

Análise de Fatores Impactantes na Recomendação de Colaborações Acadêmicas Utilizando Projeto Fatorial

Michele A. Brandão, Mirella M. Moro, Jussara M. Almeida

Universidade Federal de Minas Gerais, Brasil

{micheleabrandao, mirella, jussara}@dcc.ufmg.br

Resumo. Sistemas de recomendação têm sido muito utilizados em comércio eletrônico e redes sociais de amizade ou trabalho. Dos vários desafios de construir tais sistemas, um ainda pouco explorado é como parametrizar esses sistemas e suas avaliações. Geralmente, cada estratégia de recomendação tem seus parâmetros e fatores que podem ser variados. Neste artigo, propomos avaliar o impacto dos parâmetros principais de duas funções do estado-da-arte que recomendam colaborações acadêmicas e sua forma de avaliação. Nossos resultados mostram que os fatores afetam a revocação, novidade, diversidade e cobertura das recomendações de colaboração de formas diferentes. Por fim, tal avaliação mostra a importância de estudar os fatores e as interações entre eles no contexto de recomendações de colaboração acadêmica.

Categories and Subject Descriptors: H.2 [Database Management]: Miscellaneous

Palavras-chave: recomendação de colaboração, estratégia de divisão, projeto fatorial 2^k , fatores

1. INTRODUÇÃO

Sistemas de recomendação têm sido utilizados em comércio eletrônico e redes sociais de amizade ou trabalho. O foco deste trabalho é nas recomendações em redes sociais acadêmicas de coautoria, onde os nós representam pesquisadores e as arestas entre eles são coautoria em publicações. Aqui, a recomendação de colaborações entre pesquisadores é bastante relevante para ajudar pesquisadores a formar novos grupos e a buscar colaborações para projetos de pesquisa, para melhorar a qualidade de comunicação na rede e para investigar comunidades de pesquisa [Brandão et al. 2013]. Ademais, um trabalho recente mostra que grupos de pesquisa com uma rede social de coautoria bem conectada tendem a ser mais produtivos [Lopes et al. 2011]. Dos vários desafios de construir tais sistemas, nosso trabalho foca na avaliação das recomendações.

Sistemas de recomendação podem ser avaliados via mecanismos de feedback do usuário. Porém, no contexto acadêmico, tal feedback é complexo, pois um pesquisador pode avaliar uma recomendação como ruim devido a questões subjetivas tais como não gostar do recomendado, falta de afinidade ou competição. Outra opção é a partir das preferências dos usuários, modelar seu comportamento e usar essa modelagem para avaliar as recomendações [Shani and Gunawardana 2011]. Essa estratégia também não é adequada no cenário acadêmico, pois não há dados públicos com informações das preferências de um pesquisador em relação a outro.

Assim, as recomendações de colaboração têm sido avaliadas dividindo a rede social em duas partes [Brandão et al. 2013; Lopes et al. 2010]. A primeira parte é utilizada para aplicar as funções de recomendação e gerar uma lista com as recomendações. A segunda é utilizada para estabelecer um comparativo entre as colaborações efetivamente realizadas durante aquele período (*ground truth*) e as recomendações. A avaliação das recomendações verifica se as colaborações recomendadas estão presentes no *ground truth*. Dentre os vários desafios para gerar tais recomendações, um ainda pouco explorado é como parametrizar as funções de recomendação assim como a estratégia de avaliação adotada (particularmente no que tange à divisão dos dados em duas partes). É importante analisar como a variação no tamanho dessas divisões assim como nos valores dos parâmetros das funções de recomendação impactam no resultado das recomendações de colaboração.

Para realizar essa análise, consideramos duas funções de recomendação do estado-da-arte: a *Affin* de Brandão et al. [2013] e a *CORALS* de Lopes et al. [2010]. Essas funções de recomendação possuem pesos que podem impactar nas recomendações de colaboração. Entretanto, não foi feita nenhuma análise teórica ou experimental da sensibilidade das funções de recomendação a tais parâmetros e possíveis interações entre eles.

Este trabalho visa analisar o impacto das divisões dos dados definidas assim como dos pesos explorados pelas funções de recomendação. Essa análise consiste da realização de um projeto experimental fatorial 2^k em que cada parâmetro sob análise (chamado fator) pode assumir dois valores (ou níveis). Esse projeto permite a avaliação do impacto relativo de cada fator bem como da interação de múltiplos fatores na variável resposta sendo estudada (a eficácia da recomendação no nosso caso) [Jain 1991]. Note que há interação entre fatores quando o efeito de um fator na variável resposta depende do valor do outro [Lima et al. 2010]. Aqui, consideramos um projeto 2^k com $k = 3$ fatores: a estratégia de divisão do número total de publicações e os dois pesos explorados pelas funções de recomendação. Realizamos projetos separados para as funções *Affin* e *CORALS*, a fim de estudar o impacto relativo de cada fator na eficácia de cada uma das funções.

As recomendações de colaboração são avaliadas em relação a quatro métricas: revocação, novidade, diversidade e cobertura, que são próprias para tal contexto conforme descrito por Brandão and Moro [2012]. Também foram avaliados o número total de recomendações e o número de recomendações corretas retornadas como métricas de avaliação, pois estão relacionadas com a revocação. Ou seja, para cada função de recomendação, foram realizados projetos experimentais 2^k para cada uma destas seis métricas. A análise realizada com o projeto fatorial mostra que os fatores impactam o resultado dessas métricas de diferentes formas. Tal avaliação mostra o potencial de utilizar o projeto fatorial na avaliação de sistemas de recomendação e de outras aplicações dependentes da definição de parâmetros de dados. Este artigo segue com os seguintes tópicos: trabalhos relacionados (Seção 2); funções de recomendação de colaboração do estado-da-arte (Seção 3); fatores e especificação do projeto fatorial (Seção 4); identificação e análise dos fatores impactantes (Seção 5); e conclusões e trabalhos futuros (Seção 6).

2. TRABALHOS RELACIONADOS

É possível recomendar itens e pessoas em redes sociais. Por exemplo, Freyne et al. [2010] e He and Chu [2010] recomendam itens explorando as preferências e interações dos usuários. Já a recomendação de pessoas deve considerar aspectos das conexões sociais [Lopes et al. 2010; Symeonidis et al. 2010]. Em redes sociais acadêmicas, Brandão et al. [2013] e Lopes et al. [2010] apresentam novas funções de recomendação de colaborações. Porém, ambos fixaram os valores dos parâmetros (pesos) e não estudaram como tais valores impactam a eficácia dos métodos, que é o objetivo deste trabalho, conforme detalhado na Seção 3.

Avaliar a qualidade de recomendações não é trivial [Fouss and Saerens 2008]. Pode-se avaliar as recomendações com estratégia *online*, na qual usuários avaliam quão boa elas são, ou *offline*, onde elas são comparadas com um *ground truth*, sem interação dos usuários [Shani and Gunawardana 2011]. Por exemplo, a estratégia *online* tem sido utilizada pela Netflix e Amazon, e a *offline* para avaliar a diversidade na recomendação de livros [Ziegler et al. 2005] e de colaborações acadêmicas [Brandão et al. 2013; Lopes et al. 2010]. A estratégia de avaliação adotada é um dos parâmetros que pode influenciar no resultado das recomendações.

Este trabalho visa quantificar o impacto de diferentes fatores nas colaborações sugeridas pelas funções de recomendação propostas por Brandão et al. [2013] e Lopes et al. [2010]. São considerados como fatores tanto a estratégia de avaliação *offline* adotada (divisão da rede em duas partes) quanto parâmetros específicos das duas funções. Essa análise é feita com uma aplicação do projeto fatorial 2^k [Jain 1991]. Essa técnica tem sido utilizada, por exemplo, como diretriz para o desenvolvimento de um portal *e-government* [Marzoughi et al. 2010], para parametrizar algoritmos de programação genética [Lima et al. 2010] e para investigar a influência da concentração de Fe(III)-oleate, temperatura de reação, tempo e taxa de aquecimento sobre o núcleo de partículas, tamanho das distribuições hidrodinâmicas e magnetização [Lak et al. 2013]. Até onde sabemos, o estudo aqui realizado ainda não foi feito no contexto de recomendação de colaborações acadêmicas.

3. FUNÇÕES DE RECOMENDAÇÃO DE COLABORAÇÕES ACADÊMICAS

Considere as funções de recomendação acadêmica *Affin* [Brandão et al. 2013] e *CORALS* [Lopes et al. 2010], as quais recomendam pares de pesquisadores i e j a colaborarem, conforme as Equações 1 e 2, respectivamente.

$$r_{i,j} = \begin{cases} \text{Iniciar,} & \text{if } (Cp_{i,j} = 0) \wedge \\ & (Affin_Sc_{i,j} > \text{limiar}); \end{cases} \quad (1)$$

$$r_{i,j} = \begin{cases} \text{Iniciar,} & \text{if } (Cp_{i,j} = 0) \wedge \\ & (Cr_Sc_{i,j} > \text{limiar}); \end{cases} \quad (2)$$

$Cp_{i,j}$ é o peso para quanto o pesquisador i colaborou com outro j , onde valor *zero* indica que tal par ainda não colaborou. O peso $Affin_Sc_{i,j}$ (Equação 1) é uma média ponderada entre os pesos afiliação *Affin* e proximidade social Sc , onde *Affin* quantifica o quanto um pesquisador i colaborou com pessoas da instituição do pesquisador j , e Sc mede o menor caminho entre pares de pesquisadores i e j na rede de colaboração. O peso $Cr_Sc_{i,j}$ (Equação 2) é uma média ponderada entre os pesos correlação Cr e proximidade social, onde Cr quantifica o quanto pares de pesquisadores i e j têm publicado em áreas de pesquisa em comum.

A função *Affin* recomenda pares de pesquisadores a iniciar colaboração quando $Cp_{i,j}$ é zero e $Affin_Sc_{i,j}$ é maior que um limiar predefinido. Esse limiar é definido de acordo com intervalos que podem seguir uma escala linear, tal como *baixo* < 33% e *alto* > 66%. O valor “baixo” foi escolhido como limiar. Já a *CORALS* recomenda pesquisadores a iniciar colaboração quando $Cp_{i,j}$ é zero e $Cr_Sc_{i,j}$ é maior que “baixo” (limiar escolhido). O limiar também é um parâmetro das funções de recomendação, mas não foi incluído no projeto fatorial 2^k pelo fato dos pesos terem um maior impacto nas recomendações de colaborações acadêmicas.

4. PROJETO EXPERIMENTAL

O principal objetivo de um projeto experimental é obter a máxima quantidade de informação com o número mínimo de experimentos [Jain 1991]. Existem diversos tipos de projetos experimentais, tais como projeto simples, projeto fatorial completo, projeto fatorial fracionado, entre outros. Neste trabalho, realizamos um projeto fatorial 2^k , onde k representa o número de fatores e 2 o número de níveis que cada fator possui¹. Os fatores são os parâmetros que afetam o resultado dos experimentos, e os níveis são os valores que cada fator pode assumir. O projeto fatorial 2^k foi escolhido por permitir o estudo do impacto dos fatores e interações entre eles nas variáveis resposta. É importante notar que realizamos o projeto fatorial sem replicação. Em outras palavras, apenas um resultado é produzido para cada configuração definida pelos níveis dos fatores. Isso foi feito porque os algoritmos das funções de recomendação são determinísticos². Assim, apresentamos o conjunto de dados e detalhamos a aplicação do projeto fatorial 2^k no nosso contexto.

Em relação ao conjunto de dados, os experimentos utilizam dados reais obtidos da biblioteca digital DBLP³. A rede social acadêmica construída a partir da DBLP contém 629 pesquisadores de 45 instituições brasileiras e suas 13.867 publicações do ano de 1973 a 2012 em periódicos e eventos. Essa rede foi construída com nós dados pelos autores e arestas pela coautoria nas publicações, conforme descrito por Brandão et al. [2013]. Além disso, como o conjunto de dados é dividido em duas partes, então uma rede social acadêmica é construída para cada parte. Nessa divisão, a primeira parte possui publicações de anos inferiores ou iguais à segunda parte, e é utilizada para gerar as recomendações. Já a segunda parte é utilizada para avaliá-las.

Em relação ao projeto fatorial 2^k , os fatores que podem impactar na recomendação são: a divisão do número total de publicações em duas partes e os pesos das funções de recomendação, conforme definido a seguir.

Estratégia de divisão. A rede social acadêmica de coautoria é dividida em duas partes diferentes, conforme amostras na Tabela I, e cada divisão representa um nível possível para este fator. Por exemplo, no segundo nível, 20% dos dados são utilizados para gerar recomendações e possuem publicações com ano inferior ou igual aos 80% dos dados da segunda parte. Como esse fator está diretamente relacionado à estratégia de avaliação, analisar seu impacto significa analisar o impacto da estratégia. Para o projeto fatorial 2^k , escolhemos evitar extremos, tendo os níveis 2 e 8 como representantes dos níveis menor e maior, conforme Tabela II.

¹Os dois níveis de cada fator são aqui chamados de maior e menor.

²No caso de processos aleatórios, um projeto 2^k com replicação poderia ser adotado.

³DBLP: <http://www.informatik.uni-trier.de/~ley/db>

Tabela I. Estratégia de Divisão

Descrição	Nível	Primeira Parte		Segunda Parte	
		% Dado	# Publicação	% Dado	# Publicação
menor	1	10%	1.386	90%	12.481
	2	20%	2.773	80%	11.094
	3	30%	4.160	70%	9.707
	4	40%	5.546	60%	8.321
igual	5	50%	6.933	50%	6.933
maior	6	60%	8.321	40%	5.546
	7	70%	9.707	30%	4.160
	8	80%	11.094	20%	2.773
	9	90%	12.481	10%	1.386

Tabela II. Definição dos Níveis

Fator	Nível	Valor
Estratégia de Divisão	menor maior	20% - 80% 80% - 20%
Pesos	menor maior	10 100

Tabela III. Porcentagem de Variação (%)

Variável Resposta	<i>Affin</i>	<i>CORALS</i>
Revocação	AB: 86,88	A/AB: 96,47
Total	B/C/BC: 69,37	A/BC: 77,59
Corretas	A/B/C/BC: 99,81	A/BC/ABC: 82,23
Novidade	B/C/AB: 91,08	B/C/AB: 78,38
Diversidade	B/C/BC: 81,32	A/AB/AC/BC: 98,89
Cobertura	B/C/BC: 98,55	A/B/C: 96,24

Pesos das funções de recomendação. As funções de recomendação possuem pesos associados que quantificam a relação entre pares de pesquisadores. A *Affin* possui os pesos afiliação e proximidade social, e a *CORALS* possui os pesos correlação e proximidade social (proximidade social é comum às duas). Cada peso representa um fator que pode impactar nas recomendações de colaboração. Esses fatores são numéricos e podem ter diversos níveis. Os valores adotados como menor e maior para cada peso são mostrados na Tabela II.

Especificação do modelo. O projeto fatorial 2^k é realizado para cada função e com três fatores (estratégia de divisão, peso proximidade social e peso afiliação/correlação), ou seja, $k = 3$ sendo necessários $2^3 = 8$ experimentos. Cada fator é representado pelas variáveis x_A , x_B e x_C . Essas variáveis assumem os valores -1 e 1 representando os níveis inferior e superior de cada fator. Intuitivamente, a ideia por trás do projeto é que o valor da variável resposta pode ser regredido nas variáveis x_A , x_B e x_C usando um modelo aditivo não linear apresentado na Equação 3. O y representa a variável resposta do projeto fatorial (revocação, novidade, diversidade, cobertura, total de recomendações e recomendações corretas), cada q é o efeito do fator na variável resposta, q_0 é o comportamento médio da função de recomendação independente do fator. Especificamente, $q_0 = \frac{1}{2^3}(y_1 + y_2 + y_3 + y_4 + y_5 + y_6 + y_7 + y_8)$, onde cada y_i é obtida pela combinação dos níveis dos fatores. Por exemplo, y_1 é obtido quando os três fatores estão no nível negativo. Por exemplo, q_A é o efeito do fator A em y e q_{AB} é o efeito da interação entre os fatores A e B (Jain [1991] descreve o cálculo desses efeitos).

$$y = q_0 + q_A x_A + q_B x_B + q_C x_C + q_{AB} x_A x_B + q_{AC} x_A x_C + q_{BC} x_B x_C + q_{ABC} x_A x_B x_C \quad (3)$$

O efeito dos fatores e das interações entre eles podem ser positivos ou negativos nas variáveis resposta (um efeito positivo indica correlação positiva, e um efeito negativo indica correlação negativa). Um fator/interação com efeito positivo tem maior impacto na variável resposta quando o nível do fator é o valor superior. Já um fator/interação com efeito negativo afeta significativamente a variável resposta y quando o nível do fator é o valor inferior. Os efeitos são utilizados para calcular a porcentagem de variação dos dados que é explicada por cada fator. A porcentagem de variação captura a importância de cada fator na variável resposta. É importante notar que consideramos os fatores impactantes quando a porcentagem de variação explicada por eles é superior a 10%. Outro limiar pode ser escolhido, dependendo da aplicação e do custo para analisar os fatores.

5. ANÁLISE DOS RESULTADOS

Nesta seção, apresentamos uma análise dos resultados obtidos do projeto fatorial 2^k com o objetivo de quantificar o impacto relativo dos diversos fatores considerados nas funções de recomendação.

Função de Recomendação *Affin*. Nessa função, os fatores/interações possuem efeitos negativos e positivos. Por exemplo, os fatores estratégia de divisão e peso proximidade social possuem um efeito positivo na revocação. Já a interação entre os fatores peso proximidade social e peso afiliação possuem um efeito negativo sobre a diversidade. Esses efeitos são utilizados para calcular as porcentagens de variação explicadas por cada fator/interações nas variáveis resposta, conforme ilustrado na Figura 1.

A Figura 1 mostra que a interação entre os fatores estratégia de divisão (A) e peso proximidade social (B) é responsável pela maior parte da variação na revocação (acima de 80%). Os fatores peso proximidade social (B), peso afiliação (C) e sua interação BC são significativos para o total de recomendações, e os fatores estratégia de divisão (A), peso proximidade social (B), peso afiliação (C) e a interação ABC para a variável resposta recomendações corretas. Para a variável novidade, os fatores peso proximidade social (B), peso afiliação (C) e

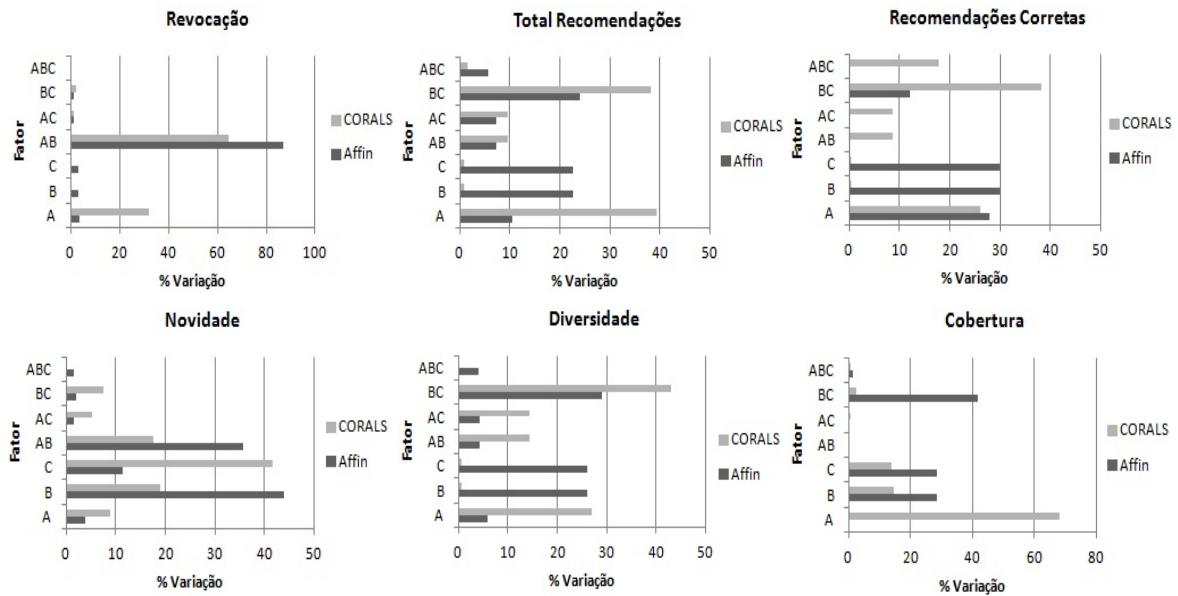


Fig. 1. Porcentagem de variação explicada por cada fator na variável resposta - *Affin* versus *CORALS*

a interação AB explicam praticamente toda a sua variação (91,08%). Já a diversidade e cobertura são afetados principalmente pelos fatores peso proximidade social (B), peso afiliação (C) e sua interação BC.

Em todas as variáveis resposta, a interação entre diferentes fatores (notavelmente entre os dois pesos BC) e a interação entre a estratégia de avaliação e o peso proximidade social (AB), têm impacto significativo. Essa interação existe quando diferenças em um fator depende do nível do outro fator. Por exemplo, na revocação, o fator estratégia de divisão (A) não deve ser considerado em separado do fator peso proximidade social (B), pois o impacto de ambos depende dos seus níveis específicos. Em outras palavras, o impacto do fator estratégia de divisão (A) na revocação depende fortemente do nível do fator peso proximidade social (B) utilizado. Se o nível do peso proximidade social for alterado, o impacto da estratégia de divisão pode mudar.

Função de Recomendação *CORALS*. Existem também efeitos positivos e negativos para as diversas variáveis resposta das recomendações geradas pela *CORALS*. A Figura 1 apresenta as porcentagens de variação dos dados explicadas por cada fator. Os fatores estratégia de divisão (A) e a interação AB são os principais responsáveis pela variação na revocação. Os fatores estratégia de divisão (A) e BC são relevantes no total de recomendações e os fatores estratégia de divisão (A), BC e ABC explicam as maiores variações no número de recomendações corretas. Em relação às variações na novidade, os fatores peso proximidade social (B), peso correlação (C) e AB são os responsáveis. A diversidade é variada pelos fatores estratégia de divisão (A), AB, AC e BC. Por fim, os fatores estratégia de divisão (A), peso proximidade social (B) e peso correlação (C) explicam a variação na cobertura, ou seja, os fatores podem ser considerados independentes na análise dessa variável resposta.

Antes de comparar os resultados obtidos, é importante notar que a realização de um projeto 2^k exige a validação de algumas premissas, em particular, que os efeitos de diferentes fatores sejam *aditivos* [Jain 1991]. Um erro comum é a realização de um projeto 2^k usando fatores cujos efeitos se multiplicam (e não se adicionam). Nesse caso, é necessário fazer uma transformação nos dados, a partir da aplicação da função logaritmo, antes de fazer o projeto 2^k , gerando assim um modelo multiplicativo⁴ [Jain 1991]. Enfatizamos que todas as premissas foram validadas nos nossos experimentos. Em particular, para testar se a premissa de fatores aditivos poderia estar influenciando nossos resultados, foram realizados também projetos com modelos multiplicativos, obtendo resultados qualitativamente iguais. Logo, nossas conclusões estão consistentes.

Análise Comparativa das Funções de Recomendação. A Tabela III apresenta os fatores que são relevantes para explicar as variações nas variáveis resposta e a porcentagem total de variação capturada pelos fatores.

⁴Isto porque se $y = a * b$, então, $\log(y) = \log(a) + \log(b)$.

Observa-se que todas as porcentagens são superiores a 69%, sendo várias acima de 90%. Então, os fatores apresentados na Tabela III explicam significativamente a maior parte das variações nas variáveis resposta.

Uma análise comparativa entre os fatores relevantes para as variáveis resposta em cada função de recomendação mostra que existem fatores semelhantes em ambas as funções. Observa-se que a interação entre a estratégia de divisão e o peso de proximidade social influenciam a revocação de ambas. Além disso, o total de recomendações, a diversidade e a cobertura da *Affin* não são muito impactados pela estratégia de divisão adotada (nem isolado e nem interagindo com outro fator). Já na *CORALS*, todas as variáveis resposta são impactadas por tal fator. Como consequência, observa-se que a forma de avaliação das recomendações de colaboração por meio da divisão da rede social em duas partes influencia nas variáveis resposta, principalmente, na *CORALS*. Outro comparativo mostra que a *CORALS* é mais sensível aos fatores do que a *Affin*, i.e. ao usá-la é preciso dedicar maior atenção na configuração dos fatores. Essa diferença entre as funções é devido aos pesos de afiliação e correlação. Esses pesos diferenciam as recomendações de colaboração feitas por cada função.

6. CONCLUSÕES

Foram avaliados os fatores que impactam em funções de recomendação utilizando a técnica de projeto fatorial 2^k . Esses fatores foram representados pela estratégia de divisão e pesos das funções de recomendação. A novidade está em descobrir como esses fatores e suas interações afetam as recomendações de colaborações acadêmicas em relação a revocação, novidade, diversidade, cobertura, total de recomendações e recomendações corretas. Os resultados mostram que a *CORALS* é muito mais sensível aos fatores, principalmente à estratégia de avaliação, em relação a *Affin*. A avaliação realizada permite focar nos parâmetros que podem influenciar os resultados das recomendações. No futuro, pretende-se considerar mais níveis no estudo dos fatores/interações para aperfeiçoar as funções de recomendação e configurar adequadamente a estratégia de avaliação.

Agradecimentos. Este trabalho foi financiado por: CAPES, CNPq, Fapemig e InWeb, Brasil.

REFERÊNCIAS

- BRANDÃO, M. A. AND MORO, M. M. Recomendação de colaboração em redes sociais acadêmicas baseada na afiliação dos pesquisadores. In *SBBD*. São Paulo, Brasil, 2012.
- BRANDÃO, M. A., MORO, M. M., LOPES, G. R., AND DE OLIVEIRA, J. P. M. Using Link Semantics to Recommend Collaborations in Academic Social Networks. In *WWW Workshops*. Rio de Janeiro, Brasil, 2013.
- FOUSS, F. AND SAERENS, M. Evaluating Performance of Recommender Systems: An Experimental Comparison. In *WI-IAT*. Sydney, Australia, pp. 735–738, 2008.
- FREYNE, J., BERKOVSKY, S., DALY, E. M., AND GEYER, W. Social networking feeds: recommending items of interest. In *RecSys*. New York, USA, pp. 277–280, 2010.
- HE, J. AND CHU, W. W. A social network-based recommender system (snrs) data mining for social network data. *Annals of Information Systems*, vol. 12. Springer US, Boston, MA, 4, pp. 47–74, 2010.
- JAIN, R. *The Art of Computer Systems Performance Analysis: techniques for experimental design, measurement, simulation, and modeling*. Wiley, 1991.
- LAK, A., LUDWIG, F., SCHOLTYSEK, J., DIECKHOFF, J., FIEGE, K., AND SCHILLING, M. Size distribution and magnetization optimization of single-core iron oxide nanoparticles by exploiting design of experiment methodology. *IEEE Transactions on Magnetics* 49 (1): 201–207, 2013.
- LIMA, E. D., PAPPAS, G., ALMEIDA, J. D., GONÇALVES, M., AND MEIRA, W. Tuning genetic programming parameters with factorial designs. In *CEC*. Shanghai, China, pp. 1–8, 2010.
- LOPES, G. R., MORO, M. M., DA SILVA, R., BARBOSA, E. M., AND DE OLIVEIRA, J. P. M. Ranking Strategy for Graduate Programs Evaluation. In *ICITA*. Sydney, Australia, 2011.
- LOPES, G. R., MORO, M. M., WIVES, L. K., AND DE OLIVEIRA, J. P. M. Collaboration Recommendation on Academic Social Networks. In *ER Workshops*. Vancouver, Canada, pp. 190–199, 2010.
- MARZOUGH, F., FARHANGIAN, M., AHMADIZADEH, E., CHAREJOO, F., AND AGHASIAN, E. Modeling an e-government portal of tourism industry using two level factorial design. In *ICEBE*. Shanghai, China, pp. 421–427, 2010.
- SHANI, G. AND GUNAWARDANA, A. Evaluating recommendation systems. In *Recommender Systems Handbook*. pp. 257–297, 2011.
- SYMEONIDIS, P., TIAKAS, E., AND MANOLOPOULOS, Y. Transitive node similarity for link prediction in social networks with positive and negative links. In *RecSys*. Barcelona, Spain, pp. 183–190, 2010.
- ZIEGLER, C.-N., MCNEE, S. M., KONSTAN, J. A., AND LAUSEN, G. Improving recommendation lists through topic diversification. In *WWW*. Chiba, Japan, pp. 22–32, 2005.