alunos Sequenciais aprendem melhor quando o conceito é expresso de maneira contínua de dificuldade e complexidade; por outro lado, os alunos Globais são multidisciplinares, aprendendo em grandes saltos e lidando com os conteúdos de forma aleatória [Felder e Silverman, 1988; Dias, Gasparini e Karczinski, 2009].

4. Modelo de Recomendação

Na Figura 1, é ilustrado o modelo de recomendação proposto nesta pesquisa. Em síntese, a partir do “Perfil do Discente” e do “Perfil do Objeto de Aprendizagem”, são calculados os melhores OA para tal aluno e, por conseguinte, tais itens são recomendados para o aluno.

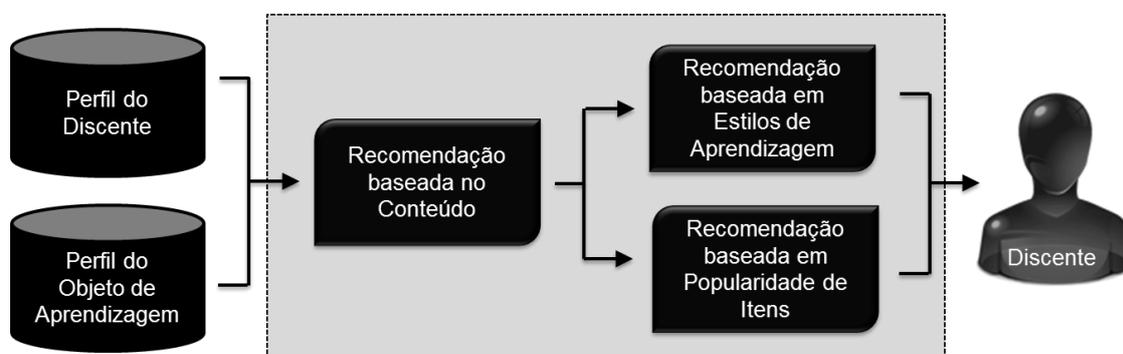


Figura 1. Modelo de recomendação de OA baseada na popularidade dos objetos e nos EA dos alunos.

O “Perfil do Discente” consiste basicamente nos EA de cada aluno, baseado no modelo de Felder–Silverman. O “Perfil do Objeto de Aprendizagem” consiste nos OA, criados com base no padrão IEEE LOM, com seus metadados devidamente preenchidos — especialmente os que se referem ao Conteúdo e à associação, realizada por Carvalho *et al.* (2014), entre os metadados dos OA do padrão IEEE LOM e as quatro dimensões de EA do modelo de Felder–Silverman.

O processo de recomendação proposto consiste inicialmente em filtrar os OA com base no seu conteúdo (para, por exemplo, alunos procurando conteúdo sobre Compiladores não receberem recomendação de OA sobre Banco de Dados etc.) e, após isso, ordenar esses OA com base nos EA do aluno, além da popularidade desses itens.

Essa ordenação é realizada com base no que foi denominado Grau de Recomendação (*GR*) do OA, calculado segundo a Equação 1, sendo P_{MP} a posição do OA no *ranking* relativo ao algoritmo MP, e sendo P_{EA} a posição do OA no *ranking* relativo ao algoritmo baseado em EA, proposto por Carvalho *et al.* (2014), chamado neste artigo de LSBR (*Learning Style based recommendation*).

$$GR(oa) = \frac{1}{P_{EA}(oa)} + \frac{1}{P_{MP}(oa)} \quad (1)$$

Suponha, por exemplo, que, com um total de 50 OA em um repositório, após a filtragem com base no conteúdo, são definidos 10 OA que abordam o conteúdo de Compiladores. Após definidos esses 10 OA, são calculados os GR de cada um deles. Para isso, tais OA são ordenados, para cada usuário-alvo, em duas listas diferentes, uma com base na execução do algoritmo LSBR (lista baseada em EA) e outra com base na execução do algoritmo MP (lista baseada em popularidade).

Considerando um OA ‘X’ na posição 2 da lista baseada em EA ($P_{EA} = 2$) e na posição 4 da lista baseada em popularidade ($P_{MP} = 4$), seu GR será igual a 0.75, ou seja $(1/2)+(1/4)$. Considerando um OA ‘Y’ na posição 1 da lista baseada em EA ($P_{EA} = 1$) e na posição 5 da lista baseada em popularidade ($P_{MP} = 5$), seu GR será igual a 1.2, ou seja $(1/1)+(1/5)$. Neste caso, o ‘Y’ é julgado mais útil que o ‘X’ para o usuário-alvo.

5. Avaliação do Modelo Proposto

O artigo clássico de Herlocker *et al.* (2004) aborda a avaliação em SR. Para medir quão relevante para o usuário é um conjunto de itens recuperados/recomendados pelo SR, há métricas de acurácia de classificação, tais como: Precisão (*Precision*), $P@n$ (*Precision at n*), Cobertura (*Recall*), $R@n$ (*Recall at n*), MAP (*Mean Average Precision*), ROC (*Receiver Operating Characteristic*), AUC (*Area Under ROC Curve*), NDCG (*Normalized Discounted Cumulative Gain*) e MRR (*Mean Reciprocal Rank*).

Para este trabalho, foram considerados que 25 OA apresentavam o mesmo conteúdo (ou seja, já seriam OA filtrados na primeira fase do modelo proposto), mas com características diferentes (valores diferentes nos metadados referente a Formato, Tipo de Recurso de Aprendizagem, Tipo de Interatividade e Estrutura). Com base nessas características, 55 estudantes de Ciência da Computação de duas universidades federais brasileiras (35 alunos de graduação e 20 alunos de pós-graduação) classificaram esses 25 OA de 1 a 5 estrelas, além de responderem o inventário ILS. As justificativas para adotar tal inventário como instrumento de mensuração de EA foram: (i) acesso livre e sem custos, disponibilizado via Web em diversos idiomas; (ii)

preenchimento fácil e simples, e (iii) confiabilidade e validade, sendo amplamente utilizado em pesquisas anteriores.

Com isso, foram comparados o algoritmo LSBR com o algoritmo híbrido proposto neste artigo (LSBR+MP), além do algoritmo MP e estes algoritmos tradicionais em SR: UserKNN e ItemKNN (FC baseada em k usuários/itens, considerados vizinhos mais próximos), e BPRMF (Fatoração de Matrizes usando BPR — *Bayesian Personal Ranking*).

Sobre a avaliação, por ser utilizada a estratégia de recomendar um conjunto ordenado de OA, foram escolhidas as seguintes métricas: AUC, MAP, MRR, NDCG, P@5 e R@5. Foi empregada a técnica de validação cruzada (*k-fold cross validation*) [Bengio e Grandvalet 2004 *apud* Bobadilla *et al.* 2013], sendo separados aleatoriamente, por cem vezes ($k=100$), os dados em dois conjuntos: um para treinar o modelo, e outro para testá-lo.

Para execução desses algoritmos tradicionais, foi utilizado o MyMediaLite [Gantner *et al.* 2011], versão 3.10, considerando o limiar de avaliação de 3 estrelas como um item útil. O MyMediaLite também foi utilizado para calcular as métricas anteriormente citadas.

No experimento realizado, além do fator Algoritmo (com os níveis ItemKNN, UserKNN, BPRMF, MP, LSBR e LSBR+MP), foi considerado o fator Porcentagem utilizada para o conjunto de treino (com os níveis 65% e 75%). Este experimento, do tipo comparativo, utilizou o Design Fatorial Completo, com 12 tratamentos (6 algoritmos \times 2 níveis de porcentagem), sendo realizadas 100 repetições para cada, totalizando 1200 ensaios.

6. Resultados e Discussão

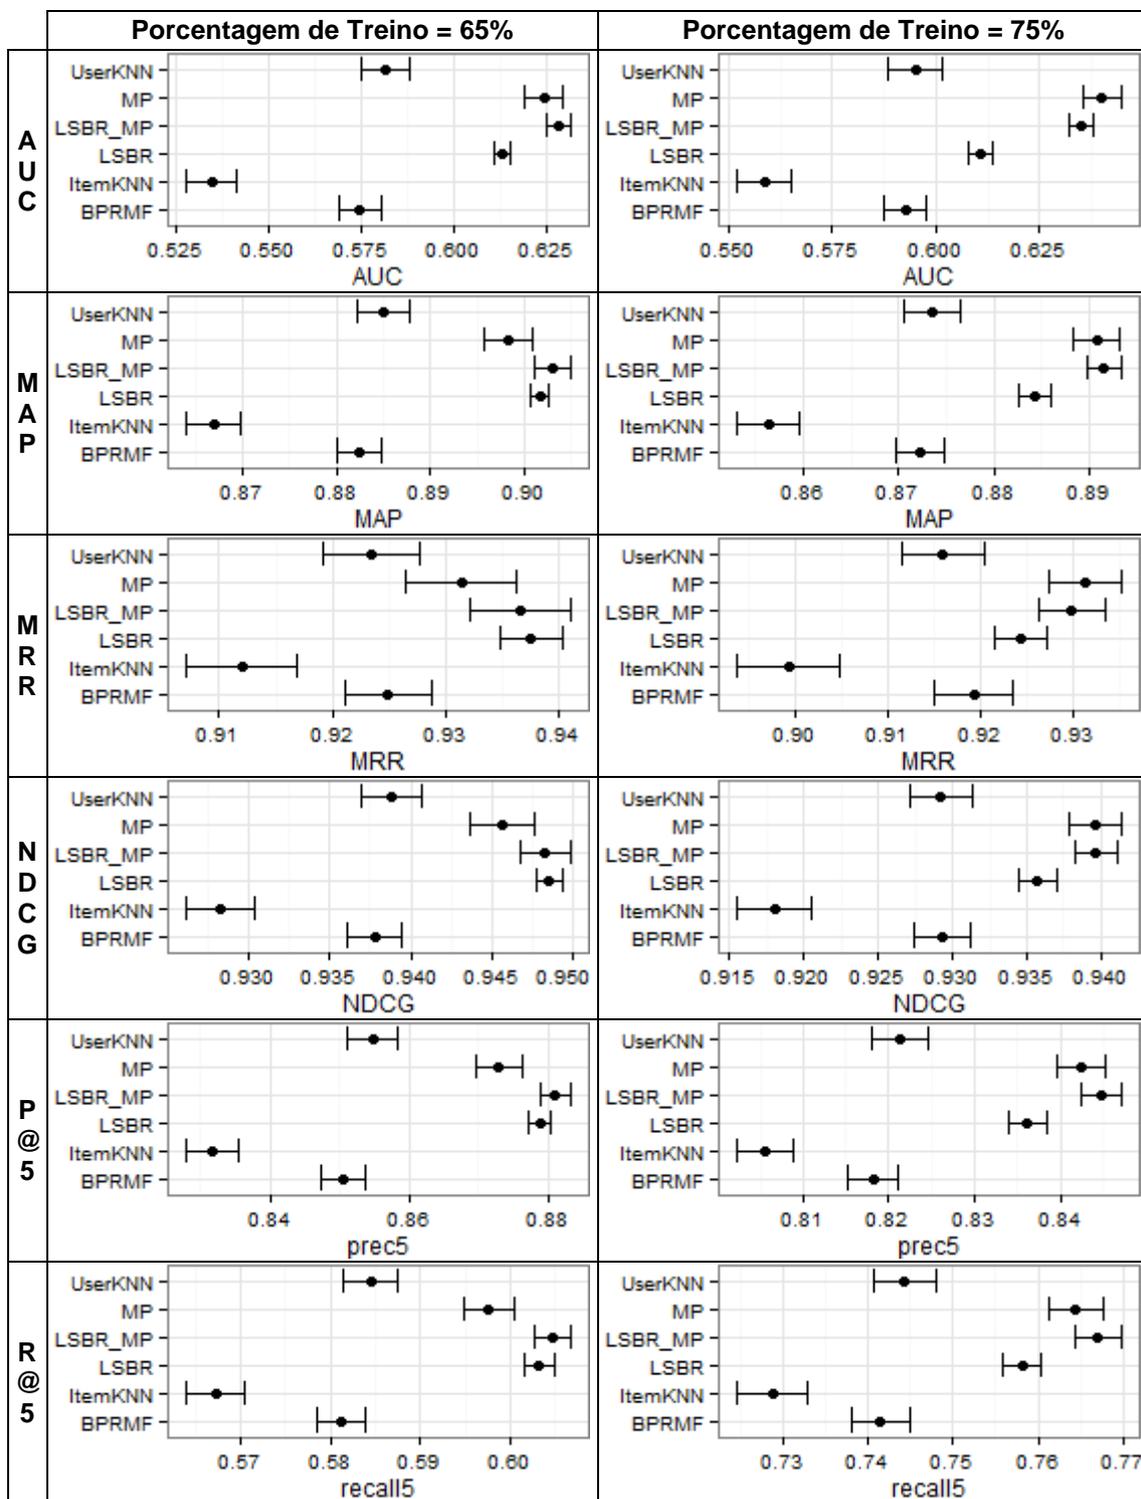
Após a execução do experimento, planejado conforme indicado na seção 5, foram gerados intervalos de confiança para as médias obtidas pelos algoritmos para cada métrica, com nível de significância de 5% (Quadro 1), a fim de verificar o desempenho do modelo proposto em relação aos outros algoritmos.

A partir do Quadro 1, percebe-se que, em geral, ao comparar os intervalos de confiança a partir das seis métricas, e da variação da porcentagem de treino, a abordagem híbrida proposta neste artigo (LSBR+MP) apresentou os melhores resultados. Nas vezes em que não se destacou dos outros algoritmos de recomendação, o intervalo de confiança manteve-se sobreposto a um dos outros algoritmos comparados.

Além do modelo proposto ser interessante por não enfrentar as limitações das abordagens de FC comentadas na seção 1, tal modelo apresentou-se, em todos os gráficos, melhor que os algoritmos tradicionais baseados em vizinhos mais próximos (UserKNN e ItemKNN), além do baseado em fatoração de matrizes (BPRMF).

Em relação à abordagem LSBR, este experimento reforça a importância do modelo proposto por Carvalho *et al.* (2014), uma vez que, em tal trabalho, apesar de ser apresentada uma simulação computacional com resultados promissores, não havia sido realizada uma avaliação comparativa como neste artigo. O modelo LSBR, em todos os gráficos, também se apresentou melhor que os algoritmos UserKNN, ItemKNN e BPRMF (apesar de uma leve sobreposição de intervalos no gráfico relativo à métrica MRR considerando a porcentagem de treino de 75%).

Quadro 1. Intervalos de confiança para comparação das abordagens de recomendação com base nas métricas AUC, MAP, MRR, NDCG, P@5 e R@5, e na porcentagem de treino utilizada (65% e 75%).



Neste experimento, ressalta-se a importância da abordagem não personalizada (MP — Mais Popular), que em alguns casos apresentou intervalos de confiança com valores até maiores que a abordagem LSBR, além de intervalos de confiança próximos ou mesmo sobrepostos aos do modelo proposto.

O uso de várias métricas de comparação e de dois distintos valores percentuais para o conjunto de treino foram estratégias visando maior generalização dos resultados obtidos. Entretanto, é importante advertir que outros experimentos, com diferentes itens e pessoas, poderiam indicar variações nesses resultados. Como é visível a partir do Quadro 1, o algoritmo ItemKNN teve desempenho sempre menor diante do algoritmo UserKNN, o que pode ser provavelmente justificado pela quantidade de usuários (55) ser maior que a quantidade de itens (25).

Todavia, dados os resultados apresentados relativos à acurácia das recomendações, ressalta-se a importância da abordagem proposta (LSBR+MP) para a área de SRE.

7. Considerações Finais

Há docentes e pesquisadores preocupados com a forma com que os aprendizes lidam particularmente com as informações, sendo o conceito de EA levado em consideração em muitas pesquisas atualmente, objetivando não tratar igualmente os estudantes em relação ao modo como adquirem e produzem conhecimento. Como exposto no mapeamento realizado por Aguiar, Fachine e Costa (2014), nos últimos anos houve um aumento de pesquisas em Informática na Educação considerando o conceito de EA.

Apesar de, no experimento apresentado neste artigo, ser utilizado o ILS como instrumento de mensuração de EA, é interessante comentar que há iniciativas considerando o modelo de Felder–Silverman que não o utilizam, sendo possível citar as pesquisas de Popescu, Trigano e Badica (2007) e Silva e Dorça (2014), que sugerem a utilização de métodos baseados na análise do comportamento implícito do estudante em sistemas de aprendizagem. Em ambas as pesquisas, além da obtenção dos EA, são realizadas dinamicamente atualizações no perfil do aluno, considerando o desempenho na avaliação de uma seção de aprendizagem [Silva e Dorça 2014] e regras como, por exemplo, um valor alto no número de postagens em fórum indica um estilo Ativo e Verbal [Popescu, Trigano e Badica 2007].

Dado o modelo exposto na Figura 1, essa ideia de atualização dinâmica pode ser facilmente incorporada na abordagem desta pesquisa, atualizando o “Perfil do Discente” com base no sistema de aprendizagem utilizado.

Neste ponto, vale ressaltar que, embora tenha se utilizado a teoria de EA de Felder–Silverman e o padrão IEEE LOM para os OA, o modelo proposto pode ser adaptado para usar outras teorias de EA (como a de [Kolb 1984]) e outros padrões de metadados (como o OBAA [Vicari *et al.* 2010]). Destaca-se apenas a necessidade de uma associação consistente entre a teoria de EA e o padrão de OA utilizados, para que os OA recomendados correspondam aos EA dos alunos. Nesse aspecto, muitas pesquisas ainda podem ser realizadas para melhorar/abranger as associações entre dimensões de EA e os metadados dos padrões dos OA [Aguiar, Fachine e Costa 2015].

Uma vez que é válido e necessário considerar as particularidades dos estudantes, os autores deste artigo defendem a necessidade, em ambientes educacionais, de recomendações personalizadas baseadas em EA como estratégia de melhorar o acesso a recursos educacionais por parte dos alunos e, por conseguinte, propiciar melhorias na aprendizagem destes. Além disso, o aspecto de popularidade de itens se torna importante por permitir que, mesmo que um aprendiz tenha uma preferência muito

particular, seja possível receber recomendações de alguns OA que foram julgados úteis pela maioria dos colegas.

Além desses aspectos para personalização de SR, estão sendo atualmente estudados meios de incorporar a teoria de Traços de Personalidade nesse modelo híbrido, visando melhorar ainda mais a acurácia das recomendações.

Agradecimentos

Os autores agradecem aos pesquisadores contatados, pelos dados e informações disponibilizados, essenciais para o desenvolvimento desta pesquisa.

Referências

- Adomavicius, G.; Tuzhilin, A. (2005). Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. In: *IEEE Transactions On Knowledge and Data Engineering*, vol. 17, n. 6, p. 734–749.
- Aguiar, J. J. B.; Fachine, J. M.; Costa, E. (2014). Estilos Cognitivos e Estilos de Aprendizagem em Informática na Educação: um mapeamento sistemático focado no SBIE, WIE e RBIE. In: *Anais do XXV Simpósio Brasileiro de Informática na Educação (SBIE)*, Dourados, p. 441–450.
- Aguiar, J. J. B.; Fachine, J. M.; Costa, E. (2015). Análise Comparativa de Abordagens de Associação entre os Estilos de Aprendizagem de Felder-Silverman e os Metadados do Padrão IEEE LOM. In: *XXXV Congresso da Sociedade Brasileira de Computação — IV Workshop de Desafios da Computação Aplicada à Educação (DesafIE)*, Recife. Sem paginação.
- Aguiar, J. J. B.; Santos, S. I. N.; Fachine, J. M.; Costa, E. (2014). Um Mapeamento Sistemático sobre Iniciativas Brasileiras em Sistemas de Recomendação Educacionais. In: *Anais do XXV Simpósio Brasileiro de Informática na Educação*, Dourados, p. 1123–1132.
- Bobadilla, J.; Ortega, F.; Hernando, A.; Gutiérrez, A. (2013). Recommender systems survey. *Knowledge Based Systems*, v. 46, p. 109–132.
- Carvalho, V. C.; Dorça, F. A.; Cattelan, R. G.; Araújo, R. D. (2014). Uma Abordagem para Recomendação Automática e Dinâmica de Objetos de Aprendizagem Baseada em Estilos de Aprendizagem. In: *Anais do XXV Simpósio Brasileiro de Informática na Educação — SBIE 2014*, Dourados, MS, p. 1188–1197.
- Casali, A.; Gerling, V.; Deco, C.; Bender, C. (2012). A Recommender System for Learning Objects Personalized Retrieval. In: Santos O.; Boticario, J. (Org.), *Educational Recommender Systems and Technologies: Practices and Challenges*, p. 182–210.
- Cazella, S. C.; Nunes, M. A. S. N.; Reategui, E. B. (2010). A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. In: *XXX Congresso da Sociedade Brasileira de Computação — Jornada de Atualização em Informática (JAI)*.
- Costa, E.; Aguiar, J.; Magalhães, J. (2013). Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações. In *II Congresso Brasileiro de Informática na Educação — Jornada de Atualização em Informática na Educação (JAIE)*, p. 57–78.
- Dias, C. C. L.; Gasparini, I.; Kemczinsk, A. (2009). Identificação dos estilos cognitivos de aprendizagem através da interação em um Ambiente EAD. In: *XXIX Congresso da Sociedade Brasileira de Computação — XVII Workshop sobre Educação em Informática (WEI)*, p. 489–498.
- Drachsler, H.; Verbert, K.; Santos, O. C.; Manouselis, N. (2015). Panorama of recommender systems to support learning. *Handbook on recommender systems*. (no prelo). Disponível em: <https://lirias.kuleuven.be/bitstream/123456789/476545/1/TEL_RecSys.pdf>. Acesso em: 28 mai. 2015.

- Felder, R. M. (2002). Author's Preface — June 2002. In: *FELDER, R. M.; SILVERMAN, L. K. Learning and Learning and Teaching Styles in Engineering Education*. Disponível em: <<http://www.ncsu.edu/felder-public/Papers/LS-1988.pdf>>. Acesso em: 31 jan. 2015.
- Felder, R. M.; Silverman, L. K. (1988). Learning and Teaching Styles in Engineering Education. *Journal of Engineering Education*, v. 78, n. 7, p. 674–681.
- Felder, R. M.; Soloman, B. A. (1999). Index of Learning Styles (ILS). Disponível em: <<http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSpa.html>>. Acesso: 15 out. 2014.
- Gantner, Z.; Rendle, S.; Freudenthaler, C.; Schmidt-Thieme, L. (2011). MyMediaLite: A Free Recommender System Library. In: *Proceedings of the 5th ACM Conference on Recommender Systems (RecSys 2011)*. Chicago, USA.
- Herlocker, J. L.; Konstan, J. A.; Terveen, L. G.; Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, 22 (1), p. 5–53.
- IEEE. (2002). IEEE Standard for Learning Object Metadata. *IEEE Std 1484.12.1-2002*, p. i–32.
- Kerkiri, T.; Manitsaris, A.; Mavridis, I. (2009). How e-learning systems may benefit from ontologies and recommendation methods to efficiently personalise resources. *International Journal of Knowledge and Learning (IJKL)*, v. 5, n. 3/4, p. 347–370.
- Kolb, D. A. (1984). *Experiential learning: experience as the source of learning and development*. Englewood Cliffs: Prentice-Hall.
- Konstan, J. A.; Miller, B. N.; Maltz, D.; Herlocker, J. L.; Gordon, L. R.; Riedl, J. (1997). GroupLens: Applying Collaborative Filtering to Usenet News. *Communications of the ACM*, New York, v.40, n.3, p. 77–87.
- Popescu, E.; Trigano, P.; Badica, C. (2007). Adaptive Educational Hypermedia Systems: A Focus on Learning Styles. In: *EUROCON 2007 — The International Conference on “Computer as a Tool”*, p. 2473–2478.
- Resende, D. T.; Dorça, F. A.; Cattelan, R. G.; Araújo, R. D. (2014). Em direção à recuperação automática de objetos de aprendizagem em repositórios através da associação dos estilos de aprendizagem de estudantes com metadados no padrão IEEE-LOM. In: *Anais do VI Workshop Brasileiro de Web Semântica e Educação (WSWEd)*, Dourados, MS.
- Ricci, F.; Rokach, L.; Shapira, B.; Kantor, P. B. (Eds.). (2011). *Handbook on Recommender Systems*. 1.ed. Springer, 845 p., ISBN: 978-0-387-85819-7.
- Silva, D. H.; Dorça, F. A. (2014). Uma Abordagem Automática para Personalização do Processo de Ensino Baseada em Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância. *Revista Brasileira de Informática na Educação (RBIE)*, v. 22, n. 2, p.1–15.
- Valaski, J.; Malucelli, A.; Reinehr, S. (2011). Revisão dos Modelos de Estilos de Aprendizagem Aplicados à Adaptação e Personalização dos Materiais de Aprendizagem. In: *Anais do XXII Simpósio Brasileiro de Informática na Educação (SBIE)*, p. 844–847.
- Vaz, M. (2009). Os Padrões Internacionais para a Construção de Material Educativo On-line. *Pearson Education do Brasil*, São Paulo, 1.ed., p. 386–396.
- Vicari, R. M.; Ribeiro, A.; Da Silva, J. M. C.; Santos, E. R.; Primo, T.; Bez, M. (2010). Brazilian proposal for agent-based learning objects metadata standard — OBAA. *Communications in Computer and Information Science*, v. 108, p. 300–311.
- Wiley, D. (2000). *Connecting learning objects to instructional design theory: A definition, a metaphor, and a taxonomy*, The Agency for Instructional Technology, Bloomington, Indiana, USA, p. 3–23.
- Zaina, L. A.; Bressan, G.; Cardieri, M. A. A.; Rodrigues Junior, J. F. (2012). E-LORS: Uma abordagem para recomendação de objetos de aprendizagem. *Revista Brasileira de Informática na Educação (RBIE)*, v. 20, n. 1, p. 4–16.