

Sistema de Recomendação Híbrido para Bibliotecas Digitais que Suportam o Protocolo OAI-PMH

Hélio Martins N. J.¹, Evandro B. Costa¹, Thyago T. M. Oliveira¹, Alan P. Silva¹, Ig I. Bittencourt¹

¹ Instituto de computação – Universidade Federal de Alagoas (UFAL)
CEP 57.072-970 – Maceió – AL – Brasil

{helio, evandro, ttmo, alan, ig.ibert}@ic.ufal.br

Abstract. *The growth of Web technologies have yielded benefits for the academic community by supporting the access of electronic publications as soon as they have been finished and then published. In this context, Digital Libraries emerges as complex information systems which are essential for disseminating and preserving data, information and knowledge. However, due to the high amount of content, users face many correlated options, what result in the phenomenon known as information overload. This work aims to decrease or even eliminate these difficulties, investigating alternative solutions to achieve the highest quality information, helping their users.*

Resumo. *O crescimento acelerado das tecnologias Web tem beneficiado pesquisadores e acadêmicos, pois as publicações de pesquisa podem ser acessadas eletronicamente tão logo elas tenham sido finalizadas e publicadas. Nesse contexto, surgem as Bibliotecas Digitais como um sistema de informação complexo que possui uma série de atividades que integram coleções, serviços e pessoas. No entanto, devido à enorme quantidade de conteúdo, os usuários acabam se deparando com uma diversidade muito grande de opções, o que leva à uma sobrecarga de informação. Este trabalho tem o objetivo de contribuir para amenizar ou até mesmo eliminar essas dificuldades, investigando soluções alternativas para alcançar mais qualidade nas indicações, ajudando seus usuários.*

1. Introdução

Frequentemente, as pessoas necessitam de informações para realizar suas atividades, sejam estas atendendo, por exemplo, suas necessidades pessoais ou profissionais. Entretanto, encontrar rapidamente a informação correta e de interesse está se tornando cada vez mais difícil devido a enorme quantidade de informação presente em meios impressos ou eletrônicos.

Considerada a maior fonte de informações do mundo, a Web se tornou um local importante, contendo muito conteúdo e facilitando a troca de experiências entre seus usuários, pois, por exemplo, resultados de pesquisas podem ser observados eletronicamente assim que os mesmos são publicados na Web. Nesse contexto, tem surgido as Bibliotecas Digitais que são coleções de documentos com serviços associados.

Porém, devido à grande quantidade de conteúdo, em especial, aqueles providos por estas bibliotecas digitais, os usuários acabam se deparando com uma diversidade muito grande de opções, o que leva ao fenômeno conhecido como sobrecarga de

informação. Nesse caso, o grande problema é, portanto, como encontrar informações relevantes diante de tamanha diversidade e grande volume de conteúdo.

Uma solução para amenizar esses problemas, particularmente o problema de sobrecarga de informação, é oferecer um sistema de recomendação que possa ajudar pessoas a filtrar informações úteis baseando-se principalmente em seus interesses individuais. Os sistemas de recomendação vêm sendo amplamente utilizados.

Os sistemas de recomendação são classificados de acordo com o método de predição utilizado. Os tipos de recomendações são classificadas usualmente em três categorias, propostas [Herlocker 2000, Claypool et al. 1999, Huang et al. 2002, Balabanovic and Shoham 1997]: Baseadas em Conteúdo, onde o usuário receberá recomendações de itens similares a itens preferidos no passado; Colaborativas, no qual o usuário receberá recomendações de itens que pessoas com gostos similares aos dele preferiram no passado; Híbridas: Consiste na junção das duas abordagens acima.

É comum em sistemas que utilizam filtragem baseada em conteúdo, apresentar limitações como: difícil análise de conteúdos pouco estruturados, como imagens e músicas; o entendimento prejudicado pelo uso de sinônimos; pode não haver surpresa na recomendação, pois o sistema só recomenda itens cujo conteúdo se assemelhe ao perfil do usuário [Reategui and Cazella 2005].

Para suprir essas necessidades, foi desenvolvida uma nova estratégia, chamada de filtragem colaborativa [Herlocker 2000]. A filtragem colaborativa apresenta vantagens como: possibilidade de apresentar aos usuários recomendações inesperadas, ou seja, recomendação de itens que não estavam sendo pesquisados de uma forma ativa; possibilidade de formação de comunidades virtuais, através da identificação de interesses similares entre usuários.

Porém, a filtragem colaborativa também apresenta alguns problemas, como por exemplo: quando um novo item é adicionado ao sistema, não existe a possibilidade desse item ser recomendado para um usuário até que ele seja classificado por outro usuário; se o número de usuários do sistema for pequeno, se comparado ao volume de informações, é possível que as pontuações para os itens se tornem muito esparsas; caso o usuário possua interesses diferentes quando comparado aos demais usuários do sistema (usuários com gostos incomuns), então esse usuário pode não se beneficiar de sistemas que utilizem filtragem colaborativa [Claypool et al. 1999].

Para tentar resolver esses problemas surge a abordagem híbrida, que procura combinar os pontos fortes da filtragem colaborativa e filtragem baseada em conteúdo [Huang et al. 2002]. Algumas de suas características são: Descoberta de novos relacionamentos entre usuários; Recomendação de itens diretamente relacionado ao histórico; Bons resultados para usuários incomuns; Precisão independente do número de usuários.

O objetivo geral deste trabalho é a elaboração de um sistema de recomendação personalizada de artigos científicos para bibliotecas digitais, combinando técnicas de filtragem de informação, através de uma abordagem híbrida. Considera-se aqui qualquer biblioteca digital que provê metadados no formato Dublin Core (DC) e dá suporte ao protocolo OAI-PMH, pode ser utilizada como fonte para prover informações sobre os artigos a serem recomendados.

Este artigo está subdividido em 5 seções. A seção 1 representa a introdução do trabalho. Em seguida, na seção 2, serão apresentados alguns trabalhos relacionados ao tema. A seção 3 descreve o sistema de recomendação proposto, enquanto que na seção 4, estarão alguns experimentos e os resultados obtidos. Por fim, na seção 5, temos as conclusões.

2. Trabalhos Relacionados

Nesta seção serão apresentados alguns sistemas de recomendação para Bibliotecas Digitais, destacando-se os propósitos da recomendação realizada e analisando-se as estratégias de recomendação.

O sistema de recomendação proposto por Hwang em [S-Y. et al. 2003] está inserido no projeto *Networked Digital Library Project* da *National Sun Yat-sen University*, em Taiwan. Dentre os objetivos principais desse projeto, destaca-se o desenvolvimento de tecnologias que dão suporte a serviços digitais, sendo, uma das etapas, o desenvolvimento de um sistema de recomendação de literatura.

Para realizar o processo de recomendação, esse sistema emprega o uso de *logs* Web. Este sistema analisa o uso da literatura e gera recomendações classificadas de acordo com as preferências do usuário ativo no sistema. A abordagem de recomendação utilizada é focada em tarefa (*task-focused approach*), a qual é representada por uma combinação de princípios da filtragem colaborativa e da mineração de dados (*data mining*).

Visando a pesquisa e o desenvolvimento de sistemas de recomendação para bibliotecas digitais, o projeto *Adaptive Recommendation Project* [ARP 2001] desenvolveu um sistema de recomendação, chamado de *TalkMine*, para a biblioteca de pesquisa do *Los Alamos National Laboratory*. Esse sistema disponibiliza para os usuários uma interface de busca para os documentos da biblioteca digital.

No trabalho de Cazella [Cazella and Alvares 2004] é proposto um sistema de recomendação multiagentes para artigos científicos. Nesse trabalho o currículo Lattes é utilizado como fonte de informações para a criação do perfil do usuário. Para o processo de recomendação, a estratégia adotada é a filtragem híbrida.

No trabalho de Torres [Torres et al. 2004] é proposto um Sistema de recomendação híbrido de artigos científicos que combina as técnicas de filtragem colaborativa e baseada em conteúdo. Ainda no trabalho de Torres, foi desenvolvido o sistema *Techlens+*, onde é possível obter uma opinião dos usuários sobre a qualidade dos algoritmos desenvolvidos.

3. Sistema de Recomendação Proposto

Esta seção apresenta uma descrição do sistema de recomendação híbrido proposto no contexto de bibliotecas digitais, abordando a sua descrição e o detalhamento de sua arquitetura.

3.1. Descrição do Sistema

O sistema de recomendação proposto neste trabalho tem como objetivo principal a recomendação de artigos científicos, tendo como base informações obtidas do currículo Lattes do usuário e avaliações dos usuários sobre um conjunto de artigos.

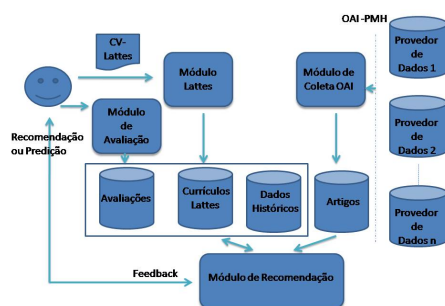


Figura 1. Arquitetura do Sistema de Recomendação Proposto

O sistema foi pensado de maneira que qualquer biblioteca digital que provê metadados no formato Dublin Core (DC) e dá suporte ao protocolo OAI-PMH, pode ser utilizada como fonte para prover informações sobre os artigos a serem recomendados. Portanto, cabe salientar que os dados utilizados como fonte para o processo de recomendação consistem de: Informações do usuário, obtidas a partir do currículo Lattes em XML; Informações sobre os documentos digitais, obtidas através de metadados no formato Dublin Core codificados em XML; Avaliações (*ratings*) sobre os documentos.

O *Curriculum Vitae* (CV) da Plataforma Lattes oferece um padrão XML o qual é mantido pela comunidade CONSCIENTIAS (Comunidade para Ontologias em Ciência, Tecnologia e Informações de Aperfeiçoamento de Nível Superior).

3.2. Arquitetura

Esta seção apresenta a arquitetura do sistema de recomendação proposto neste trabalho. A Figura 1 mostra os módulos presentes na arquitetura do sistema de recomendação híbrido.

O funcionamento do sistema proposto ocorrerá da seguinte maneira: Primeiramente, o usuário irá se cadastrar no sistema, onde ele deverá fornecer um login, senha e o arquivo XML correspondente ao seu currículo Lattes. Em seguida, o **módulo Lattes** analisará o currículo Lattes do usuário e armazenará as informações relevantes na base de dados **Currículos Lattes**.

Após isso, o **módulo de Coleta OAI** enviará requisições OAI-PMH a um ou vários provedores de dados cadastrados no sistema, na tentativa de fazer colheita (*harvesting*) dos metadados dos documentos digitais específicos de cada Biblioteca Digital. Esse módulo receberá um documento XML como resposta. Nessa etapa, os metadados relevantes no formato Dublin Core serão extraídos do documento XML e armazenados na base de dados local **Artigos**.

Através do **módulo de Avaliação** o usuário fornecerá avaliações (*ratings*) numa escala de 1-5 aos artigos de suas áreas de interesse cadastradas no seu currículo Lattes. Essas avaliações são armazenadas na base de dados **Avaliações**. Essas avaliações serão utilizadas, posteriormente, no módulo de filtragem colaborativa.

A base de **Dados Históricos** armazenam informações sobre itens consultados ou adquiridos pelos usuários, evitando-se assim o envio de artigos que o usuário já tenha visto ou avaliado. Para finalizar, o **módulo de Recomendação** é acionado e então a recomendação ocorrerá.

3.3. O módulo Lattes

Este módulo tem como função extrair informações relevantes dos pesquisadores e armazená-las na base de dados *Currículos Lattes*. O módulo recebe como entrada um arquivo xml, correspondente ao currículo do pesquisador.

3.3.1. Processo de Obtenção dos Metadados dos Documentos

Para que seja realizado o processo de recomendação, primeiramente é necessário obter os metadados que descrevem os arquivos que serão recomendados. Tal funcionalidade, é realizada pelo módulo *Coleta OAI*, o qual é o *harvester* do provedor de serviços. Este módulo envia requisições OAI-PMH para realizar a colheita de metadados de provedores de dados de Bibliotecas Digitais.

3.4. O módulo de Avaliação

Este módulo tem a função de armazenar avaliações (*ratings*) dos usuários sobre os artigos vistos pelos mesmos. Os *ratings* são armazenados na base avaliações. Cada usuário avalia um artigo utilizando-se uma escala de zero a cinco pontos. Um artigo que tem a mínima contribuição para o usuário é avaliado como zero e um artigo excelente é avaliado com nota cinco.

3.5. O módulo de Recomendação

O módulo de recomendação possui a função de recomendar artigos aos pesquisadores baseado no perfil de cada um deles. Este módulo utiliza um algoritmo híbrido para a recomendação dos artigos

Segundo [Burke 2002], os sistemas de recomendação híbridos combinam duas ou mais técnicas de recomendação com o objetivo de melhorar a performance e evitar as limitações apresentadas em sistemas que aplicam apenas uma abordagem. Neste artigo combinamos a filtragem colaborativa e a filtragem baseada em conteúdo.

São dois os algoritmos utilizados no nosso sistema:

- O algoritmo Misto
- O algoritmo Ponderado

O algoritmo misto implementa os métodos colaborativo e baseado em conteúdo separadamente e combina as predições geradas por ambos: desta forma é possível combinar as avaliações obtidas individualmente em cada um dos métodos para oferecer uma recomendação final.

Os dois algoritmos são executados em paralelo e o resultado final é obtido juntando as listas dos módulos colaborativo e baseado em conteúdo. Para combinar as recomendações de cada técnica, cada item presente nas listas recebe um valor correspondente a sua posição. A lista final é gerada da forma: cada item presente em ambas as listas é adicionado a lista final com uma pontuação. Essa pontuação é a soma de suas posições nas listas de recomendações originais. A lista é, então, ordenada de forma crescente, onde quanto menor a pontuação de um artigo, mais próximo do início ele está. Para os artigos que não estiverem presentes em ambas as listas, serão inseridos na lista final intercalados um a um, começando pela lista gerada por filtragem colaborativa.

O algoritmo misto utilizado é baseado algoritmo Fusion do trabalho de Torres [Torres 2004].

No segundo algoritmo: o ponderado, o peso de um determinado item recomendado é computado dos resultados de todas as técnicas disponíveis de recomendação atuais do sistema. Este algoritmo híbrido combina os pesos de cada componente usando uma fórmula linear.

Um exemplo do cálculo realizado pelo recomendador híbrido ponderado é mostrado na figura 2.

Artigo	Rank1	Pontuação1	Pontuação2	Rank2	peso	1-peso	Pontuação Computada	Rank Híbrido
					0,4	0,6		
a	1	0,9	0,5	6			0,66	2
b	2	0,7	0,6	4			0,64	3
c	3	0,65	0,95	1			0,83	1
d	4	0,6	0,58	5			0,59	4
f	5	0,4	0,46	7			0,44	6
g	6	0,2	0,3	8			0,26	8
h	7	0,1	0,88	2			0,57	5
i	8	0,04	0,1	10			0,08	10
l	9	0,03	0,66	3			0,41	7
m	10	0,02	0,23	9			0,15	9

Figura 2. Exemplo de Cálculo Realizado pelo Algoritmo Ponderado

Os ranks 1 e 2 são os ranks do recomendador1 e do recomendador2, embora não mostrado na figura 2, podem existir artigos do recomendador1 ou do recomendador2 que não tenham pontuações.

A pontuação híbrida computada para o artigo **a** é :

- $RHP(a) = p \cdot R1(a) + (1-p) \cdot R2(a)$
- $RHP(a) = 0,4 * 0,9 + 0,6 * 0,5 = 0,66$

Este cálculo é realizado para todos os artigos e em seguida, os resultados são colocados em ordem decrescente.

4. Experimentos e Resultados

Esta seção apresenta os experimentos realizados e uma discussão sobre os resultados obtidos.

4.1. Dados

Para a realização dos experimentos foi necessário um conjunto de dados com usuários e seus respectivos currículos lattes, artigos e avaliações.

Em relação aos usuários, foram solicitados os currículos lattes em xml de dez pesquisadores. Cada usuário possui no mínimo um artigo publicado, isto é necessário para que a filtragem baseada em conteúdo possa ser utilizada. Os artigos foram obtidos da biblioteca digital do Citeseer [Bollacker et al. 1999], um repositório online¹ de artigos de Ciência da Computação. Os artigos foram obtidos utilizando o protocolo OAI-PMH, tendo como base a URL <http://cs1.ist.psu.edu/cgi-bin/oai.cgi> . O Citeseer disponibiliza aproximadamente setecentos mil artigos no formato *Dublin Core*.

¹O Citeseer encontra-se disponível em <http://citeseer.ist.psu.edu/>

As avaliações dos artigos foram obtidas de um subconjunto da base de dados do MovieLens. O MovieLens é uma base de dados utilizada para teste de vários sistemas de recomendação. Para testar nossos algoritmos rapidamente, nós construímos uma base de dados contendo uma amostra de dois mil artigos escolhidos aleatoriamente do CiteSeer e um subconjunto de quatro mil quinhentos e setenta e oito avaliações da base do MovieLens também escolhidos de forma aleatória.

4.2. Métricas

Para avaliar a recomendação top-n nós usamos duas medidas amplamente utilizadas na comunidade de pesquisa de recuperação de informação, são elas: precisão(*precision*) e cobertura(*recall*).

A seguir é mostrado o procedimento utilizado: Inicialmente, os dados são divididos em dois conjuntos - um conjunto de treinamento e um conjunto de teste. Os algoritmos de recomendação trabalham no conjunto de treinamento, e geram um número de recomendações, que chamamos de **top-n**. O principal objetivo é observar o conjunto de teste, (por exemplo, a porção escondida dos dados adquiridos) e comparar os artigos com o conjunto top-n. Os artigos que aparecem em ambos os conjuntos são membros de um conjunto especial, que nós chamamos de conjunto *hit*. Abaixo, mostra-se as definições de cobertura e precisão no contexto de sistema de recomendação:

Cobertura: Razão entre o tamanho do conjunto hit sobre o tamanho conjunto de teste. Cobertura= $|hit| / |teste|$.

Precisão: Razão entre o tamanho do conjunto hit sobre o tamanho do conjunto top-n. Precisão= $|hit| / |top - n|$.

Denomina-se F1 a media harmonica entre Cobertura e Precisão.

4.3. Teste

Cada algoritmo recebe como entrada os dados de treinamento e manipulá-os da forma que o convém. A avaliação é executada retendo-se aleatoriamente vinte avaliações positivas (avaliação 4 ou 5) de cada usuário. Esses serão os artigos da base de teste em que o desempenho do recomendador será avaliado. Todas as outras avaliações são consideradas parte do perfil de treinamento. Ao algoritmo de recomendação é fornecido a base de treinamento, sem os artigos positivamente avaliados, e o recomendador realiza dez recomendações. O resultado do processo da recomendação é um subconjunto classificado da base de dados que contém aqueles artigos possivelmente de interesse do usuário. Desse conjunto, nós registramos a posição de cada artigo positivamente avaliado do teste.

4.4. Apresentação dos Resultados

4.4.1. Resultados da Filtragem Colaborativa

A tabela 1 mostra a similaridade de todos os usuários em relação ao usuário1, através do coeficiente de Pearson.

Observando os dados da tabela 1 vemos que o usuário1 possui como melhores dois vizinhos os usuários 4 e 9 (excetuando-se o próprio usuário1).


Segundo Herlocker [Herlocker et al. 1999], o número de vizinhos influencia a qualidade do processo de recomendação.

Tabela 1. Similaridade usando Pearson entre o usuário1 e todos os usuários

<i>Usuário</i>	<i>Similaridade</i>
1	1,0
2	-0,017892922197050555
3	0,1709765025387663
4	0,30480224542068957
5	0,08221849337356409
6	0,248981564461246
7	0,14388551457155654
8	0,06977915405003718
9	0,4504023308083442
10	0,3063380596004754

4.4.2. Resultados da Filtragem Baseada em Conteúdo

A figura 3 mostra a métrica F1 de cada usuário para a filtragem por conteúdo.

**Figura 3. Filtragem Baseada em Conteúdo**

4.4.3. Resultados da Filtragem Híbrida utilizando o Algoritmo Misto

A tabela 2 mostra as 5 primeiras recomendações em ordem decrescente para o usuário1.

Tabela 2. Top-5 artigos recomendados para o usuário1 utilizando filtragem híbrida mista

<i>id do artigo</i>	<i>título</i>
180	SuperWeb: Research Issues in Java-Based Global Computing.
1464	Towards Reliable Autonomous Agents.
689	Selforganization in a System of Binary Strings With Topological Interactions.
932	Intelligent Interface Agents for Intelligent Environments.
68	Nozomi - A Fast, Memory-Efficient Stack Decoder For Lvcscr.

4.4.4. Resultados da Filtragem Híbrida utilizando o Algoritmo Ponderado

A tabela 3 mostra as 5 primeiras recomendações em ordem decrescente para o usuário1.

Tabela 3. Top-5 artigos recomendados para o usuário1 utilizando filtragem híbrida ponderada com $p=0,6$

<i>id do artigo</i>	<i>título</i>
177	Closed Loop Identification Of Nonlinear Systems.
194	Neutrino Oscillations With Three-Generation Mixings and Mass Hierarchy.
68	Nozomi - A Fast, Memory-Efficient Stack Decoder For Lvcsr.
180	SuperWeb: Research Issues in Java-Based Global Computing.
689	Selforganization in a System of Binary Strings With Topological Interactions.

4.5. Avaliação dos Resultados

O valor médio de F1 para filtragem colaborativa foi de 0,235. O valor médio de F1 para filtragem baseada em conteúdo foi de 0,018. O valor médio de F1 para filtragem híbrida mista foi de 0,266. O valor médio de F1 para filtragem híbrida ponderada com peso máximo para Filtragem Colaborativa foi de 0,255.

A figura 4 mostra a métrica F1 de cada usuário para as quatro técnicas.



Figura 4. Comparação do resultado das técnicas

O melhor resultado obtido foi para o algoritmo Misto com 0,266. Observa-se, assim, a melhoria da filtragem híbrida em relação a filtragem baseada em conteúdo ou colaborativa.

5. Conclusões

Este trabalho apresentou uma proposta de um sistema de recomendação personalizada de artigos científicos para Bibliotecas Digitais. Tal sistema, objetiva a personalização da informação, considerando o perfil do usuário. Foi proposta uma solução para representar o perfil do usuário, através da extração de informações de um arquivo xml referente ao currículo Lattes do usuário. Além disso, foi desenvolvido um mecanismo que possibilita a modificação do perfil por parte do usuário, permitindo-lhe tratar eventuais informações desatualizadas extraídas do seu Lattes, relativamente as suas atuais preferências. O sistema garante que qualquer biblioteca digital que provê metadados no formato Dublin Core (DC) e dá suporte ao protocolo OAI-PMH, possa ser utilizada como fonte para prover informações sobre os artigos a serem recomendados.

Os resultados dos experimentos mostraram-se satisfatórios, pois a filtragem

híbrida melhorou a métrica F1 em relação as filtragens colaborativa e conteúdo. Com isso pode-se ganhar mais qualidade com relação às medidas de precisão e cobertura.

ï»¿

Referências

- ARP (2001). Arp - active recommendation project. Disponível em: <http://informatics.indiana.edu/rocha/lwww>. Acesso: Jan. 2008.
- Balabanovic, M. and Shoham, Y. (1997). Combining content-based and collaborative recommendation. *Communications of the ACM*, 40(3).
- Bollacker, K. D., Lawrence, S., and Giles, C. L. (1999). A system for automatic personalized tracking of scientific literature on the web. In *In Digital Libraries 99 - The Fourth ACM Conference on Digital Libraries*, pages 105–113. ACM Press.
- Burke, R. (2002). Hybrid recommender systems survey and experiments.
- Cazella, S. C. and Alvares, L. O. C. (2004). Creating virtual web communities through a hybrid recommender system. II WORKSHOP DE TESES E DISSERTACOES EM INTELIGENCIA ARTIFICIAL. Sao Luis, Brazil.
- Claypool, M., Gokhale, A., Miranda, T., Murnikov, P., Netes, D., and Sartin, M. (1999). Combining content-based and collaborative filters in an online newspaper.
- Herlocker, J. L. (2000). *Understanding and improving automated collaborative filtering systems*. Doutorado em ciencia da computacao, University of Minnesota, Minnesota.
- Herlocker, J. L., Konstan, J. A., Borchers, A., and Riedl, J. (1999). An algorithmic framework for performing collaborative filtering. In *SIGIR '99: Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, pages 230–237, New York, NY, USA. ACM.
- Huang, Z., Chung, W., Ong, T.-H., and Chen, H. (2002). A graph-based recommender system for digital library.
- Reategui, E. B. and Cazella, S. C. (2005). Sistemas de recomendacao. Disponível em: http://www.addlabs.uff.br/enia_site/dw/sistemasrecomendacao.zip. Acesso: Jan. 2008.
- S-Y., H., W-C., H., and W-S., Y. (2003). Content-independent task-focused recommendation. *Online Information Review*, 27(3):169–182.
- Torres, R. (2004). *Personalização na Internet*. Novatec.
- Torres, R., McNee, S. M., Abel, M., Konstan, J. A., and Riedl, J. (2004). Enhancing digital libraries with techlens+. In *JCDL '04: Proceedings of the 4th ACM/IEEE-CS joint conference on Digital libraries*, pages 228–236, New York, NY, USA. ACM.