

Leandro Simões

Universidade Federal Juiz de Fora
Rua José Lourenço Kelmer, S/n
Juiz de Fora - MG, 36036-330
leandro@ice.ufjf.br

Victor Ströele

Universidade Federal Juiz de Fora
Rua José Lourenço Kelmer, S/n
Juiz de Fora - MG, 36036-330
victor.stroele@ice.ufjf.br

Hugo Guércio

Universidade Federal Juiz de Fora
Rua José Lourenço Kelmer, S/n
Juiz de Fora - MG, 36036-330
ugo.guercio@gmail.com

Rafael F. Almeida

Universidade Federal Juiz de Fora
Rua José Lourenço Kelmer, S/n
Juiz de Fora - MG, 36036-330
rafaelalmeida@gmail.com

José Maria David

Universidade Federal Juiz de Fora
Rua José Lourenço Kelmer, S/n
Juiz de Fora - MG, 36036-330
j.david@ufff.edu.br

Fernanda Campos

Universidade Federal Juiz de Fora
Rua José Lourenço Kelmer, S/n
Juiz de Fora - MG, 36036-330
fernanda.campos@ufff.edu.br

Regina Braga

Universidade Federal Juiz de Fora
Rua José Lourenço Kelmer, S/n
Juiz de Fora - MG, 36036-330
regina.braga@ufff.edu.br

ABSTRACT

This article describes a recommender system metamodel, including steps, profile and context aspects, techniques and methods, that can be extensible to different domains. The proposal was developed from a systematic literature mapping and the research group experience in educational applications. To validate the proposal we present BROAD-GRS, a recommender system able to extract the information from social networks to identify characteristics of a group and its members in order to assist the process of search and selection of educational resources through a recommender systems for Groups. Preliminary results point to the viability of the model.

RESUMO

Esse artigo descreve um metamodelo de sistemas de recomendação, composto de etapas, aspectos de perfil e contexto, técnicas e métodos, que pode ser adaptado a diversos domínios. A proposta foi desenvolvida a partir de um mapeamento sistemático da literatura e experiências do Grupo de Pesquisa, notadamente na área educacional. Para validar a proposta é apresentado o BROAD-GRS um sistema capaz de extrair as informações disponíveis nas redes sociais para identificar características de um grupo e de seus membros de forma a auxiliar o processo de busca e seleção de recursos educacionais, através de um Sistema de Recomendação para Grupos. Os resultados preliminares apontam para a viabilidade do modelo.

Keywords

Recommender Systems, educational groups, social networks.

1. INTRODUÇÃO

Sistemas de recomendação (SR) são capazes de sugerir produtos, serviços e objetos alinhados ao perfil e contexto do usuário ou grupo, sendo possível aplicá-los a diversos domínios, entre eles e-commerce, e-learning, turismo e eScience. No entanto, a recomendação em ambiente educacional tem suas peculiaridades, pois os alunos possuem processos de aprendizagem próprios e alcançam diferentes níveis de competências [15].

Em ambientes sociais os SR são de particular importância, porque os usuários compartilham recursos formando grupos com interesses comuns [15, 16]. Nesse cenário de interação um dos grandes desafios desses sistemas é como lidar adequadamente com as preferências de cada integrante de um grupo para geração de uma recomendação conjunta [4].

Diante da diversidade de algoritmos de filtragem, métodos e técnicas, modelos de extração e enriquecimento de perfil e contexto, e, principalmente, da diversidade de domínios de aplicação e recursos recomendáveis nos SR, este trabalho pretende categorizar as etapas necessárias para o processo de recomendação incluindo os modelos identificados na literatura. Assim, o objetivo é construir um metamodelo de sistemas de recomendação, denominado MMRecommender, adaptável a diferentes domínios. Nesse artigo apresentamos a arquitetura do metamodelo.

Para validar o metamodelo proposto esse artigo também descreve o sistema de recomendação BROAD-GRS, cuja arquitetura segue o metamodelo proposto [1]. Esse sistema é capaz de extrair e explorar as informações disponíveis nas redes sociais para identificar características de um grupo e de seus usuários membros, e, a partir destas características, fazer recomendações de recursos educacionais aos usuários membros do grupo.

Este trabalho pretende avançar as pesquisas relacionadas ao projeto BROAD de recomendação de recursos educacionais [09, 10, 11, 12]. A principal ideia do projeto BROAD é que cada nova versão da arquitetura represente um passo à frente em relação aos objetivos da pesquisa considerando a adoção de novas tecnologias. Nosso foco na área educacional é a recomendação em Redes Sociais, individuais ou em grupos, usando repositórios locais, dados ligados ou outras mídias disponíveis.

O artigo está assim organizado: o mapeamento sistemático, os trabalhos relacionados e a identificação dos itens que compõem modelos de recomendação estão na seção 2. O metamodelo de recomendação MMRecommender proposto é descrito na seção 3. Na seção 4 é apresentado o BROAD-GRS, sistema para recomendação para grupos, desenvolvido a partir do metamodelo

e validado em um estudo de caso. Finalmente as considerações finais são apresentadas na seção 5

2. MAPEAMENTO SISTEMÁTICO

Essa etapa da pesquisa foi direcionada pela metodologia de mapeamento e revisão sistemática da literatura descrito por [17]. Teve como objetivo identificar modelos de recomendação presentes na literatura. Foi realizada entre outubro e dezembro de 2015. Foi utilizado o processo GQM (Goal/Question/Metric) a partir do qual foi extraída a questão de pesquisa primária, que norteou a construção do protocolo de revisão, assim como as *strings* de busca e também os critérios de inclusão e exclusão dos artigos. O processo foi dividido nas etapas de planejamento, condução e divulgação.

Planejamento: O método GQM (Tabela 1) ilustra o escopo da pesquisa em três aspectos: conceitual, no qual são definidos os objetivos da pesquisa; operacional, no qual são levantadas as perguntas que devem ser respondidas pelo mapeamento sistemático; e quantitativo, no qual são definidas as métricas para avaliar os trabalhos identificados.

Tabela 1. Quadro GQM

Método GQM	
Goal	Identificar modelos de recomendação.
Question	Quais as etapas necessárias na construção de sistemas de recomendação?
Metric	Quantidade de componentes em modelos de recomendação.

Após a construção do GQM foi definida a questão primária (QP) de pesquisa. E a questão secundária (QS) que, a partir das respostas coletadas, pretende responder à questão primária deste mapeamento: QP: Quais são as etapas necessárias na construção de sistemas de recomendação? e QS: Quais as técnicas utilizadas na construção de modelos de recomendação? Com essas questões espera-se identificar como um sistema pode gerar recomendações alinhadas ao perfil do usuário ou do grupo de usuários.

Para a busca dos trabalhos foram realizadas pesquisas em bases digitais indexadas através de *strings* de busca. Na construção da *string* genérica foi utilizado o framework PICOC (*Population, Intervention, Comparison, Outcome, Context*) proposto por [10] (Tabela 2).

Tabela 2. Quadro PICOC

PICOC		
Termo	Descrição	Keywords
Population	Algoritmos, abordagens e métodos baseados em modelo ou memória.	memory-based, model-based, algorithms, approaches, methods
Intervention	Efetuar recomendação	Recommendation
Comparison	--	--
Outcome	Modelos de recomendação	recommendermodel, recommendationmodel
Context	Sistemas de recomendação	recommender system, recommendation system

A partir do PICOC foi gerada a string de busca genérica (Tabela 3), que preserva a relação entre os termos procurados, mantendo a ordem lógica. A seguir foram escolhidas as bases de pesquisa: Scopus (www.scopus.com); IEEE (www.ieee.org); ScienceDirect (www.sciencedirect.com); ACM DL (www.dl.acm.org) e Web of Science (www.webofknowledge.com).

Os trabalhos retornados da busca foram submetidos aos critérios de inclusão (CI): artigos primários (CI1) e trabalhos nos idiomas espanhol, inglês e português (CI2).

Tabela 3. String genérica derivada do PICOC.

String genérica
("memory-based" OR "model-based" OR "algorithms" OR "approaches" OR "methods") AND ("recommender model" OR "recommendation model") OR ("recommender system" OR "recommendation system")

Esses trabalhos também foram submetidos aos seguintes critérios de exclusão: ano de publicação dos trabalhos, sendo excluídos os anteriores a 2005 (CE1); trabalhos duplicados foram excluídos mantendo sempre o mais recente (CE2); trabalhos sem acesso ao texto completo (CE3); trabalhos que não abordam o tema principal (CE4) (modelos ou componentes de recomendação).

Foi realizada a leitura do resumo, título e palavras-chaves de todos os artigos que não foram excluídos pelos critérios citados.

Condução: Na fase de condução os resultados foram quantificados por base e aplicados os critérios de inclusão e de exclusão(Tabela 4). Foi realizada a leitura dos resumos dos trabalhos (CE4) a fim de identificar possíveis respostas às questões de pesquisa. Ao final dessa etapa de leitura foram aceitos 151 trabalhos, sendo 23 indisponíveis (CE3), resultando em 128 trabalhos no final de todo o processo. A Figura 1 apresenta o fluxo de trabalho por etapas, explicitando a quantidade de artigos mantidos em cada uma delas. A Figura 2 mostra a relação de trabalhos selecionados e aceitos por base de pesquisa.

Tabela 4. Quantidade de trabalhos incluídos e excluídos.

Base	Inclusos	Anterior a 2005	Duplicados
Scopus	427	19	29
ACM DL	51	2	2
Web of Science	137	6	75
Science Direct	763	33	44
IEEE	205	16	11
ACM DL	1583	76	161
Total		1507	1346

Relatório: A Figura 3 e a Tabela 5 mostram, respectivamente, a quantidade de trabalhos selecionados publicados por ano e os principais domínios de aplicação. Assim, é possível inferir que é um tema atual, apresentando um crescimento de trabalhos publicados por ano. SR é um tema expansível a diferentes domínios de aplicação com tendências de aplicações, como em redes sociais. É importante observar que muitos domínios de aplicação são também considerados como itens de recomendação.

Com o intuito de analisar as técnicas utilizadas na construção de modelos de recomendação, os trabalhos foram agrupados de acordo com as técnicas mais utilizadas: Collaborative Filtering (54), Hybrid (18), Trust Model (7), Fuzzy Model (7), Clustering (6), Probabilistic (6), Bayesian Networks (5), Matrix Factorization (5), Knn (4) e Markov Model (3).

Tabela 5. Domínios de aplicação.

Domínio	Qtd.
Social Network	18
E-commerce	17
E-learning	10
Tourism	7
Music/Movies	6
Academic Papers	5
Web Services	4
News	4
Sites	4




Figura 1. Fluxo do mapeamento identificando a quantidade de trabalhos em cada etapa.




Figura 2. Trabalhos aceitos e selecionados por fonte.

2.1 Ameaças a Validade

A validação do protocolo do mapeamento sistemático foi feita por uma pesquisadora da área, porém, não houve validação ou participação de um grupo de pessoas na seleção e extração dos dados dos trabalhos, sendo essa uma ameaça à validade do mapeamento sistemático devido à possível presença de viés.

Outra ameaça está ligada à quantidade de trabalhos analisados (1346) em um curto período de tempo, o que demandou grande esforço podendo ter ocasionado fadiga no processo.

Em relação ao processo de seleção dos trabalhos nas fontes de pesquisa, as *strings* de busca não foram exatamente as mesmas, logo, há a possibilidade de uma *string* específica não realizar a busca exatamente conforme esperado. Para mitigar esta ameaça as *strings* foram criadas com bases nos tutoriais e arquivos de ajuda de cada base digital.



Figura 3. Quantidade de trabalhos aceitos por ano de publicação.

2.2 Trabalhos relacionados

Do resultado do mapeamento, foram selecionados dois artigos que reúnem, categorizam ou descrevem trabalhos que abordam temas relacionados à recomendação adaptável e expansível a diferentes domínios [2, 09].

Em [2] os autores realizam uma revisão a partir da extração dos termos mais relevantes em sistemas de recomendação com base em 300 artigos publicados em periódicos e congressos. O trabalho identifica os principais modelos e algoritmos utilizados e descreve taxonomias da área. Também apresenta métricas utilizadas para avaliação da recomendação, abordando inclusive possíveis tendências na área como a integração de diferentes fontes de dados, além da utilização do conceito de Internet of things e sensibilidade ao contexto.

Os autores de [09] apresentam uma revisão para sistemas de recomendação dividida em quatro dimensões: métodos e técnicas de recomendação, softwares que utilizam recomendação, domínios de aplicação e plataformas de aplicação. O processo é

feito com base na seleção de palavras-chaves, através da busca em bases digitais indexadas. O trabalho também descreve e agrupa diferentes domínios de aplicação e de recursos recomendáveis como turismo, e-learning, músicas e vídeos, documentos, redes sociais, entre outros, além de abordar a recomendação para grupos de usuários. Por fim, é apresentado um guia para aplicar e desenvolver sistemas que utilizam recomendação.

Outras revisões sobre o tema, em geral abordam temas específicos (como, partida fria) ou domínios restritos e foram descartadas por não oferecerem uma descrição expansível a múltiplos domínios como proposto nesse trabalho.

Também destacamos um mapeamento sistemático com foco na recomendação de recursos educacionais para grupos em redes sociais publicado anteriormente pelo núcleo de pesquisa no qual esse trabalho está inserido [1], diretamente relacionado com o sistema de recomendação que ilustra essa proposta.

Em [1] é apresentado um mapeamento sistemático com foco na recomendação de recursos educacionais para grupos em redes sociais. O trabalho identifica técnicas de extração de dados com o objetivo de construir o perfil do grupo, além de agrupar os trabalhos por abordagem de recomendação utilizada, sendo filtragem colaborativa, baseada em conteúdo e híbrida. O mapeamento também identifica os recursos educacionais mais utilizados no contexto do mapeamento a fim de inferir preferências dos grupos educacionais quanto ao tipo de mídia recomendada.

A principal diferença entre os trabalhos relacionados e o mapeamento citado e o proposto é que o objetivo do presente trabalho não é propor modelos de recomendação específicos para um domínio ou técnica e sim uma infraestrutura que possa auxiliar na criação de SRs instanciados ou derivados do metamodelo MMRRecommender.

2.3 Componentes de um modelo de recomendação

A partir dos artigos identificados no mapeamento foi gerada uma planilha de termos, características e sub características, etapas e atividades dos sistemas de recomendação para compor o metamodelo.

Os principais termos identificados foram: Collaborative Filtering, Content-Based, Demographic, Social e Hybrid que representam técnicas de filtragem ou agrupamento dos objetos recomendados. Trust model, Fuzzy model, Clustering, Probabilistic, Bayesian networks, Matrix factorization, Knn, Markov model, LDA Model, HRM, Heuristic, User-Item-Feature-based, CSFS, Random Forest, Genetic, Context-aware, Slope One, TS-PMF, Similarity Metrics, Machine Learning, Natural Language Processing como métodos que relacionam o perfil e contexto do usuário com os objetos recomendados.

Também foram identificados termos relacionados à forma de extração dos dados como: Implicit Feedback que são dados não informados diretamente pelo usuário, como por exemplo as atividades executadas pelo usuário dentro do sistema; Explicit Feedback que são os dados informados diretamente ao sistema, como avaliações de conteúdo, além de Context, Profile, User, Groups e Top-N que podem indicar a forma com que os objetos serão recomendados, por exemplo se a recomendação será feita para usuários de forma individual ou em grupo.

Em seguida os termos identificados foram agrupados de acordo com as funcionalidades e etapas. Nessa fase também foram

observados termos similares em funcionalidades e criados subgrupos. A partir dos grupos e subgrupos formados foi gerado um primeiro modelo de representação que posteriormente evoluiu para um metamodelo de recomendação descrito a seguir.

3. MMRecommender – Metamodelo para Sistemas de Recomendação

A partir do mapeamento sistemático e das propostas anteriores do grupo, notadamente na área sistemas de recomendações de recursos educacionais [11, 12], este artigo apresenta a primeira versão de um metamodelo com os componentes necessários para construção de SR, denominado MMRecommender. O metamodelo é constituído de quatro etapas: Extração, Filtragem, Método e Recomendação, além da sub-etapa Enriquecimento conforme exibido na Figura 4.

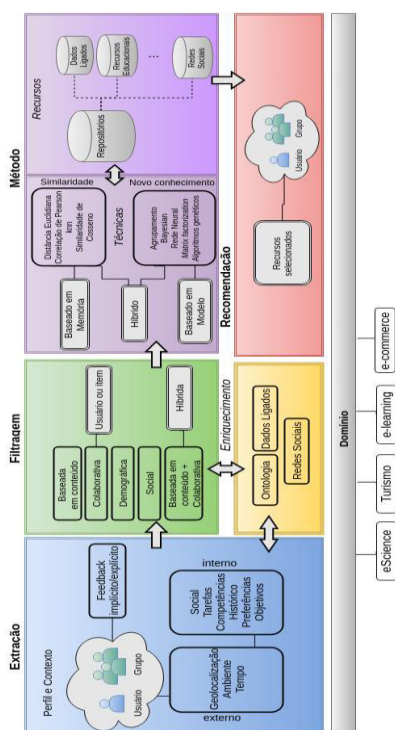


Figura 4. Arquitetura conceitual MMRecommender.

Extração: É a etapa onde as informações que irão compor o perfil do usuário ou do grupo serão extraídas, seja de forma implícita ou explícita. O contexto é o fator responsável pela forma de utilização do sistema e construção do perfil do usuário ou grupo. Foi utilizada a categorização proposta por [6]: interno e externo. A sub-etapa Enriquecimento (*Improvement*) é responsável pelo aprimoramento do perfil extraído através de informações contidas nas redes sociais [3], em dados ligados e ou em ontologias.

Filtragem: Nessa etapa o algoritmo de filtragem é aplicado. Segundo [2], uma categorização bem aceita na área divide os algoritmos em cinco tipos: Baseada em Conteúdo (*Content-based*) realiza as recomendações com base nas escolhas já feitas pelo usuário; Colaborativa (*Collaborative*) recomenda com base nas escolhas de outros usuários com perfil e preferências similares (existem dois subtipos *user-based* e *item-based*); Demográfica (*Demographic*) que divide os usuários em grupos com preferências similares; Social (*Social*) baseado na recomendação em redes sociais e grupos de usuários, formados de modo

explícito ou implícito e Híbrida (*Hybrid*) que é a combinação de duas ou mais técnicas.

Método: É a etapa em que a estratégia de recomendação é aplicada, sendo os mais comuns: *Model-based* (que cria um modelo que define o perfil e preferências do usuário ou grupos de usuários [2]); *Memory-based* (também conhecido como *similarity-based*, podendo ser subdivido em *user-similarity* ou *item-similarity*) e *Hybrid* (que é a combinação das estratégias anteriores). Os algoritmos de recomendação utilizam técnicas estatísticas, de mineração de dados, inteligência artificial, entre outras. A partir da aplicação do método os itens são recomendados.

A sub-etapa Recursos pode ser utilizada para fornecer recursos externos que serão recomendados, como por exemplo, vídeo aulas do Youtube (www.youtube.com/) ou através de uma abordagem que utiliza dados ligados para representação de recursos educacionais [16].

Recomendação: É a etapa final do processo de recomendação, onde os recursos são selecionados para serem apresentados aos usuários ou grupo de usuários.

Os SR podem adotar estratégias diferentes para apresentar as recomendações dependendo do domínio de aplicação: listas de itens, ordenação pela aderência ao perfil ou por avaliações de outros usuários, por associação entre preferências de usuários semelhantes ou por objetos recomendados com características similares. Essa etapa está diretamente relacionada aos repositórios de recursos de onde sairão os itens que serão selecionados e apresentados aos usuários.

4. Avaliando o metamodelo com o BROAD-GRS

Para cada aplicação instanciada do metamodelo MMRecommender é necessário definir as etapas Extração, Filtragem, Método e Recomendação e especificar os itens que as compõem.

Para avaliar a arquitetura do metamodelo no domínio educacional apresentamos o BROAD-GRS, um Sistema de Recomendação para Grupos, desenvolvido no contexto do projeto BROAD (Figura 5). A proposta desse sistema de recomendação evoluiu e inovou as propostas de [15] e [16] com características identificadas em [1] e nos trabalhos relacionados da literatura [05, 09, 14, 16].

Foi desenvolvido um protótipo capaz de extrair informações, definir o perfil educacional do grupo e recomendar recursos educacionais aos seus membros, utilizando a rede social Facebook.

A proposta adota uma Filtragem Híbrida, pois identifica o conteúdo relevante ao usuário, utilizando o seu perfil na formação do perfil do grupo (filtragem baseada em conteúdo) e recomenda com base na aderência ao perfil da maioria do grupo (filtragem colaborativa).

A recomendação é feita através de três abordagens: baseada em repositórios de recursos educacionais, em repositórios de Dados Ligados e em um repositório de vídeos. Após o desenvolvimento do protótipo foi realizado um estudo de caso [17] que permitiu observar as primeiras evidências sobre a eficiência do BROAD-GRS instanciado do metamodelo.

A arquitetura do BROAD-GRS é dividida em 5 módulos: (1) Camada de extração de informações; (2) Camada de definição do perfil do grupo; (3) Camada de representação semântica; (4) Camada de recomendação e (5) Camada de interface onde, os recursos são apresentados ao usuário. A Figura 5 apresenta o instanciamento do metamodelo MMRRecommender para o BROAD-GRS

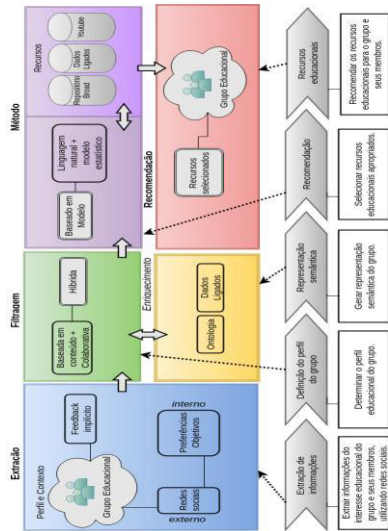


Figura 5. Instância derivada do MMRRecommender para o BROAD-GRS.

A recomendação dos recursos educacionais em repositórios se dá a partir da relação estabelecida entre as características do perfil do grupo e os metadados dos recursos educacionais. O projeto BROAD já prevê a catalogação de recursos educacionais [3]. Dentre as iniciativas de disponibilização de conteúdo através de Dados Ligados foram utilizadas neste trabalho a DBpedia (wiki.dbpedia.org/Datasets) e a Open University (data.open.ac.uk/). A recomendação em vídeos se dá através do YouTube.

4.1 Estudo de Caso

A avaliação da proposta foi feita através de um estudo de caso que analisou grupos de usuários na rede social Facebook. Foram criados grupos educacionais compostos de participantes voluntários sendo o Grupo 1, formado por 16 participantes, integrantes de uma Escola Técnica de Informática, e o Grupo 2 composto por 10 participantes de áreas distintas como Direito, Engenharia Ambiental e Ciência da Computação. Após cada membro permitir que o protótipo tivesse acesso às suas informações pessoais no Facebook, o perfil educacional do grupo foi definido. Com base nesse perfil, o tema educacional escolhido para o Grupo 1 foi “Wireless Network” enquanto o tema “Cotas Raciais” foi abordado no Grupo 2.


No estudo de caso foram implementadas as três abordagens para os recursos a serem recomendados: repositório local de recursos educacionais BROAD, dados ligados e vídeos. Foi definida a estratégia de recomendar três recursos educacionais por abordagem. O protótipo indicou os recursos ao administrador do grupo, que repassou as informações para os membros do grupo. A Figura 6 apresenta os recursos educacionais, do repositório BROAD de objetos de aprendizagem, recomendados ao Grupo 1. No momento da avaliação, esse repositório possuía 74 recursos educacionais relacionados à área de Ciência da Computação. Após o estudo de caso os participantes responderam um

questionário contendo perguntas de múltipla escolha, usando a escala “Muito Ruim”, “Ruim”, “Razoável”, “Bom e “Muito Bom”. O Gráfico 1 apresenta o quantitativo de respostas dos usuários a respeito da aceitação em relação às suas características pessoais extraídas, bem como as características de cada grupo respectivamente. O Gráfico 2 apresenta a aceitação dos usuários em relação às recomendações educacionais feitas ao grupo respectivamente, levando em consideração suas características individuais e do grupo.




Figura 6 – Recomendação de recursos educacionais do repositório BROAD para o Grupo 1.

Gráfico 1 – Aceitação das características extraídas dos Grupos.



Os participantes do Grupo 1 avaliaram positivamente o processo de extração de seus dados, com 38% e 25%, respectivamente, de avaliações “Bom” e “Muito Bom”, para o Grupo 2 as avaliações positivas foram de 30% e 40%, para “Bom” e “Muito Bom” respectivamente.

Gráfico 2 – Aceitação dos usuários em relação às recomendações feitas ao Grupo 1.



Os recursos recomendados para o Grupo 1 obtiveram 69% de avaliações positivas, enquanto o Grupo 2 obteve 90% de avaliações positivas. A avaliação da recomendação baseada em Dados Ligados obteve 63% de satisfação, considerando as avaliações “Bom” e “Muito Bom” para o Grupo 1 e 80% de avaliações “Bom” e “Muito Bom” para o Grupo 2. Nas recomendações em vídeos, os dados são ainda melhores, 86% para o Grupo 1 e 90% para o Grupo 2, de satisfação considerando as avaliações “Bom” e “Muito Bom”. Os dados coletados sugerem que a proposta BROAD-GRS foi eficaz na recomendação de recursos educacionais no contexto dos participantes do Grupo 1 e Grupo 2, além de apresentar evidências que os recursos educacionais em vídeo são mais aderentes ao perfil dos grupos analisados.

4.1.1 Ameaças a Validade

O protótipo utiliza como base dados de perfil do Facebook para a formação de grupos, dessa forma dados privados do usuário podem dificultar a identificação precisa de interesses do grupo. A falta de informações relevantes para a formação de grupos também é um ponto importante que pode dificultar a recomendação visto que o Facebook é uma rede social que não

possuía o foco na formação de grupos educacionais. O estudo de caso não considerou aspectos temporais como a variação do interesse e características dos participantes do grupo, tais aspectos serão tratados em trabalhos futuros.

5. Considerações Finais

O mapeamento sistemático identificou 128 trabalhos sobre modelos de recomendação publicados entre 2006 e 2015, que auxiliaram a identificação de categorias, definições e modelos. A quantidade de crescente de publicações pode ser um indicio de que ainda é um tema atual e de interesse na comunidade científica. Também foi possível perceber que aplicações em redes sociais ainda demandam muitas pesquisas na área.

Existem múltiplas aplicações de sistemas de recomendação, o que dificulta a existência de classificações e taxonomias na área. Sob essa ótica foi proposto um metamodelo, denominado MMRRecommender, para apoiar o desenvolvimento de SR em diversos domínios. Dessa forma, é possível derivar modelos de recomendação que podem ser instanciados a cenários educacionais diferenciados.

Para validar a proposta foi desenvolvido e avaliado o BROAD-GRS [1], um SR para grupos educacionais em redes sociais. Os resultados preliminares apontam para a viabilidade do modelo. A recomendação utilizando três abordagens (repositório de dados, dados ligados e vídeos) foi considerada satisfatória e complementar. O uso de dados ligados e de um repositório de vídeos no processo de seleção de recursos permitiu ampliar as possibilidades de recomendações oferecidas aos usuários, não ficando restrito a repositórios de recursos educacionais com temas específicos. Além disso, o envio dos recursos educacionais através da recomendação em redes sociais oferece ao usuário a utilização dos ícones de interatividade do ambiente, que permitem curtir e compartilhar suas experiências sobre um recurso educacional recomendado.

Como trabalhos futuros, em termos do metamodelo proposto, serão derivados modelos de recomendação em diferentes domínios para aperfeiçoamento do mesmo e, num futuro próximo, na definição de um ecossistema de software de recomendação.

Em termos do BROAD-GRS pretende-se aperfeiçoar a abordagem de definição do perfil educacional do grupo e do processo de recomendação considerando, por exemplo, as recomendações feitas para usuários que possuem interesses comuns e não fazem parte de um grupo, através do histórico de recomendações dos recursos educacionais com a avaliação dos usuários e na reputação dessas recomendações.

Agradecimentos: à FAPEMIG, CNPq, UFJF e Capes pelo apoio financeiro ao projeto.

6. Referências

- [1] Almeida, R.F., Campos, F. and Stroele, V. 2014. "Sistemas de Recomendação de Recursos Educacionais para Grupos de Redes Sociais: um Mapeamento Sistemático". *Sbie* (2014), 1022–1031.
- [2] Bobadilla, J., Ortega, F., Hernando, a. and Gutierrez, a. 2013. *Recommender Systems Survey*. *Knowledge-Based Systems*. 46, (2013), 109–132.
- [3] Campos, F., Braga, R., Nery, T. and Santos, N. 2012. Rede de Ontologias: apoio semântico a linha de produtos de objetos de aprendizagem. *Anais do Simpósio Brasileiro de Informática na Educação*. 23, *Sbie* (2012), 26–30.
- [4] Carvalho, L. a M.C. and Macedo, H.T. 2014. Introdução aos sistemas de recomendação para grupos. *Revista de Informática Teórica e Aplicada*. 21, (2014), 78–109.
- [5] Casagrande, M.F.R., Kozima, G. and Willrich, R. 2015. Técnica de Recomendação Baseada em Metadados para Repositórios Digitais Voltados ao Ensino. *Revista Brasileira de Informática na Educação*. 23, 02 (2015), 70.
- [6] Fleishmann, A., Bastos, B.R. and Pernas, H. 2012. Sensibilidade à Situação em Sistemas Educacionais na Web Tese de doutorado.
- [7] Fritzen, E., Siqueira, S.W.M. and de Andrade, L.C.V. 2012. Recuperação Contextual de Informação na Web para Apoiar Aprendizagem Colaborativa em Redes Sociais. *XXIII Anais do Simpósio Brasileiro de Informática na Educação*. 23, *Simpósio Brasileiro de Informática na Educação* (2012), 26–30.
- [8] Kitchenham, B. A., and Charters, S. 2007. Guidelines for performing Systematic Literature Reviews in Software Engineering. Keele University and University of Durham, EBSErugbycamarilacbbbjjllhkkkokoujhujhujmhhhh Technical Report Version 2.3.
- [9] Lu, J., Wu, D., Mao, M., Wang, W. and Zhang, G. 2015. Recommender system application developments: A survey. *Decision Support Systems*. 74, (2015), 12–32.
- [10] Manouselis, N, H. Drachsler, H., Vuorikari, R., Hummel, H., Koper, R. 2011. *Recommender Systems Handbook: A Complete Guide for Research Scientists and Practitioners*. Springer. 387–409.
- [11] Nery, T., Campos, F., Braga, R., Santos, N., Mattos, E., Engineering, K. and Program, C.S. 2012. BROAD Project: Semantic Search and Application of Learning Objects. *IEEE Technology and Engineering Education (ITEE)*. 7, 3 (2012).
- [12] Pereira, C.K., Campos, F., Ströele, V., David, M.N. and Braga, R. 2014. Extração de Características de Perfil e de Contexto em Redes Sociais para Recomendação de Recursos Educacionais. *Xxv Sbie 2014*. 25, *Cbie* (2014), 506–515.
- [13] Pereira, C.K., Campos, F., Ströele, V., N, J.M. and Braga, R. 2015. Explorando Dados Ligados através de um Sistema de Recomendação Educacional. *Anais do XXVI Simpósio Brasileiro de Informática na Educação (SBIE)*. *Sbie* (2015), No Prelo.
- [14] Quijano-Sanchez, L., Recio-Garcia, J.A. and Diaz-Agudo, B. 2011. HappyMovie: A facebook application for recommending movies to groups. *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI*. (2011), 239–244.
- [15] Rezende, P.A.A., Pereira, C.K., Campos, F., David, J.M.N. and Braga, R. 2015. PERSONNA: proposta de ontologia de contexto e perfil de alunos para recomendação de objetos de aprendizagem. *Revista Brasileira de Informática na Educação*. 23, 01 (2015), 70.
- [16] Ribeiro, F.A.A., Fonseca, L.C.C. and Freitas, M.D.S. 2013. Recomendando Objetos de Aprendizagem a partir das hashtags postadas no Moodle. *XXIV Simpósio Brasileiro de Informática* Wang, S.-L. and Wu, C.-Y. 2011.
- [17] Wohlin, C., Runeson, P., Host, M., Ohlsson, C.M., Regnell, B. and Wesslen, A. 2012. *Experimentation in Software Engineering*. Springer.