



UTILIZANDO SISTEMAS DE RECOMENDAÇÃO NA CRIAÇÃO DE COMUNIDADES VIRTUAIS DE APRENDIZAGEM

Tiago Masiero*
Silvio César Cazella**
Eliseo Reategui***

Resumo. Atualmente, os usuários desperdiçam muito tempo para encontrar na Internet conteúdo realmente relevante para eles, devido às múltiplas alternativas retornadas pelos mecanismos de busca. Procurando facilitar o acesso a informação optou-se trabalhar com sistemas de recomendação e comunidades virtuais de aprendizagem, visando permitir que os usuários pudessem trocar informações e compartilhar conhecimento. Desta forma foi implementado um protótipo de um sistema de comunidades virtuais de aprendizagem onde os pesquisadores podem trocar experiências e conhecimento. Além disso, estes usuários podem receber recomendações de itens e de outros usuários que possuem interesses em comum para promover a colaboração.

Palavras-chaves: *Comunidades virtuais, sistemas de recomendação, modelagem de usuário.*

USING RECOMMENDER SYSTEMS TO BUILD LEARNING VIRTUAL COMMUNITIES

Abstract. Nowadays users waste too much time to find relevant information in the Internet due to the large amount of alternatives presented by search mechanisms. Recommender Systems and virtual communities have been introduced in order to make the access to information easier, letting users exchange experiences and share their knowledge. This paper presents a novel approach to community formation, where Recommender Systems are used and the prominence of the user's opinion is considered in the recommendation process. A multi-agent architecture has been used to implement the system. The results of an offline experiment designed to validate our approach are present, as well as conclusions and directions for future work

Keywords: *Virtual communities, recommender systems, user modeling.*

1. Introdução

A pesquisa tanto em Educação quanto em Psicologia tem demonstrado a importância da socialização na construção do conhecimento (Vygostky, 1984; Maturana, 1995). Neste contexto, as comunidades virtuais de aprendizagem podem cumprir um papel importante, permitindo que pessoas com interesses afins possam trocar informações e experiências. Este artigo apresenta um método para construção de comunidades virtuais de aprendizagem através dos sistemas de recomendação e agentes de software.

A enorme quantidade de informação presente nas bases de dados tem dificultado o acesso dos usuários a informação realmente relevante, aumentando cada vez mais o tempo despendido na procura de informações (Han e Kamber, 2001; Balabanovic e Shoham, 1993). Uma solução interessante para facilitar esta procura por informações relevantes se dá através da utilização de sistemas de comunidades virtuais de

* Aluno de graduação do curso de Ciência da Computação da Universidade do Vale do Rio dos Sinos, Av. Unisinos 950, CEP 93.022-000, São Leopoldo, RS. E-mail: tiago.masiero@gmail.com

** Doutor em Computação. Professor Adjunto do Centro de Ciências Exatas e Tecnológicas, Universidade do Vale do Rio dos Sinos, Av. Unisinos 950, CEP 93.022-000, São Leopoldo, RS. E-mail: cazella@unisinos.br

*** Doutor em Computação. Professor Adjunto do Departamento de Informática – Universidade de Caxias do Sul (UCS). Rua Francisco Getúlio Vargas, 1130 – 95070-560 Caxias do Sul – RS – Brasil. E-mail: ebreateg@ucs.br

aprendizagem e sistemas de recomendação. Os sistemas de comunidades virtuais são locais cibernéticos onde as pessoas com interesses em comum encontram-se para trocar experiências, responder perguntas e promover colaboração (Cazella e Reategui 2005). Os usuários destes sistemas podem integrar-se nas comunidades de acordo com os seus interesses. A procura pode ser feita pelo nome ou pela descrição de uma comunidade, ou também, pode-se criar uma nova comunidade e convidar membros em potencial.

Procurando minimizar este esforço, propõe-se, neste artigo, a utilização de Sistemas de Recomendação (Sarwar et al., 2000) para identificar os usuários que possuem interesses e gostos em comum para integrar-se em uma mesma comunidade (Romm et al., 1997). Nestes sistemas, através da abordagem colaborativa, a essência está na troca de experiências entre as pessoas que possuem interesse em comum, isto é, a recomendação de um item é gerada a partir de avaliações feitas por outros usuários de mesmo interesse (Shaffer et al., 2001).

Portanto, para resolver o problema da descoberta de relações entre usuários de interesses e gostos em comum para constituírem uma comunidade virtual, foi necessário a implementação de três agentes de software: Agente Pessoal, Agente Recomendador e Agente Comunitário.

A contribuição maior deste trabalho esta na proposta de integrar sistemas de recomendação na identificação automática de comunidades virtuais de aprendizagem, sem a necessidade de busca manual por perfis de usuários, conforme existente hoje nos sistemas de comunidades virtuais.

Este artigo está estruturado em 7 seções, sendo o primeiro a Introdução e o último a Conclusão. Na seção 2 apresentam-se conceitos e exemplos de comunidades virtuais que estão sendo utilizadas pelos usuários da Internet. A seção 3 apresenta conceitos sobre Sistemas de Recomendação e como estes sistemas serão úteis para atingir os objetivos deste estudo. As abordagens sobre Mineração de Dados e Regras de Associação serão feitas na seção 4. Na seção 5 será apresentado o protótipo da ferramenta desenvolvida para este estudo, sendo que os experimentos realizados e os resultados serão apresentados na seção 6.

2. Comunidades Virtuais de Aprendizagem

Neste estudo, o termo comunidade refere-se a um local onde pessoas com interesses em comum reúnem-se para compartilhar experiências, responder perguntas e promover colaboração (Agrawal et al., 1996). Uma comunidade é um local útil para que as pessoas aprendam com a experiência e conhecimento dos outros participantes, e compartilhem casos de sucessos e insucessos (Cazella e Alvares, 2005). Visto o conceito de comunidade, pode-se então, entender o termo “comunidade virtual de aprendizagem” como sendo grupos de pessoas que se comunicam com as outras através de meios eletrônicos de acordo com os interesses comuns dos usuários, com a finalidade de socializar as produções, informações e experiências dos membros da comunidade (Romm et al., 1997).

No campo acadêmico, as comunidades virtuais de aprendizagem fornecem uma excelente fonte de conhecimento, informação e, mais importante, elas auxiliam a evitar duplicação de esforços dos membros. Por exemplo, um estudante de graduação, iniciante em um trabalho de pesquisa, tende a desperdiçar uma quantidade considerável de tempo pesquisando por informações que outros pesquisadores previamente já coletaram em seus trabalhos. Porém, se o estudante estiver registrado em uma

comunidade virtual, esta pode fornecer-lhe atalhos para facilitar o trabalho (Cazella e Alvares, 2005).

A fim de criar uma comunidade virtual, necessita-se levar em consideração alguns desafios: os membros devem ser direcionados a outros que contenham os mesmos interesses em comum e a informações relevantes, ter acesso a informações requeridas (sem se sentirem sobrecarregados), serem informados sobre outros membros de mesmos gostos (like-minded) e, por fim, poderem disseminar a informação às pessoas apropriadas.

3. Sistemas de Recomendação

Um Sistema de Recomendação constitui-se em uma nova abordagem para ajudar o usuário na procura de informações relevantes (Shaffer et al., 2001). Quase todos os Sistemas de Recomendação fazem a mesma coisa: eles identificam itens baseados em alguns critérios para então oferecer ao usuário (Cazella e Alvares, 2005b).

Esse tipo de sistema passa a ser cada vez mais utilizado em diversas áreas. São utilizados com frequência em sites de empresas de comércio eletrônico (ex. Amazon.com, Drugstore.com, eBay, MovieFinder.com, entre outros) – com o intuito de obter um aumento em suas vendas e melhor atender seu cliente na Internet. Na área de marketing, tais sistemas identificam os tipos de produtos e serviços oferecer através do histórico do cliente (Shardanand e Maes, 1995).

Na Educação, tais sistemas têm sido empregados na identificação de seqüências de navegação apropriadas para cada estudante (Reategui et al, 2006), de forma análoga à recuperação de experiências em ambientes interativos de aprendizagem baseados na técnica de raciocínio baseado em casos (Schank e Cleary, 1995).

Para recomendar itens a um usuário, o sistema primeiramente coleta informações e cria uma representação sobre este. Tais dados podem ser coletados de forma implícita (informados deliberadamente pelo usuário), ou implícita (na medida em que o usuário utiliza o sistema). Os Sistemas de Recomendação basicamente realizam a filtragem de informações relevantes para os usuários através da análise de seus perfis e recomendam itens resultantes desta filtragem. São utilizadas em geral três abordagens de filtragem de informação: Filtragem Baseada em Conteúdo, Filtragem Colaborativa, foco deste trabalho (também conhecida como filtragem social) e Filtragem Híbrida (combinação das técnicas de filtragem citadas anteriormente) (Shardanand e Maes, 1995).

A técnica de filtragem colaborativa (mais detalhes podem ser obtidas em Balabanovic e Shoham (1997) e Sarwar et al. (2000)) pode ser separada em três passos: 1) calcular o peso de cada usuário em relação à similaridade ao usuário ativo (ex. coeficiente de Pearson); 2) selecionar um subconjunto de usuários com maiores similaridades (vizinhos) para considerar na predição (aplicar um limiar aceitável); 3) normalizar as avaliações e computar as predições ponderando as avaliações dos vizinhos com seus pesos. O coeficiente de Pearson, utilizado no passo 1 da filtragem colaborativa mede a “força” do relacionamento de duas variáveis. Esta força é representada por um número que varia entre -1, que indica ausência total de correlação, e 1, que indica forte correlação.

4. Mineração de dados

Witten e Frank (2000) descrevem mineração de dados como sendo um tópico prático e envolve aprendizado na prática, isto é, não possui um sentido teórico. Este autor trata

deste termo como sendo: “o passo que processa os dados buscando identificar os padrões, integrante das etapas da descoberta de conhecimento”.

Para a captação dos dados relevantes no processo da descoberta de conhecimento, existem alguns tipos de padrões que podem ser minerados (Han e Kamber, 2001), neste trabalho foi aplicada a mineração por regras de associação.

4.1. Regras de associação

O objetivo desta mineração é encontrar todas as regras de associação relevantes entre os itens, do tipo X (antecedente) \rightarrow Y (conseqüente). Agrawal et al. (1996) propõem um algoritmo onde as regras de associação geradas devem atender a um suporte e confiança mínimos especificados pelo decisor.

O suporte mínimo (*minsup*) garante que ao menos *s%* das transações no banco de dados satisfaz a união dos itens do X com os do Y. A confiança mínima (*minconf*) garante que ao menos *c%* das transações que satisfaçam o X das regras também satisfaçam o Y das regras (Agrawal et al., 1993).

As regras de associação neste trabalho fornecem informações para gerar recomendação de novas áreas de interesse para o usuário e evitar o problema da super-especialização (Balabanovic e Shoham, 1997) no momento da recomendação.

Esta técnica é aplicada para identificar relacionamentos escondidos na base de dados. Neste trabalho, é aplicado o algoritmo Apriori (Agrawal et al., 1996; Han e Kamber, 2001) juntamente com o framework de predição (seção 4.2.2) na tentativa de prever novas áreas de interesse do usuário.

4.2. Métricas e Framework para predição

Antes de apresentar o framework proposto por Cazella e Alvares (2005a) para prever novas áreas de interesse do usuário, é necessário o conhecimento da métrica denominada Ranking do Recomendador utilizada neste framework.

Métrica Ranking do Recomendador

A métrica Ranking do Recomendador (RR) é um valor entre 0 e 10 que representa a relevância de opinião do usuário em uma área de interesse específica. Por exemplo, um RR igual a 0 representa que o usuário tem pouca experiência em uma área de interesse, um RR igual a 5 indica que o usuário tem uma experiência mediana, já um usuário com RR igual a 10 possui uma grande experiência na área de interesse (Cazella e Alvares, 2005c).

Cada usuário terá um $RR_{\text{Área}}$ para cada área de interesse, e um RR_{Total} , que é a média entre todos os $RR_{\text{Área}}$ do usuário e descreve a relevância da opinião do usuário para todas as áreas de interesse selecionadas pelo mesmo.

A importância da criação desta métrica RR decorre do fato de que a mesma será utilizada pelo framework de recomendação para recomendar novas áreas de interesse para o usuário, fazendo com que o mesmo receba novos artigos, se engaje em novas áreas e comunidades, evitando assim a sua super-especialização.

Framework para prever novas áreas de interesse do usuário

O framework para predição de novas áreas de interesse do usuário é dividido em 3 fases principais (Cazella e Alvares, 2005a):

Fase 1 – Mineração de dados: O framework extrai de uma base de perfis as áreas de interesse do usuário e transforma em uma matriz, onde as linhas representam os usuários e as colunas são as áreas de interesse. Cada transação usuário *versus* área recebe um valor binário, onde 1 representa interesse e 0 a ausência de interesse do usuário por uma área. Após a criação da matriz, a mesma é submetida ao algoritmo de associação Apriori. Para decidir quais regras são relevantes, na fase seguinte serão utilizadas as métricas de suporte e confiança.

Fase 2 – Filtrando regras baseadas na relevância de opinião do usuário: Nesta fase o framework tenta encontrar todos os usuários que “casam” com cada regra selecionada na Fase 1. Por exemplo, se é retornada a regra R: $A1 \rightarrow A2$, significa que A2 será uma área de interesse se A1 aparecer, para isto é preciso selecionar os usuário que “casam” com esta regra na base de dados. O motivo deste passo é identificar a relevância da opinião dos usuários que “casam” com esta regra. As métricas como suporte e confiança podem mostrar se esta regra é interessante, mas não informa a relevância de opinião do usuário. Esta informação é muito importante quando se deseja trabalhar com a recomendação de artigos acadêmicos. Para decidir se uma simples regra fará parte do conjunto final de regras é utilizada a métrica RR_{Total} , assumindo-se que se tenha 10 regras da Fase 1, baseadas nas métricas de suporte e confiança, e neste instante deseja-se saber quais regras “casam” com os usuários que possuem uma boa relevância de opinião.

Fase 3 – Selecionando usuário para aplicar o novo conhecimento: Tendo as regras obtidas da Fase 2, o sistema verifica em uma base de regras do passado se as mesmas ainda não foram utilizadas. Se a regra estiver presente nesta base, ela não entrará para o novo conjunto de regras a serem aplicadas. Uma vez identificados os usuários que “casam” com as novas regras, é gerada a predição das novas áreas de interesse para estes e seus perfis são temporariamente atualizados.

5. Protótipo da Ferramenta

Para o desenvolvimento do protótipo, foram implementados três agentes de software propostos no projeto do sistema W-RECMAS (a RECommender system to Web based on Multi-Agent System for academic paper recommendation) (Cazella e Alvares, 2005b). Na figura 1 é apresentada uma visão macro do funcionamento do protótipo e na figura 2 a interface do protótipo.

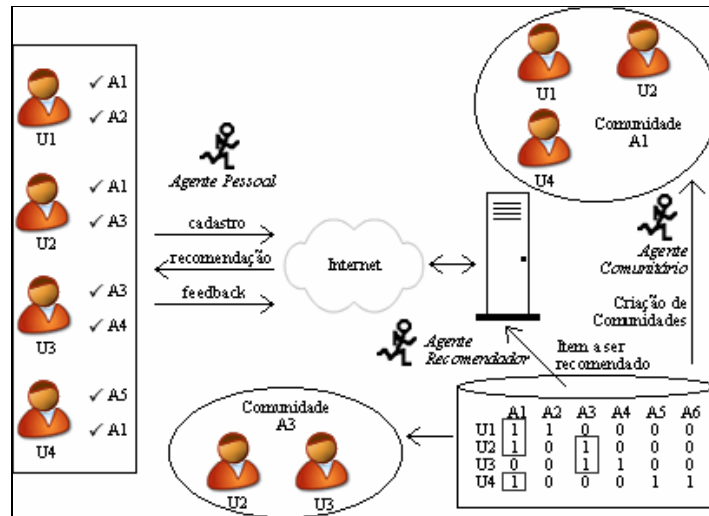


Figura 1 – Visão macro do protótipo

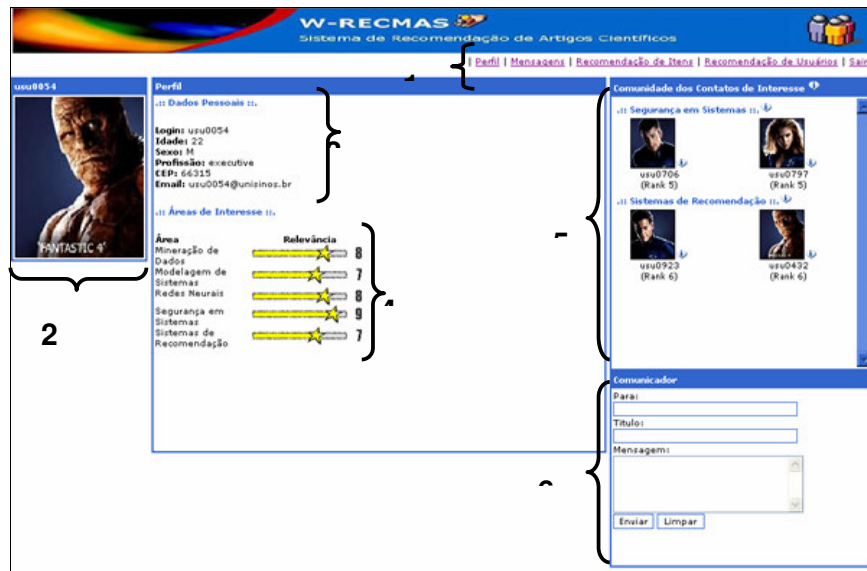


Figura 2 – Interface do protótipo

Na figura 2 é possível identificar o menu de navegação do protótipo (1), a fotografia do usuário (2), seus dados pessoais (3) como login, idade, sexo, profissão, cep e e-mail, as áreas de interesse do usuário e a relevância de opinião do mesmo em cada área (4), a comunidade dos contatos de interesse (5), que neste exemplo possuem dois contatos nas áreas de “Segurança em Sistema” e “Sistemas de Recomendação”, e um sistema comunicador (6) onde o usuário pode enviar mensagens para os usuários cadastrados na comunidade de contatos de interesse.

5.1. Agentes de Software

A seguir serão descritos os agentes de software implementados no protótipo.

- **Agente Comunitário:** Com o propósito de gerar comunidades virtuais de aprendizagem (onde os indivíduos possam trocar informações de forma direta), este agente busca identificar, em dois passos, os candidatos com potencial para fazer

parte destas comunidades. No primeiro passo, este agente verifica quais usuários possuem pelo menos uma área de interesse em comum. No passo seguinte é calculada a correlação entre estes usuários através do coeficiente de Pearson. Este coeficiente leva em consideração as avaliações dadas pelos usuários a artigos pontuados em comum. Caso estes usuários tenham uma forte correlação (coeficiente > 0 , em uma escala entre -1 e 1), então os mesmos continuam sendo candidatos a pertencerem a uma mesma comunidade, caso contrário, a relação entre estes usuários é desconsiderada.

- **Agente Recomendador:** O agente recomendador tem como objetivo principal recomendar artigos e novos contatos para um usuário alvo da recomendação. Conhecendo todos os perfis de usuários que possuem forte correlação, o Agente Recomendador seleciona um usuário alvo e a partir dos artigos pontuados entre este usuário e os demais (participantes da recomendação) verifica quais destes artigos foram pontuados pelos participantes e que ainda não foram pontuados pelo usuário alvo. Tendo uma quantidade mínima de três artigos não pontuados pelo usuário alvo em relação aos participantes, é gerada uma predição (possível nota que o usuário alvo daria para o artigo caso o lesse) e estes são recomendados para o usuário alvo. O objetivo desta predição é verificar o nível de confiança entre os usuários alvo e participantes. Se a avaliação do usuário alvo (nota de 1 a 5, onde 1 significa que o usuário não se interessou pelo artigo e 5 significa que ele demonstrou grande interesse pelo artigo) for igual a predição calculada em dois ou mais itens então pode-se concluir que há confiança entre eles e são fortes candidatos a pertencerem a uma mesma comunidade.
- **Agente Pessal:** Este agente funciona como um elo entre os agentes Comunitário e Recomendador com o usuário do sistema. Este agente tem como principais funcionalidades apresentar os artigos recomendados e os usuários de mesmos interesses a um usuário alvo. Também é através do agente pessoal que é retornado o feedback do usuário a respeito de um artigo recomendado, assim como as respostas dizendo se desejam ou não entrar em contato com um usuário de interesse comum descoberto pelo agente recomendador.

6. Experimentos e Resultados

Para a realização dos experimentos foi utilizada uma base de dados sintéticos, adaptada de uma base de dados real (MovieLens). Uma das adaptações foi a geração de um RR_{Area} para cada área de interesse do usuário. Esta base possui 943 perfis de usuários, 1689 filmes relacionados a 18 áreas e 100.000 avaliações.

Gerando comunidades de contatos

Para que os dois ou mais usuários sejam identificados como usuários com potencial para a criação de uma comunidade virtual, três critérios devem ser satisfeitos: 1) Possuírem interesse comum em pelo menos uma área de interesse - esta fase retorna um conjunto de relações usuário-para-usuário em suas áreas de interesse em comum, ao todo, na base utilizada, foram encontradas 670.760 relações para 643 usuários em 18 áreas de interesse, com uma média de 37264,44 e desvio padrão de 20092,04 relações por área de interesse, e uma média de 1043,17 contatos para cada usuário; 2) Existir forte correlação entre eles - nesta fase foi preciso calcular a correlação entre estes usuários e suas respectivas áreas de interesse em comum através do coeficiente de Pearson, das 670.760 relações encontradas na fase anterior, apenas 49762 (ou 7,42%) delas foram

consideradas fortes, com uma média de 2764,55 e desvio padrão de 3379,55 relações por área de interesse, e uma média de 52,77 contatos “fortes” para cada usuário; 3) A avaliações dadas por eles demonstrarem uma relação de confiança (nota predita = nota real) - nesta etapa são recomendados 3 artigos (selecionados aleatoriamente) para os usuários alvos da recomendação e de acordo com o feedback da avaliação dada é possível verificar se a mesma esta dentro do conjunto predito para aquele item, foram geradas um total de 1421 comunidades. Estes novos contatos serão apresentados entre si. Para a confirmação da criação da nova comunidade é solicitado que os usuários envolvidos respondam se realmente desejam conhecer o contato recomendado. Caso uma das partes discorde, a comunidade não é criada.

6.1 Descobrimo novas áreas de interesse

Após terem sido criadas as comunidades de contato foi preciso que o sistema identifique novas área de interesse do usuário. Para a descoberta destas novas áreas foram utilizadas as técnicas apresentadas na seção 4.2 deste artigo, com suporte mínimo de 5%, confiança de 80%, solicitando um retorno de 10 novas regras. Na tabela 2 pode-se observar algumas das regras obtidas.

Tabela 1 – Regras de Associação descobertas juntamente com suas médias dos RR_{Total}

Associação descoberta	#Usuários na Regra	Média RR_{Total}	Quantidade de usuários
R1 = A8=1 A14=1 A15=1 ==> A17=1	101	7,65	8
R2 = A8=1 A13=1 A14=1 ==> A17=1	116	7,71	10
R3 = A1=1 A8=1 A14=1 ==> A17=1	104	7,61	9
R4 = A1=1 A8=1 ==> A17=1	122	7,55	12
R5 = A13=1 A14=1 A16=1 ==> A17=1	96	7,49	10

Conforme observa-se na Tabela 2, para a regra R1, 8 usuários que “casam” com o antecedente desta regra e “negam” o conseqüente receberão artigos relacionados a esta área negada (neste caso, A17). Analisando o feedback dado por cada usuário aos itens recomendados, será possível verificar se o mesmo tem ou não interesse nesta nova área descoberta. Caso isto se afirme, o perfil deste usuário será atualizado para mais esta área de interesse, resolvendo assim o problema da super-especialização em sistemas de recomendação.

7. Conclusão

Visando identificar interesses comuns em grupos de usuários e diminuir o tempo gasto na procura por informação relevante, foi apresentada neste artigo a viabilidade da criação de comunidades virtuais de aprendizagem automaticamente, utilizando-se de sistemas de recomendação e técnicas de mineração de dados, baseando-se no perfil e na consulta a itens pelos usuários do sistema.

Para viabilizar a criação destas comunidades, foram desenvolvidos três agentes de software, os quais se utilizam de métodos de filtragem colaborativa para descobrir, em

uma base de perfis, quais usuário possuem interesses em comum para colocá-los em contato.

Com o estudo realizado e com a implementação do protótipo verificou-se a viabilidade da criação de comunidades virtuais de aprendizagem. Entretanto, como o experimento verificou-se a criação de um número menor de comunidades do que o esperado devido a esparcialidade de avaliações contidas na base de dados, dificultando assim, a busca por usuários similares.

A maior contribuição deste trabalho se aplica a usuários que utilizam a Internet como ferramenta de pesquisa em busca de informações relevantes. Uma vez utilizando o sistema proposto neste trabalho, o usuário terá um local onde poderá trocar experiências com outros que possuem interesse em comum. Estes usuários em comum serão automaticamente descobertos pelo sistema, sem a necessidade de busca manual por perfis de usuários, conforme existente hoje nos sistemas de comunidades virtuais.

Outra contribuição deste trabalho decorre do fato de que mesmo a pessoa cadastrada não demonstrar interesse por outra área além das que estão em seu perfil, o sistema, através do framework de recomendação tenta descobrir novas áreas de interesse baseando-se no perfil dos demais usuários cadastrados no sistema. Esta descoberta procura solucionar um problema muito comum encontrado em sistemas de recomendação, a super-especialização (Balabanovic e Shoham, 1997).

Uma das limitações deste trabalho foi a realização de experimentos offline sobre uma base de dados sintéticos, desta forma não foi possível analisar o feedback dos usuários em relação as recomendações realizadas. Outra limitação decorre da não verificação da satisfação dos usuários com as comunidades criadas, isto é, o sistema não realiza novas verificações de confiança entre os membros.

8. Referências

- AGRAWAL, R. et al. Fast discovery of Association Rules. In **Advanced in knowledge discovery and data mining**, AAAI/MIT Press, Menlo Park, Calif., USA, cap.12, pp. 307-328, (1996).
- AGRAWAL, R., IMIELINSKI, T., SWAMI, A. Mining association rules between sets of items in large databases. **Proc. of the ACM SIGMOD Conference**. Washington, DC, USA, p. 207-216, (1993).
- BALABANOVIĆ, M., SHOHAM Y. Fab: content-based, collaborative recommendation, **Communications of the ACM**, v.40 n.3, p.66-72, (1997).
- CAZELLA, S. C., ALVARES, L. C., Combining Data Mining Technique and Users' Relevance Opinion to Build an Efficient Recommender System. **Revista Tecnologia da Informação**, UCB, v. 4, n. 2, (2005a).
- CAZELLA, S. C., ALVARES, L. C., Creating Academic Web Communities: A Recommender System to Aid Brazilian Researchers to Find Information and Contact Relevant People. In: **6th Annual Global Information Technology Management World Conference**, 2005, Alaska, (2005b).
- CAZELLA, S. C., ALVARES, L. C., Modeling user's opinion relevance to recommending research papers. In: **UM 2005 User Modeling: The Proceedings of the Tenth International Conference**. Springer's LNAI, 2005.L. Ardissono, P. Brna, and A. Mitrovic (Eds.): UM 2005, LNAI 3538, pp. 337 – 341, 2005. © Springer-Verlag Berlin Heidelberg, (2005c).



- CAZELLA, S. C., REATEGUI, E. Mini-curso: Sistemas de Recomendação. Em: **Encontro Nacional de Inteligência Artificial (ENIA 05)**, 2005, São Leopoldo, RS.
- HAN, J., KAMBER, M. **Data mining: concepts and techniques**. Morgan Kaufmann Publishers, San Francisco, USA, (2001).
- MATURANA, H. e VARELA, F. **Árvore do conhecimento**. Ed. Psy, Campinas, 1995.
- REATEGUI, E., BOFF, E., CAMPBELL, J. A. (2006). Endowing a Virtual Character with Personalization Capabilities. **18th IEEE International Conference on Tools with Artificial Intelligence**. Washington, DC, November 2006.
- ROMM, C., PLISKIN, N., e CLARKE, R., Virtual communities and society: Toward an integrative three phase model. **International Journal of Information Management**, 17(4), 261-270, (1997).
- SARWAR, B. M., et al. Analysis of recommender algorithms for e-commerce. In **Proceedings of the 2nd ACM E-Commerce Conference (EC'00)**, Minneapolis, MN, October (2000).
- SCHANK, R. e CLEARY, M. **Engines for Education**. Lawrence Erlbaum Associates, 1995.
- SHAFFER, J.B. et al. E-Commerce Recommendation applications. **Data Mining and Knowledge Discovery**, Kluwer Academic Publishers, Hingham, MA, USA, Vol 5. Issue 5, (2001).
- SHARDANAND, U., MAES, P., Social information filtering: Algorithms for automating "word of mouth", In: **Human Factors in Computing Systems. Proceedings...**, p. 210-217, (1995).
- VYGOTSKY, L. S. **A Formação Social da Mente: o Desenvolvimento dos Processos Psicológicos Superiores**. Editora Martins Fontes, São Paulo. 1998.
- WITTEN, I.H., FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations**. Morgan Kaufmann Publishers, San Francisco, USA, (2000).