

Capítulo

3

Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações

Evandro Costa, Janderson Aguiar e Jonathas Magalhães

Abstract

A fast increasing in the volume of digital educational resources available on the open Web or even private digital libraries has occurred in recent years. Due to the large volume of resources available, it is a hard task for a user to find the content which his/her is interested. Personalized Recommendation Systems have recently emerged to address this problem. However, such systems need to be better disseminated among users of educational resources, such as students and teachers, as these systems will help significantly in the performance of their activities. In this chapter, the concepts, the principal techniques and information filtering algorithms will be viewed with applications for recommendation of digital educational resources, demonstrating the potential of this type of system.

Resumo

Nos últimos anos tem-se observado um crescimento acentuado no volume de recursos digitais educacionais disponíveis na Web aberta ou mesmo em bibliotecas digitais privadas. Portanto, trata-se de um grande volume de recursos, tornando uma tarefa complicada para um usuário ter acesso ao que lhe interessa. Para abordar esse problema, surgiram recentemente os Sistemas de Recomendação personalizada. Entretanto, esse tipo de sistema precisa ser mais bem disseminado para os usuários de recursos educacionais, a exemplo de estudantes e professores, pois ajudarão significativamente no desempenho de suas atividades. Neste capítulo, os conceitos e as principais técnicas e algoritmos de filtragem de informação serão vistos com aplicações na recomendação de recursos digitais educacionais, demonstrando o potencial desse tipo de sistema.

3.1. Introdução

O crescente uso de tecnologias de informação e comunicação possibilita mudanças a cada dia no processo de ensino e aprendizagem. A Web se consolida cada vez mais como meio de apoio para esse processo, a exemplo do que acontece no seu suporte aos Ambientes Virtuais de Aprendizagem (AVA). Com isso, amplia-se significativamente também a quantidade de recursos educacionais disponíveis para estudantes e professores.

Na perspectiva mencionada anteriormente, portanto, é desafiador para os professores selecionar e organizar os diversos recursos educacionais que vão surgindo na Web, de forma a contribuir para aumentar a aprendizagem e a motivação dos alunos. Um bom exemplo a ser citado é o caso da Educação a Distância que trabalha com aspectos como motivação. Muitos autores julgam que é pertinente a existência de atrativos em AVA, como por exemplo, a recomendação de materiais didáticos [Ferro 2010]. Como defendem Cazella *et al.* (2010), é ainda mais desafiador quando se pretende identificar e recomendar materiais personalizados, baseando-se em necessidades individuais de cada aluno, além de interesses e competências a serem desenvolvidos.

Os Sistemas de Recomendação, na maioria dos casos, apresentam algumas limitações quando utilizados em contextos educacionais. Nessas situações, é necessário considerar outras questões além das preferências do professor ou do estudante em determinado recurso, mas também o quanto o recurso irá ajudá-los a alcançar os objetivos de aprendizagem [Tang e McCalla 2004]. Em particular, alguns requisitos adicionais deveriam ser considerados no projeto e desenvolvimento de Sistemas de Recomendação no caso de ambientes educacionais online.

Diante do contexto apresentado, surge o seguinte desafio: como utilizar os recursos de um ambiente educacional tendo em vista ampliar o aprendizado? Ou seja, como desenvolver ambientes educacionais mais eficazes, de forma que o estudante se sinta motivado e aprenda mais e em menos tempo? Nesse sentido, os Sistemas de Recomendação consistem em uma possível solução, uma vez que são sistemas capazes de identificar conteúdos adequados, de maneira automática, para cada indivíduo, baseando-se em suas características e/ou preferências [Adomavicius e Tuzhilin 2005].

Sistemas de Recomendação, portanto, prestam-se, por exemplo, para filtrar recursos educacionais contemplando os perfis individuais dos alunos ou até mesmo perfis de um grupo de alunos de uma disciplina. Dessa forma, esses sistemas podem auxiliar o professor na composição de recursos digitais para uma disciplina e no acompanhamento dos alunos — uma vez que a preocupação em identificar e tratar perfis diferenciados é parcialmente ou até mesmo completamente resolvida com a personalização provida por esses sistemas. Assim, os Sistemas de Recomendação podem atingir todos os envolvidos no processo de ensino e aprendizagem.

Além disso, os professores podem se beneficiar com os Sistemas de Recomendação de forma a obterem conteúdos que complementem seus planos de aulas, além de outros inúmeros recursos. Apesar de os sistemas de busca na Web serem bastante úteis e utilizados, muitos dados são retornados e, dentre esses, conteúdos irrelevantes para os professores. Sistemas de recomendações específicos permitem aos professores encontrar conteúdos próximos ao seu perfil, agilizando seu trabalho.

Quais técnicas de recomendação melhor se adaptam às necessidades de estudantes e professores no processo de ensino e aprendizagem? Questões como essa despertam cada vez mais o interesse entre os acadêmicos de Informática na Educação. A partir disso, percebe-se, então, a necessidade de se estudar sobre como realizar boas recomendações de recursos educacionais.

Em síntese, este capítulo tem os seguintes objetivos: (i) Apresentar as principais funcionalidades e abordagens utilizadas em Sistemas de Recomendação, esclarecendo seu potencial para AVA; (ii) Capacitar o leitor para a utilização de técnicas e estratégias de recomendação no contexto educacional; (iii) Mostrar modelos de recomendação de recursos educacionais, elaborados por autores diversos; e (iv) Detalhar, a partir do enfoque na ferramenta RecSalt, como funciona esse tipo de recomendação.

3.2. Técnicas de Recomendação

Um Sistema de Recomendação baseado em filtragem funciona, segundo Drumond *et al.* (2006), basicamente em três etapas: (i) criação de modelos de usuário a partir de suas preferências, adquiridas por meio explícito (formulários) ou implícito (observação de comportamento); (ii) criação das representações internas dos elementos de informação por meio de técnicas, como, por exemplo, árvores de decisão e ontologias; e (iii) comparação de similaridade entre os elementos de informação e os modelos de usuário, sendo recomendados os elementos mais similares ao usuário.

Para o cálculo de similaridade de um usuário-alvo com os outros usuários, há várias medidas existentes. Huang (2008) expõe várias medidas comumente utilizadas, tais como a Distância Euclidiana e a Medida dos Cossenos:

- **Distância Euclidiana:** Calcula a distância entre dois vetores que representam perfis de usuário. O valor calculado é um número real no intervalo $[0, \infty[$ e representa a similaridade entre os usuários. Quanto mais próximo de 0 mais similares são os perfis de usuário, conseqüentemente, quanto mais distante de 0 menos similares são os usuários.
- **Medida dos Cossenos:** Calcula o cosseno do ângulo formado pelos dois vetores que representam os perfis de usuário. O valor do cosseno calculado, que varia de 0 (zero) a 1 (um), indica a similaridade entre os usuários. Quanto mais próximo a 1, mais similares são os perfis dos usuários. Quanto mais próximo a 0, menos similares eles são.

No Quadro 3.1 são apresentadas as equações para a Distância Euclidiana e Medida dos Cossenos.

Quadro 3.1. Equações para cálculo de similaridade

Distância Euclidiana	Medida dos Cossenos
$D_{a,b} = \sqrt{\sum_{i=1}^m w_{a,i} - w_{b,i} ^2}$	$C_{a,b} = \frac{\sum_{i=1}^m (w_{a,i} * w_{b,i})}{\sqrt{\sum_{i=1}^m (w_{a,i})^2} \times \sqrt{\sum_{i=1}^m (w_{b,i})^2}}$

Para as equações do Quadro 3.1, considere: $D_{a,b}$ a distância euclidiana entre o usuário-alvo a com um determinado usuário b ; $C_{a,b}$ o cálculo do cosseno entre o usuário-alvo a com um determinado usuário b ; $w_{a,i}$ a avaliação do usuário a para o item i ; $w_{b,i}$ a avaliação do usuário b para o mesmo item; e m a quantidade de itens existentes.

Quanto às técnicas de filtragem de informação, as abordagens mais conhecidas são a Filtragem por Conteúdo e a Filtragem Colaborativa, elucidadas nas subseções seguintes. Alguns autores, como Burke (2002), definem também a Filtragem Baseada em Conhecimento — itens recomendados com base em inferências das preferências e necessidades do usuário por meio de conhecimento estruturado de forma funcional —, a Filtragem Baseada em Utilidade — itens recomendados com base na sua utilidade para o usuário — e a Filtragem Demográfica — usuários classificados em classes com relação a perfis em comum. Seguindo o pensamento de Burke, Gonzalez *et al.* (2007 apud Cazella *et al.* 2010) propõem a Filtragem Baseada em Outros Contextos, envolvendo aspectos psicológicos (inteligência emocional) do usuário combinados aos aspectos caracterizadores dos itens.

3.2.1. Filtragem por Conteúdo

Recomendação baseada em filtragem por conteúdo utiliza informações anteriores do usuário em relação a um item para recomendar itens similares; por exemplo, serão recomendados os produtos mais parecidos com aqueles avaliados anteriormente de forma positiva. A indexação de frequência de termos é bastante utilizada nessa abordagem, sendo as informações dos documentos e necessidades dos usuários descritas por vetores que armazenam a frequência com que as palavras ocorrem em um documento ou em uma consulta do usuário [Cazella *et al.* 2010].

Na Figura 3.1, é exemplificada a ideia da abordagem de recomendação baseada em filtragem por conteúdo. Como o usuário leu os livros X, Y e Z e o livro B não possui informações semelhantes a esses, então B não será recomendado ao usuário; todavia, o livro A possui características que se assemelham aos três livros lidos, logo, será recomendado; os livros C e D, dependendo do nível de similaridade considerado no sistema, também podem ser recomendados, sendo C mais similar ao gosto do usuário que D.

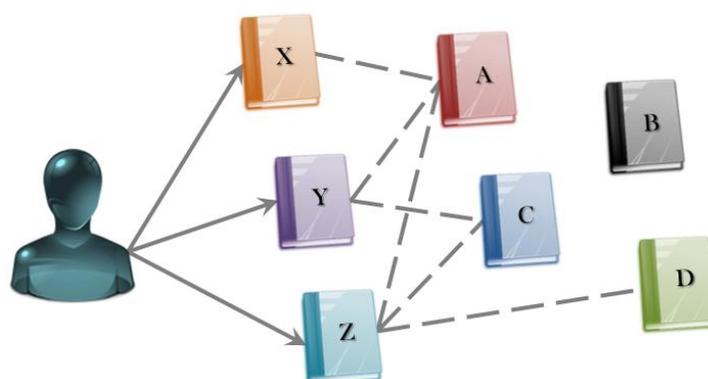


Figura 3.1. Representação da abordagem de filtragem por conteúdo

3.2.2. Filtragem Colaborativa

Recomendação baseada em filtragem colaborativa baseia-se no julgamento de usuários com interesses em comum. Para isso, os usuários devem avaliar os itens do sistema, e

essas avaliações permitem descobrir médias para os itens; com isso, o Sistema de Recomendação pode descobrir padrões de comportamento e sugerir automaticamente os itens considerados mais interessantes pelos usuários com gostos similares. A técnica de descoberta automática de relações entre o usuário e seus “vizinhos mais próximos” consiste em (i) calcular a similaridade do usuário alvo em relação aos outros usuários; (ii) selecionar um grupo de usuários com maiores similaridades para considerar na predição; e (iii) normalizar as avaliações e computar as predições, ponderando as avaliações dos usuários mais similares [Cazella *et al.* 2010].

Na Figura 3.2, é mostrado um exemplo com a ideia da abordagem de recomendação baseada em filtragem colaborativa. Considerando que o usuário alvo gostou dos livros X, Y e Z, os vizinhos mais próximos são os usuários 1 e 3, que também leram esses três livros; uma vez que ambos gostaram também dos livros A e B, o sistema recomendará esses dois livros ao usuário.

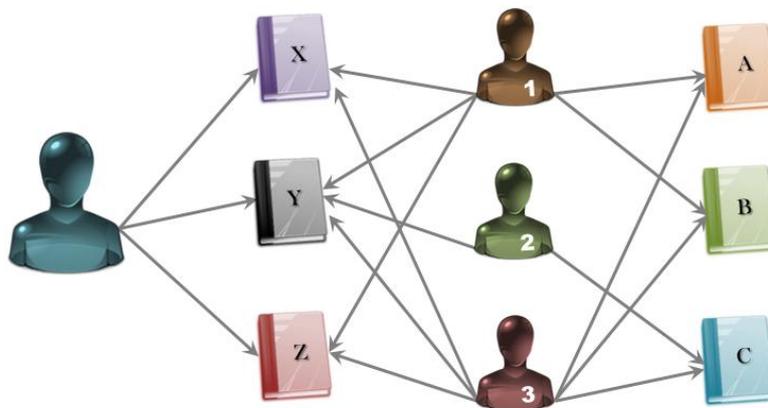


Figura 3.2. Representação da abordagem de filtragem colaborativa

3.2.3. Filtragem Híbrida

Adomavicius e Tuzhilin (2005) apontam a limitação na análise de conteúdo de dados pouco estruturados, além da complexidade existente na extração/análise de conteúdo não textual (multimídia, por exemplo). Devido a isso, a recomendação de itens com informações textuais, como sites Web, consiste no foco, em geral, dos sistemas baseados em filtragem por conteúdo. Outra dificuldade relacionada a essa abordagem consiste em analisar a semântica de textos que, mesmo contendo termos semelhantes, podem ter qualidades bem distintas. Em relação aos sistemas colaborativos, as limitações se referem à coleta de informações dos usuários, destacando-se os problemas de: (i) primeiro avaliador, uma vez que um novo item não é recomendado até que usuários o avaliem; (ii) pontuações esparsas, em casos de sistemas com pequeno número de usuários e grande número de itens; (iii) usuário com gostos muito diferentes, dado que as recomendações para ele podem ser fracas pela escassez de usuários com gostos similares.

Para minimizar essas barreiras, existe a abordagem híbrida (Figura 3.3), que une as vantagens da filtragem colaborativa e da filtragem por conteúdo [Cazella *et al.* 2010].

Além do trabalho de Adomavicius e Tuzhilin (2005), outro que se destaca ao abordar a filtragem híbrida é o de Burke (2002). Em relação a como obter um Sistema de Recomendação híbrido, Ferro (2010) elencou as seguintes maneiras abordadas nesses dois trabalhos:

1. Recomendação baseada no passado dos usuários e recomendação baseada na colaboração dos usuários individualmente, gerando uma única recomendação a partir das pontuações dessas recomendações;
2. Escolha da abordagem utilizada para realizar a recomendação — se baseada no conteúdo ou baseada na filtragem colaborativa — por critérios estipulados no sistema.
3. Geração de recomendações por diversas abordagens, simultaneamente, permitindo ao usuário obter várias recomendações.
4. Geração de recomendação em cascata, na qual uma técnica seleciona alguns itens que, por sua vez, são avaliados por outra técnica de recomendação.
5. Construção de um modelo unificado que contemple a abordagem baseada em conteúdo e a filtragem colaborativa.

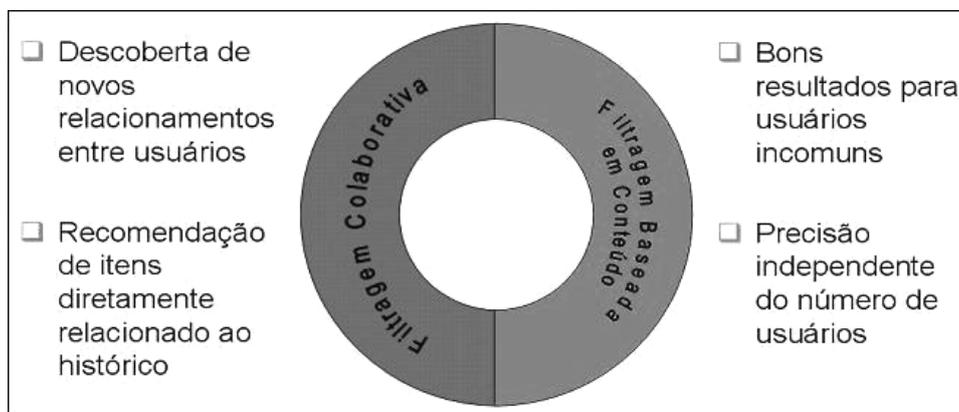


Figura 3.3. Filtragem híbrida. Fonte: Cazella *et al.*, 2010, p. 20

3.3. Estratégias de Recomendação

A ação de recomendar itens é fortemente relacionada à oferta de produtos e, portanto, muitos trabalhos sobre Sistemas de Recomendação são relacionados a *e-commerce*. É possível encontrar diferentes estratégias para a personalização de ofertas para os usuários, tais como os indicados por Cazella *et al.* (2010):

- Reputação do Produto: é comum encontrar, próximos aos itens, ícones que representam a opinião dos outros usuários, sendo essa opinião coletada após um usuário adquirir/consultar determinado item.
- Recomendação por Associação: obtida a partir de análise dos hábitos de compras/consultas a itens do usuário, para identificar padrões e, baseando-se nesses padrões, recomendar itens.
- Associação por Conteúdo: recomendações baseadas no conteúdo de determinado item, tais como autor, palavras-chave, ano, etc.
- Análise de Sequências de Ações: identificação de padrões de compras/consultas dos usuários a partir de sequências temporais, diferenciando-se da recomendação por considerar o tempo em que ocorrem as ações.

Na Figura 3.4 são encontradas as estratégias de recomendação anteriormente mencionadas. Os ícones de estrela (seta 1) representando avaliações — escala de 1 a 5 estrelas —, além das indicações de “Eu Amo”, “Eu Quero” e “Eu Tenho” (seta 2), exemplificam a estratégia de Reputação do Produto. A parte indicada pela seta 3 exemplifica a estratégia de Recomendação por Associação. A estratégia de Associação por Conteúdo pode ser percebida nas partes indicadas pelas setas 5 e 6. E, finalmente, a

estratégia de Análise de Sequências de Ações pode ser exemplificada na parte indicada pela seta 4.

1 Livro - Inferno: uma Nova Aventura de Robert Langdon - Dan Brown

(Cód. Item 1972035)
(Cód EAN 9788580411522) Outros produtos **Editora Arqueiro**

★★★★★ 4,7 (6 avaliações) Leia 6 Avaliações | Faça uma Avaliação

De: R\$ 39,90
Por: **R\$ 29,90**
em até 2X de R\$ 14,95

Economia de: R\$ 10,00

GANHE 14 PONTOS

Comprar
Colocar no Carrinho

Adicionar à Lista de Casamento

2 O Que Achou?

15 59 12

Eu Amo Eu Quero Eu Tenho

3 Quem procura este item também se interessa por:

- Livro - Inferno - Dan Brown
De: R\$ 95,90
Por: **R\$ 77,31**
ou 7X de R\$ 11,04 sem juros
- Livro - O Silêncio das Montanhas - Khaled Hosseini
De: R\$ 39,90
Por: **R\$ 24,90**
ou 2X de R\$ 12,45 sem juros
- Livro - Coleção Dan Brown - 5 Livros
De: R\$ 139,50
Por: **R\$ 103,50**
ou 10X de R\$ 10,35 sem juros
- Livro - A Marca de Atena - Livro 3 - Rick Riordan
De: R\$ 39,90
Por: **R\$ 29,90**
ou 2X de R\$ 14,95 sem juros
- Livro - Wild Cards - O Começo de Tudo - Livro 1 - George R. R. Martin
De: R\$ 44,90
Por: **R\$ 30,90**
ou 3X de R\$ 10,30 sem juros

4 Após visitar este item, o que os clientes acabam comprando?

- 87% compram**
Livro - Inferno: uma Nova Aventura de Robert Langdon - Dan Brown
De: R\$ 39,90
Por: **R\$ 29,90**
ou 2X de R\$ 14,95 sem juros
- 4% compram**
Livro - O Silêncio das Montanhas - Khaled Hosseini
De: R\$ 39,90
Por: **R\$ 24,90**
ou 2X de R\$ 12,45 sem juros
- 2% compram**
Livro - Crossfire - Para Sempre Sua - Volume 3 - Sylvia Day
De: R\$ 29,90
Por: **R\$ 18,90**
- 2% compram**
Livro - A Culpa é das Estrelas - John Green
De: R\$ 29,90
Por: **R\$ 21,80**
ou 2X de R\$ 10,90 sem juros

5 Buscas relacionadas a este produto:

Inferno Dan Brown|Inferno|Dan Brown|O Inferno Dan Brown

6 Aproveite e compre junto:

- Livro - Inferno: uma Nova Aventura de Robert Langdon - Dan Brown
De: R\$ 39,90
Por: **R\$ 29,90**
ou 2X de R\$ 14,95 sem juros
- Livro - O Silêncio das Montanhas - Khaled Hosseini
De: R\$ 39,90
Por: **R\$ 24,90**
ou 2X de R\$ 12,45 sem juros

Preço dos 2 itens
De: R\$ 79,80
Por: **R\$ 54,80**

Comprar Junto

Figura 3.4. Exemplo de utilização de estratégias de recomendação em um site de e-commerce. Fonte: Adaptado do site pontofrio.com.br

3.4. Recomendação de Recursos Educacionais

Assim como o domínio comercial, entre outros, o domínio educacional também pode usufruir dessas estratégias de recomendação para a melhoria do processo de ensino e aprendizagem. Como defende Ferro (2010), a utilização de Sistemas de Recomendação em AVA pode contribuir bastante no processo de ensino e aprendizagem, uma vez que os alunos poderão receber recomendações personalizadas de materiais didáticos, além de contribuir para explorar mais o acervo existente, permitindo maior interação entre os materiais didáticos e os usuários.

No Moodle¹, por exemplo, há um plugin denominado *Recommender* [Moodle 2013], disponível no ambiente em forma de bloco (Figura 3.5), que oferece alguns serviços de recomendação:

- Atividades mais populares: lista os 10 recursos e atividades mais vistos/atualizados no curso em que o bloco está sendo visualizado no momento;
- Cursos mais populares: lista os 3 cursos que mais têm alunos matriculados em comum com o curso em que o bloco está sendo visualizado no momento;
- *Bookmarks* compartilhados: permite aos professores fazer suas próprias recomendações, adicionando qualquer *link* ao bloco.

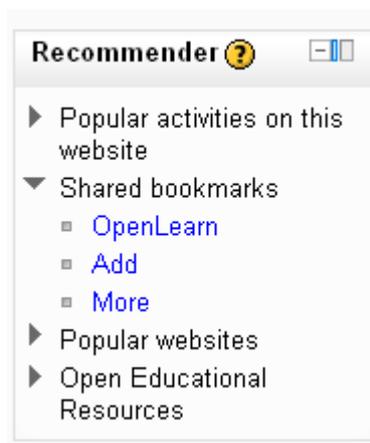


Figura 3.5. Bloco *Recommender*. Fonte: Moodle, 2013

Apesar de não utilizar abordagens como filtragem colaborativa e filtragem baseada em conteúdo, o plugin *Recommender* é um exemplo de utilização do conceito de recomendação de itens no contexto educacional. É interessante ressaltar que o Moodle permite a criação de novos plugins, sendo possível, então, implementar modelos diversos de recomendação de recursos educacionais para esse AVA amplamente utilizado pela comunidade.

Entre as primeiras iniciativas no contexto educacional, é possível citar o *GroupLens*, um projeto de pesquisa, desenvolvido pela Universidade de Minnesota na década de 1990, relacionado à filtragem colaborativa, cujo sistema auxiliava a busca de artigos, coletando a avaliação dos usuários referente aos artigos lidos e, a partir da identificação dos usuários com avaliações similares, recomendava novos artigos [Konstan *et al.* 1997].

¹ O Moodle (<https://moodle.org/>) é um AVA bastante popular entre educadores de todo o mundo.

Apesar dos Sistemas de Recomendação serem atualmente utilizados com sucesso para recomendar itens em uma variedade de domínios, segundo Parveen *et al.* (2012) o contexto educacional possui algumas particularidades, o que requer uma reflexão especial. Por exemplo, Manouselis *et al.* (2011) mostram que é preciso considerar o tipo de aprendizagem que se deseja — aprender um novo conceito ou reforçar um conhecimento existente pode exigir tipos diferentes de recursos de aprendizagem.

Um aspecto que difere bastante os Sistemas de Recomendação de recursos educacionais em relação a outros, é a forma de avaliá-los. Há vários conjuntos de dados com características específicas disponíveis que são usados como referência para avaliar novos modelos de recomendação. Entretanto, em se tratando de Sistemas de Recomendação voltados para o processo de ensino e aprendizagem, faltam conjuntos de dados de referência e há pouca padronização dos procedimentos de avaliação. Esse aspecto é bastante complexo, pois há várias dimensões de avaliação possíveis, como as dimensões pedagógicas [Manouselis *et al.* 2011].

As subseções a seguir apresentam exemplos de modelos elaborados por diversos pesquisadores para recomendações de recursos educacionais, sendo abordado também, de modo geral, como avaliaram seus modelos.

3.4.1. Estudo de Caso de Alertas e Recomendações para Educação a Distância Aplicado em Turmas Heterogêneas

Morais e Franco (2011) propõem um modelo de recomendação utilizando técnicas que identificam os alunos com baixas interações, verificando seus níveis de participação e conhecimento, ajudando, assim, tanto alunos quanto professores.

O trabalho [Morais e Franco 2011] apresenta um conceito importante a considerar em Educação a Distância: turmas heterogêneas. A metodologia consistiu em estudos de caso, observando o comportamento de 90 alunos de pós-graduação (*lato sensu*) no curso de Informática na Educação, utilizando o ambiente TelEduc, e o comportamento de 137 alunos no curso de Informática instrumental, utilizando o ambiente Moodle. Embora a maioria dos alunos tenha sido das áreas humanas, havia alunos de diversas áreas do conhecimento, tais como: biologia, matemática, química, psicologia, engenharia e veterinária.

Inicialmente, foram analisadas as ações e interações realizadas pelos alunos, nos AVA anteriormente mencionados, sobre os materiais disponíveis, a exemplo de apostilas on-line, recursos multimídia e CD-ROM. Além disso, foram analisados o desempenho da turma heterogênea e as correlações dos itens disponíveis nos AVA e, com isso, os autores apresentaram uma proposta de sistema de alerta e recomendações.

Para obter informações do perfil do aluno, foram coletados dados a partir do questionário do sistema de matrícula, além dos relatórios de acesso aos ambientes, identificando a presença ativa ou não nos recursos disponíveis (fórum, bate-papo, e-mail, atividades e material de apoio). Essas informações em planilhas possibilitaram ao professor verificar o perfil heterogêneo da turma.

A partir do primeiro estudo de caso, realizado no TelEduc, foi percebida a correlação entre conteúdo e atividades, e foi considerado útil a construção de

ferramentas de recomendação e alertas, possibilitando aos docentes observar comportamentos e perceber dificuldades dos alunos.

O estudo de caso realizado no Moodle simulou o ambiente de alertas e recomendação para verificar se essa solução realmente ajudaria os alunos. Em linhas gerais, iniciou-se com a familiarização dos alunos com o material da disciplina, sendo enviadas por e-mail, para aluno e professor, mensagens de alerta a cada participação do aluno. Na Figura 3.6 é mostrado um exemplo dessas mensagens de alerta.

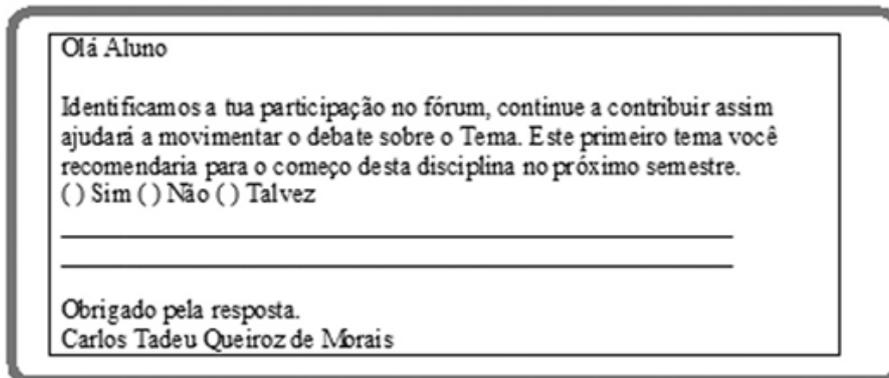


Figura 3.6. Exemplo 1 de mensagem de alerta. Fonte: Moraes e Franco, 2011, p. 139

Na Figura 3.7, por sua vez, é exemplificado um alerta para os alunos provocando-os a participar, ao referenciar alguns alunos pela participação e destacando a importância das contribuições.

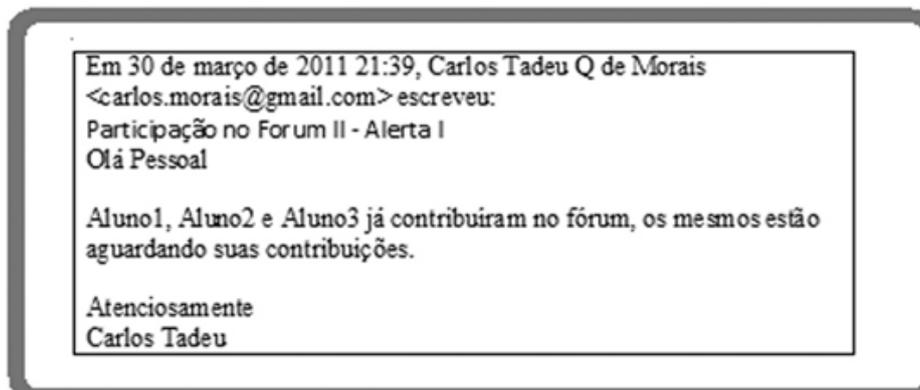


Figura 3.7. Exemplo 2 de mensagem de alerta. Fonte: Moraes e Franco, 2011, p. 140

O modelo de recomendação proposto por Moraes e Franco (2011), basicamente, contempla três módulos: (i) módulo do Perfil dos usuários, que obtém informações como, nome e formação acadêmica dos alunos e professores, entre outras; (ii) módulo de Correlação para obter informações, que define padrões na criação dos textos, para gerar correlações, possibilitando o aumento da eficiência do processo de filtragem, sendo os dados disponibilizados em formatos XML; e (iii) módulo para Recomendação, onde são combinadas informações processadas pelas técnicas de correlação item-a-item e filtragem colaborativa para gerar recomendação.

A partir do modelo proposto, é possível que os professores acompanhem os alunos e que estes recebam recomendações úteis para sua aprendizagem.

3.4.2. LORSys: um Sistema de Recomendação de Objetos de Aprendizagem

Ferreira e Raabe (2010) propõem um modelo de Sistema de Recomendação de objetos de aprendizagem para o ambiente Sophia, uma personalização do Moodle desenvolvida pela Universidade do Vale do Itajaí (UNIVALI).

Os objetos de aprendizagem em questão seguem o formato SCORM (*Sharable Content Object Reference Model*), uma coleção que especifica e padroniza como organizar esses objetos para serem acessados por AVA, garantindo acessibilidade, interoperabilidade, reusabilidade e durabilidade [Ferreira e Raabe 2010].

Ao registrar a navegação do usuário, o ambiente Sophia possibilita a identificação da similaridade entre usuários e, além disso, os metadados que descrevem os objetos de aprendizagem permitem a identificação da similaridade entre conteúdos [Ferreira e Raabe 2010].

O sistema desenvolvido, denominado LorSys (*Learning Object Recommender System*), gera recomendações por meio das técnicas de filtragem colaborativa e de filtragem baseada em conteúdo. Ferreira e Raabe (2010) apontam que a necessidade desse sistema surgiu ao perceber que muitos alunos não faziam uso dos objetos de aprendizagem da forma esperada pelos seus criadores.

Em relação ao processo de recomendação, as técnicas são utilizadas de forma independente. Entretanto, quando ambas as técnicas recomendam um mesmo objeto de aprendizagem, este é classificado/recomendado como “dica quente” [Ferreira e Raabe 2010].

Em relação à filtragem baseada em conteúdo, cabe ao professor definir o grau de relacionamento entre os objetos de aprendizagem (“Pré-Requisito”, “Complemento”, “Similar” ou “Sem relação”). Na Figura 3.8 é ilustrada a interface utilizada para a definição dos graus de relacionamento, mostrando, na parte superior, as informações sobre um determinado objeto de aprendizagem, e, na parte inferior, os outros objetos de aprendizagem aos quais deve ser definido o grau de relacionamento.

Título:	Árvore Binária de Busca		
Assunto:	Estrutura de Dados, Árvore Binária de Busca, Aplicativo		
Descrição:	Permite ao acadêmico visualizar e interagir com a estrutura de dados de uma Árvore Binária de Busca.		
Autor:	Laboratório de Soluções em Software	Organizador:	UNIVALI
Contribuição:	Vinicius H. Ferreira (Produtor do Objeto), Elieser Ademir de Jesus (Desenvolvedor do Aplicativo), Rudimar Luís Scaranto Dazzi (Desenvolvedor do Aplicativo), Fabiane Vavassori (Produtora do Objeto).		
Licença:	(BY-NC-ND)Esta obra está licenciada sob uma Licença Creative Commons (http://creativecommons.org/licenses/by-nc-nd/3.0/deed.pt)		

Título	Relação
Utilizando estrutura de dados Lista: desafio Controle de Lista de Espera Companhia Aérea	Sem relação ▼
Utilizando estrutura de dados Pilha: desafio do Armazém	Pré-Requisito ▼
Preencha as lacunas	Complemento ▼

Figura 3.8. Relacionamento de objetos de aprendizagem. Fonte: Ferreira e Raabe (2010), p. 6

Em relação à filtragem colaborativa, o sistema recomenda o objeto de aprendizagem mais acessado pelos outros usuários, além de recomendar o último objeto de aprendizagem acessado por usuários mais similares (os que acessaram os mesmos objetos que o usuário alvo).

Definidos os objetos a serem recomendados, os usuários do ambiente visualizam as indicações a partir de um bloco (recurso do Moodle), ilustrado na Figura 3.9.



Figura 3.9. Bloco LORSys. Fonte: Ferreira e Raabe, 2010, p. 7

Ferreira e Raabe (2010) realizaram uma avaliação quantitativa e qualitativa do LorSys, disponibilizando-o a um pequeno grupo de usuários com objetos de aprendizagem na área de Ciência da Computação. Em geral, as avaliações foram positivas, indicando também uma maior aceitação das recomendações geradas por meio da filtragem baseada em conteúdo. Dentre as justificativas possíveis indicadas no trabalho, os autores acreditam que isso se deve ao fato dessas recomendações serem mostradas no topo do bloco.

3.4.3. Recomendação de Objetos de Aprendizagem Empregando Filtragem Colaborativa e Competências

Cazella *et al.* (2009) propõem um Sistema de Recomendação com a finalidade de filtrar os objetos de aprendizagem por meio de competências contemplando perfis de alunos de Educação a Distância, permitindo que se moldem e se adaptem aos diferentes contextos e situações proporcionadas por meio do ensino e da aprendizagem online.

As regras de competência objetivam a filtragem dos objetos de aprendizagem de acordo com as competências que precisam ser desenvolvidas e, com isso, são descartados os objetos que não desenvolvem competências indicadas como importantes pelos professores em determinados momentos da disciplina [Cazella *et al.* 2009]. A estratégia de recomendar objetos de aprendizagem que melhor se adaptam aos interesses do aluno, mas respeitando competências que precisam ser desenvolvidas, é importante e pode ser mais um atrativo em AVA, nos quais se luta contra a evasão dos alunos.

O modelo elaborado por Cazella *et al.* (2009) auxilia os alunos acessarem materiais educacionais relacionados ao desenvolvimento de competências específicas, além de flexibilizar o processo de recomendação de materiais a serem consultados pelos alunos, com base nos interesses que vão surgindo de cada um deles.

Em linhas gerais, o modelo proposto (Figura 3.10) segue estes passos para seu funcionamento: (i) o professor planeja as aulas com base nas competências descritas na ementa da disciplina, disponibilizando os objetos de aprendizagem a serem utilizados para desenvolver as respectivas competências; (ii) o modelo realiza os cálculos de coeficiente de similaridade (utilizando o coeficiente de Pearson) e de predição; (iii) o modelo aplica as regras da competência, que filtram os conteúdos recomendados pela predição para permitir ao usuário o desenvolvimento de determinadas competências em um determinado tempo [Cazella *et al.* 2009].

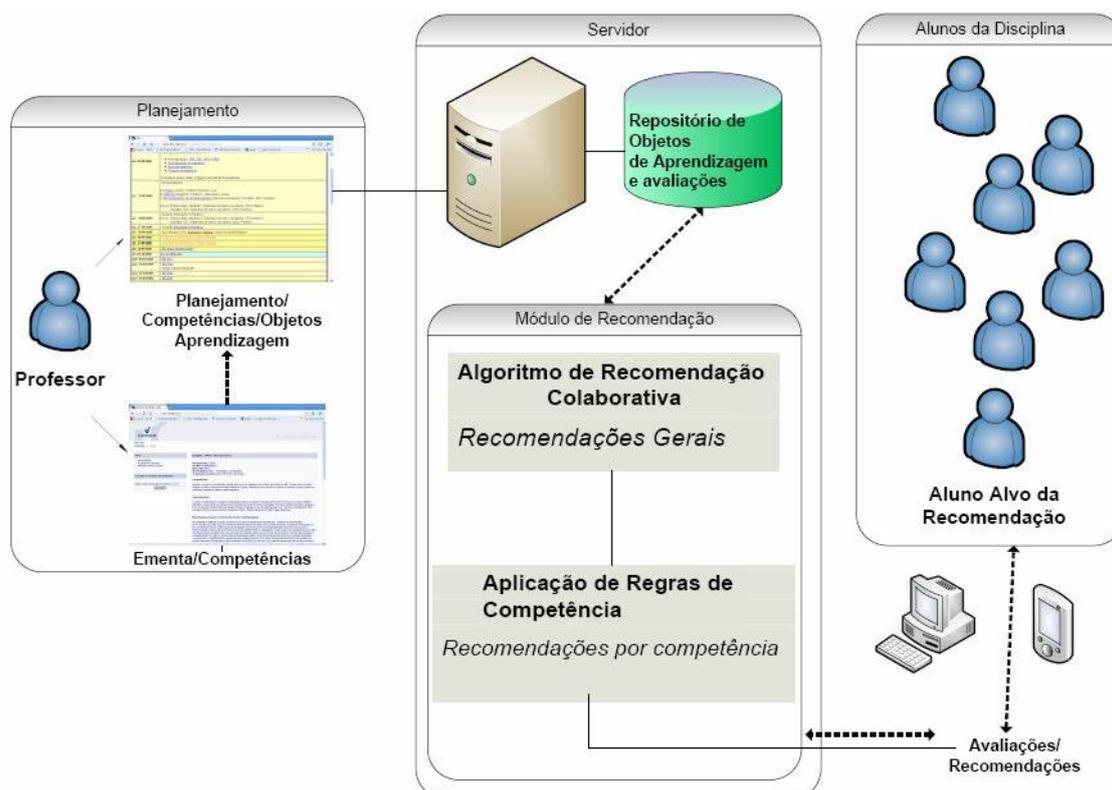


Figura 3.10. Modelo proposto para recomendação de objetos de aprendizagem empregando filtragem colaborativa e competências. Fonte: Cazella *et al.*, 2009, p. 5

Cazella *et al.* (2009) prototiparam esse modelo e realizaram experimentos com 10 graduandos do final do curso de Engenharia da Computação. Os objetos de aprendizagem consistiram em artigos científicos relacionados com competências pretendidas na disciplina de Banco de Dados e selecionados por um professor especialista da área. Com os experimentos, os autores afirmam que o grau de precisão alcançado pelas recomendações geradas pelo protótipo foi satisfatório (76%).

3.4.4. Recommendations in Online Discussion Forums for E-Learning Systems

Abel *et al.* (2010), ao avaliarem diferentes estratégias de recomendação para um fórum de discussão com extensões específicas de *e-learning* (o sistema Comtella Discussions — Comtella-D), propõem uma solução baseada em serviço Web (*Web Service*) com recomendações personalizadas para fóruns de discussão.

O Comtella-D é uma comunidade online para discussão de questões sociais, éticas, legais e gerenciais relacionadas à tecnologia da informação e à biotecnologia

[Webster e Vassileva 2006 apud Abel *et al.* 2010]. Esse sistema permite aos alunos avaliar as postagens, adicionando ou removendo energia delas. A energia é notada a partir da cor (quanto mais energia, ou seja, mais avaliações positivas, mais clara a postagem). Essa funcionalidade do sistema, ilustrada na Figura 3.11, possibilita, entre vários aspectos, avaliar as contribuições de cada um dos estudantes.

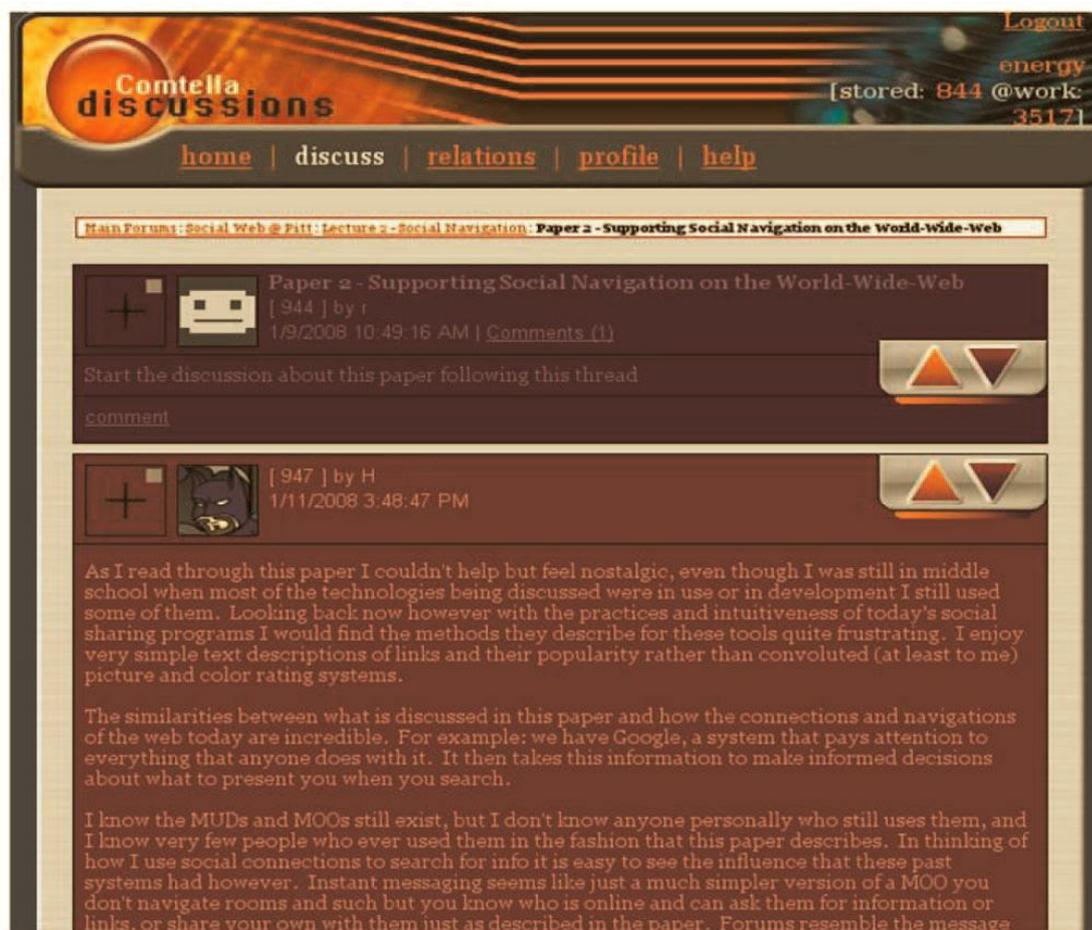


Figura 3.11. Exemplo de duas postagens no sistema Comtella, com níveis diferentes de energia. Fonte: Abel *et al.*, 2010, p. 168

Uma vez que diversos tópicos são criados semanalmente, Abel *et al.* (2010), ao perceberem que os alunos podem, com isso, perder temas relevantes de seu interesse, apontaram a necessidade de realizar recomendações nesse sistema. Além disso, considerando que usuários não agem da mesma forma no sistema, os autores usaram personalização baseada em regras para gerar as recomendações, e consideraram estes diferentes grupos de usuários: (i) usuários que contribuem regularmente com novas postagens, (ii) usuários que contribuem casualmente/raramente com novas postagens, (iii) usuários que não contribuem com novas postagens, mas avaliam regularmente as dos outros, (iv) usuários que não contribuem com novas postagens e casualmente/raramente avaliam as dos outros, e (v) usuários que não contribuem, nem postando nem avaliando.

Os autores elaboraram uma arquitetura não acoplada entre os componentes, assegurando a integração de diferentes algoritmos de recomendação com base no uso de *Web Services* e mostrando como integrar funcionalidade de personalização externa.

Portanto, as aplicações devem definir regras de personalização para selecionar, acessar e, opcionalmente, combinar diferentes algoritmos de personalização [Abel *et al.* 2010].

O Comtella-D foi utilizado por Abel *et al.* (2010) como apoio (recurso adicional) ao curso *Ethics and Computer Science* para graduandos da Universidade de Saskatchewan, em 2006, com o objetivo da turma compartilhar e discutir informações relacionadas aos temas do curso. Para avaliação, o estudo de caso contou com 110 usuários registrados, sendo apenas 36 o número de usuários que contribuíram regularmente postando no fórum de discussão. Em geral, os autores indicam que um pequeno número de usuários e uma pequena quantidade de dados de entrada (duas postagens ou duas atribuições de energia), é suficiente para criar regras que gerem recomendações precisas de fóruns para os alunos em sistemas *e-learning* [Abel *et al.* 2010].

Ao utilizarem *Web Service* para prover o serviço de recomendação, além dos recursos de personalização, os autores tornaram reutilizável a solução para diferentes fóruns de discussão e outros sistemas de *e-learning*. Em geral, o trabalho identificou vantagens de se utilizar fóruns de discussão em um sistema *e-learning*, com serviços de recomendação, para estimular a comunicação e o consequente aprendizado entre os alunos.

3.4.5. Sistema de Recomendação Acadêmico para Apoio a Aprendizagem

Barcellos *et al.* (2007) apresentam um modelo de recomendação dispensando a intervenção do usuário no momento de traçar seu perfil, minimizando o tempo gasto. O trabalho objetivou realizar recomendações mais relevantes, no contexto acadêmico, a partir da integração de sistemas de busca e perfil do usuário, criado automaticamente a partir do que o usuário tem disponível na Internet (no currículo Lattes e em sua página pessoal, caso exista), evitando que o usuário precise, por exemplo, preencher formulários.

O sistema realiza uma busca de artigos acadêmicos — com o auxílio da ferramenta Google Scholar — sobre um determinado assunto considerando o perfil do usuário, sendo dados pessoais, idiomas, formação acadêmica, áreas de interesse e atuação as informações do usuário consideradas pelo sistema [Barcellos *et al.* 2007]. Na Figura 3.12 é ilustrado o modelo proposto, no qual (i) o usuário pode se cadastrar no sistema e, a partir do seu nome, é feita uma busca implícita na Internet para criação do seu perfil; (ii) o usuário cadastrado pode informar o assunto de interesse que deseja procurar; (iii) o sistema processa implicitamente o perfil do usuário e seleciona artigos julgados adequados para o usuário, focando nos que são referenciados em mais de uma base de dados de artigos; e (iii) o sistema apresenta esses artigos selecionados. É interessante destacar que as pesquisas realizadas são armazenadas no histórico dos usuários.

Para avaliar o modelo, foi implementado o protótipo denominado “Ponto com filtro” e realizado um estudo de caso, no qual 10 usuários (entre 29 e 40 anos) usaram o sistema e responderam um questionário em relação às recomendações recebidas, funcionalidades e comparações entre o Google Scholar e o “Ponto com filtro” [Barcellos *et al.* 2007]. Os autores afirmam que os usuários demonstraram bastante satisfação com os resultados das buscas providos pelo sistema.

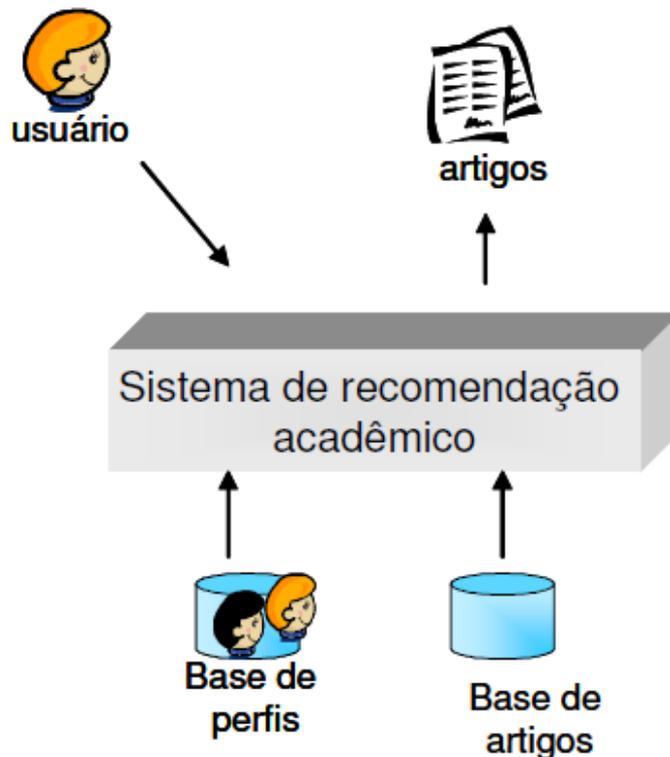


Figura 3.12. Sistema de recomendação acadêmico. Fonte: Adaptado de Barcellos *et al.*, 2007, p. 6

3.4.6. Um Modelo de Sistema de Recomendação de Materiais Didáticos para Ambientes Virtuais de Aprendizagem

Uma vez que AVA, em geral, armazenam diversos materiais didáticos, cuja quantidade só tende a aumentar, Ferro *et al.* (2011) criaram um modelo de Sistema de Recomendação desses materiais nesses ambientes.

Para isso, foi utilizada uma técnica de geração de recomendação híbrida, combinando a recomendação não personalizada [Schafer *et al.* 1999 apud Ferro *et al.* 2011], a recomendação baseada no conteúdo e a recomendação baseada em filtragem colaborativa, como ilustrado na Figura 3.13.

Em linhas gerais, o processo de geração de recomendações realizado por Ferro *et al.* (2011) consiste nestas quatro etapas:

1. Geração de uma lista de materiais didáticos usando filtragem colaborativa. A posição de cada item dessa lista é denominada Posição de premeditação.
2. Geração de uma lista ordenada (estilo *ranking*) dos materiais da lista gerada em 1, cuja ordenação é feita a partir do Grau de Utilidade da técnica de recomendação baseada no conteúdo. A posição de cada item dessa lista é denominada Posição da utilidade.
3. Geração de uma lista ordenada (estilo *ranking*) dos materiais da lista gerada em 1, cuja ordenação é feita a partir da procura dos materiais didáticos mais requisitados por outros usuários (técnica de recomendação não personalizada). A posição de cada item dessa lista é denominada Posição do Quantitativo.
4. Cálculo dos Graus de Utilidade Híbrida — $uh(item)$ —, a partir das listas geradas em 1, 2 e 3, cuja equação é mostrada no Quadro 3.2.

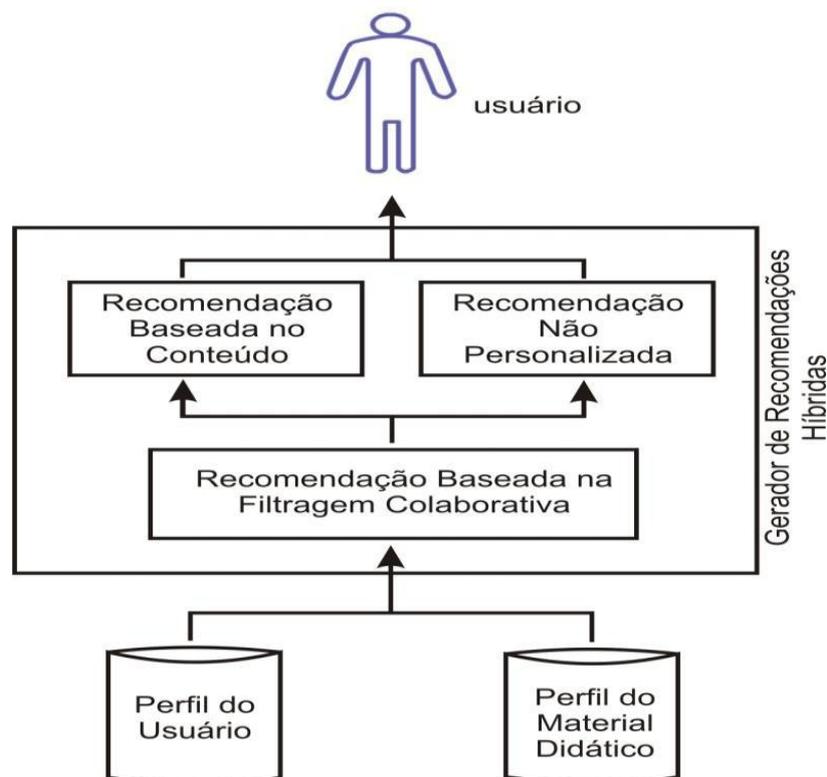


Figura 3.13. Modelo do componente Gerador de Recomendações Híbridas.
Fonte: Ferro *et al.*, 2011, p. 4

Quadro 3.2. Equação para cálculo dos graus de utilidade híbrida. Fonte: Ferro *et al.*, 2011, p. 5

$$uh(item) = \frac{1}{\text{Posição da premeditação}(item)} + \frac{1}{\text{Posição da utilidade}(item)} + \frac{1}{\text{Posição do Quantitativo}(item)}$$

Para validação do modelo, Ferro *et al.* (2011) escolheram o Moodle como AVA para implementar um protótipo do modelo. Os autores afirmam que o modelo de recomendação híbrido proposto foi satisfatório nos testes iniciais e no experimento envolvendo alunos reais em um curso de extensão.

3.5. Ferramenta RecSalt

A ferramenta RecSalt² é um Sistema de Recomendação personalizado para recomendar recursos digitais educacionais. Em sua primeira versão, o sistema apenas recomenda artigos científicos no domínio de Ciência da Computação. A recomendação é realizada da seguinte forma: o perfil de usuário é construído por meio da integração de suas informações de seu currículo Lattes³, da plataforma Mendeley⁴ e da rede social LinkedIn⁵, e a recomendação é realizada utilizando filtragem baseada em conteúdo.

² <http://recsalt.com/>

³ <http://lattes.cnpq.br/>

⁴ <http://www.mendeley.com/>

⁵ <http://www.linkedin.com/>

Uma primeira análise dos algoritmos utilizados no RecSalt pode ser encontrado em [Magalhães *et al.* 2012].

A ferramenta, ilustrada nas Figuras 3.14, 3.15, 3.16 e 3.17, pode ser utilizada por um professor na obtenção de recursos educacionais de forma a compor o material de uma disciplina, como também por estudantes que desejam aprender mais sobre determinada área. Na Figura 3.14, é apresentada a Tela de Login da ferramenta. Para novos usuários, o cadastro é realizado a partir do envio, ao sistema, do nome, sobrenome, e-mail e senha.

Figura 3.14. RecSalt — Tela de login. Fonte: <http://recsalt.com/>

Ao acessar a ferramenta RecSalt pela primeira vez, o usuário deve fornecer, na Página Inicial (Figura 3.15), dados para acesso às fontes externas — Lattes, LinkedIn e Mendeley —, das quais serão extraídas informações relativas a: (i) publicações e proficiência linguística, a partir do Lattes; (ii) competências e especialidades, a partir do LinkedIn; e (iii) acervo de documentos do Mendeley.

Figura 3.15. RecSalt — Página inicial. Fonte: <http://recsalt.com/>

Na página de Perfil (Figura 3.16), é apresentado o nível de interesse — previsto a partir do perfil — nas subáreas do conhecimento relacionadas à área de interesse do usuário. No entanto, é permitido que o usuário inspecione o seu perfil e realize as modificações que desejar, essas informações são utilizadas para atualizar o seu perfil.

Area do Conhecimento	Nível de interesse
Algorithms and Computational Theory	★ ★ ☆ ☆ ☆
Artificial Intelligence	★ ★ ★ ★ ★ Muito alto
Computer Architecture	★ ☆ ☆ ☆ ☆
Computer Security	★ ☆ ☆ ☆ ☆
Data Communication and Networks	★ ☆ ☆ ☆ ☆
Database Systems	★ ★ ★ ★ ☆
Design Automation	★ ☆ ☆ ☆ ☆
Electronic Commerce	★ ☆ ☆ ☆ ☆

Figura 3.16. RecSalt — Página de Perfil. Fonte: <http://recsalt.com/>

Os artigos do usuário são organizados na página Meus Artigos (Figura 3.17), composta por três abas:

- Lidos: ficam listados os artigos cujo usuário marcou sua preferência, que é expressada pela quantidade de estrelas com o seguinte significado: 1–Inadequado, 2–Ruim, 3–Médio, 4–Bom e 5–Excelente;
- Para Ler: são listados os artigos que o usuário deseja ler posteriormente. Em qualquer momento o usuário pode marcar o artigo como lido ou retirá-lo desta lista;
- Recomendados: são exibidos, em ordem decrescente de relevância, os artigos recomendados pelo sistema. O usuário pode expressar sua preferência pelo artigo ou então pode marcá-lo para ler depois.

Título: [Shallow NLP techniques for internet search](#)
Relevância: ★ ★ ★ ★ ★
Abstract: Information Retrieval (IR) is a major component in many of our daily activities, with perhaps its most prominent role manifested in search engines. Today's most advanced engines use the keyword-based ("bag of words") paradigm, which concedes some inherent disadvantages. We believe that natural language (NL) is a more user-oriented, context-preservative and intuitive mechanism for web search. In this paper, we explore shallow NLP techniques to support a range of NL queries over an existing keyword-based engine. We present JASE, a web application enveloping the Google search engine, which performs web searches by decomposing input NL queries and generating new queries that are more suitable for the search engine. By using some of Google's syntactic operators and filters, it creates "clever" queries to improve precision. A preliminary evaluation was conducted to test JASE's accuracy, and results have been encouraging. We conclude that the NL model has potential to not only rival the keyword-based paradigm, but substantially surpass it.
Link: <http://dl.acm.org/citation.cfm?id=1151699.1151719&coll=DL&dl=ACM&CFID=323039840&CFTOKEN=12174221>

Título: [Semantic web and language resources for e-government: linguistically motivated data mining](#)
Relevância: ★ ★ ★ ★ ★

Título: [ERkNN: efficient reverse k-nearest neighbors retrieval with local kNN-distance estimation](#)
Relevância: ★ ★ ★ ★ ★

Título: [Adaptive hypermedia for the semantic web](#)
Relevância: ★ ★ ★ ★ ★

Título: [Partnering enhanced-NLP with semantic analysis in support of information extraction](#)
Relevância: ★ ★ ★ ★ ☆

Título: [Neural network based systems for computer-aided musical composition: supervised x unsupervised learning](#)
Relevância: ★ ★ ★ ★ ☆

Figura 3.17. RecSalt — Página Meus Artigos, ao clicar sobre o título do artigo são apresentados seus detalhes, tais como *abstract* e *link*. Fonte: <http://recsalt.com/>

Nas próximas versões do RecSalt pretende-se: (i) estender sua abrangência para outras áreas do conhecimento (ex. Medicina); (ii) inserir uma camada social, na qual os usuários poderão criar grupos, fazer amizades e compartilhar artigos; e (iii) recomendar outros recursos, tais como conferências, co-autorias, entre outros.

3.6. Considerações Finais

Neste capítulo foram apresentados conceitos, técnicas e aplicações em Sistemas de Recomendação de recursos educacionais, com o objetivo de disponibilizar um texto que sirva como base para estudos nessa linha de pesquisa e, por conseguinte, propiciando melhorias no processo de ensino e aprendizagem a partir de novas tecnologias da computação.

Além de conceitos gerais, utilizando referências adequadas para possíveis leituras e aprofundamentos, o texto aborda alguns trabalhos, na área de Sistemas de Recomendação aplicada à Educação, que os autores julgaram interessantes como iniciativas na área. Finalmente, para ilustrar o campo de recomendação de recursos educacionais, foi apresentada a ferramenta RecSalt, cujo enfoque é a recomendação de artigos.

Para pesquisas mais aprofundadas, recomenda-se a leitura de artigos de periódicos e conferências nacionais e internacionais na área de Sistemas de Recomendação, Informática na Educação, e Inteligência Artificial Aplicada à Educação. Em relação a periódicos, é possível destacar o *Informatics in Education* e a *Revista Brasileira de Informática na Educação*. Dentre as conferências, é possível destacar as seguintes: *ACM Recommender Systems Conference*, *International Conference on Artificial Intelligence and Education*, *International Conference on Intelligent Tutoring Systems*, *Simpósio Brasileiro de Informática na Educação*.

A partir deste capítulo, os autores esperam despertar o interesse e ajudar a guiar os primeiros passos em iniciativas na área de Sistemas de Recomendação voltada para a educação, que se mostra promissora e desafiadora.

Referências

- Abel, F., Bittencourt, I. I., Costa, E. B., Henze, N., Krause, D. & Vassileva, J. (2010). Recommendations in Online Discussion Forums for E-Learning Systems. *IEEE Transactions on Learning Technologies (TLT)* 3, no. 2, 165–176.
- Adomavicius, G. & Tuzhilin, A. (2005). Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. In *IEEE Transactions On Knowledge and Data Engineering*, vol. 17, no. 6, p. 734–749.
- Barcellos, C., Musa, D. L., Brandão, A. & Warpechowski, M. (2007). Sistema de Recomendação Acadêmico para Apoio a Aprendizagem. *RENOTE. Revista Novas Tecnologias na Educação*, v. 5, p. 4.
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, Dordrecht, v. 12, p. 4, p. 331–370.
- Cazella, S. C., Nunes, M. A. S. N. & Reategui, E. B. (2010). A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. In *XXX Congresso da Sociedade*

- Brasileira de Computação — Jornada de Atualização em Informática (JAI)*, <http://www.dcomp.ufs.br/~gutanunes/hp/publications/JAI4.pdf>.
- Cazella, S. C., Reategui, E. B., Machado, M. & Barbosa, J. L. V. (2009). Recomendação de Objetos de Aprendizagem Empregando Filtragem Colaborativa e Competências. In *XX Simpósio Brasileiro de Informática na Educação*, <http://www.br-ie.org/pub/index.php/sbie/article/view/1158/1061>.
- Drumond, L. R., Lindoso, A. N. & Girardi, R. (2006). InfoNorma: Um Sistema de Recomendação baseado em Tecnologias da Web Semântica. *Infocomp — Journal of Computer Science*, v.5, n.4, <http://www.dcc.ufla.br/infocomp/artigos/v5.4/art11.pdf>.
- Ferreira, V. F. & Raabe, A. L. A. (2010). LorSys — Um Sistema de Recomendação de Objetos de Aprendizagem SCORM. *RENOTE. Revista Novas Tecnologias na Educação*, v. 8, p. 16, 2010.
- Ferro, M. R. C. (2010). Modelo de Sistema de Recomendação de Materiais Didáticos para Ambientes Virtuais de Aprendizagem. Dissertação de Mestrado, Universidade Federal de Alagoas — Instituto de Computação, Maceió, Alagoas, Brasil.
- Ferro, M. R. C., Junior, H. M. N., Paraguaçu, F., Costa, E. B. & Monteiro, L. A. L. (2011). Um Modelo de Sistema de Recomendação de Materiais Didáticos para Ambientes Virtuais de Aprendizagem. *Anais do XXII Simpósio Brasileiro de Informática na Educação — SBIE 2011*, p. 810–819, Aracaju, PE.
- Huang, A. (2008). Similarity measures for text document clustering. In *New Zealand Computer Science Research Student Conference*, pp. 49–56.
- Manouselis, N., Drachsler, H., Vuorikari, R. & Hummel, H. (2011). Recommender Systems in Technology Enhanced Learning. (F. Ricci, L. Rokach, B. Shapira, & P. B. Kantor, Eds.) *Learning*, Springer US, p. 387-415, <http://www.springerlink.com/index/10.1007/978-0-387-85820-3>
- Moodle (2013). *Moodle Plugins Directory: Recommender*. Disponível em: <https://moodle.org/plugins/view.php?plugin=block_recommender>. Acesso em: 24 set. 2013.
- Morais, C. T. Q. & Franco, S. R. K. (2011). Estudo de Caso de Alertas e Recomendações para Educação a Distância Aplicado em Turmas Heterogêneas. *Informática na Educação: teoria & prática*. Porto Alegre, v. 14, p. 129, 2011.
- Parveen, R., Jaiswa, A. K. & Kant, V. (2012). E-Learning Recommendation Systems – A Survey. *International Journal of Engineering Research and Development*, v. 4, p. 10-12, <http://www.ijerd.com/paper/vol4-issue12/B04121012.pdf>.
- Konstan, J. A., Miller, B. N., Maltz, D., Herlocker, J. L., Gordon, L. R. & Riedl, J. (1997). Grouplens: Applying Collaborative Filtering to Usenet News. *Communications of the ACM*, New York, v.40, n.3, pp. 77-87.
- Magalhães, J., de Souza, C. C., Silva, P., Costa, E., & Fechine, J. M. (2012). Improving a recommender system through integration of user profiles: a semantic approach. In *UMAP Workshops*.

Tang, T. Y. & McCalla, G. I. (2004). Beyond learners' interest: Personalized paper recommendation based on their pedagogical features for an e-learning system. In: *PRICAI*. pp. 301–310.