

UNIVERSIDADE FEDERAL FLUMINENSE
Instituto de Computação

Leandro Neumann Ciuffo

Um Estudo de Caso para Verificar a Suscetibilidade a Incentivos de Avaliadores de Produtos na Web

Niterói
Novembro de 2005

UNIVERSIDADE FEDERAL FLUMINENSE
Instituto de Computação

Leandro Neumann Ciuffo

Um Estudo de Caso para Verificar a Suscetibilidade a Incentivos de Avaliadores de Produtos na Web

Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para obtenção do título de Mestre. Área de concentração: Otimização Combinatória e Inteligência Artificial.

Orientadora:

Prof^a. Ana Cristina Bicharra Garcia. Ph.D.

Niterói, RJ
Novembro de 2005

Leandro Neumann Ciuffo

Um Estudo de Caso para Verificar a Suscetibilidade a Incentivos de Avaliadores de Produtos na Web

Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para obtenção do título de Mestre. Área de concentração: Otimização Combinatória e Inteligência Artificial.

Aprovada em 17 de novembro de 2005.

Banca Examinadora:

Prof^a. Ana Cristina Bicharra Garcia, Ph.D. (Orientadora)
Universidade Federal Fluminense – UFF

Prof^a. Cláudia Lage Rebello da Motta, D.Sc.
Universidade Federal do Rio de Janeiro –NCE/UFRJ

Prof^a. Simone Diniz Junqueira Barbosa, D.Sc.
Pontifícia Universidade Católica – PUC-Rio

Niterói, RJ
Novembro de 2005

Agradecimentos

À **Prof^a. Ana Cristina Bicharra Garcia**, pelo incentivo e orientação.

Aos membros da banca examinadora, **Prof^a Claudia Motta** e **Prof^a Simone Junqueira**, que gentilmente aceitaram participar e colaborar com este trabalho.

Ao **Prof. Luiz Satoru Ochi**, que tão bem me acolheu no programa de Pós-Graduação.

À equipe do sítio **Cinefilia**, por ter compartilhado comigo o entusiasmo do desenvolvimento de um serviço pioneiro.

Ao cinema **Duo Cine Santa Cruz** e às videolocadoras **Cinéfilos Anônimos**, **Imagem Vídeo Show**, **Star Home Vídeo**, **DVD Video Club** e **Vix Vídeo**, por viabilizarem a realização desta pesquisa.

À equipe do FISIOCOMP, em especial ao **Prof. Rodrigo Weber dos Santos** pela compreensão na reta final da produção deste trabalho.

Aos professores da UFJF **Tarcísio de Souza Lima**, **Rubens de Oliveira** e **Raul Fonseca Neto**, que torceram por mim e tiveram participação decisiva na minha caminhada até aqui.

Aos colegas de curso e amigos, em especial aos “irmãos de orientação” **José Luiz Nogueira**, **Cristiano Maciel** e **Alexandre Lopes** e a todos aqueles que ajudaram a testar as primeiras versões do sistema.

Às pessoas que foram a minha família no período em que eu residi em Niterói: **Marcos Ribeiro**, **Luciana Brugiolo**, **Bruno Novelli**, **Juliana Mendes** e **Cristiane Rivelli**.

À **Sandrinha**, que sempre torceu pelo meu trabalho mais do que eu.

À minha irmã **Vivian** e à **Viviane** por terem perdido horas me ajudando a cadastrar 300 filmes no sistema.

Aos meus maravilhosos pais **Amauri** e **Terezinha**, bem como todos os integrantes da família que sentiram minha ausência durante a realização deste curso.

Um agradecimento especial à **Tia Zizinha** pelo investimento em mim no início da minha jornada.

Sumário

Agradecimentos	iv
Sumário	v
Lista de Figuras	viii
Lista de Tabelas	x
Lista de Siglas e Abreviações	xi
Resumo	xii
Abstract	xiii
1. Introdução	14
1.1. Objetivos, Contribuições e Hipóteses do Estudo	18
1.2. Procedimentos	19
1.3. Organização do Trabalho	20
2. Sistemas de Recomendação.....	21
2.1. Estratégias de Recomendação	22
2.2. Coleta de Dados	27
2.2.1. Forma Implícita	28
2.2.2. Forma Explícita	29
2.3. Técnicas Empregadas para Extração das Informações	31
2.3.1. Filtragem Baseada em Conteúdo.....	31
2.3.1.1. Limitações da Filtragem Baseada em Conteúdo	32
2.3.2. Filtragem Colaborativa.....	33
2.3.2.1. Vantagens da Filtragem Colaborativa	40
2.3.2.2. Desvantagens da Filtragem Colaborativa.....	41
2.3.2.3. Problemas da Filtragem Colaborativa	42
2.3.3. Filtragem Híbrida	46
2.4. Conclusões	49

3. Avaliações Desonestas	51
3.1. Comportamentos desonestos.....	52
3.2. Iniciativas para motivar os usuários.....	54
3.3. Sistemas de Reputação.....	55
3.4. Mecanismos para garantir a honestidade das avaliações	59
3.5. Conclusões	61
4. HYRIWYG: How You Rate Influences What You Get	63
4.1. Modelo	64
4.2. Incentivo Indexado pela Qualidade da Avaliação.....	69
5. Estudo de Caso.....	75
5.1. Objeto de Estudo.....	75
5.2. Procedimentos	76
5.2.1. Seleção dos Avaliadores.....	77
5.2.2. Divulgação da Pesquisa	78
5.2.3. Participação das Videolocadoras	78
5.3. Definição das variáveis de medição.....	79
5.4. Instrumento e Coleta de Dados	80
5.4.1. Características do SR	81
5.4.2. Períodos de Coleta de Dados.....	84
5.5. População	85
5.6. Análise dos Dados.....	87
5.7. Conclusões	99
6. Conclusões e Trabalhos Futuros	101
6.1. Contribuições da Pesquisa.....	103
6.2. Limitações	105
6.3. Lições Aprendidas	106
6.4. Trabalhos Futuros.....	111
7. Referências Bibliográficas	112
Anexo A – Lista dos filmes cadastrados no Sistema de Recomendação	A1

Anexo B – Modelagem do Sistema de Recomendação	B1
Anexo C – Interfaces do Sistema de Recomendação	C1

Lista de Figuras

Figura 1 - Características das avaliações submetidas ao SR em 3 diferentes cenários	19
Figura 2 - Lista de recomendação do sítio Americanas.com	23
Figura 3 - Comentários sobre um software disponibilizado para download no sítio Superdownloads.....	24
Figura 4 - Recomendação geral de um filme no sítio IMDb.....	24
Figura 5 - Recomendação de livros no sítio da Livraria Siciliano	25
Figura 6 - Tela do cliente do SR de Músicas para o software iTunes	26
Figura 7 - Funcionamento de um Sistema de Recomendação.....	28
Figura 8 - Customização dos interesses do usuário no sítio da Amazon.com.....	29
Figura 9 - Configuração do perfil de um usuário do sítio MovieLens	30
Figura 10 - Entrada de dados da FC	36
Figura 11 - Distintivos (<i>badges</i>) temporários usados na Amazon.com para auxiliar os clientes a identificar os melhores avaliadores	54
Figura 12 - Reputação de um vendedor do sítio MercadoLivre.....	56
Figura 13 - Reputação de um produto exposto no sítio Epinions	57
Figura 14 - Perfil de um membro do sítio Epinions	58
Figura 15 - Formulário para avaliação de uma transação no sítio MercadoLivre.....	59
Figura 16 - Avaliação de um produto na Amazon.com.....	60
Figura 17 - Esquema básico de utilização do HYRIWYG em um SR.....	65
Figura 18 - Descontos que podem ser obtidos pela usuária Júlia em função da nota atribuída por ela ao produto P.....	67
Figura 19 - Variação do desconto concedido à Júlia para $\alpha = -0,2$	68

Figura 20 - Variação do valor da medida de similaridade entre Júlia e André e entre Júlia e Fábio em função da nota atribuída por Júlia ao produto P	71
Figura 21 - Exemplo de uma lista com três filmes para avaliação.....	82
Figura 22 - Trecho da página que é exibida quando o usuário já opinou sobre todos os filmes listados para sua avaliação.....	83
Figura 23 - Gráfico de Grantt dos períodos de coleta de dados	85
Figura 24 - Distribuição dos usuários cadastrados no SR.....	86
Figura 25 - Perfil dos usuários de Juiz de Fora	88
Figura 26 - Avaliações submetidas pelos usuários de Juiz de Fora durante o período de cada fase	88
Figura 27 - Esparsidade das avaliações dos usuários de Juiz de Fora durante as 3 fases consideradas.....	89
Figura 28 - Esparsidade das avaliações dos últimos 100 usuários de Juiz de Fora cadastrados durante períodos livres de incentivo	90
Figura 29 - Perfil dos usuários de outras cidades.....	91
Figura 30 - Esparsidade das avaliações dos usuários de outras cidades	92
Figura 31 - Avaliação das recomendações geradas pelo sistema	95
Figura 32 - Questionário enviado a todos os usuários que não resgataram o filme recomendado.....	97
Figura 33 - Distribuição das respostas dos usuários.....	97
Figura 34 - Distribuição das notas submetidas pelos primeiros usuários de Juiz de Fora cadastrados.....	108
Figura 35 - Distribuição das avaliações recebidas por cada filme	109

Lista de Tabelas

Tabela 1 -Avaliação de 5 usuários para 5 filmes	37
Tabela 2 -Média aritmética das notas de cada usuário.....	37
Tabela 3 -Matriz de similaridade entre os usuários.....	38
Tabela 4 -Implicações dos valores de α	69
Tabela 5 -Produtos avaliados por André, Fábio e Júlia no SR da loja virtual	70
Tabela 6 -Resumo dos dados analisados - usuários de Juiz de Fora	91
Tabela 7 -Resumo dos dados analisados - usuários de outras cidades.....	93
Tabela 8 -Tempo médio de sessão da primeira página de avaliações	94

Lista de Siglas e Abreviações

B2C	<i>Business-to-Consumer</i>
C2C	<i>Consumer-to-Consumer</i>
CD	<i>Compact Disc</i>
CRM	<i>Customer Relationship Management</i>
CSV	<i>Comma Separated Value</i>
DVD	<i>Digital Video Disc</i>
FBC	Filtragem Baseada em Conteúdo
FC	Filtragem Colaborativa
IMDb	<i>Internet Movie Database</i>
SR	Sistema de Recomendação
WWW	<i>World Wide Web</i>
XML	<i>eXtensible Markup Language</i>

Resumo

O uso de Sistemas de Recomendação (SR) tem se tornado cada vez mais importante no auxílio a usuários na busca por produtos ou informações relevantes em ambientes como a *World Wide Web*. Uma das técnicas mais utilizadas na implementação de um SR é a Filtragem Colaborativa, que infere predileções de um usuário com base na similaridade com outros usuários. Contudo, para que um SR funcione corretamente, é preciso confiar na veracidade das opiniões fornecidas. O mecanismo HYRIWYG propõe um modelo de incentivo para motivar usuários a colaborarem com mais avaliações sobre os itens e, mais importante, tentando garantir a veracidade dessas informações. Este trabalho apresenta o mecanismo HYRIWYG e os resultados de um estudo empírico aplicado ao mundo de recomendações de filmes. Os resultados obtidos mostram os potenciais benefícios de sua utilização.

Abstract

The use of Recommender Systems (RS) has become common in several e-commerce websites. Collaborative Filtering is one of the most popular RS techniques. It infers an user's predilections based on similarity with other users. However, to work correctly, the RS depends on the evaluator's participation with truly opinions. The HYRIWYG mechanism proposes an incentive model to motivate users to contribute with a high number of opinions and, more important, trying to guarantee the truthfulness of the information. In this paper, we present HYRIWYG mechanism and discuss it using an empirical study in the movie evaluation domain. The results highlight the great potential benefits of using this kind of incentive mechanism.

1. Introdução

Diariamente vivemos situações em que é necessário fazer escolhas entre diversas opções disponíveis: seja decidir que artigos ler entre os publicados nos anais de um congresso, que filme alugar ao chegar à locadora no fim da tarde, para qual cidade viajar nas férias, ou mesmo qual sítio acessar entre os milhares listados em uma busca no *Google*.

Freqüentemente perdemos um tempo considerável nesse processo de filtragem e seleção de qual informação, produto ou serviço melhor atenderá nossas expectativas. Isto acontece porque existe uma enorme quantidade de opções de produtos e informações dentre as quais as pessoas podem decidir consumir. Muitas vezes possuímos pouca ou quase nenhuma experiência pessoal para realizar escolhas acertadas.

Uma alternativa comumente utilizada no auxílio a esse processo de escolha é a consulta a revistas, guias especializados, impressos de jornais, entre outras fontes de informação. Entretanto, a oferta desse tipo de material especializado está aumentando tanto que já é comum perdermos tempo escolhendo quais deles devemos consultar. Hoje, somente sobre informática, encontramos nas bancas de revistas mais de 10 títulos nacionais, sem contar os suplementos especializados publicados em cada jornal [54].

Esses impressos são, na verdade, maneiras de se fazer recomendações gerais para um público não personalizado. No entanto, por melhor que seja a fonte de informação consultada pelo consumidor, não devemos esquecer que cada pessoa é única e possui preferências individuais. Um determinado produto, por mais que agrade à maioria de seus compradores, não satisfaz a todos. Essa heterogeneidade de preferências se mostra acentuada em produtos subjetivos, tais como filmes ou canções, por exemplo. Um mesmo filme pode ser idolatrado por

uma pessoa e odiado por outra, independente do filme ter sido premiado com um Oscar, o mais famoso prêmio de cinema do mundo, atribuído pela Academia de Artes e Ciências Cinematográficas de Hollywood.

A popularização cada vez maior do acesso à Internet e o crescimento acelerado da *World Wide Web* também têm contribuído para aumentar a sobrecarga de informações. Originalmente desenvolvida para ser um instrumento de distribuição de conteúdo entre instituições de pesquisa, a Web se transformou em um ambiente democrático onde qualquer pessoa pode expressar livremente suas opiniões. Atualmente, todos podem publicar um texto na Rede ou comercializar produtos on-line. Além disso, empresas têm percebido que precisam investir em presença na Web para se manter competitivas. Esse cenário tem propiciado o aumento constante da quantidade de sítios de comércio eletrônico, jornais, informativos, guia de produtos e diversos outros serviços on-line, tornando cada vez mais difícil para uma pessoa encontrar a informação desejada.

Devido à sua característica de alcance global e à ausência de controle sobre o conteúdo publicado, a Web também está repleta de informações erradas, impróprias, repulsivas e até ilegais. Neste contexto, os Sistemas de Recomendação [43;44;49] surgem como uma alternativa para selecionar, de acordo com os interesses de cada pessoa, as melhores opções. Podem ser definidos como programas que atuam como facilitadores de um processo de escolha, fornecendo boas sugestões de itens (produtos, serviços ou informações) aos seus usuários. Assim, através da geração de recomendações personalizadas, as chances de atender às necessidades das pessoas são maiores.

Uma das técnicas mais utilizadas no desenvolvimento de Sistemas de Recomendação (SR) é a da Filtragem Colaborativa [43;11]. Criada em 1992 por Goldberg D. et al. [22], a técnica baseia-se na análise humana do conteúdo dos itens, que consiste em solicitar aos usuários que avaliem, através da atribuição de uma nota, os itens conhecidos (por exemplo, um texto lido). Essas avaliações são acumuladas e então utilizadas para identificar vizinhanças de usuários que avaliam itens de forma similar, ou seja, usuários com interesses em comum. Uma vez identificadas as vizinhanças, para recomendar um item a um determinado usuário, deve-se procurar aqueles bem avaliados pelos seus vizinhos e que ainda não são conhecidos por ele. Essa técnica possibilita a recomendação de qualquer tipo de produto, mesmo daqueles em que as avaliações são baseadas em critérios predominantemente subjetivos, como músicas e viagens.

Porém, o emprego da Filtragem Colaborativa depende de um número considerável de usuários e de avaliações sobre os itens para que sejam produzidos resultados de boa qualidade. Quanto maior o número de avaliações acumuladas, melhor será a capacidade do SR para fornecer recomendações individuais e personalizadas a cada pessoa. Desta forma, para o bom funcionamento do sistema, é essencial que os usuários dediquem algum tempo fornecendo suas impressões sobre os itens disponíveis para avaliação.

Normalmente, as pessoas não percebem de imediato o benefício que suas avaliações proporcionarão a elas mesmas no futuro. A impressão percebida é a perda de tempo ocasionada pelo preenchimento de formulários eletrônicos. Na falta de incentivos, não existe razão aparente para uma pessoa colaborar através da submissão de suas avaliações, pois essa ação irá beneficiar principalmente aos demais usuários, e não diretamente a pessoa que colaborou.

Além disso, no caso da Filtragem Colaborativa, quanto mais específica e personalizada for uma recomendação, mais o sistema depende de avaliações imparciais e honestas. A fim de promover determinado produto, um grupo de usuários poderá mentir sobre a qualidade do mesmo. Ou um usuário apressado poderá fornecer avaliações aleatórias para o SR.

Nesse contexto, dois problemas mostram-se como desafios para o sucesso de Sistemas de Recomendação que usam a técnica da Filtragem Colaborativa:

- 1) Como motivar os usuários a dedicar tempo no fornecimento de avaliações sobre produtos?
- 2) Como garantir que as opiniões fornecidas sejam verdadeiras?

Para atenuar a incidência desses problemas, uma solução comumente empregada por diversos sítios é a implantação de Sistemas de Reputação [45]. Outra solução proposta na literatura é a adoção de redes de confiança [34;35]. Entretanto, essas soluções demandam alterações nas características originais dos Sistemas de Recomendação. Além disso, dependem de um relacionamento de longo prazo entre os usuários e o sistema para funcionarem de forma adequada.

No estudo de caso apresentado neste trabalho, optamos por utilizar o mecanismo de incentivo HYRIWYG (*How You Rate Influences What You Get*) [16;17], uma nova proposta para combater os problemas relatados acima, mantendo as características originais dos Sistemas de Recomendação.

O emprego do HYRIWYG visa incentivar os usuários a fornecerem um grande número de avaliações verdadeiras ao SR. Isso acontece porque os usuários são recompensados

em função da contribuição de cada um na configuração do mecanismo de inferência do sistema. Quanto maior a contribuição, maior o incentivo acumulado pelo usuário. A veracidade das avaliações é obtida através da aplicação de uma regra que limita o uso dos incentivos recebidos a produtos inferidos pelo SR de acordo com o perfil de interesses do usuário. O perfil é ajustado automaticamente de acordo com as avaliações submetidas. Assim, os usuários são desencorajados a serem desonestos em suas avaliações, pois, caso contrário, podem vir a receber um produto indesejado.

1.1. Objetivos, Contribuições e Hipóteses do Estudo

A principal contribuição deste trabalho é a de investigar a viabilidade do mecanismo de incentivo HYRIWYG em garantir a coleta de informações verdadeiras e em quantidade suficiente para propiciar o correto funcionamento de Sistemas de Recomendação baseados na Filtragem Colaborativa. Também procuramos estudar a sensibilidade do método quando os valores dos incentivos são alterados. Para isso, realizamos um estudo empírico aplicado ao mundo de recomendações de filmes com o objetivo de testar duas hipóteses centrais:

Hipótese 1: O HYRIWYG faz com que a quantidade de avaliações fornecidas ao SR seja maior do que quando nenhum incentivo é concedido aos usuários.

Hipótese 2: O HYRIWYG faz com que as pessoas avaliem mais honestamente do que quando o incentivo concedido é aberto, ou seja, quando o SR não interfere na determinação de quais os itens em que os incentivos podem ser utilizados.

Este trabalho também apresenta como contribuição uma discussão sobre os diversos problemas que ocorrem no universo dos Sistemas de Recomendação e de como o HYRIWYG pode ajudar a atenuar grande parte deles.

1.2. Procedimentos

Com base em uma revisão bibliográfica de trabalhos já publicados [11;24;27;28;40;43;45;50;51;53;57], desenvolvemos um Sistema de Recomendação de Filmes baseado na técnica da Filtragem Colaborativa e o disponibilizamos para uso público em um sítio brasileiro especializado em cinema [9].

Depois, para testar as hipóteses levantadas, coletamos e analisamos os dados referentes à interação dos usuários com o sistema em três diferentes cenários: (i) quando nenhum incentivo foi oferecido aos usuários; (ii) quando oferecemos incentivos abertos, proporcionais à quantidade de avaliações fornecidas ao SR; (iii) quando o mecanismo HYRIWYG foi aplicado. A Figura 1 ilustra os resultados esperados em cada cenário analisado.

	Sem incentivo	Incentivo aberto	HYRIWYG
Quantidade de avaliações			
Veracidade das avaliações			

Figura 1 – Características das avaliações submetidas ao SR em 3 diferentes cenários

Em nossa pesquisa, os incentivos foram convertidos em locações gratuitas de DVDs. Para isso, foi necessária a realização de parcerias com várias videolocadoras para que as locações pudessem ser oferecidas aos participantes do experimento. Ao todo, 565 usuários se cadastraram para utilizar o SR desenvolvido, que dispõe de 300 filmes diferentes para avaliação.

Os resultados alcançados ao longo de 21 semanas de estudos e observações mostram os potenciais benefícios que podem ser obtidos com a aplicação do mecanismo em questão.

1.3. Organização do Trabalho

Este trabalho está organizado da seguinte forma: o Capítulo 2 introduz os Sistemas de Recomendação, enfatizando as técnicas da Filtragem Baseada em Conteúdo e da Filtragem Colaborativa, assim como suas vantagens e desvantagens. No capítulo 3, discutimos sobre as ocorrências de avaliações desonestas em Sistemas de Recomendação. A descrição do mecanismo HYRIWYG é mostrada no capítulo 4. Já no capítulo 5, apresentamos o estudo de caso realizado, bem como a análise e discussão dos dados coletados. Finalmente, no Capítulo 6, resumizamos as principais conclusões obtidas, relatamos as lições aprendidas e apontamos sugestões para trabalhos futuros.

2. Sistemas de Recomendação

Uma recomendação é o ato de sugerir ou indicar alguma coisa a alguém. Frequentemente, pedimos recomendações a pessoas que conhecem nossos gostos pessoais, como amigos e familiares. Também é comum recorrermos a especialistas quando não temos experiência suficiente para tomar uma decisão. Nesse contexto, os Sistemas de Recomendação surgem como uma solução para automatizar esse processo de indicação já bastante conhecido na relação social entre seres humanos [44].

O interesse na pesquisa e desenvolvimento de Sistemas de Recomendação cresce na medida em que a quantidade de informação livre e disponível na *World Wide Web* aumenta. Percebemos que, para encontrar uma simples informação, na maioria das vezes nos deparamos com uma imensa sobrecarga de conteúdo. Mesmo com o auxílio de filtros, levamos muito tempo para encontrar o resultado desejado. Segundo Shardanand e Maes [51], o volume de conteúdos disponíveis ultrapassa a capacidade humana de manipulá-los. Portanto, filtros tornam-se imprescindíveis para nos guiarmos nas informações.

Sistemas de Recomendação podem ser definidos como programas capazes de sugerir itens sob medida para uma pessoa (e.g. livros, músicas, filmes, sítios etc.) com base num conjunto de informações coletadas sobre as preferências pessoais de um grupo de usuários. Em um sistema típico, as pessoas fornecem recomendações como entrada, e o sistema agrega e direciona essas recomendações para os potenciais usuários interessados em recebê-las [41].

Os primeiros trabalhos sobre Sistemas de Recomendação [22;43] visavam à filtragem de conteúdo relevante para os seus usuários, como a seleção de notícias e artigos. Mas em função do aumento das transações de comércio eletrônico na rede mundial de computadores,

os Sistemas de Recomendação também estão sendo utilizados para fazer o “casamento” entre o perfil de preferências de um cliente e os itens de uma loja virtual, de forma que apenas os produtos mais interessantes ao cliente sejam recomendados [54]. Dessa forma, os Sistemas de Recomendação podem ser considerados importantes ferramentas de CRM¹ (*Customer Relationship Management*), utilizados para fidelizar clientes e, conseqüentemente, aumentar a lucratividade das empresas.

Sumarizando, os Sistemas de Recomendação são indicados para ambientes onde existem abundância e diversidade de opções, como em bibliotecas digitais ou grandes sítios de comércio eletrônico, sendo utilizados para recomendar itens dos mais variados tipos, como livros, artigos científicos, filmes, músicas, carros, restaurantes etc.

Existem diversas maneiras de se recomendar um item a um usuário. Inúmeras classificações de sistemas de recomendação foram propostas [48]. Algumas delas consideram a forma como as recomendações são apresentadas aos usuários, outras classificam os sistemas de acordo com a técnica empregada para a geração das recomendações [54]. Nesse capítulo, apresentamos as principais características de um sistema de recomendação discutidas na literatura.

2.1. Estratégias de Recomendação

Dividimos as estratégias de recomendação em duas categorias: gerais e personalizadas. Recomendações gerais são dirigidas a todas as pessoas sem distinção. São exemplos de recomendações gerais:

¹ CRM é o nome dado ao conjunto de técnicas adotadas por empresas para descobrir as necessidades de consumo e comportamentos de seus clientes, a fim de se estabelecer um relacionamento mais duradouro. [12,30]

- **Listas de recomendação:** são facilmente encontradas em revistas e sítios de vendas. Consiste em exibir listas de itens organizadas por tipos de interesses, como os produtos mais vendidos, em oferta e sugestões para presentes. A Figura 2 mostra uma das listas de recomendação utilizadas pelo sítio das Lojas Americanas². No exemplo, são recomendados apenas os CDs lançados recentemente, ordenados pelos mais vendidos no sítio.



Figura 2 – Lista de recomendação do sítio *Americanas.com*

- **Comentários de texto:** os usuários podem escrever comentários sobre os produtos que compraram ou conhecem para que outros usuários tenham acesso às suas opiniões. Essa estratégia de recomendação provê liberdade aos usuários para expressar suas opiniões de diversas formas, sem que haja influência de editores. A Figura 3 ilustra a adoção desta estratégia no sítio Superdownloads³. No exemplo, a opinião de vários usuários sobre um determinado *software* disponibilizado para *download* é exibida para auxiliar os visitantes do sítio a decidirem se devem ou não utilizá-lo.

² <http://www.americanas.com>

³ <http://superdownloads.ubbi.com.br>

Comentários (9 de 14 opiniões foram selecionadas)	
✓	Razoável, porém único (Por lewrydiboy em 14.09.2005 sobre a versão 2005) Há muitas pessoas que corrompem seus dados e os colocam para compartilhar, porém ainda tem o mais vasto conteúdo.
✓	Gostei, recomendo (Por Cadari em 12.09.2005 sobre a versão 2005) Testei todos, esse está bem melhor q outros
✗	nao presta (Por clintondasilva em 12.09.2005 sobre a versão 2005) nao mudou nada do anterior só a propaganda do mercado livre nao é bom o emule é melhor
✗	Voltamos à versão anterior (Por itor em 10.09.2005 sobre a versão 2005) Poxa vida! Se ao menos conecta-se....!
✓	Existe melhores! (Por felipeborela em 09.09.2005 sobre a versão 2005) O programa é bom, ele praticamente foi traduzido com algumas mudanças, mas o kazaa lite k++ ou o resurrection continuam sendo melhores!

Figura 3 – Comentários sobre um *software* disponibilizado para *download* no sítio Superdownloads

- **Avaliações:** os usuários podem submeter avaliações numéricas (nota de 0 a 10) ou binárias (Gostou do produto? Sim/Não) sobre os itens disponíveis no sistema. Geralmente, a média de avaliações recebidas por um item é mostrada para auxiliar o usuário na decisão de compra de um produto. A Figura 4 mostra a média de avaliações de um determinado filme fornecidas pelos visitantes do sítio IMDb⁴, considerado o maior banco de dados on-line sobre cinema.



Figura 4 – Recomendação geral de um filme no sítio IMDb

Um das maiores vantagens das recomendações gerais é a sua facilidade de implementação. Entretanto, essa forma de recomendação pode-se mostrar ineficiente em domínios em que existe heterogeneidade de opiniões, pois cada pessoa é única e possui suas preferências individuais. Um determinado produto, por mais que agrade a maioria de seus compradores, não satisfaz a todos.

⁴ <http://www.imdb.com>

As recomendações personalizadas, por sua vez, levam em consideração as características individuais dos consumidores. Para isso, é necessário que o sistema seja capaz de descobrir os hábitos de consumo e de identificar as preferências pessoais de cada usuário.

São estratégias de recomendações personalizadas:

- **Correlação item-a-item:** são identificados os itens que possuem uma relação de associação com outros itens que o usuário tenha gostado. Um tipo simples de associação é a venda casada, como recomendar uma bola de futebol para o usuário que está adquirindo uma chuteira. Outro tipo mais elaborado de associação, muito comum em sítios de venda, são recomendações na forma “usuários que compraram X também compraram Y”, mostrada na Figura 5. Esse tipo de recomendação exige análise mais profunda em todas as compras realizadas por cada usuário para a identificação dos padrões de consumo.



Figura 5 – Recomendação de livros no sítio da Livraria Siciliano⁵

- **Correlação usuário-a-usuário:** um produto é recomendado para um usuário de acordo com a similaridade entre ele e os outros clientes da loja virtual. O princípio por trás desta estratégia considera o seguinte: se várias pessoas com o mesmo hábito de consumo de um usuário X gostaram de um determinado produto, é bem provável que o usuário X também goste dele. A correlação usuário-a-usuário é adotada na técnica da Filtragem

⁵ <http://www.siciliano.com.br>

Colaborativa, apresentada mais adiante neste capítulo. A Figura 6 mostra um exemplo de recomendação gerada através da similaridade entre o perfil de preferências dos usuários. No exemplo, utilizamos um SR de músicas desenvolvido pela Universidade de Illinois [6]. O sistema opera em conjunto com o *software* iTunes⁶, o mais novo programa da Apple para reproduzir e gerenciar arquivos de áudio. O iTunes permite que seus usuários avaliem as músicas disponíveis em sua lista de reprodução pessoal, chamada de “*playlist*”. Um cliente do SR submete a *playlist* do usuário corrente para um servidor on-line e então realiza a comparação das músicas preferidas de cada usuário para gerar as recomendações. São recomendadas as músicas prediletas dos usuários com gosto musical similar às do usuário que solicitou a recomendação.



Figura 6 – Tela do cliente do Sistema de Recomendação de Músicas para o software iTunes

⁶ <http://www.apple.com/itunes/>

É importante salientar que um mesmo sítio pode adotar mais de uma estratégia de recomendação. Lojas como a Amazon.com e Livraria Siciliano, por exemplo, utilizam listas de recomendação e associação entre itens para recomendar seus produtos.

2.2. Coleta de Dados

Para que um Sistema de Recomendação (SR) recomende produtos de acordo com as preferências individuais de um usuário, é necessário, primeiramente, ter conhecimento sobre quem é este usuário [41]. A forma mais comum de identificação é através de um identificador (*login*) e de uma senha, que são informados manualmente pelos usuários antes de usar o SR. Naturalmente, todos os usuários precisam preencher algum tipo de formulário de cadastro ao utilizar o sistema pela primeira vez. Essas informações ficam armazenadas em um banco de dados no servidor da loja virtual.

Também é possível dispor do recurso de *cookies* para identificar o computador que está utilizando o SR. Entretanto, esse método não é recomendado para casos em que um mesmo computador é utilizado por mais de um usuário, pois inviabiliza a geração de recomendações personalizadas.

Depois de identificar unicamente seus usuários, o SR precisa descobrir os hábitos e as preferências de cada um. Para isso, as interações dos usuários com o sistema são monitoradas e utilizadas para a configuração de um perfil de preferências. É através da análise desse perfil que o sistema gera as recomendações. Em geral, a cada interação de um usuário com o SR, um novo ajuste na configuração do seu perfil é realizado. A Figura 7 mostra o esquema e funcionamento básico de um Sistema de Recomendação. O SR coleta as informações sobre as preferências do

usuário e as adiciona ao seu perfil, que é utilizado pelo sistema para inferir as recomendações mais adequadas para o usuário.




Figura 7 – Funcionamento de um Sistema de Recomendação

Existem basicamente duas formas pelas quais o perfil de um usuário pode ser construído: implícita ou explícita.

2.2.1. Forma Implícita

Nesse tipo de coleta de dados, o usuário não percebe que as informações estão sendo coletadas, ou seja, o sistema é responsável por descobrir automaticamente quais as suas preferências. Um exemplo de obtenção de informações de forma implícita é através da análise do comportamento de um usuário ao visitar um sítio de comércio eletrônico: quais seções ele visita, quais palavras-chave utiliza em suas buscas, quais produtos ele adquire etc. Desta forma, pode-se conhecer as preferências de um usuário sem que ele tenha que dedicar parte do seu tempo fornecendo informações explicitamente ao sistema, o que geralmente é feito através do preenchimento de extensos e cansativos formulários eletrônicos.

É importante salientar que, apesar de não perceber a extração automática de informações, o usuário deve conhecer a política de privacidade adotada pelo sítio e autorizá-lo

previamente a coletar suas informações comportamentais. Entretanto, o receio de não ter o controle das informações que serão coletadas e o medo de ter seus dados utilizados como ativos no processo de negociação com outras empresas, fazem com que muitos usuários não autorizem o sítio a praticar essa forma de coleta.

Além disso, monitorar os hábitos de navegação e analisar o histórico de compras de um usuário pode não ser totalmente confiável. Um cliente pode, por exemplo, comprar um presente para alguém. Desta forma, o presente faz parte da preferência da pessoa presenteada e não do usuário que efetuou a compra.

2.2.2. Forma Explícita

Nessa forma de construção do perfil, o usuário é responsável por declarar espontaneamente suas preferências ao sistema. Normalmente isso é feito pedindo aos usuários para avaliar/selecionar uma lista de itens. A Figura 8 mostra um dos formulários que permitem aos usuários da Amazon.com declarar preferências pessoais. No formulário em questão, o usuário indica quais são seus departamentos prediletos na loja.




Figura 8 – Customização dos interesses do usuário no sítio da Amazon.com

A Figura 9 ilustra outro formulário, desta vez utilizado pelo sítio MovieLens [24] para que os usuários possam registrar suas avaliações pessoais sobre os filmes assistidos.

(hide) Predictions for you ↕	Your Ratings	Movie Information	Wish List
???	Not seen ▾	MASH (a.k.a. M*A*S*H) (1970) DVD VHS info edit details imdb Comedy, Drama, War	☐
★★★	2.5 stars ▾	Star Wars: Episode II - Attack of the Clones (2002) DVD VHS info edit details imdb Action, Adventure, Fantasy, Mystery, Romance, Sci-Fi	☐
★★★★	3.5 stars ▾	Aladdin (1992) DVD info edit details imdb Adventure, Animation, Children, Comedy, Musical	☐
★★★★★	Not seen ▾	Apollo 13 (1995) DVD info edit details imdb Adventure, Drama	☒ 🍌
★★★★★	4.5 stars ▾	Monsters, Inc. (2001) DVD VHS info edit details imdb Animation, Children, Comedy, Fantasy	☐

Figura 9 – Configuração do perfil de um usuário do sítio MovieLens⁷

Apesar da forma explícita permitir melhor customização das preferências, essa forma de coleta de dados exige maior “esforço” e atenção da parte dos usuários. Além disso, muitos usuários não têm paciência para configurar ativamente o seu perfil. Geralmente os usuários querem receber boas recomendações sem ter que realizar “trabalho extra” para isso [54].

Outra questão que merece ser discutida é a mudança de preferências ao longo do tempo. Possivelmente um usuário terá necessidades diferentes no decorrer de sua vida. Por exemplo, uma pessoa possui um conjunto de preferências quando estudante, outro depois de formado, ao se tornar pai etc. Ciclos de moda e evoluções tecnológicas também influenciam as mudanças de preferências. Assim, é importante que os sítios colem constantemente informações sobre as preferências dos usuários, renovando-as depois de certo tempo.

⁷ <http://movielens.umn.edu>

2.3. Técnicas Empregadas para Extração das Informações

Para extrair as informações relativas ao perfil dos usuários e gerar recomendações personalizadas, diferentes técnicas de inteligência artificial podem ser utilizadas, tais como regras de associação, árvores de decisão, sistemas multiagentes, redes bayesianas e raciocínio baseado em casos [17].

Entretanto, as técnicas de filtragem de informação são as mais utilizadas na literatura, em especial a Filtragem Baseada em Conteúdo [11;40;54] e a Filtragem Colaborativa [26;27;28;51]. O funcionamento dessas técnicas é apresentado a seguir.

2.3.1. Filtragem Baseada em Conteúdo

A Filtragem Baseada em Conteúdo (FBC) é utilizada para recomendar itens cujo conteúdo é descrito e analisado automaticamente. O conteúdo de um item pode ser um atributo explícito (ano, autor, tipo de publicação etc.) ou um conteúdo textual (título, resumo, descrição etc). Assim, produtos textuais, como artigos científicos, notícias e páginas web, são os itens mais comuns que podem ser recomendados por esta técnica.

A recomendação de um item é realizada através da comparação de seus atributos com uma lista de palavras-chave que representam o perfil de um usuário. Em um sistema de recomendação de notícias, por exemplo, as palavras-chave das reportagens lidas e/ou bem classificadas por um usuário são acrescentadas ao seu perfil. As palavras recorrentes recebem um peso maior que as outras. Assim, quanto maior a frequência de uma palavra-chave nas reportagens lidas pelo usuário, mais relevante é esta palavra na determinação das recomendações para ele.

A FBC parte do princípio da continuidade de preferências, isto é, se um usuário gostou de um determinado item, ele deve gostar de um item similar no futuro [3]. Desta forma,

para se recomendar um produto/informação, busca-se um item com atributos similares aos definidos no perfil de preferências do usuário, considerando a parametrização feita para descrever seu conteúdo. São recomendados apenas os produtos cuja similaridade calculada atingiu um valor mínimo, que varia de acordo com o perfil de cada usuário [11].

Diferentes técnicas podem ser usadas para calcular a similaridade entre os perfis dos usuários e os produtos [41]. No caso de documentos textuais, em que os atributos podem ser extraídos automaticamente, o texto é pré-processado para a eliminação de *stopwords* e extração do radical das palavras (*stemming*) antes da aplicação de qualquer técnica. *Stopwords* são as palavras que não são importantes na análise do texto, como as conjunções, preposições e artigos. Dependendo do domínio de aplicação, algumas palavras não muito discriminantes podem ser definidas como *stopwords*, como, por exemplo, a palavra “coração” em uma base de dados contendo somente artigos sobre cardiologia.

Como exemplo, considerando um processo de eliminação de *stopwords* e *stemming*, a frase: “Sistemas de Recomendação são uma excelente solução para a sobrecarga de informação na Internet” é transformada no seguinte conjunto de palavras-chave: “sistema recom excel soluc sobrecarga inform Internet” [54]. Essas palavras, então, são automaticamente armazenadas no perfil do usuário quando ele lê e/ou avalia positivamente esse texto.

2.3.1.1. Limitações da Filtragem Baseada em Conteúdo

Quando utilizada na recomendação de textos, a percepção dos usuários sobre a didática ou a qualidade dos documentos não é considerada. Por exemplo: um artigo bem escrito não é diferenciado de um artigo mal escrito se ambos possuírem termos semelhantes [19]. Essa é uma característica subjetiva que não pode ser parametrizada.

O uso da FBC também pode resultar na superespecialização das recomendações, pois, como os produtos são recomendados com base no casamento de atributos, essa técnica tende a recomendar sempre itens semelhantes. Dessa forma, não há espaço para a sugestão de novos produtos que possam ser de interesse do usuário. Além disso, se o atributo de um item não for bem descrito ou muito informativo, as recomendações serão pouco eficientes.

Outro aspecto limitador da FBC é o fato de que o conteúdo dos itens precisa ser legível pelas máquinas. Desse modo, itens cujo conteúdo são difíceis de se estruturar (e.g. filmes, músicas, restaurantes) não podem ser recomendados por essa técnica.

Para tratar dessas limitações, uma outra técnica chamada Filtragem Colaborativa foi criada. Na próxima seção apresentamos em detalhes seu funcionamento.

2.3.2. Filtragem Colaborativa

A Filtragem Colaborativa (FC), também chamada de Filtragem Social, é uma técnica que, como o próprio nome diz, depende da colaboração de todos os usuários do SR para selecionar (filtrar) os itens que são recomendados a um usuário específico.

A essência dos sistemas colaborativos está na troca de experiências entre pessoas que possuem interesses em comum [41]. Segundo Shardanand e Maes [51], esta técnica automatiza o processo de recomendações “boca-a-boca”.

Para ilustrar melhor essa definição, imagine o seguinte cenário: João deseja fazer uma viagem com sua namorada durante um feriado prolongado. Ele já escolheu o destino, mas não sabe onde se hospedar. Nessa situação, a maioria das pessoas pediria opinião a um amigo ou a um membro da família que já tenha viajado para o mesmo lugar. De preferência a alguém que

também tenha viajado com a namorada, ou seja, uma pessoa com interesses semelhantes ao de João. Esse processo é comum no cotidiano das pessoas, pois constantemente recomendamos filmes, livros, bares e inúmeros outros itens a nossos amigos.

Em um SR, para uma pessoa dizer se “gostou” ou não de um determinado item, ela precisa fornecer avaliações numéricas ao sistema. Essas avaliações são expressas na forma de uma nota dentro de um intervalo bem definido (geralmente de 1 a 5 ou de 1 a 7). Quanto maior o número, mais o usuário gostou daquele item. Em alguns sistemas, os números são mapeados em uma escala qualitativa (ruim / razoável / bom / excelente). O conjunto dessas avaliações constitui o perfil de preferências de um usuário, e é através da análise do conjunto desses perfis que o SR pode inferir quais itens serão recomendados a cada pessoa.

É importante salientar que a FC exige que o usuário interaja com o SR de duas maneiras distintas e em tempos diferentes: primeiro como *produtor* - alimentando o sistema com avaliações sobre os itens disponíveis - e depois como *consumidor* - usufruindo das recomendações geradas.

A fim de ilustrar o funcionamento da FC, podemos esquematizar de algoritmo da seguinte forma:

Considere os conjuntos U e I , contendo, respectivamente, todos os usuários cadastrados e todos os itens disponíveis para avaliação em um SR.

$$\begin{aligned} U &= \{u_1, u_2, \dots, u_n\} & |U| &= n \\ I &= \{i_1, i_2, \dots, i_m\} & |I| &= m \end{aligned}$$

Associado a cada usuário, existe um conjunto de itens avaliados por ele. Esse conjunto forma o perfil de preferência do usuário, e pode ser representado por:

$$I_{ur} = \{i_{r1}, i_{r2}, \dots, i_{rq}\} \quad |I_{ur}| = q \quad 0 \leq q \leq m \quad I_{ur} \subseteq I$$

A FC considera a seguinte hipótese: usuários que forneceram avaliações semelhantes no passado tendem a avaliar da mesma forma no futuro. Assim, usuários que possuem opiniões semelhantes sobre os itens consumidos em comum provavelmente terão opiniões parecidas sobre os itens que ainda não consumiram [11].

Dessa forma, para recomendar um item para um usuário específico, chamado de usuário ativo (u_a), primeiro é necessário encontrar os usuários com perfil mais semelhante ao do usuário que deseja receber a recomendação (seus vizinhos mais próximos). Depois, procuram-se os itens bem avaliados por esses vizinhos e que o usuário ativo ainda não tenha avaliado. Como eles “concordaram” sobre os itens consumidos no passado, provavelmente terão opiniões semelhantes sobre os itens ainda não consumidos. Os itens bem avaliados pelos vizinhos e ainda não avaliados pelo usuário ativo serão recomendados.

A forma tradicional de entrada de dados utilizada é uma matriz de avaliações $n \times m$, ilustrada na Figura 10. Cada linha i representa um usuário e cada coluna j um item disponível para avaliação. Apenas os itens representados pelas colunas da matriz podem ser avaliados e, conseqüentemente, recomendados. Cada célula da matriz contém a avaliação atribuída por um usuário i a um item j . As células vazias indicam que o item não foi avaliado pelo respectivo usuário. Na Figura, destacamos o usuário ativo u_a e o respectivo conjunto de itens avaliados por ele.




Figura 10 – Entrada de dados da FC

Para identificar os vizinhos mais próximos ao usuário ativo, diferentes tecnologias podem ser empregadas, como redes Bayesianas e técnicas de clusterização (agrupamento) [46]. Entretanto, algoritmos baseados em métodos estatísticos são os mais comumente utilizados, especialmente os que fazem uso do coeficiente de Pearson, também chamado de coeficiente de correlação produto-momento [20;27;40;43].

Esse coeficiente, bastante utilizado em modelos econômicos, permite medir a “força” do relacionamento entre duas variáveis [54]. Normalmente é representado pela letra “r” e assume apenas valores entre -1 e 1.

Ao ser empregado pela FC, cada conjunto de avaliações é considerado uma variável. Assim, a similaridade entre os usuários é medida selecionando cada conjunto de avaliações e medindo sua relação com todos os demais.

Para facilitar a compreensão do algoritmo da FC e da utilização do coeficiente de Pearson, tomemos o exemplo prático descrito a seguir. A Tabela 1 representa o cadastro de cinco usuários em um Sistema de Recomendação de Filmes. A escala de avaliação utilizada no exemplo é de 0 a 6. As células não preenchidas sinalizam que o filme não foi avaliado pelo usuário.

Tabela 1 - Avaliação de 5 usuários para 5 filmes

	Hulk	Matrix	A Vila	Olga	Tróia
André		2	2	5	
Fábio	6	4	4	2	
Júlia	5	4	3	2	5
Paula			5	4	4
Pedro	4	5	6	3	5

Para recomendar um filme para o usuário Fábio, o sistema deverá procurar qual usuário possui um conjunto de avaliações mais semelhante ao dele, ou seja, qual usuário gostou dos mesmos filmes que Fábio. Ao fazer rápida investigação na matriz, podemos perceber que Júlia é o usuário mais semelhante. Computacionalmente, a medida do grau de correlação de Pearson é a mais utilizada para chegar a essa conclusão. A correlação r entre um usuário a e um usuário b é dada por:

$$r_{a,b} = \frac{\sum (N_{a,f} - \bar{N}_a)(N_{b,f} - \bar{N}_b)}{\sqrt{\sum (N_{a,f} - \bar{N}_a)^2 \sum (N_{b,f} - \bar{N}_b)^2}} \quad (1)$$

onde:

$f \in$ Filmes assistidos pelo usuário a e pelo usuário b ;

$N_{u,f}$ é a nota que o usuário u atribuiu ao filme f . $N_{u,f} \in [0,1,2,3,4,5,6]$

$\bar{N}_u$ é a média aritmética das notas fornecidas pelo usuário u .

Ainda da Tabela 1, podemos gerar um vetor com a média $\bar{N}_u$ das notas de cada usuário u , como é mostrado na Tabela 2.

Tabela 2 - Média aritmética das notas de cada usuário

	André	Fábio	Júlia	Paula	Pedro
Média	3	4	3,8	4,33	4,6

Aplicando o cálculo do grau de correlação (Eq. 1) a cada par de usuários, a matriz apresentada na Tabela 3 é gerada. Agora, para determinar qual é o usuário com perfil mais semelhante ao de Fábio, basta fazer uma busca pelo maior grau de correlação na sua respectiva linha ou coluna na matriz.

Tabela 3 - Matriz de similaridade entre os usuários

	André	Fábio	Júlia	Paula	Pedro
André	1	- 0,816	- 0,618	- 0,8	- 0.943
Fábio	- 0,816	1	+ 0,916	+ 0,447	+ 0,314
Júlia	- 0,618	+ 0,916	1	- 0,176	+ 0,269
Paula	- 0,8	+ 0,447	- 0,176	1	+ 0,754
Pedro	- 0,943	+ 0,314	+ 0,269	+ 0,754	1

O valor de um grau de correlação varia entre -1 e +1. O valor 0 (zero) significa que não há relação linear, o valor +1 indica uma relação linear perfeita (perfis idênticos) e o valor -1 também indica uma relação linear perfeita, porém inversa (perfis completamente opostos) [20;58]. Quanto mais próximo a esses limites for o valor calculado, melhor o SR poderá inferir se os usuários gostarão ou não de um determinado filme. Um grau de correlação com valor próximo a zero, como entre Paula e Júlia, não permite ao sistema recomendar filmes com qualidade.

Analisando a matriz gerada, podemos notar que André e Pedro possuem gostos muito diferentes, ou seja, André gosta dos filmes que Pedro não gosta. Embora a relação linear inversa também possa ser utilizada pelo sistema para gerar recomendações, em nosso trabalho não consideramos os graus de valores negativos, i.e., apenas valores entre 0 e +1 foram considerados.

Uma vez calculada a similaridade entre os usuários, o próximo passo do algoritmo da FC é determinar as vizinhanças. Basicamente, há duas formas de se determinar vizinhanças: *similaridade e número de vizinhos* [26].

- **Similaridade:** nesse método, determina-se um grau de correlação mínimo, e todos os usuários que tiverem um grau de similaridade maior ou igual ao limiar estabelecido são incluídos na vizinhança do usuário ativo. A desvantagem é que existe possibilidade de serem geradas vizinhanças com poucos ou nenhum usuário. No exemplo apresentado, se considerarmos que o limiar é 0,4, os vizinhos de Fábio são Júlia e Paula.
- **Número de vizinhos:** nesse método é estabelecido um número **k** máximo de usuários vizinhos, independente de um valor mínimo para o grau de correlação. Assim, os **k** vizinhos mais próximos são selecionados. No exemplo apresentado, se definirmos que o número de vizinhos deve ser igual a 3, os vizinhos de Fábio são Júlia, Paula e Pedro. Esse método pode garantir que a vizinhança conterá um número suficiente de usuários, mas não um elevado grau de correlação entre eles. A inclusão de usuários com baixa similaridade na vizinhança pode introduzir ruído na hora de gerar as recomendações [54].

Depois de estabelecida a vizinhança, o último passo do algoritmo é a geração da recomendação. Os itens recomendados a um usuário são aqueles que possuem maior valor de predição, ou seja, aqueles para os quais há uma maior probabilidade de receber uma alta avaliação do usuário, caso ele o consuma.

O valor da predição $p_{a,i}$ do item **i** para o usuário ativo **a** pode ser calculada por meio de uma média ponderada das avaliações dadas ao item **i** pelos vizinhos de **a** [41;43]. Esse cálculo é mostrado na equação 2.

$$p_{a,i} = \bar{N}_a + \frac{\sum_{u=1}^n N_{u,i} - \bar{N}_u * r_{a,u}}{\sum_{u=1}^n |r_{a,u}|} \quad (2)$$

Considerando que a vizinhança foi determinada pelo método da similaridade em nosso exemplo, a suposta nota atribuída por Fábio ao filme Tróia seria:

$$p_{Fábio, Tróia} = 4 + \frac{(5 - 3,8) * 0,916 + (4 - 4,33) * 0,447}{|0,916| + |0,447|} \cong 4,7$$

De acordo com os cálculos, caso Fábio tivesse assistido ao filme “Tróia”, provavelmente ele avaliaria esse filme com a nota 4,7 (em uma escala de 0 a 6). A ocorrência de valores fracionários é comum no cálculo da predição. Os itens com maior valor calculado devem ser recomendados ao usuário ativo. A escolha de qual deve ser o valor mínimo previsto para se recomendar um item é determinada por cada sistema de recomendação que utiliza a filtragem colaborativa. Em nosso exemplo, podemos considerar que filmes com avaliações previstas maiores ou iguais a 4 podem ser recomendados.

2.3.2.1. Vantagens da Filtragem Colaborativa

Ao contrário da FBC, que foca nas características dos produtos, as recomendações geradas pela FC baseiam-se nas características das pessoas, e não na análise de conteúdo executada por *softwares* [28]. Isso permite a aplicação da técnica da FC em qualquer domínio de conhecimento, não exigindo esforços de classificação de itens ou descrição de conteúdos. Assim, qualquer tipo de item pode ser recomendado de forma automática, sejam livros, artigos, filmes [24], canções [50], videogames [42], restaurantes [42] ou até mesmo piadas [31].

O que caracteriza a maior vantagem da FC é a capacidade de se recomendar um item baseado nas análises subjetivas de cada usuário, expressadas por meio de avaliações

positivas ou negativas, de acordo com o “gosto” de cada pessoa. Assim, o SR é capaz de gerar recomendações boas e inesperadas [54;28]. Para exemplificar essa situação, imagine dois clientes de um sítio de comércio eletrônico que possuam perfis muito semelhantes em virtude de um gosto em comum por CDs de música clássica e por livros esotéricos. Se um dos clientes avaliar bem um livro de suspense, esse livro pode ser recomendado ao outro cliente, mesmo que histórias de suspense não façam parte de suas preferências.

Outra vantagem da FC é a alteração freqüente das vizinhanças. Isso acontece porque toda vez que um usuário fornece uma avaliação, seu perfil é atualizado. Assim, cada vez que uma recomendação é requisitada, a matriz de similaridade precisa ser recalculada. Conseqüentemente, um usuário pode ter uma vizinhança determinada na parte da manhã e outra determinada na parte da tarde, fazendo o SR gerar recomendações diferentes em cada momento.

2.3.2.2. Desvantagens da Filtragem Colaborativa

Para gerar a matriz de similaridade usando o coeficiente de Pearson, é necessário calcular o grau de correlação entre todos os pares de usuários possíveis. Assim, em um sistema com **n** usuários cadastrados, é necessário efetuar o cálculo do grau de correlação $\sum_{x=1}^{n-1} x$ vezes. Além disso, para cada correlação calculada, o algoritmo precisa efetuar uma busca na matriz de avaliações para determinar quais foram os itens avaliados por ambos os usuários.

Como a vizinhança deve ser gerada para cada pedido de recomendação, a FC requer bastante capacidade de processamento em virtude de seu custo computacional. Se imaginarmos o sistema de recomendação de um grande sítio de vendas on-line, com milhares de clientes e milhares de produtos comercializados, o uso dessa técnica pode gerar um sério

problema de escalabilidade. Assim, o que descrevemos na seção anterior com sendo uma das vantagens da FC também representa uma de suas maiores desvantagens.

Diversos trabalhos presentes da literatura [11;26;27;46;51] se concentram na discussão de novas técnicas e algoritmos para tentar reduzir esse alto custo computacional e diminuir a sobrecarga do servidor que calcula as recomendações. Entretanto, essas questões tornam-se menores quando pensamos na viabilidade de aplicarmos o método propriamente dito. Entendemos que outros tipos de problemas, inerentes às questões de desempenho, podem ser mais prejudiciais ao bom funcionamento de um SR, como os referentes à quantidade e qualidade das informações submetidas. Esses problemas são apresentados na próxima seção.

2.3.2.3. Problemas da Filtragem Colaborativa

Apesar de seu grande potencial, a FC pura se mostra muito vulnerável. A capacidade dessa técnica em gerar boas recomendações depende fortemente da interação dos usuários com o sistema. De nada adianta a tecnologia utilizada na implementação de um SR se os usuários não forem motivados a alimentar o sistema com avaliações sobre os itens consumidos.

Apresentamos a seguir os principais problemas enfrentados pelos Sistemas de Recomendação que utilizam a FC:

1. O problema da Matriz Esparsa:

No mundo real, a matriz de dados utilizada pelo SR de um grande sítio de comércio eletrônico deve possuir milhares de itens e milhares de usuários cadastrados no sistema. Estima-se que na *Amazon.com* existam mais de 3 milhões de itens. Logo, para consumir 0,1% dos produtos, é necessário que um usuário compre 3000 produtos [54].

Normalmente, os usuários só avaliam um pequeno subconjunto de todos os itens disponíveis para avaliação, resultando numa matriz esparsa de avaliações, ou seja, uma matriz com um grande número de células vazias. Segundo Massa e Bhattacharjee [35], a base de dados disponibilizada pelo sítio *MovieLens* [24] é 95,8% esparsa.

Em virtude dessa esparsidade, torna-se difícil encontrar bons vizinhos devido ao baixo número de itens avaliados em comum pelos usuários. Assim, a utilização do coeficiente de Pearson pode gerar medidas de similaridade não muito confiáveis.

Os Sistemas de Recomendação recém criados são os que mais sofrem com este problema, uma vez que possuem poucos usuários cadastrados e, conseqüentemente, poucas avaliações fornecidas. A aplicação de métodos para redução da dimensionalidade dos dados é apresentada como uma proposta para reduzir a esparsidade da matriz [60]. Contudo, informações potencialmente úteis podem ser perdidas durante o processo de redução [59]. Trabalhos recentes [35;59] sugerem a adoção de redes sociais para aumentar o volume de dados utilizado pelos SRs através da exploração da transitividade entre usuários semelhantes.

2. O problema da Primeira Avaliação:

Uma vez que a FC utiliza as avaliações dos usuários para gerar as recomendações, um determinado produto, por melhor que seja, jamais poderá ser recomendado se nenhum usuário fornecer avaliações sobre ele [41]. Esse problema afeta principalmente os novos itens cadastrados no sistema, como os produtos recém lançados em uma loja [54]. Isso acontece porque não é possível recomendar itens que ainda não tenham sido avaliados.

Para que novos produtos não deixem de ser recomendados, é comum os sítios adotarem mais de uma estratégia de recomendação. A adoção de abordagens híbridas que combinam as técnicas da FC e da FBC também são uma alternativa para a minimização deste problema [61].

3. O problema da Partida a Frio (*cold start problem*):

O algoritmo da FC é incapaz de computar recomendações para os usuários que não avaliaram nenhum item, pois, para medir a similaridade entre o perfil de dois usuários quaisquer, é necessário que ambos tenham avaliado um certo número de filmes em comum.

A solução de praxe utilizada nesse caso é definir um número mínimo de avaliações que um usuário precisa realizar para que o sistema seja capaz de gerar as primeiras recomendações. Nos sistemas *MovieLens* [24], *Jester* [31] e *Rating Zone* [42], são exigidas pelo menos 15 avaliações para o sistema entrar em funcionamento. Os usuários que avaliam quantidade de itens menor que a quantidade mínima estabelecida são chamados de “usuários frios” (*cold start users*).

4. O problema do Falso Bom Vizinho:

Se a quantidade mínima de avaliações exigidas pelo sistema for muito baixa (quatro, por exemplo), poderão ser encontrados com frequência perfis com similaridade igual a 1 (perfis idênticos). Porém, o fato de dois usuários terem avaliado quatro itens com as mesmas notas não significa necessariamente que esses usuários possuem gostos semelhantes. Pode ter sido apenas uma coincidência.

Em contrapartida, se dois usuários que avaliaram mais de 30 itens em comum possuem um grau de correlação igual a 0,7, a relação de similaridade entre seus perfis é, aparentemente, mais confiável.

Uma solução para este problema é atribuir um peso a cada coeficiente de similaridade, de tal forma que se a quantidade de produtos avaliados em comum por dois usuários for pequena, o valor do grau de similaridade é reduzido [54].

5. O problema da ovelha negra (*Gray Sheep*):

Em alguns casos pode não ser possível encontrar vizinhos para um usuário. Normalmente isso acontece com pessoas que possuem hábitos de consumo ou opiniões que divergem dos outros usuários [10]. Quanto menor o número de usuários que colaboram com o sistema, maior é a frequência de ocorrência desse tipo de problema.

6. O problema da falta de motivação:

Muitos usuários não têm paciência para fornecer avaliações sobre todos os itens consumidos [53]. Exigir que um usuário avalie grande quantidade de itens para começar a receber as recomendações pode provocar desestímulo à utilização do SR. Em geral, os usuários querem simplesmente receber as recomendações sem ter que realizar muito esforço para isso.

Para motivar os usuários, alguns sítios oferecem formas de compensação monetárias em troca de avaliações [18] ou concedem selos que elevam a reputação dos avaliadores mais participativos. Essas soluções são discutidas no próximo capítulo.

7. O problema das pessoas mal intencionadas (*Shilling Effects*):

Trabalhos recentes têm reportado formas de ataques a Sistemas de Recomendação [7;32;35]. Esses trabalhos relatam a existência de usuários maliciosos capazes de influenciar as recomendações geradas pelo sistema. Mais especificamente, um ataque simples, porém efetivo, pode ser descrito como segue: imagine um usuário malicioso que deseja influenciar o SR a recomendar um produto X fabricado por sua empresa. Esse usuário pode criar vários cadastros falsos e avaliar os itens disponíveis de maneira similar ao que ele espera que o consumidor-alvo de seu produto avalie. Desta forma, ele estaria implantando no sistema perfis semelhantes aos dos usuários para os quais ele planeja recomendar seu produto. Feito isso, para cada falso usuário criado, basta ele avaliar com a maior nota possível o produto que ele deseja recomendar. Assim, quando o SR for correlacionar os usuários, existirá grande probabilidade de um dos falsos usuários ser vizinho do usuário que solicitou recomendação. Provavelmente o produto X será recomendado a esse usuário.

Entretanto, a existência desses ataques exige que o usuário malicioso tenha conhecimento do processo de geração das recomendações. Por esse motivo, muitos sítios não revelam como suas recomendações são geradas.

2.3.3. Filtragem Híbrida

Cada uma das técnicas de filtragem apresentadas possuem suas vantagens e desvantagens. Algumas são melhores que outras quando aplicadas em diferentes domínios. Sistemas que combinam as técnicas da FBC e FC são chamados de sistema de filtragem híbrida [3;41]. Essa

estratégia procura combinar os pontos fortes de cada técnica visando criar sistemas mais eficientes, uma vez que suas vantagens e desvantagens são complementares umas às outras [54].

De acordo com [62], duas ou mais técnicas de extração de informações podem ser combinadas para se construir sistemas de recomendação híbridos. Apresentamos a seguir os sete métodos de hibridização de acordo com a taxonomia proposta por [62]. A classificação leva em consideração apenas o modo como as técnicas podem ser combinadas, independente de quais sejam.

1. Ponderado (*Weighted*):

A similaridade de um item é calculada a partir da combinação dos resultados de todas as técnicas utilizadas pelo sistema, cada uma com um peso diferente. O peso atribuído a cada técnica pode ser alterado ao longo do ciclo de vida do sistema. Por exemplo, o peso atribuído aos resultados gerados pela FC pode ser reduzido para minimizar a influência do problema da primeira avaliação.

2. Alternado (*Switching*):

O sistema estabelece um critério para alternar a técnica utilizada para gerar as recomendações. Esse método introduz uma complexidade adicional ao processo de recomendação, uma vez que o critério de alternância precisa ser determinado, acrescentando mais um nível de parametrização.

3. Misto (*Mixed*):

Recomendações geradas por mais de uma técnica são apresentadas em uma mesma lista. Pode-se utilizar algum tipo de arbitragem entre as técnicas para determinar a ordem em que os resultados são apresentados.

4. **Combinação de Características (*Feature Combination*):**

Os resultados das diferentes técnicas de recomendação são utilizados como dados de entrada em um único algoritmo de recomendação. Todavia, a combinação de muitas técnicas pode afetar a precisão das recomendações.

5. **Cascata (*Cascade*):**

Uma técnica de recomendação é primeiramente empregada para produzir um conjunto de itens candidatos à recomendação. Em seguida, utiliza-se uma segunda técnica para refinar os resultados da primeira. Uma das desvantagens desse método é que os problemas existentes na primeira técnica persistem, não sendo atenuados pelo emprego da segunda.

6. **Aumento de Características (*Feature Augmentation*):**

As recomendações geradas por uma técnica são incorporadas ao processo de recomendação de outra. O acréscimo de informações objetiva melhorar o desempenho da segunda técnica utilizada, mas assim como no método em cascata, a escolha da primeira técnica influencia os resultados obtidos pela segunda.

7. ***Metal-level*:**

O modelo de uma técnica de recomendação é utilizado como informação de entrada para outra técnica. Diferentemente do método anterior, onde apenas as recomendações geradas por um modelo são utilizadas como entrada de dados, neste método todo o modelo é combinado e empregado no processo de recomendação.

Em geral, o emprego de um dos métodos de hibridização apresentados acarreta na construção de sistemas consideravelmente mais complexos. Adicionalmente, a maioria das

aplicações que implementam abordagens híbridas combinam a técnica da FC com alguma outra técnica na tentativa de eliminar os problemas relacionados à quantidade de itens avaliados pelos usuários [62].

2.4. Conclusões

Como as recomendações gerais não consideram as preferências individuais de cada pessoa, as recomendações personalizadas têm mais chance de satisfazer as necessidades dos usuários. Todavia, para implantar esse tipo de recomendação, é necessário que cada usuário possua um perfil de preferências armazenado no sistema, pois é baseado nas informações contidas nesses perfis que o SR é capaz de recomendar itens sob medida.

Dentre as recomendações personalizadas, as técnicas de correlação usuário-a-usuário são as que apresentam menor restrição quanto ao domínio de aplicação. Como as recomendações são baseadas nas avaliações que os usuários provêm, qualquer tipo de item pode ser recomendado. No entanto, inerente à questão da tecnologia utilizada, motivar os usuários a colaborarem com o sistema através da configuração explícita de seus perfis é de suma importância.

Essa questão se torna evidente ao analisarmos os problemas da Filtragem Colaborativa discutidos na seção 2.3.2.3. A maioria dos problemas relatados estão relacionados com a quantidade de avaliações fornecidas. Dessa forma, incentivar as pessoas a alimentarem o SR com o maior número possível de avaliações é fundamental para minimizar a ocorrência desses problemas.

Sem o oferecimento de incentivos, aparentemente não existem razões para um usuário despender seu tempo numa tarefa que beneficiará, principalmente, os demais usuários do sistema. Uma solução para motivar os usuários é oferecer brindes ou algum tipo de compensação monetária de forma proporcional à quantidade de avaliações submetidas. Entretanto, simplesmente motivar os usuários a avaliarem uma maior quantidade de itens não garante a veracidade das avaliações. O usuário pode vir a ser recompensado simplesmente porque avaliou muitos itens, mesmo não sendo honesto em suas avaliações.

Assim, ao passo que essa abordagem soluciona os problemas relacionados à quantidade de avaliações, ela favorece a ocorrência de falsas avaliações. Em ambientes colaborativos, um conjunto de opiniões equivocadas pode ser tão prejudicial quanto a ausência delas, pois influenciará na qualidade e acurácia das recomendações geradas pelo SR.

No próximo capítulo discutimos algumas soluções propostas na literatura para combater a ocorrência de avaliações desonestas em Sistemas de Recomendação.

3. Avaliações Desonestas

Sistemas de Recomendação são filtros que auxiliam usuários a encontrar informações relevantes, de acordo com a perspectiva de cada um. Conforme discutimos no capítulo anterior, a geração de recomendações personalizadas, em especial através da técnica da FC, depende do acúmulo de avaliações fornecidas pelos consumidores das recomendações.

Em geral, é assumido que toda informação submetida é verdadeira. Entretanto, não podemos fazer tal suposição. A fim de promover ou prejudicar determinado produto, um usuário pode deliberadamente fornecer falsas avaliações ao sistema. Ataques de usuários maliciosos a Sistemas de Recomendação são reportados em diversos trabalhos [7;13;32;34].

Além das avaliações deliberadamente desonestas, existem aquelas que são aleatórias, fornecidas por usuários que não entendem (ou não se importam) em como o processo de recomendação é gerado [16;52;53]. Apesar dos benefícios obtidos com o fornecimento de informações que ajudarão a configurar o mecanismo de inferência do sistema, muitos usuários não percebem este ganho no momento em que submetem suas avaliações. O que esses usuários percebem é a perda do seu tempo na realização de uma tarefa muitas vezes considerada cansativa. Assim, o interesse desses usuários é o de atuar apenas como *consumidor* de recomendações, não se esforçando em desempenhar seu papel de *produtor* de informações.

Um conjunto de avaliações equivocadas ou fraudulentas pode ser tão prejudicial quanto a ausência de avaliações. Imagine um cliente que não ficou satisfeito com um produto sugerido por uma loja, ou uma pessoa que detestou um filme que lhe fora recomendado. Esses usuários perderão a credibilidade no SR e deixarão de usá-lo. Mais que isso, a imagem da empresa que disponibilizou o serviço é prejudicada. Essa é uma questão muito grave, pois

convencer um usuário a retornar a um sítio é mais difícil do que atraí-lo para uma primeira visita. O mesmo acontece para clientes de uma loja, em que fidelizar um cliente é mais importante do que realizar uma única venda. Desta forma, o que deveria ser um instrumento para fidelizar clientes e transformar navegadores em compradores acaba atuando de forma contrária ao esperado, provocando queda nas vendas.

3.1. Comportamentos desonestos

Ekström, Garcia e Björnsson [16;17] identificaram quatro razões principais para a ocorrência de comportamentos desonestos. São elas:

- **Interesses especiais:** algumas pessoas podem ter interesses especiais em avaliar um determinado item. Por exemplo: um autor pode pedir aos seus familiares para opinarem sobre o seu mais recente livro no sítio de uma livraria virtual; ou então, o dono de uma fábrica pode pedir aos seus funcionários para avaliarem positivamente todos os produtos fabricados por eles.
- **Medo de ser mal avaliado:** esse comportamento é comum em sítios de leilões, em que as pessoas avaliam umas as outras. Por exemplo: ao concluir uma transação, geralmente é solicitado ao comprador avaliar a atuação do vendedor e vice-versa. Neste tipo de sítio, muitos usuários desempenham ambos os papéis: o de comprador e o de vendedor de mercadorias. Dessa forma, muitas pessoas concedem avaliações positivas apenas para receberem boas avaliações em troca. Esses usuários estão preocupados em manter sua boa reputação, não se importando com o mecanismo de reputação do sítio como um todo. Esse tipo de comportamento faz com que o sistema fique sobrecarregado de avaliações positivas, fornecendo recomendações ineficientes.

- **Manter a vantagem competitiva:** um vendedor pode solicitar a um grupo de amigos que o avaliem positivamente para aumentar sua reputação. Conseqüentemente, esse vendedor poderá aumentar seu volume de vendas e/ou o preço das mercadorias comercializadas. Por outro lado, um grupo de compradores pode se unir e criar falsos usuários para avaliar negativamente um determinado fornecedor, forçando-o a não aumentar o preço de suas mercadorias. Um vendedor também pode solicitar a um grupo de amigos que avaliem negativamente outro vendedor, fazendo diminuir a competitividade do concorrente. Assim como no item anterior, esses comportamentos ocorrem, predominantemente, em sítios que promovem o livre comércio entre seus usuários, chamados de portais C2C (*Consumer-to-Consumer*).
- **Não contribuir para ações coletivas:** a identificação do problema do “carona” (*free rider*) é uma das maiores preocupações no desenvolvimento de sistemas de recomendação. Como vimos, para que um SR possa gerar recomendações acuradas, os avaliadores precisam fornecer avaliações honestas e imparciais ao sistema. Um usuário que alimenta o sistema com avaliações escassas ou mal-intencionadas se beneficiará das avaliações fornecidas pelos outros usuários sem contribuir para o bem comum. Muitas vezes o usuário não percebe que seu comportamento é prejudicial ao sistema. Formulários de avaliações extensos tornam a tarefa de configurar o perfil de preferências muito cansativa. Para não perder tempo nessa tarefa, é comum os usuários fornecerem avaliações aleatórias ou constantes (avaliar todos os itens com uma mesma nota). Quanto mais exaustiva for a forma de coleta de dados, maiores as chances desse problema ocorrer.

3.2. Iniciativas para motivar os usuários

Sítios pioneiros no uso comercial de Sistemas de Recomendação, como a Amazon.com, Epinions e eBay, possuem hoje anos de experiência. Para incentivar seus usuários a colaborarem com os respectivos SRs, diferentes formas de incentivo são utilizadas.

Na Amazon.com, os usuários são classificados de acordo com a utilidade da avaliação fornecida. Assim, os avaliadores que almejam reconhecimento da maior loja virtual do planeta são motivados a contribuir com avaliações de qualidade. Os usuários que se destacam recebem distintivos, que são exibidos junto ao seu nome na página “About You” [1]. A maioria dos distintivos é temporária. Assim, para manter o *status* conquistado, os avaliadores precisam continuar colaborando com o sistema continuamente. A Figura 11 mostra os distintivos temporários que podem ser concedidos aos membros da Amazon.com. Essa estratégia incentiva os usuários a colaborarem constantemente com avaliações de qualidade sobre os produtos em troca do reconhecimento da comunidade.



Figura 11 – Distintivos (*badges*) temporários usados na Amazon.com para auxiliar os clientes a identificar os melhores avaliadores

O sítio Epinions [18], que reúne opiniões de usuários sobre os mais diversos tipos de produtos e serviços, oferece crédito na forma de *Eroyalties* para todos os usuários que contribuírem com avaliações que ajudarão outros usuários a tomar decisões de compra. Os *Eroyalties* adquiridos são convertidos em dinheiro através de um programa de divisão de parte dos lucros obtidos pelo sítio mensalmente. O sítio ainda adverte que os incentivos não estão relacionados com a compra de um produto, podendo um usuário ser recompensado tanto por

submeter avaliações positivas quanto negativas, desde que elas ajudem o cliente a tomar uma decisão.

O Epinions também faz uso de uma rede de confiança (*web-of-trust*), que é utilizada para indicar quem confia em quem. O usuário que gostar das avaliações fornecidas por outro usuário pode adicioná-lo em sua rede de confiança. A construção desse tipo de rede ajuda o SR a inferir sugestões para seus usuários baseadas nas avaliações das pessoas que cada um confia. Em contrapartida, um usuário também pode criar uma lista de bloqueio para desconsiderar a opinião de algumas pessoas. Assim, as avaliações fraudulentas ou desonestas poderão afetar a reputação do usuário perante as pessoas que confiam nele. Conseqüentemente, suas opiniões poderão não ser consideradas para ajudar essas pessoas a tomarem decisões.

No eBay, assim como em outros sítios de leilões, como MercadoLivre e Arremate.com, não existem incentivos diretos para motivar os usuários a submeterem avaliações. A própria organização natural desses sítios, onde compradores também atuam como vendedores, faz com que seus usuários se conscientizem da importância das avaliações na construção da reputação de cada um. A seguir, apresentamos o funcionamento dos Sistemas de Reputação, muito utilizados nesses tipos de sítio.

3.3. Sistemas de Reputação

Além de ser a maior fonte de disseminação de informação do planeta, a Web também é utilizada para promover a comunicação entre pessoas. A interação entre quem não se conhece em Fóruns, Blogs, sítios de relacionamento e de leilões, por exemplo, tem se tornado cada vez mais freqüente. Nesse contexto, existe o risco iminente de nos depararmos com pseudoprofissionais ou pessoas desonestas e mal-intencionadas.

Uma solução para reduzir o risco associado à perda da noção de confiança entre as pessoas no ambiente da WWW é o desenvolvimento de Sistemas de Reputação [45]. Esses sistemas têm se mostrado peças-chave de sítios que permitem aos seus usuários expressarem livremente opiniões.

No mundo real, nossas decisões sobre confiar ou não numa determinada pessoa ou empresa baseiam-se em nossas experiências passadas. Uma relação de confiança é construída na medida em que as pessoas ou entidades interagem entre si ao longo do tempo.

Os Sistemas de Reputação tentam reproduzir essa percepção natural dos seres humanos. A experiência adquirida da interação entre duas pessoas é representada pela avaliação mútua entre as partes. Por exemplo: após a conclusão de uma transação realizada através de um sítio de leilões, o comprador deve avaliar a performance do vendedor, e vice-versa. O conjunto das avaliações que um usuário recebe constitui sua reputação no sistema. Conhecer a reputação dos usuários nos permite analisar suas experiências anteriores para nos auxiliar a tomar decisões inteligentes de compra ou venda. A Figura 12 mostra um exemplo de reputação de um vendedor do sítio MercadoLivre. As estatísticas sobre passado de negociações do vendedor apresentadas na Figura auxiliam o usuário comprador a tomar uma decisão de compra.

Resumo das qualificações					
Pontos:	120	Qualificações Recebidas	Últimos 7 dias	Último Mês	Últimos 6 meses
Qualificações Positivas:	136 (89%)	+ Positiva	16	25	138
Qualificações Negativas:	16 (11%)	● Neutra	2	4	20
Estas qualificações são de usuários únicos.		- Negativa	2	2	16
Total de qualificações positivas:	137	Negociações Realizadas	Últimos 7 dias	Último Mês	Últimos 6 meses
Total de qualificações negativas:	16	Produtos Vendidos	53	106	386
Aprenda mais sobre esses números		Produtos Comprados	1	3	3

Figura 12 – Reputação de um vendedor do sítio MercadoLivre

Além dos sítios de leilões, portais que divulgam ou comercializam produtos também fazem uso de sistemas de reputação para tentar aumentar o comprometimento dos usuários que avaliam os produtos expostos. Nesses sítios, tanto os usuários quanto os produtos possuem uma reputação. A Figura 13 mostra a reputação de um produto exposto no sítio *Epinions*. A reputação do produto é formada pela média das avaliações submetidas pelos usuários que o avaliaram.



Figura 13 – Reputação de um produto exposto no sítio Epinions

O visitante do sítio também tem acesso à avaliação individual realizada por cada membro da comunidade, bem como sua respectiva reputação. Assim, cabe ao consumidor decidir se confiará ou não nas informações submetidas pelos avaliadores.

Para atestar ainda mais uma reputação, é comum os sítios exibirem etiquetas junto ao perfil do avaliador informando se o mesmo se cadastrou utilizando seu nome real (confirmado pela operadora do cartão de crédito) ou se o avaliador é especialista em algum determinado assunto. A Figura 14 mostra parte do perfil de um avaliador cadastrado no sítio Epinions. No exemplo, o usuário é considerado consultor e um dos mais ativos avaliadores da categoria

software. Além disso, o usuário é membro da comunidade desde dezembro de 1999. Todas essas informações contribuem para aumentar a confiança associada a este avaliador.

happy2000usa's Profile



About happy2000usa
ADVISOR in [Software](#)
TOP REVIEWER in [Software](#)
Member: **Wayne Arnold**
Epinions.com ID: **happy2000usa**
Location: **Tracy, California, USA**
Member Since: **Dec 16 '99**
Homepage: <http://www.booksunbound.com/bspd.html>

Activity Summary
Reviews Written: **97**
Member Visits: **8,796**
Total Visits: **105,846**

Figura 14 – Perfil de um membro do sítio Epinions

Porém, para que um Sistema de Reputação seja implantado, é necessário que exista um relacionamento de longo prazo entre os usuários e o sítio, de forma que interações futuras sejam sempre esperadas. Também é preciso capturar as avaliações dos usuários sobre as transações realizadas, além das avaliações sobre os itens expostos. Em portais C2C, as partes envolvidas na transação são convidadas a preencher um pequeno formulário eletrônico, que fica disponível para acesso durante um período pré-estabelecido. No sítio Arremate.com, por exemplo, as partes têm até 21 dias depois de finalizada a transação para submeterem suas avaliações [2]. A Figura 15 ilustra um exemplo de formulário de avaliação utilizado pelo sítio MercadoLivre. No exemplo, o formulário refere-se à avaliação de um vendedor após a realização de uma negociação. Uma vez qualificado o vendedor, não é permitido ao usuário alterar sua avaliação. Também não é permitido ao usuário assinalar a resposta “não” à primeira pergunta nos três primeiros dias após a realização da negociação. Essa estratégia evita que os usuários se precipitem em avaliar uma negociação como “não concretizada” em caso de um pequeno atraso no contato da contraparte.

MercadoLivre Brasil - Microsoft Internet Explorer

Arquivo Editar Exibir Favoritos Ferramentas Ajuda

A. Após o encerramento da negociação no MercadoLivre você concretizou a transação com a contraparte?

☐ Sim

☐ Não --> Selecione o motivo: --Escolha o motivo--

▶ Se a negociação não for concretizada, você deverá qualificar como "**não concretizada**", somente após o 3º dia.

B. Como você qualifica o Vendedor?

☐ Positiva

☐ Neutra

☐ Negativa

C. Quais seus comentários sobre a negociação?

Máximo 160 caracteres

ATENÇÃO:

▶ Ao inserir uma qualificação ela não poderá ser removida.

▶ Releia seu comentário antes de gravar a qualificação.

▶ Qualifique a contra-parte com responsabilidade.

▶ Se a negociação não foi concretizada, a qualificação somente poderá ser negativa ou neutra.

Gravar a qualificação **Cancelar**

Internet

Figura 15 – Formulário para avaliação de uma transação no sítio MercadoLivre

A consciência dos usuários de que as ações realizadas no passado terão conseqüências no futuro, seja na reciprocidade de ações ou na retaliação de outros usuários, criam um incentivo natural ao bom comportamento. O cientista político Robert Axelrod, *apud* [45], se refere a esse fenômeno como a “sombra do futuro”. Os sistemas de reputação tentam reproduzir essa “sombra” a cada transação, criando uma expectativa nos usuários de que suas ações serão levadas em conta pelos compradores no futuro.

3.4. Mecanismos para garantir a honestidade das avaliações

A FC, assim como as demais técnicas comumente utilizadas, não considera o grau de confiabilidade dos usuários envolvidos em um processo de recomendação. Alguns trabalhos

presentes na literatura sugerem que a reputação dos usuários envolvidos nesse processo seja considerada [5;39;38].

Dessa forma, as avaliações submetidas ao sistema podem ter pesos diferentes de acordo com a reputação ou expertise de cada usuário. Um exemplo simples pode ser visto no sítio da Amazon.com: ao submeter uma avaliação, o usuário pode informar se ele possui o respectivo produto (Figura 16). Nesse caso, a avaliação do usuário para esse item poderá receber um peso maior que as demais.




Figura 16 – Avaliação de um produto na Amazon.com

Diferentemente da Amazon.com, a maioria dos sítios de leilões só permite a avaliação entre compradores e vendedores depois que a transação comercial é concluída. Apesar de garantir mais autenticidade às avaliações, essa política limita o conjunto de avaliadores.

Os sítios de leilões também adotam políticas para inabilitar usuários que não atinjam uma reputação mínima pré-estabelecida. Tanto no sítio MercadoLivre quanto no Arremate.com, o usuário soma 1 ponto para cada avaliação positiva e perde 1 ponto para cada avaliação negativa recebida. Nesses sítios, se a reputação de um usuário alcançar, respectivamente, -2 ou -4 pontos, o usuário é inabilitado a efetuar transações no sítio de forma

definitiva. O MercadoLivre ainda exige que o percentual de avaliações negativas seja menor que 30%, independente do número de pontos acumulados pelo usuário [37].

Formas implícitas de coleta de dados também podem ser usadas para influenciar no peso de uma avaliação, como o número de compras repetidas, i.e., a quantidade de vezes que um usuário realizou uma compra com um mesmo vendedor.

No entanto, essas soluções são mais aplicáveis em sítios que promovem vendas on-line, em que as decisões de compra podem ser efetivamente registradas, ao contrário de Sistemas de Recomendação puros como o do sítio MovieLens, que não garante se os usuários realmente assistiram aos filmes antes de avaliá-los.

A determinação implícita da reputação de um usuário tem sido foco de muitos trabalhos. O'Donovan e Smyth [39] sugerem que a reputação de um usuário pode ser inferida automaticamente através da análise das recomendações que o seu perfil de preferências ajudou a gerar. Quanto melhores as recomendações geradas para o usuário alvo, maior a reputação do usuário analisado. Alguns trabalhos também propõem a adoção de redes de confiança (como a utilizada no sítio Epinions) para auxiliar na construção da reputação de um usuário [34;35;59].

3.5. Conclusões

Para reduzir a ocorrência de avaliações não confiáveis, diversas soluções são propostas para motivar os usuários e aumentar seu nível de comprometimento com o sistema. Uma das práticas mais comumente empregadas é a utilização de Sistemas de Reputação. Sua implantação faz com que as avaliações de cada usuário tenham um “peso” diferente em função da reputação de cada um.

Entretanto, adoção de Sistemas de Reputação e redes de confiança desestimula o cadastro de novos usuários. Para que essas soluções tenham o efeito desejado, é necessário que os membros da comunidade estabeleçam um relacionamento de longo prazo com o sistema. Usuários recém cadastrados ainda não possuem uma reputação consolidada ou uma rede de relacionamentos bem formada.

Além disso, as soluções apresentadas neste capítulo são iniciativas para dificultar a ação de usuários maliciosos que avaliam os itens disponíveis de acordo com seus próprios interesses. Assim, os usuários honestos que tradicionalmente fornecem boas avaliações continuam desmotivados a colaborar com o sistema, a não ser que sejam usuários de longa data com uma boa reputação construída.

Outra possível solução é assumir que todos os usuários possuem uma mesma reputação e criar mecanismos para incentivá-los a utilizar o SR sem promover a ocorrência de avaliações não confiáveis. A idéia é aumentar proporção de avaliações verdadeiras, fazendo com que as avaliações intencionalmente desonestas, submetidas por usuários mal intencionados ou com interesses particulares, tornem-se desprezíveis em relação ao montante de avaliações. Apresentamos no próximo capítulo um modelo de incentivo que segue essa abordagem e cuja utilização não implica alterar as características originais de um SR.

4. HYRIWYG: *How You Rate Influences What You Get*

Acreditamos que é comum as pessoas desejarem obter coisas sem fornecer nada em troca. Esse tipo de comportamento fica evidente ao se usar um desses programas de compartilhamento de músicas e arquivos pela Internet. As pessoas se sentem à vontade em copiar arquivos de músicas do mundo inteiro, configurando o programa para aceitar o máximo de *downloads* permitidos, mas não gostam de ceder seus arquivos, limitando o número de pastas compartilhadas a quase zero.

Os Sistemas de Recomendação estão sujeitos a esse mesmo problema: as pessoas desejam receber boas recomendações, mas não gostam de perder tempo fornecendo suas avaliações para ajustar o sistema. Dessa forma, a esparsidade da matriz de avaliações será aumentada e o SR poderá não ter dados suficientes para construir boas correlações de usuários.

Uma estratégia para reduzir a esparsidade em base de dados recém criadas é a de oferecer vantagens em troca de avaliações, como brindes, descontos, milhas de viagem etc. Em geral, os usuários de um SR não têm incentivos para avaliar os itens disponíveis. Na FC, as avaliações de um usuário ajudam o sistema a recomendar itens para as outras pessoas, mas não diretamente para o usuário que as forneceu. Dessa forma, um usuário deve ser recompensado por fornecer informações que beneficiará os participantes do SR como um todo.

Contudo, incentivos por si só não garantem que as avaliações fornecidas sejam fidedignas. Pior: podem fazer com que usuários com passado de informações verdadeiras comecem a ser desonestos em suas avaliações apenas para desfrutar das vantagens oferecidas. Assim, uma pessoa pode ser recompensada porque avaliou muitos itens, mesmo não sendo honesta em suas avaliações.

O mecanismo HYRIWYG (*How You Rate Influences What You Get*) [16;17] é uma proposta para, além de promover o aumento da quantidade de avaliações fornecidas pelos usuários, tentar garantir a veracidade das mesmas.

Uma das maiores vantagens desse mecanismo é a sua facilidade de implantação em qualquer SR capaz de gerar recomendações personalizadas, funcionando como um serviço complementar aos sistemas colaborativos existentes. Como nesse tipo de sistema as recomendações são extraídas do conjunto de avaliações individuais de cada usuário, a aplicação do HYRIWYG resulta num melhor ajuste do mecanismo de inferência do SR e, conseqüentemente, numa maior acurácia das recomendações geradas.

4.1. Modelo

O HYRIWYG propõe a cessão de incentivos de forma proporcional à colaboração de cada usuário na calibragem do SR. Assim, quanto mais o usuário contribui com o ajuste do seu perfil de preferências, melhor ele será recompensado por isso, fazendo com que o sistema entre num ciclo virtuoso, como esquematizado na Figura 17.

A fim de explicar melhor o funcionamento do mecanismo de incentivo, considere um conjunto de usuários avaliadores $I = \{1,2,...,n\}$. Cada usuário i possui um perfil de preferências θ_i . Associado a cada item disponível para avaliação existe um vetor $x = (K, \tau_1, \tau_2, ..., \tau_i)$, em que k é avaliação acumulada do produto e τ é o incentivo concedido para cada um dos n usuários. O valor de K varia de acordo com o modelo de avaliação adotado por cada SR (bom/ruim, nota de 0 a 5 etc.).




Figura 17 – Esquema básico de utilização do HYRIWYG em um SR

Cada usuário i deseja maximizar sua função utilidade u_i . Dessa forma, quanto maior o trabalho do usuário no ajuste de seu perfil, mais ele deve ser recompensado. O HYRIWYG propõe uma *função de compensação* para incentivar cada usuário a ajustar o seu perfil. Essa função é mostrada a seguir.

Função de compensação:

A Equação 3 mostra a compensação do usuário i por ter fornecido uma recomendação individual de um item.

$$\tau_i = C * (1 + \alpha * |v'(SR(\theta_i)) - v_i|), \quad (3)$$

onde:

C é uma constante que corresponde ao incentivo que será concedido. É determinada pela estratégia de marketing da empresa, podendo ser pontos, vale-descontos, milhas de viagem etc.;

$v'(RS(\theta_i))$ é a suposta avaliação fornecida pelo usuário i , inferida pelo SR considerando o perfil θ_i .

v_i é a real avaliação fornecida pelo usuário i ;

$|v'(SR(\theta_i)) - v_i|$ é a contribuição do usuário i para o ajuste do sistema.

α é uma constante utilizada para calibragem do sistema de avaliação. Assim como a constante C , seu valor também é determinado de acordo com a estratégia de negócios da empresa, podendo ser alterado ao longo do período de vida do SR.

Quanto maior o valor de $|v'(SR(\theta_i)) - v_i|$, maior é a contribuição do usuário no ajuste do SR, pois ele estará corrigindo a avaliação predita pelo sistema. Conseqüentemente, maiores serão os incentivos que o usuário poderá vir a receber, que são cumulativos.

Para exemplificar o uso da *função de compensação*, consideremos o seguinte cenário: uma loja virtual deseja conceder descontos aos seus clientes como forma de incentivar o uso de seu Sistema de Recomendação. Para isso, é oferecido um desconto de R\$ 5,00 (cinco reais) para cada avaliação submetida ao sistema ($C = 5$). Consideremos também o mesmo conjunto de usuários mostrado na Tabela 3. Imaginemos agora que Júlia se tornou cliente da loja e avaliou um determinado produto P com a nota 3 na escala de 0 a 10 ($K \in [0...10]$). Como Júlia é uma usuária recente, o sistema ainda não dispõe de muitas informações sobre suas preferências. O SR ainda está se ajustando para gerar recomendações acuradas para ela. Desta forma, a nota inferida pelo sistema para Júlia ainda não é muito precisa, digamos 5. Considere ainda que o administrador do sistema definiu a constante α como 0,2. Dadas essas condições, a compensação determinada para Júlia seria:

$$\tau_{Júlia} = 5 * (1 + 0,2 * |5 - 3|) = R\$7,00$$

Caso Júlia avaliasse o mesmo produto P com a nota 2, o valor do desconto concedido seria aumentado:

$$\tau_{Júlia} = 5 * (1 + 0,2 * |5 - 2|) = R\$8,00$$

O gráfico da Figura 18 mostra o valor do desconto concedido à Júlia para cada possível nota atribuída por ela ao produto P. Quanto mais a avaliação fornecida pelo usuário se afasta da avaliação inferida pelo sistema, maior será o valor do incentivo concedido.




Figura 18 – Descontos que podem ser obtidos pela usuária Júlia em função da nota atribuída por ela ao produto P

Ao passar do tempo, espera-se que o conjunto de avaliações submetidas ajuste o sistema de tal forma que as avaliações inferidas sejam idênticas às avaliações reais dos usuários.

Quando isso ocorrer, a constante α será anulada e o incentivo passará a ser direto. No caso do exemplo anterior, ele assumirá o desconto mínimo de R\$5,00 por avaliação.

Valores positivos definidos para α elevam o incentivo concedido quanto maior for a contribuição do usuário para o ajuste do SR. Valores negativos também podem ser utilizados, porém, neste caso ocorre a redução do incentivo à medida em que a avaliação fornecida pelo usuário desvia da nota inferida pelo sistema. Essa situação sinaliza que a homogeneidade de opiniões é desejada pela entidade mantenedora do SR.

Ainda considerando o mesmo exemplo apresentado anteriormente, o gráfico da Figura 19 mostra a variação do desconto concedido à Júlia caso o administrador do sistema instanciasse a constante α com o valor -0,2.




Figura 19 – Variação do desconto concedido à Júlia para $\alpha = -0,2$

No caso da anulação da constante α ($\alpha=0$), o incentivo permanecerá o mesmo independente da avaliação fornecida pelo usuário. A Tabela 4 sumariza as possíveis configurações de α e os reflexos dessas configurações na *função de compensação*.

Tabela 4 – Implicações dos valores de α

$\alpha > 0$	$\alpha = 0$	$\alpha < 0$
C é o piso do incentivo concedido por avaliação	C é o valor do incentivo concedido por avaliação	C é o teto do incentivo concedido por avaliação
O incentivo aumenta quanto mais a nota do usuário desvia da nota inferida	O incentivo é o mesmo independente da nota fornecida pelo usuário	O incentivo aumenta quanto mais a nota do usuário se aproxima da nota inferida
Estimula a diversidade de opiniões	---	Estimula a homogeneidade de opiniões

4.2. Incentivo Indexado pela Qualidade da Avaliação

A estratégia de recompensar os usuários cujas avaliações desviam dos valores inferidos pelo sistema pode fazer com que as pessoas mintam sobre suas preferências. Dessa forma, um novo problema é criado, pois os usuários que antes eram honestos em suas avaliações passam a alimentar o sistema com informações não confiáveis apenas para aumentar o valor dos incentivos. Esse tipo de comportamento é extremamente prejudicial ao funcionamento de um SR, fazendo com que sejam geradas recomendações ruins ou, no mínimo, duvidosas [16].

Para evitar esse problema, o HYRIWYG propõe uma *regra de resgate*. A idéia é usar o próprio SR para determinar, de acordo com cada perfil θ_i , qual o conjunto de itens em que um usuário i poderá utilizar os incentivos recebidos. A *regra de resgate* é mostrada na Eq. 4.

Regra de resgate:

$$\$_{item} = \$_{item} - f(\tau), \text{ se e somente se } \tau > T \text{ e item} \in \{ \text{SR(itens}, \theta_i) \} \quad (4)$$

onde:

T é um limite mínimo estabelecido para que um usuário seja beneficiado;

$\$_{item}$ é o preço do item que foi recomendado ao usuário;

$f(\tau)$ é o desconto associado a τ ;

$\text{SR(itens}, \theta_i)$ é o conjunto de itens que o SR pode sugerir de acordo com o perfil θ_i .

Completando o exemplo utilizado na seção anterior, tomemos outros dois usuários mostrados na Tabela 3: Fábio, que possui um perfil de preferências muito similar ao de Júlia e André, com interesses opostos ao dela. Imagine que esses três usuários avaliaram 4 produtos em comum no SR da suposta loja virtual. A Tabela 5 destaca a matriz com as avaliações desses usuários.

Tabela 5 – Produtos avaliados por André, Fábio e Júlia no SR da loja virtual

	Produto A	Produto B	Produto C	Produto P
André	5	6	6	9
Fábio	8	2	5	2
Júlia	9	2	4	3

De acordo com a tabela, André avaliou o produto P com a nota 9, enquanto que Fábio avaliou o mesmo produto com a nota 2. Sabemos que a verdadeira nota de Júlia para o produto P é 3. Entretanto, para aumentar o valor do desconto concedido pela *função de compensação*, imagine que ela resolveu avaliar P com a nota 10. Essa ação contribui para que o

perfil de preferências de Júlia se ajuste para deixar de ser semelhante ao de Fábio e se aproxime do perfil de André. A Figura 20 mostra como as possíveis notas de Júlia para o produto P alteram a medida de similaridade entre ela e os outros dois usuários. Os valores foram calculados utilizando o coeficiente de correlação de Pearson (Eq.1).




Figura 20 – Variação do valor da medida de similaridade entre Júlia e André e entre Júlia e Fábio em função da nota atribuída por Júlia ao produto P

Como a *regra de resgate* determina que os incentivos recebidos por um usuário só podem ser utilizados em itens determinados pelo SR, Júlia estará limitada a usar o desconto obtido apenas na compra de produtos que fazem parte das preferências de André, que se tornou o usuário mais similar a ela. Assim, para evitar desperdiçar os incentivos acumulados em produtos que não são de seu interesse, espera-se que as próximas avaliações fornecidas por Júlia configurem seu perfil da melhor maneira possível.

Esse simples sistema de recompensas estimula a colaboração dos usuários com avaliações verdadeiras, de acordo com a perspectiva de cada um. A utilidade do incentivo recebido é relacionada com a qualidade das recomendações geradas pelo sistema. Assim, os usuários são desencorajados a mentir em suas avaliações, caso contrário podem vir a receber um incentivo indesejado.

Como outro exemplo, o cliente de uma companhia aérea que mentir em suas avaliações para acumular mais milhas de viagem pode vir a ter que usar as milhas adquiridas em um trecho de operação da companhia que não é do seu interesse.

Uma outra questão tratada pelo HYRIWYG é descrita como segue: na FC, quando um item novo é disponibilizado pela avaliação, é desejável que esse item receba muitas avaliações o mais rápido possível para que possa ser recomendado a outros usuários. Além disso, a maioria dos itens disponíveis em um SR possui um ciclo de vida com momentos de maior interesse pelos usuários. Por exemplo: imagine um novo bronzeador lançado no início do verão. Para que esse bronzeador possa ser recomendado, ele precisa receber grande quantidade de avaliações antes do fim da estação.

Pensando nisso, além de incentivar os usuários a alimentar o sistema com avaliações verdadeiras, o HYRIWYG também propõe incentivar de maneira diferenciada os primeiros usuários a opinar sobre um determinado item. Para isso, a constante C é ajustada de forma que os incentivos diminuam na medida em que a quantidade de avaliações aumenta. A Equação 5 mostra a constante C ajustada.

$$\tau_i = C * e^{-\delta E} * (1 + \alpha * |v'(SR(\theta_i)) - v_i|) \quad (5)$$

onde E é a quantidade de avaliações já recebidas pelo item, ajustada por δ .

Dessa forma, o mecanismo de incentivo apresentado neste capítulo motiva os usuários de um SR a, voluntariamente, fornecerem avaliações honestas, de forma rápida e em grande quantidade. Essas características ajudam a minimizar parte dos problemas apresentados pela FC, descritos no Capítulo 2.

É importante ressaltar que o HYRIWYG só pode ser implementado em ambientes onde exista heterogeneidade de opiniões e os usuários possam ser identificados unicamente. Por exemplo: a aplicação do mecanismo em sítios de vendas como eBay [15] e MercadoLivre [37] não é recomendada, pois nesses sítios a maioria dos usuários avalia positivamente os vendedores.

Outra questão que precisa ser enfatizada é que a coleta das avaliações e a concessão dos incentivos ocorrem em momentos diferentes da interação dos usuários com o SR. A *função de compensação* é aplicada todas as vezes em que o usuário atua como *produtor de recomendações*, enquanto a *regra de resgate* só é aplicada quando o usuário atinge a quantidade mínima de itens avaliados determinada pelo administrador do sistema.

Durante o ciclo de vida de um SR, quando mais cedo o HYRIWYG for implantado melhor serão os benefícios percebidos de sua utilização. Espera-se que sua aplicação reduza o tempo necessário para que os novos produtos cadastrados no sistema comecem a ser recomendados, além de aumentar a quantidade de avaliações confiáveis na base de dados.

Entretanto, apesar do modelo ser teoricamente funcional, sua aplicação ainda não foi testada em cenários reais de uso. O impacto da utilização por agentes humanos ainda é desconhecido. O estudo de caso apresentado no próximo capítulo inaugura uma nova frente de investigação, em que comparamos o comportamento dos usuários ao interagir com um SR em

três momentos distintos: (i) quando nenhum incentivo é concedido para motivá-los; (ii) quando apenas a *função de compensação* é aplicada; e (iii) quando o HYRIWYG é completamente implantado.

5. Estudo de Caso

O objetivo do estudo de caso proposto foi o de testar as hipóteses formuladas no Capítulo 1. Para isso, realizamos uma investigação empírica que permitiu verificar a viabilidade do modelo de incentivo proposto pelo HYRIWYG. Observamos a variação da quantidade e da qualidade das informações providas por avaliadores de produtos na Web ao longo dos experimentos realizados. Neste capítulo, descrevemos como esses experimentos foram configurados e conduzidos.

5.1. Objeto de Estudo

O presente estudo utiliza como objeto de investigação um conjunto de avaliações sobre filmes. Cada avaliação corresponde a uma nota atribuída por uma pessoa a um determinado filme, de acordo com suas perspectivas individuais. As avaliações podem ser nulas, indicando que o avaliador desconhece ou ainda não assistiu ao filme a ser avaliado, ou um valor numérico pertencente a uma escala discreta de 0 a 6, com rótulos descritivos variando de 0 a 10. Quanto mais alta for a avaliação dentro dessa escala, maior é a predileção do avaliador pelo filme listado.

Essas avaliações foram obtidas através da aplicação de um questionário a um grupo de usuários de um Sistema de Recomendação de Filmes. O questionário utilizado é composto por 300 filmes diferentes, de clássicos do cinema até os mais recentes lançamentos em vídeo. A lista completa desses filmes pode ser vista no anexo A deste trabalho.

O objeto de estudo foi agrupado por avaliador, constituindo o perfil de preferências dos participantes do experimento. Utilizamos a técnica da FC para gerar recomendações personalizadas de filmes a cada participante, de acordo com as avaliações realizadas por cada um.

5.2. Procedimentos

Nosso experimento se desenvolveu através da análise do objeto de estudo coletado ao longo de três fases distintas, cada uma com duração de três semanas e executadas de forma não simultânea. A seção 5.4.2 apresenta em mais detalhes os períodos de coleta de dados considerados. As peculiaridades de cada fase são descritas a seguir.

Na primeira fase, nenhum incentivo foi concedido aos avaliadores. Eles eram apenas informados que, quanto mais filmes fossem avaliados, melhor seria a qualidade da recomendação recebida. A ausência de incentivos à colaboração é a situação mais comumente encontrada nos sistemas de recomendação existentes.

Na segunda fase, distribuímos locações grátis de DVDs de forma proporcional ao número de filmes avaliados por cada participante. Essa fase se caracterizou pelo incentivo aberto, ou seja, os avaliadores contemplados puderam escolher livremente os filmes a serem alugados.

A terceira e última fase também distribuiu locações grátis de DVDs de forma proporcional ao número de filmes avaliados. Entretanto, desta vez não foi permitido aos avaliadores escolher os filmes a serem alugados. Utilizamos a regra de resgate proposta pelo HYRIWYG para determinar quais filmes poderiam ser alugados por cada participante. Apenas os filmes não avaliados, dentre os 300 listados no formulário de avaliação, eram passíveis de serem alugados.

Para que a realização desta pesquisa fosse possível, um importante trabalho de marketing precisou ser feito para angariar parceiros que viabilizassem o oferecimento de incentivos durante as duas últimas fases do experimento. Seis videolocadoras de médio porte da

cidade de Juiz de Fora, MG, aceitaram nosso convite e nos ajudaram fornecendo condições especiais para que as locações pudessem ser concedidas aos participantes do experimento. Logo, apenas os DVDs disponíveis no acervo dessas videolocadoras puderam ser alugados durante as fases de distribuição de incentivos.

Especificamente durante a terceira fase do experimento, solicitamos aos participantes contemplados com o incentivo que avaliassem, no ato da devolução, o filme alugado gratuitamente. Esses dados constituíram um segundo conjunto de avaliações, utilizado para verificar a satisfação do avaliador com os filmes selecionados pela regra de resgate.

5.2.1. Seleção dos Avaliadores

Os avaliadores participantes são pessoas que deliberadamente se tornaram usuários do SR de Filmes utilizado nesta pesquisa. O sistema em questão, apresentado em mais detalhes na seção 5.4, foi disponibilizado na WWW para livre utilização.

O conjunto de avaliações que formam nosso objeto de estudo pertence aos usuários que se cadastraram durante o período de execução de cada fase. Dessa forma, ao término de cada fase foram coletadas apenas as avaliações submetidas por usuários cadastrados durante sua vigência.

Não houve limitações quanto ao perfil ou à quantidade de usuários aptos a se cadastrarem para utilizar o SR. Entretanto, não foi permitido que um mesmo usuário se cadastrasse mais de uma vez no sistema.

É importante salientar que os avaliadores considerados nos experimentos são pessoas desconhecidas do autor deste trabalho. Colegas, amigos e parentes só tiveram atuação

durante os dois primeiros meses do período de testes e ajustes descrito na seção 5.4.2, não exercendo qualquer influência nos resultados apresentados.

5.2.2. Divulgação da Pesquisa

A divulgação da pesquisa foi feita através da fixação de cartazes nas locadoras parceiras e da publicação de um *banner* eletrônico no sítio que abrigou o instrumento de coleta de dados. Assim, os avaliadores participantes do experimento ficaram limitados aos clientes das locadoras e aos visitantes do sítio.

5.2.3. Participação das Videolocadoras

As seis videolocadoras parceiras foram divididas em dois grupos. Três delas participaram da cessão de locações durante a segunda fase do experimento, enquanto que as outras três, de porte semelhante e localizadas nos mesmos bairros, participaram durante a fase 3.

Optamos por trabalhar com dois grupos de locadoras diferentes para que os clientes que se cadastraram sob as condições da fase 2 não tomassem conhecimento das condições definidas na fase 3 e vice-versa.

Ao realizar a fase 3 utilizando o mesmo grupo de videolocadoras participantes da fase 2, a quantidade de cadastros realizados no sistema durante a última fase ficou muito abaixo da esperada. Percebemos que a decisão de manter as mesmas locadoras em ambas as fases fez com que a primeira fase executada captasse um número maior de clientes, prejudicando a coleta de dados da fase seguinte. Assim, para que a terceira fase tivesse as mesmas condições de atrair novos usuários, repetimos a execução da fase 3 considerando outro grupo de videolocadoras.

5.3. Definição das variáveis de medição

A função de compensação utilizada em nosso estudo não considera a calibragem do sistema de avaliações ($\alpha = 0$). A suposta avaliação $v'(RS(\theta_i))$, inferida pelo sistema, também não é considerada no cálculo da função.

A constante C equivale a $\frac{1}{40}$ de uma locação gratuita de DVD. Assim, a função

de compensação passa a ser definida como:

$$\tau_i = \frac{1}{40} \times n_i, \quad n_i \geq 0 \quad (6)$$

onde:

n_i é o número de filmes avaliados pelo avaliador i ;

τ_i é a quantidade de locações gratuitas que serão concedidas ao avaliador i . Apenas a parte inteira do número é considerada. Assim, se um participante avaliou entre 40 e 79 filmes, $\tau_i = 1$; entre 80 e 119 filmes, $\tau_i = 2$; e assim por diante.

A função também pode ser descrita de forma direta como: *para cada avaliação fornecida, o avaliador ganha $\frac{1}{40}$ de uma locação gratuita de DVD.*

As duas fases finais do experimento utilizam a mesma função de compensação, entretanto a regra de resgate só é aplicada na terceira fase.

A regra pode ser definida de forma direta como: *todo avaliador i tem direito a alugar gratuitamente τ_i DVDs em qualquer uma das videolocadoras parceiras do experimento se e somente se o filme a ser alugado $\in \{SR(filmes, \theta_i) \cap Acervo(filmes)\}$, onde:*

$SR(filmes, \theta_i)$ é o conjunto de filmes que o SR instrumento deste estudo pode recomendar de acordo com o perfil θ_i ;

$Acervo(filmes)$ é o conjunto de todos os filmes disponíveis no acervo das videolocadoras parceiras.

5.4. Instrumento e Coleta de Dados

Os instrumentos de coleta de dados utilizados foram questionários, aplicados via Web na forma de formulários eletrônicos. Esses questionários são parte de um Sistema de Recomendação on-line de Filmes desenvolvido especificamente para este trabalho. A implementação desse sistema foi baseada na técnica da Filtragem Colaborativa, discutida na seção 2.3.2.. Sua modelagem é mostrada no Anexo B.

Disponibilizamos o sistema desenvolvido para uso público na Web através de sua integração com um sítio especializado em cinema [9]. O sítio em questão, também desenvolvido pelo autor deste trabalho, compõe uma das seções do portal local da emissora afiliada à rede Globo de televisão na cidade de Juiz de Fora, MG [55].

Cada participante da pesquisa é um visitante do sítio que deliberadamente se cadastrou para usar o Sistema de Recomendação de Filmes, se transformando em um usuário do sistema. As avaliações, que são o objeto de estudo desta pesquisa, juntamente com as informações oriundas do cadastro desses visitantes, foram coletadas de forma explícita e

armazenadas em um único banco de dados on-line integrado ao sítio. Informações coletadas de forma implícita também foram utilizadas para monitorar o comportamento dos participantes, como a data e o tempo de duração de cada acesso ao sistema. Essas informações foram armazenadas em um arquivo *log* no formato CSV (*Comma Separated Value*).

As interfaces do SR desenvolvido são mostradas no Anexo C deste trabalho. Apresentamos a seguir algumas características do funcionamento do sistema, necessárias para uma melhor compreensão dos resultados obtidos.

5.4.1. Características do SR

Os visitantes do sítio são convidados a conhecer o Sistema de Recomendação de Filmes através de um *full-banner* publicado em sua página principal. Esse *banner* eletrônico direciona o usuário para uma página que contém uma breve explicação sobre o funcionamento do sistema. De acordo com [52] e [53], os usuários se sentem mais confortáveis em utilizar sistemas de recomendação quando entendem a forma como as recomendações são geradas. Essa página, durante as fases 2 e 3 do experimento, também possuía explicações sobre as condições para que os participantes fossem contemplados com uma ou mais locações.

Para utilizar o SR de filmes, o visitante precisa efetuar um pequeno cadastro no sítio. Esse cadastro é obrigatório para que o SR seja capaz de identificar unicamente cada usuário e assim consiga recomendar filmes de forma personalizada a cada um.

Um dos campos do formulário de cadastro permite ao usuário informar quais são seus gêneros prediletos e se existe algum gênero que ele não goste. Desta forma, apenas filmes dos gêneros preferidos pelo usuário são exibidos para avaliação nos primeiros acessos ao sistema.

Essa estratégia, também adotada pelo SR da *Amazon.com*, visa aumentar as chances dos filmes listados para avaliação terem sido assistidos pelo usuário, incentivando-o a opinar sobre eles.

Imediatamente após a realização do cadastro, apenas 30 filmes são listados para avaliação do usuário, que pode optar por não avaliar os filmes nesse instante. Uma vez cadastrado, o usuário pode acessar o SR a qualquer momento. A cada acesso realizado, uma lista com 10 novos filmes é exibida para avaliação, que consiste em assinalar uma nota de 0 a 10 entre as 7 posições disponíveis na escala de gradação mostrada na Figura 21.

A interface de avaliação de filmes apresenta uma escala de 0 a 10, representada por sete círculos. Acima da escala, há uma seta horizontal com um ícone de bomba no início e um ícone de coroa no fim. Abaixo da escala, há uma opção "Não vi" com um círculo de seleção. A interface também inclui botões "Desmarcar" e "Avaliar filmes".

Filme	0	1	2	3	4	5	6	7	8	9	10	Não vi
Halloween: Ressurreição	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐
Extermínio	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐
A Bruxa de Blair	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐	☐

Figura 21 – Exemplo de uma lista com três filmes para avaliação

O usuário também pode assinalar a opção “Não vi” para indicar os filmes ainda não assistidos por ele. Se nenhuma opção for assinalada, o respectivo filme continuará sendo listado para avaliação a cada acesso ao sistema.

Conforme dito anteriormente, serão listados para avaliação apenas filmes cujo gênero esteja na lista dos preferidos pelo usuário. Desta forma, a não ser que o usuário tenha assinalado todos os gêneros ao efetuar seu cadastro, menos de 300 filmes serão listados para avaliação. Para que todos os usuários tenham a oportunidade de avaliar uma mesma quantidade de filmes, o sistema permite que sejam listados todos os demais filmes de sua base de dados. Para

isso, é necessário que o usuário já tenha avaliado (ou marcado como “Não vi”) todos os filmes de seus gêneros prediletos e concorde com a pergunta feita pelo sistema mostrada na Figura 22.




Figura 22 – Trecho da página que é exibida quando o usuário já opinou sobre todos os filmes listados para sua avaliação

Os filmes passíveis de serem recomendados a um usuário são: (i) todos os filmes cadastrados cujo gênero é diferente daquele que o usuário declarou não gostar no ato do seu cadastro e (ii) aqueles que ainda não foram assistidos por ele, ou seja, os filmes que não tiveram nenhuma nota atribuída pelo usuário.

No caso do usuário ter concordado em avaliar filmes de todos os gêneros (Figura 19), os filmes passíveis de recomendação passam a ser todos aqueles que ainda não foram avaliados por ele ou foram marcados como “Não vi” dentre os 300 cadastrados.

A exemplo do sítio MovieLens [24], é necessário que o usuário avalie pelo menos 15 filmes para que o sistema gere as primeiras recomendações. Os usuários que já avaliaram essa quantidade de filmes podem solicitar uma recomendação a qualquer momento clicando no *link* “Quero receber uma recomendação”, localizado na página que é carregada quando o sistema é acessado. Esse link abre uma janela que contém um conjunto de informações sobre o filme recomendado. Com base nas informações apresentadas, o usuário pode avaliar a sugestão do sistema atribuindo a suposta nota que ele daria ao filme caso o tivesse assistido. Essas avaliações foram utilizadas para medir a qualidade das recomendações geradas durante as duas primeiras fases do experimento.

O sistema foi desenvolvido utilizando a linguagem PHP 4 e hospedado em um dos servidores Linux de uma conceituada empresa de hospedagem profissional de *sites*. Todas as avaliações submetidas foram armazenadas em um banco de dados MySQL 5.

5.4.2. *Períodos de Coleta de Dados*

Embora o Sistema de Recomendação de Filmes tenha sido implantado no sítio Cinefilia em dezembro de 2004, apenas as informações dos usuários cadastrados a partir do dia 17 de maio de 2005 foram consideradas para análise dos resultados aqui apresentados. Até abril de 2005, o sistema precisou passar por diversos ajustes. Nesse período, também realizamos dois experimentos de teste, apresentados no Capítulo 6.

A distribuição de locações grátis de DVDs proporcional ao número de filmes avaliados, descritas nas fases 2 e 3 do experimento, foram realizadas nos períodos de 8 a 29 de junho e de 27 de agosto a 17 de setembro de 2005, respectivamente. Os demais períodos são equivalentes à fase 1, ou seja, nenhum incentivo foi concedido aos usuários do sistema. Entretanto, para efeito de análise dos resultados relativos a essa fase, consideramos o período de 17 de maio a 7 de junho 2005. Escolhemos essas datas por serem isentas de fatores externos que influenciaram o número de visitas ao sítio, como por exemplo, a realização de campanhas de divulgação. O cronograma apresentado na Figura 23 destaca os períodos considerados em nossa pesquisa.

O período de execução da fase 3 aparece bastante deslocado em relação ao período da fase 2 em função da necessidade de se repetir o experimento da terceira fase, como discutido na seção 5.2.3.




Figura 23 – Gráfico de Grantt dos períodos de coleta de dados

5.5. População

A página principal do sítio que abriga o instrumento de coleta de dados deste estudo teve 20.431 impressões no segundo e terceiro trimestre de 2005, segundo o software que mede as estatísticas de acesso fornecido pelo serviço de hospedagem web. Entretanto, a página do formulário de cadastro para uso do Sistema de Recomendação recebeu apenas 958 acessos no mesmo período de tempo.

Ao todo, 565 usuários se cadastraram no sistema, e mais da metade desses cadastros são de usuários da cidade de Juiz de Fora, MG. Apesar de não existirem fronteiras na rede mundial de computadores, esse grande número de acessos localizados deve-se, principalmente, ao fato do sítio ter parte de seu conteúdo voltado para atender especificamente ao público dessa região, como por exemplo, a programação semanal das salas de cinema local.

Mostramos na Figura 24 a distribuição por cidade dos usuários cadastrados em nosso sistema. Apenas as cidades com pelo menos 10 usuários cadastrados estão em destaque.

Segundo o gráfico, 27% dos usuários são residentes em outras cidades brasileiras. Estas cidades abrangem todos os estados da federação, exceto o Acre e o Amazonas.




Figura 24 – Distribuição dos usuários cadastrados no SR

Assim, limitamos nosso experimento apenas à cidade de Juiz de Fora, cuja escolha para a realização desta pesquisa se deveu em função de três fatores principais:

1. Como mostrado, o sítio que abrigou o Sistema de Recomendação tinha nos visitantes de Juiz de Fora um nicho bem definido de usuários;
2. O autor deste trabalho reside em Juiz de Fora, o que facilitou a operacionalização do experimento nesta cidade;
3. O valor da locação de DVD praticado pelas locadoras de Juiz de Fora, em especial as participantes do experimento, é inferior ao valor cobrado pelas videolocadoras consultadas nas cidades do Rio de Janeiro e Niterói, também cogitadas como alternativas para este estudo.

Devido à ausência de financiamento para esta pesquisa, o último fator relatado foi o mais determinante para a escolha de Juiz de Fora. Nas locadoras parceiras, o valor de uma locação no final de semana de um filme recém lançado varia de R\$3,50 a R\$4,50. Nas mesmas condições, o valor praticado por grandes videolocadoras no Rio de Janeiro chega a R\$7,50.

Entretanto, ao mesmo passo que essa economia ajudou a viabilizar a realização da pesquisa, o valor agregado do incentivo concedido é menor para os usuários de Juiz de Fora, o que pode afetar os resultados obtidos.

5.6. Análise dos Dados

Hipótese 1: *O HYRIWYG faz com que a quantidade de avaliações fornecidas ao SR seja maior do que quando nenhum incentivo é concedido aos usuários.*

Para testar essa hipótese, comparamos a quantidade de avaliações fornecidas pelos usuários cadastrados no sistema durante as três fases do experimento. O período de duração de cada fase analisada foi de três semanas, conforme apresentado na seção 5.4.2.

Apresentamos na Figura 25 o gráfico referente à quantidade de avaliações submetidas pelos usuários residentes em Juiz de Fora. As linhas verticais delimitam o fim de cada fase, enquanto que a linha horizontal representa a quantidade mínima de avaliações necessárias (40) para que o usuário fosse contemplado com uma locação grátis. Essa linha não é mostrada na parte do gráfico correspondente à fase livre de incentivos. Cada barra vertical representa a quantidade de avaliações submetidas por um usuário. A disposição das barras acompanha a ordem dos cadastrados realizados. O tamanho de cada barra varia de 0 (nenhum filme avaliado) a 300 (o usuário avaliou todos os filmes). A parte cinza indica a proporção de filmes assinalados com a opção “Não vi”, enquanto que a parte azul indica a proporção de filmes avaliados com uma nota de 0 a 10.




Figura 25 – Perfil dos usuários de Juiz de Fora

A fim de facilitar o entendimento da Figura 25, separamos as avaliações submetidas durante cada fase em três gráficos distintos, mostrados na Figura 26.




Figura 26 – Avaliações submetidas pelos usuários de Juiz de Fora durante o período de cada fase

Uma outra visão do gráfico da Figura 25 é mostrada na Figura 27. Desta vez, ordenamos os usuários pela quantidade de avaliações submetidas em cada fase, enfatizando a esparsidade da matriz de avaliações em cada período. É importante lembrar que, quanto menor a esparsidade, melhor são as condições para que a técnica da Filtragem Colaborativa gere boas recomendações.

Podemos observar que poucos usuários se cadastraram no sistema durante a fase 1 (apenas 8). Além disso, os poucos que se cadastraram não se esforçaram em avaliar uma grande quantidade de filmes. Nesta fase, a matriz de avaliações ficou 62% esparsa.




Figura 27 – Esparsidade das avaliações dos usuários de Juiz de Fora durante as 3 fases consideradas

Como a quantidade de usuários cadastrados durante a fase 1 não forma uma amostra muito representativa, mostramos na Figura 28 a esparsidade da base de dados quando considerados os últimos 100 usuários cadastrados durante os períodos livres de incentivo. Se considerarmos apenas as avaliações submetidas durante esses períodos, a esparsidade da base de dados cai para 53.89% e o sistema registra 3 cadastros em média por semana.




Figura 28 – Esparsidade das avaliações dos últimos 100 usuários de Juiz de Fora cadastrados durante períodos livres de incentivo

Este seria um excelente percentual para qualquer Sistema de Recomendação, entretanto, num universo de avaliação de apenas 300 filmes esse número se torna menos expressivo.

A fase em que o HYRIWYG foi aplicado obteve o menor índice de esparsialidade, apenas 29,73%. Esperávamos que a base de dados da fase 2 registrasse o menor índice de todas, entretanto ela ficou 35,4% esparsa. Apesar disso, a taxa de cadastros realizados durante a segunda fase foi bastante alta. Motivados pelo incentivo aberto, mais de 16 usuários se cadastraram no sistema por semana.

A fase em que o HYRIWYG foi aplicado também proporcionou um grande número de cadastros (7 por semana), registrando um número muito superior ao da fase 1, que obteve menos de 3 cadastros por semana em média.

Também comparamos a proporção dos usuários que optaram por avaliar filmes de todos os gêneros. A Tabela 6 apresenta um quadro comparativo das três fases analisadas.

Tabela 6 – Resumo dos dados analisados – usuários de Juiz de Fora

	Fase 1 sem incentivo	Fase 2 incentivo aberto	Fase 3 HYRIWYG
Período considerado para coleta de dados	De 17/5 a 7/6	De 8/6 a 30/6	De 27/8 a 11/9
Média de cadastro/semana	2,66	16,33	7
Média de avaliações com notas/usuário	93,375	115,97	120,5
Esparsidade da matriz	62%	35,4%	29,73%
% de usuários que optaram por avaliar filmes de todos os gêneros	25%	54,16%	42,85%

A Figura 29 mostra a quantidade de avaliações fornecidas ao sistema pelos usuários de outras cidades durante os períodos equivalentes às três fases do experimento. Como esses usuários não eram contemplados com as locações grátis, eles só podiam interagir com o sistema de forma altruísta. Dessa forma, a quantidade média de usuários cadastrados não sofreu muitas variações em cada uma das três fases.




Figura 29 – Perfil dos usuários de outras cidades

No gráfico, pode-se notar pela quantidade de barras de tamanho inferior a 120 um número reduzido de avaliações fornecidas, fazendo com que a matriz de avaliações ficasse muito esparsa.

A média de cadastros no SR ficou em 3.33 cadastros por semana, sendo coerente com os períodos livres de incentivo. A Figura 30 enfatiza a esparsidade dos dados, e a Tabela 7 apresenta um resumo das informações.




Figura 30 – Esparsidade das avaliações dos usuários de outras cidades

Como esperado, o oferecimento de incentivos aumentou a quantidade de avaliações fornecidas ao sistema. No período em que o usuário pôde escolher livremente o incentivo a ser recebido, a taxa de cadastro semanal foi a maior desde que o sistema foi disponibilizado na web. Entretanto, apenas os cadastros de usuários de Juiz de Fora tiveram essa taxa aumentada. Em geral, considerando os usuários de outras cidades e os usuários de Juiz de Fora cadastrados nos períodos em que nenhum incentivo foi oferecido, a média de cadastros no Sistema de Recomendação girou em torno de 3 cadastros por semana. Quando passamos a oferecer o incentivo indexado à recomendação gerada pelo sistema (fase 3), esse número mais que dobrou, mas ainda ficou muito abaixo da taxa de cadastro percebida durante a segunda fase.

Tabela 7 – Resumo dos dados analisados – usuários de outras cidades

	Fase 1	Fase 2	Fase 3
	Sem incentivo		
Período considerado para coleta de dados	De 17/5 a 7/6	De 8/6 a 30/6	De 27/8 a 11/9
Média de cadastro/semana	3,33	3	3,66
Média de avaliações com notas/usuário	47,7	78,89	51,1
Esparsidade da matriz	69,07%	47,89%	65,87%
% de usuários que optaram por avaliar filmes de todos os gêneros	10%	22,22%	18%

Hipótese 2: *O HYRIWYG faz com que as pessoas avaliem mais honestamente do que quando o incentivo concedido é aberto.*

Procuramos com essa hipótese investigar alterações de comportamento que podem sugerir uma maior qualidade das avaliações submetidas ao SR. Uma das informações analisadas foi o tempo gasto pelos usuários no preenchimento do formulário que contém os 30 primeiros filmes listados para avaliação. Acreditamos que quanto maior o tempo despendido, maior a atenção e interesse do usuário em colaborar com o sistema.

A Tabela 8 mostra o tempo médio gasto na avaliação dessa primeira listagem. Para cada usuário, contamos o tempo do momento em que a página foi carregada até submissão das avaliações para o sistema. Os usuários que não avaliaram nenhum filme não foram considerados. Para evitar distorções na amostra, definimos um tempo máximo permitido de 9 minutos para o preenchimento do formulário, pois acreditamos que tempos maiores que este podem sinalizar que o usuário abandonou o computador ou teve dificuldades em operá-lo. Não realizamos nenhum estudo específico para determinar esse tempo. Apenas efetuamos uma busca na base de dados e constatamos que a grande maioria dos usuários preencheu o formulário de avaliação dentro do

intervalo estabelecido. Apenas dois usuários registraram tempos de sessão muito superiores a 9 minutos, o que nos levou a considera-los como ruído na amostra.

Tabela 8 – Tempo médio de sessão da primeira página de avaliações

	Fase 1	Fase 2	Fase 3
Usuários de Juiz de Fora	162s	146.7s	205.8s

Podemos notar que o tempo em média gasto pelos usuários de Juiz de Fora durante a fase de aplicação do HYRIWYG (205.8 segundos) foi bem maior que as demais fases, especialmente a fase 2, caracterizada pelo incentivo aberto. A diferença chegou a quase 1 minuto, o que corresponde a um acréscimo de 40% do tempo gasto durante a terceira fase.

Esses resultados insinuem que associar as locações oferecidas às avaliações fornecidas aumenta o comprometimento dos usuários em avaliar com mais atenção os filmes do sistema.

Também analisamos a opinião dos usuários a respeito das recomendações geradas. Um alto índice de satisfação sinaliza que as avaliações dos usuários que colaboraram com o sistema foram honestas em sua maioria.

Para essa análise, comparamos as notas atribuídas a cada recomendação recebida. Essas notas representam o quanto um usuário concordou com o filme sugerido. O sistema desenvolvido recomenda apenas os filmes cuja nota inferida para um usuário é maior ou igual a 4 em uma escala discreta de 0 a 6. Assim, um usuário que avalia a sugestão recebida com uma nota superior a 3 está em concordância com a inferência do sistema.

Separamos em outra base de dados o conjunto de avaliações fornecidas pelos usuários cadastrados durante a segunda fase do experimento. As recomendações inferidas para esses usuários foram extraídas dessa base de dados particular. Desta forma, evitamos que as avaliações fornecidas durante os períodos livres de incentivo influenciassem a geração das recomendações.

Essa base de dados é composta pelas avaliações de 48 usuários, um número pequeno de cadastros para que o algoritmo desenvolvido possa correlacionar usuário-a-usuário e construir boas vizinhanças através do coeficiente de Pearson. Mesmo assim, mostramos na Figura 31 um comparativo de como os usuários avaliaram as sugestões do sistema. Nesta análise, não consideramos o período da fase 3, pois os usuários desta fase foram convidados a avaliar o filme recomendado no ato da devolução da locação grátis.




Figura 31 – Avaliação das recomendações geradas pelo sistema

Observamos que a quantidade de avaliações positivas sobre as recomendações geradas foi muito semelhante nos dois conjuntos de dados analisados. 60,81% das avaliações

foram maiores ou igual a 4 durante os períodos sem incentivo, enquanto que esse número ficou em 59,46% durante a fase 2.

Esperávamos que esse percentual fosse consideravelmente menor durante a fase 2, entretanto, alguns fatores podem ter contribuído para a não obtenção do resultado esperado. São eles:

1. A amostra de 48 usuários cadastrados durante a fase 2 não foi representativa o suficiente;
2. A pouca quantidade de filmes cadastrados no sistema não permitiu uma maior personalização da recomendação gerada;
3. O incentivo oferecido não foi suficientemente bom para fazer com que parte dos avaliadores fossem desonestos em suas avaliações. Espera-se que, quanto melhor o incentivo, maior a ocorrência de avaliações desonestas, podendo ser representadas nesta pesquisa pela baixa quantidade de filmes avaliados como “Não vi”.

Esse último fator pôde ser percebido pela quantidade de filmes avaliados como “Não vi” durante a segunda fase, equivalente a 40,1% dos filmes avaliados. Surpreendentemente, esse número foi superior à média geral do sistema, que é de 36,2%. Para o cálculo dessa média, consideramos todos os usuários cadastrados nos períodos livres de incentivo, independentemente da cidade de origem.

Apesar de desejável, não foi possível repetir o mesmo processo de criação de uma base de dados particular para fase 3 devido ao número ainda mais reduzido de cadastros: apenas 21. Optamos em fazer a união do conjunto de avaliações fornecidas durante a terceira fase com o conjunto de avaliações coletadas durante os demais períodos livres de incentivo. Assim, as

recomendações geradas para os usuários cadastrados no período da fase 3, assim como em todos os demais (exceto fase 2), foram inferidas a partir de uma mesma base de dados.

A baixa qualidade do incentivo concedido também pôde ser percebida durante as duas últimas fases. Menos da metade dos usuários que avaliaram pelo menos 40 filmes foram às locadoras para resgatar os filmes recomendados na fase 3. Dos 17 usuários aptos a efetuar locações gratuitas, apenas 7 realmente o fizeram.

A fim de investigar o motivo pelo qual os demais usuários não fizeram uso das locações recebidas, enviamos uma mensagem por e-mail a todos eles solicitando que nos respondessem com uma das 3 afirmações mostradas na Figura 32. A distribuição das respostas é apresentada na Figura 33.

- A) Gostei das recomendações, mas não as resgatei porque não tive tempo.
 - B) Gostei das recomendações, mas não as resgatei porque as locadoras ficam longe da minha casa.
 - C) Não resgatei as locações porque não gostei dos filmes recomendados.

Figura 32 – Questionário enviado a todos os usuários que não resgataram o filme recomendado




Figura 33 – Distribuição das respostas dos usuários

Mesmo durante a fase 2, quando os usuários ganhadores puderam escolher livremente os filmes a serem alugados, 44.7% dos participantes não usufruíram das locações a que tinham direito. Esse dado denota que o incentivo concedido pelo experimento não foi suficientemente bom para motivar os participantes a irem às locadoras.

Ainda sobre os 17 usuários contemplados durante a terceira fase, dois deles avaliaram mais de 250 filmes com uma nota, como pode ser percebido no gráfico da Figura 22. Para esses usuários, o SR não foi capaz de gerar boas recomendações, visto que ambos avaliaram quase a totalidade dos filmes disponíveis. Assim, excepcionalmente para esses usuários, foi permitida a livre escolha dos filmes a serem alugados (6 locações gratuitas para cada um). No entanto, a exemplo dos outros usuários contemplados na mesma fase, estes também foram convidados a avaliar o filme alugado no ato da devolução.

Apesar de terem a liberdade de escolher o filme desejado, esses dois usuários avaliaram positivamente apenas metade dos filmes alugados. Em contrapartida, os cinco usuários que efetuaram as locações determinadas pelo SR avaliaram positivamente todas as sugestões inferidas (16 no total).

Apesar de pequena, essa amostra nos permite ressaltar o valor dos Sistemas de Recomendação em auxiliar as pessoas a realizarem as escolhas acertadas. Além disso, o alto grau de satisfação dos cinco usuários a cerca das recomendações geradas sugere a predominância de informações fidedignas na base de dados do SR.

5.7. Conclusões

Os dados analisados demonstram o potencial do mecanismo de incentivo HYRIWYG em aumentar o número de avaliações fornecidas pelos usuários sem promover a ocorrência de comportamentos que sugerem falsas avaliações. Entretanto, os resultados deste estudo foram mais sugestivos do que conclusivos. Faz-se necessário então, ressaltar algumas limitações da pesquisa e suas respectivas implicações nos resultados obtidos.

A primeira delas diz respeito à quantidade de usuários participantes do experimento. Apesar da página principal do Cinefilia ter em média 4300 impressões mensais, boa parte desses acessos são de visitantes fidelizados que têm o hábito de visitar regularmente o sítio. Além disso, muitos desses visitantes já estavam cadastrados no SR antes dos períodos de coleta de dados considerados. A característica local do sítio em ter parte de suas ações voltadas para atender aos usuários de Juiz de Fora, uma cidade de porte médio com menos de 500 mil habitantes [30], também contribuiu para limitar a população do experimento.

A escolha das locadoras parceiras também exerceu influência na quantidade de participantes. Apesar de estarem situadas em 4 bairros diferentes, abrangendo uma grande parte da região central de Juiz de Fora (área de maior densidade populacional [30]), os usuários que residem em outras regiões encontraram na localização das videolocadoras um obstáculo para colaborarem com o sistema em troca dos incentivos. Em alguns casos, não é compensatório para um usuário efetuar o resgate de uma locação devido aos custos de deslocamento até a videolocadora parceira.

Dessa forma, a qualidade do incentivo concedido também foi um fator limitador. Muitos visitantes do sítio possuem interesse apenas em ler a análise dos filmes e consultar a

programação das salas de cinema, não se interessando em colaborar com o sistema de recomendação. Para esses usuários, os incentivos não foram suficientemente bons para convencê-los a se cadastrar e avaliar o mínimo de 40 filmes. Acreditamos que a amostra dos dados poderia ser mais representativa se a quantidade mínima de avaliações necessárias para que um usuário recebesse uma locação fosse reduzida, ou então, se os usuários fossem presenteados com DVDs em troca de um maior número de avaliações.

Questões de projeto do SR desenvolvido também podem ter contribuído para uma redução de comportamentos desonestos. As informações sobre o funcionamento do sistema na página que antecedia o cadastro dos usuários fizeram com que o SR não fosse considerado uma “caixa preta” pelos avaliadores. Segundo [28], as explicações ajudam o usuário a entender o processo de recomendação da FC. Até o período de início da fase 1, o sistema exibia, em conjunto com a recomendação gerada, o valor do grau de correlação do usuário ativo com o seu vizinho mais próximo. O sistema ainda explicava que, quanto maior fosse o valor apresentado, maior seria a chance do usuário gostar da recomendação recebida. A transparência no processo de recomendação faz com que os usuários submetam suas avaliações com mais responsabilidade, ao invés de darem “tiros no escuro” [52].

Apesar das limitações apresentadas, os resultados obtidos mostram a viabilidade real das hipóteses levantadas. Superada essas limitações, novos estudos podem apresentar resultados conclusivos.

6. Conclusões e Trabalhos Futuros

O interesse no desenvolvimento de Sistemas de Recomendação tem crescido, em especial pelos sítios de comércio eletrônico. Esses sistemas também têm chamado atenção em novas áreas de pesquisa, como a Web Semântica [21;23], a Computação Pervasiva [36] e a TV Digital Interativa [54]. A primeira tem contribuído através da estruturação de linguagens baseadas em XML que visam permitir a criação de uma rede de confiança global. Essa rede poderia ser compartilhada por diferentes Sistemas de Recomendação on-line para inibir a atuação de avaliadores mal intencionados. *Chips* inteligentes em eletrodomésticos como fornos de microondas e geladeiras também poderiam fornecer informações sobre os hábitos de consumo de seus proprietários, abrindo uma grande área para a exploração de técnicas de personalização. De forma similar, emissoras digitais poderiam oferecer programas de TV de acordo com as preferências individuais dos telespectadores.

Atualmente, muitos trabalhos são desenvolvidos no sentido de apresentar novas abordagens híbridas de filtragem de informação, novos estudos de interface, novos algoritmos etc. Entretanto, incentivar os usuários a contribuir com avaliações verdadeiras está além destas questões. Esse é um problema substancial, uma vez que os usuários precisam dedicar parte do seu tempo e atenção em uma tarefa que beneficiará, principalmente, aos outros usuários do sistema [17].

A presença de avaliações desonestas também afeta a confiabilidade das recomendações geradas por um SR. Uma vez que na FC as recomendações são baseadas nas avaliações fornecidas por um conjunto de usuários, os recomendadores podem se aproveitar deste

fato e deliberadamente fornecer falsas avaliações a fim de promover ou prejudicar determinado produto.

Na tentativa de minimizar esses problemas, diversas estratégias são propostas para incentivar os usuários a colaborarem fornecendo avaliações de qualidade. Para serem bem sucedidas, a maioria delas necessita que os recomendadores possuam um relacionamento de longo prazo com o sítio, incorporando sistemas complementares aos Sistemas de Recomendação.

O mecanismo HYRIWYG é uma proposta para motivar os usuários de um SR a, voluntariamente, fornecerem avaliações honestas, de forma rápida e em grande quantidade, podendo ser facilmente implementado em sistemas colaborativos sem alterar suas características originais.

A *regra de resgate* do HYRIWYG tem como objetivo evitar que os usuários honestos, porém desmotivados, comecem a ser desonestos em suas avaliações apenas para acumular os incentivos. Desta forma, o mecanismo tenta garantir que os usuários honestos permaneçam honestos e colaborem com um maior número de avaliações. Com isso, a proporção de avaliações verdadeiras se torna maior, fazendo com que as avaliações intencionalmente desonestas sejam interpretadas como “ruído” em relação ao total de avaliações submetidas ao sistema.

Apesar de teoricamente funcional, o modelo proposto pelo HYRIWYG ainda não foi testado na prática. Dessa forma, propomos um estudo de caso para investigar o impacto de sua utilização por agentes humanos. Para isso, levantamos duas hipóteses:

Hipótese 1: O HYRIWYG faz com que a quantidade de avaliações fornecidas ao SR seja maior do que quando nenhum incentivo é concedido aos usuários.

Hipótese 2: O HYRIWYG faz com que as pessoas avaliem mais honestamente do que quando o incentivo concedido é aberto.

Para verificar as hipóteses levantadas, construímos nosso próprio Sistema de Recomendação e o disponibilizamos para uso público na Web. Em seguida, comparamos o comportamento dos usuários ao interagir com o SR desenvolvido em três momentos distintos: (i) quando nenhum incentivo é concedido para motivá-los; (ii) quando são concedidos incentivos abertos e (iii) quando o HYRIWYG é implantado.

Destacamos, então, nosso esforço em realizar um estudo pioneiro com usuários reais em um cenário real de aplicação. Além disso, o desenvolvimento de um SR próprio nos permitiu aprender bastante sobre o funcionamento desse tipo de sistema, das possíveis formas de implementação a questões relativas à interface.

6.1. Contribuições da Pesquisa

Verificamos que os avaliadores de produtos na web são suscetíveis a incentivos. Verificamos também que o experimento é sensível aos valores dos parâmetros. Por fim, os resultados apresentados não só mostram que as hipóteses levantadas são factíveis, como também apontam os potenciais benefícios que podem ser obtidos com a aplicação do mecanismo HYRIWYG. São eles:

- **Redução do problema da falta de motivação.** Os incentivos concedidos são um estímulo à colaboração com o sistema. Os usuários percebem de imediato que podem

tirar proveito das vantagens oferecidas em troca da avaliação de muitos itens, sendo motivados a realizar uma tarefa antes considerada desinteressante.

- **Redução do problema do “carona”.** A *função de compensação* aliada à *regra de resgate* incentiva os usuários a contribuírem com ações que beneficiarão, além deles próprios, a todos os demais usuários do sistema. Os experimentos mostraram o aumento do tempo médio gasto pelos usuários na avaliação dos filmes quando o HYRIWYG foi implementado. Isso demonstra uma maior atenção e interesse dos usuários em fornecer avaliações ao SR.
- **Matriz de avaliação menos esparsa.** Com a redução do problema da falta de motivação, a quantidade de itens avaliados por cada usuário tende a crescer. Os usuários sabem que quanto mais itens forem avaliados, maior a quantidade de incentivos acumulados. Os resultados mostraram a redução da esparsidade dos dados nas fases em que os incentivos foram concedidos.
- **Satisfação com a recomendação recebida e predominância de avaliações honestas.** A importância dos Sistemas de Recomendação em auxiliar os usuários a realizarem escolhas acertadas foi constatada pela quantidade de filmes avaliados positivamente quando sugeridos pelo HYRIWYG em comparação com a quantidade de filmes avaliados positivamente quando escolhidos livremente pelos usuários. Os participantes do experimento se mostraram satisfeitos com todas as recomendações realizadas pelo HYRIWYG, o que sugere a predominância de informações confiáveis submetidas ao SR.

6.2. Limitações

A distribuição restrita de incentivos apenas a usuários residentes na cidade de Juiz de Fora se mostrou uma das maiores limitações desse estudo. Essa restrição, em conjunto com o baixo valor agregado ao incentivo concedido, contribuiu para que a quantidade de usuários ficasse abaixo da desejada.

Em sua maioria, as limitações discutidas neste trabalho se deveram à falta de financiamento para arcar com os custos relativos à cessão dos incentivos, representados nesta pesquisa pelas locações grátis de filmes. Acreditamos que, se fossem oferecidos mais incentivos aos usuários, ou incentivos com maior valor agregado, os resultados poderiam ter sido mais expressivos. A extensão dos incentivos a outras cidades brasileiras também seria de fundamental importância para o aprimoramento dos resultados.

No entanto, inerente a essas limitações, percebemos que a implantação do HYRIWYG não soluciona os seguintes problemas:

- **O problema da Primeira Avaliação.** Apesar do HYRIWYG prever uma forma de aumentar o valor do incentivo quanto mais cedo um novo item disponibilizado no SR for avaliado, essa abordagem não soluciona o problema em questão. A implantação do HYRIWYG apenas faz com que haja uma redução de tempo entre a disponibilização de um novo item no sistema e a sua efetiva recomendação para a comunidade.
- **Pessoas mal intencionadas.** O HYRIWYG se mostra ineficiente no combate às avaliações deliberadamente desonestas, submetidas por usuários mal intencionados ou com interesses particulares, como aquelas fruto de ataques a Sistemas de

Recomendação. Conforme discutido em [29], o homem pode destruir qualquer processo que tente garantir a confiabilidade em sistemas, se for do interesse dele.

A implantação do HYRIWYG também não é recomendada para promover avaliações honestas de pessoas em vez de produtos. O medo de ter sua reputação mal avaliada como forma de retaliação por ter submetido avaliações negativas faz com que usuários sobrecarreguem o sistema com avaliações positivas. A ausência de diversidade de opiniões não permite que a utilização do HYRIWYG tenha a performance desejada.

6.3. Lições Aprendidas

O Sistema de Recomendação de Filmes utilizado em nosso estudo foi integrado ao sítio Cinefilia em dezembro de 2004. Da sua publicação no sítio até o início do período de coleta de dados, realizamos alguns experimentos isolados que nos ajudaram a preparar melhor o sistema para a realização do estudo de caso apresentado.

O primeiro desses experimentos consistiu em distribuir ingressos de cinema para os 10 usuários que mais avaliaram filmes com uma nota. Os ingressos, válidos em qualquer cinema do país, foram oferecidos por uma distribuidora para promover lançamentos de filmes específicos. A cada semana, os 10 usuários mais participativos eram contemplados, independentemente da cidade de origem de cada um.

Depois de três semanas de realização desse experimento, observamos um comportamento curioso: após a primeira distribuição de ingressos, os usuários não contemplados forneciam suas avaliações ao sistema com menos frequência que os usuários ganhadores. Estes, motivados pelo ingresso recebido, criaram o hábito de acessar o SR regularmente, pois nesse

período ainda estávamos cadastrando os filmes no sistema e, semanalmente, novos filmes eram disponibilizados para avaliação.

No início de cada semana, quando a distribuição dos ingressos era realizada, ao investigar quais eram os usuários que mais avaliavam filmes, apenas os usuários contemplados na distribuição de ingressos da semana anterior ou os usuários recém-cadastrados eram listados pelo sistema. Ou seja, os usuários que passaram pela decepção de não serem contemplados com os ingressos anunciados foram desmotivados a continuar colaborando com o SR.

Em seguida, um segundo experimento foi realizado, desta vez voltado apenas para os usuários da cidade de Juiz de Fora: oferecemos um ingresso de cinema de cortesia para cada 50 filmes avaliados com uma nota. Para isso, firmamos uma parceria com uma empresa de cinema local. O cinema parceiro possui duas salas que exibem uma média de quatro filmes diferentes por semana. É importante ressaltar que Juiz de Fora conta com nove salas de exibição ao todo, divididas entre três empresas. Assim, esse experimento cobriu 22% das salas de exibição da cidade. O usuário contemplado pôde escolher qual filme assistir entre os que estavam em cartaz no cinema conveniado.

Analisando os perfis dos usuários durante o período de realização dos dois experimentos relatados acima, alguns comportamentos que sugerem falsas avaliações foram detectados, como, por exemplo, a existência de usuários que forneceram a mesma nota a todos os filmes ou avaliações realizadas em curtos intervalos de tempo.

O gráfico da Figura 34 mostra a distribuição da quantidade de notas submetidas pelos usuários de Juiz de Fora durante as primeiras 17 semanas de operação do SR.




Figura 34 – Distribuição das notas submetidas pelos primeiros usuários de Juiz de Fora cadastrados

Esses experimentos nos mostraram que era factível seguirmos em frente com nossa pesquisa, pois constatou-se que o oferecimento de incentivos realmente influenciava o comportamento dos usuários ao interagir com o sistema. Entretanto, optamos por abandonar a distribuição de ingressos de cinema como forma de incentivo devido à restrição de filmes que poderiam ser oferecidos aos usuários. Essa restrição seria uma barreira à utilização do SR para inferir quais filmes o usuário poderia assistir com o ingresso de cortesia recebido. Optamos então por adotar locações gratuitas como forma de incentivo.

Algumas questões de projeto também merecem ser discutidas. Por exemplo, o sistema implementado não seleciona de forma aleatória os filmes que serão exibidos para a avaliação dos usuários, seguindo sempre a ordem em que foram cadastrados no sistema. Assim, o filme *Blade Runner* é sempre o primeiro filme disponibilizado para avaliação para os usuários que declaram gostar de filmes do gênero “ficção científica”.

Essa simplificação adotada no projeto de implementação fez com que os últimos filmes cadastrados no SR tivessem menos chances de serem avaliados e recomendados para os usuários. A Figura 35 mostra a distribuição das notas recebidas por cada filme, do 1º ao 300º cadastrado.

Alguns vales percebidos no gráfico, como nas proximidades do 20º e 110º filme, representam filmes que receberam uma quantidade de avaliações abaixo da média. Em sua maioria são filmes do gênero “musical” ou “documentário”, que não fazem parte da lista de preferências da maioria dos usuários. Apenas a título de curiosidade, o filme mais assistido pelos usuários foi “O Sexto Sentido”, que foi o 6º filme cadastrado no sistema.




Figura 35 – Distribuição das avaliações recebidas por cada filme

Também percebemos que a quantidade de filmes cadastrados deve ser aumentada, pois vários usuários avaliaram com uma nota todos os 300 filmes disponíveis no sistema. Como consequência, a geração de recomendações para esses usuários se tornou impossível. Essa

situação não é comum em Sistemas de Recomendação, em que normalmente existem muitos mais itens cadastrados do que um usuário é capaz de avaliar.

Outra questão constatada em nosso estudo foi a necessidade de pré-processamento off-line da matriz de similaridade. Conforme discutido no Capítulo 2, essa matriz é o resultado da aplicação da correlação de Pearson em todas as possíveis duplas de perfis cadastrados. Ao final da nossa pesquisa, 545 usuários estavam cadastrados em nossa base de dados, o que implicava no cálculo de 148.785 correlações. Cada correlação calculada envolve várias consultas ao banco de dados, o que contribui para aumentar o custo computacional do algoritmo de geração da matriz. Para essa quantidade de usuários, o processo de construção da matriz gastava em torno de 25 minutos quando executada em uma máquina AMD Athlon™ 2400 com 256MB de memória RAM.

Uma das políticas de segurança adotada pelos provedores de hospedagem consiste em interromper a execução de qualquer aplicação que exceda o tempo de 30 segundos. Isso nos forçou a, diariamente, fazer um *backup* de toda a base de dados on-line para uma máquina local, e então calcular a matriz de similaridade nesta máquina off-line. O resultado gerado pelo nosso algoritmo é a matriz representada em um arquivo texto do tipo CSV, que depois de construído era transferido para uso do SR on-line.

Para evitar o trabalho de, respectivamente, fazer o *download* da base de dados, gerar a matriz de similaridade e fazer o *upload* dos resultados, aconselhamos que os Sistemas de Recomendação disponibilizados na web sejam implantados em servidores dedicados, onde temos autonomia para configurar o tempo máximo permitido para a execução de uma aplicação. Independente desta questão, é inviável a construção da matriz de similaridade a cada pedido de

recomendação de um usuário. A solução que adotamos foi a de pré-processar a matriz uma vez ao dia. Desta forma, um usuário recém cadastrado em nosso sistema e que avaliou uma quantidade de filmes superior ao mínimo estipulado só pode receber as primeiras recomendações 24 horas após o seu cadastro, quando a matriz, considerando o seu perfil, for calculada.

6.4. Trabalhos Futuros

Atualmente estamos à procura de empresas parceiras que viabilizem a realização de novos experimentos em várias cidades brasileiras simultaneamente. A negociação com uma grande empresa do setor de entretenimento já foi iniciada. Para os novos experimentos, pretendemos:

- Testar várias configurações diferentes das variáveis de medição, tais como a da variação do valor da constante C ;
- Desenvolver outro Sistema de Recomendação e disponibilizá-lo em um sítio que não possua segmentação de conteúdo;
- Cadastrar um número maior de filmes na base de dados e implementar a aleatoriedade da seleção para diminuir a concentração de avaliações nos primeiros filmes cadastrados.

Com essas ações, esperamos melhorar a qualidade das recomendações geradas e atrair maior quantidade de usuários para o nosso sistema, aumentando substancialmente o volume de dados coletados. Os novos resultados obtidos serão publicados em trabalhos futuros.

7. Referências Bibliográficas

- [1] Amazon.com. **Frequently Asked Questions - Amazon.com Services**. 2005. Disponível em: <<http://www.amazon.com>> Consultado em 24/9/2005
- [2] Arremate.com. **Políticas, Normas e Segurança - A reputação dos usuários**. Disponível em: <<http://www.arremate.com.br/gen/ajuda/politicas/politicas/calificaciones.html>> Consultado em: 24/9/2005
- [3] BALABANOVIC, M. e SHOHAM Y. **Fab: content-based, collaborative recommendation**, Communications of the ACM, v.40 n.3, p.66-72, 1997
- [4] BERNERS-LEE, T.; HENDLER, J.; LASSILA, O. **The Semantic Web**. Scientific American, 2001
- [5] CHEN, M.; SINGH, J.P. **Computing and using reputations for internet ratings**. Proceedings of the 3rd ACM conference on Electronic Commerce, October 2001
- [6] CHIN, R.; TULEY, J. e LOTTES, J. **Music Recommendation System for iTunes**. University of Illinois (Champaign-Urbana), 2004. Disponível em: <<http://music.cs.uiuc.edu/about.php>> Consultado em: 10/10/2005
- [7] CHIRITA, P.; NEJDL, W.; ZAMFIR, C. **Preventing shilling attacks in online recommender systems**. In Proceedings of the 7th ACM Workshop on Information and Data Management, Bremen, Alemanha, 2005
- [8] CHOPRA, K.; WALLACE, W.A. **Trust in Electronic Environments**. In 36th Annual Hawaii International Conference on System Sciences (HICSS'03), pág. 331--340, Big Island, Hawaii, Janeiro, 2003
- [9] CIUFFO, L. N. et al. **Cinefilia**. Disponível em: <<http://www.canalcinefilia.com.br>> Consultado em: 27/02/2005

- [10] CLAYPOOL, M.; GOKHALE, A.; MIRANDA, T.; et al. **Combining Content-Based and Collaborative Filters in an Online Newspaper**. In: ACM SIGIR Workshop on Recommender Systems, Berkeley, EUA, 1999
- [11] CÖSTER, R. **The Architecture and Implementation of a System Collaborative and Content-based Filtering**. Novembro de 2002. Disponível em: <<http://www.dsv.su.se/~rick/papers/final-system.pdf>> Consultado em: 25/02/2005
- [12] CRM Tutorial. Disponível em: <<http://crmtutorial.com/CRM/CRM.aspx>> Consultado em: 2/8/2005
- [13] DELLAROCAS, C. **Immunizing Online Reputation Reporting Systems Against Unfair Ratings and Discriminatory Behavior**. Proceedings of the 2nd ACM conference on Electronic commerce. pp.150 - 157. Minneapolis, Minnesota, EUA. 2000
- [14] DOUKIDIS, G.; MYLONOPOULOS, N. and POULOUDI, N. **Building Trust Online: The Design of Robust Reputation Reporting Mechanisms in Online Trading Communities**. Idea Book Publishing, Setembro de 2003
- [15] eBay Inc. Disponível em: <<http://www.ebay.com>> Consultado em: 24/9/2005
- [16] EKSTRÖM, M.; GARCIA, A. C. B.; BJÖRNSSON, H. **HYRIWYG: Leveraging Personalization to Elicit Honest Recommendations**. Proceedings of the 5th ACM conference on Electronic commerce, New York, NY, EUA. ACM Press, 2004, Pág 232 - 233. Disponível em: <<http://portal.acm.org/citation.cfm?id=988809>> Consultado em: 25/02/2005
- [17] EKSTRÖM, M.; GARCIA, A. C. B.; BJÖRNSSON, H. **Rewarding honest ratings thought personalized recommendations in electronic commerce**. In: International Journal of Electronic Business (IJEB). 2004
- [18] Epinions, Inc. **Frequently Asked Questions - Earnings on Epinions**. Disponível em: <http://www.epinions.com/help/faq/show_~faq_earnings> Consultado em: 24/9/2005

- [19] FILHO, W.D.S. e CAZELLA, S.C. **Um Framework para recomendação de artigos científicos baseado na relevância da opinião dos usuários e em filtragem colaborativa.** São Leopoldo, 2004. 56p. Monografia (Bacharelado em Informática) - Centro de Ciências Exatas e Tecnológicas - UNISINOS
- [20] FONSECA, J. S.; MARTINS G. A.; TOLEDO L. G. **Estatística Aplicada.** 2ª edição – São Paulo: Atlas, 1985
- [21] GOLBECK, J.; HENDLER, J.; PARSIA, B. **Trust Networks on the Semantic Web.** In Proceedings of Cooperative Intelligent Agents, 2003
- [22] GOLDBERG, D; NICHOLS, D.; OKI, B.M. e TERRY, D. **Using collaborative filtering to weave an information Tapestry.** Communications of the ACM. pp.61-70, 1992. Disponível em: <<http://portal.acm.org/citation.cfm?id=138867>> Consultado em: 10/9/2005
- [23] GRANT, J. **Recommendation systems as a basis for trust in the Semantic Web.** W3C Semantic Web Advanced Development for Europe (SWAD-Europe). ILRT, University of Bristol, 2004. Disponível em: <<http://www.w3.org/2001/sw/Europe/reports/trust/11.1/recsys.html>> Consultado em: 24/9/2005
- [24] GROUPLENS RESEARCH. **MovieLens.** Hospedada pela Universidade de Minnesota, EUA. Disponível em: <<http://movielens.umn.edu>> Consultado em: 26/02/2005
- [25] HARUECHAIYASAK, C.; SHYU, M.; e CHEN, S. **A Data Mining Framework for Building A Web-Page Recommender System,** the 2004 IEEE International Conference on Information Reuse and Integration (IRI'2004), pp. 357-362, Las Vegas, Nevada, EUA, Novembro de 2004.
- [26] HERLOCKER, J.L. **Understanding and Improving Automated Collaborative Filtering Systems,** Tese de Doutorado (Doutorado em Ciência da Computação), University of Minnesota, Minnesota, 2000.

- [27] HERLOCKER, J.L.; KONSTAN, J.A.; BORCHERS, A.; RIEDL, J. **An Algorithmic Framework for Performing Collaborative Filtering**. In Proceedings of the 1999 Conference on Research and Development in Information Retrieval, 1999.
- [28] HERLOCKER, J.L.; KONSTAN, J.A.; RIEDL, J. **Explaining Collaborative Filtering Recommendations**. In Proc. of Computer Supported Cooperative Work, CSCW 2000, 2000. Disponível em: <<http://citeseer.ist.psu.edu/herlocker00explaining.html>> Consultado em: 24/9/2005
- [29] HORTON, J.L. **Reputation Systems and the Internet**. Disponível em: <http://www.online-pr.com/Holding/Reputation_Systems.pdf> Consultado em: 24/9/2005
- [30] IBGE; DPGE. **Anuário Estatístico de Juiz de Fora**, 2004. Disponível em: <http://www.pjf.mg.gov.br/acidade/documentos/pop_regiao.pdf> Consultado em: 2/8/2005
- [31] Jester: **The On-Line Joke Recommender**. Hospedado pela Universidade de Berkeley, CA, EUA. Jul. 2001. Disponível em: <<http://shadow.ieor.berkeley.edu/humor/>> Consultado em: 13/06/2005
- [32] LAM, S.K.; e RIEDL, J. **Shilling recommender systems for fun and profit**. In WWW'04: Proceedings of the 13th international conference on World Wide Web, pp. 393–402, New York, NY, EUA, 2004. ACM Press.
- [33] LINDEN, G.; SMITH, B.; YORK, J. **Amazon.com Recommendations: Item-to-Item Collaborative Filtering**. IEEE Internet Computing, pp.76-80, Fevereiro de 2003.
- [34] MASSA, P.; AVESANI, P.; TIELLA, R. **A Trust-enhanced Recommender System application: Moleskiing**. In ACM Symposium on Applied Computing, 2005.
- [35] MASSA, P.; BHATTACHARJEE, B. **Using trust in recommender systems: an experimental analysis**. Proceedings of 2nd International Conference on Trust Managment, Oxford, England, 2004.

- [36] McDONALD, D.W. **Ubiquitous Recommendation Systems**. IEEE Computer, Outubro de 2003, pp. 111-112. Disponível em:
<<http://www.ischool.washington.edu/mcdonald/papers/McDonald.IEEECComputer.pdf>>
Consultado em: 24/9/2005
- [37] MercadoLivre Brasil. **Perguntas – Qualificações**. Disponível em:
<http://www.mercadolivre.com.br/brasil/ml/org_ayuda.main?as_faq_id=491> Consultado em: 24/9/2005
- [38] MUI, L.; SZOLOVITS, P.; ANG, C. **Collaborative sanctioning: applications in restaurant recommendations based on reputation**. Proceedings of the fifth international conference on Autonomous agents, Maio de 2001.
- [39] O'DONOVAN, J.; SMYTH, B. **Trust in recommender systems**. Proceedings of the 10th international conference on Intelligent user interfaces, Janeiro de 2005.
- [40] PAZZANI, M. J. **A Framework for Collaborative, Content-based and Demographic Filtering**. Universidade da Califórnia, Irvine, CA, EUA, 1999. Disponível em:
<<http://www.ics.uci.edu/~pazzani/Publications/AIREVIEW.pdf>> Consultado em: 25/04/2005
- [41] RAETENGUI, E.B. e CAZELLA, S.C. **Sistemas de Recomendação**. XXV Congresso da Sociedade Brasileira da Computação, V ENIA. São Leopoldo, RS, 2005. Disponível em:
<http://www.addlabs.uff.br/enia_site/dw/sistemasrecomendacao.zip> Consultado em: 10/9/2005
- [42] Rating Zone. Disponível em: <<http://www.ratingzone.com>> Consultado em: 15/06/2005
- [43] RESNICK, P.; IACOVOU, N.; SUCHAK, M.; BERGSTROM, P.; RIEDL, J. **GroupLens: an open architecture for collaborative filtering of netnews**. Proceedings of the 1994 Conference on Computer Supported Cooperative Work (CSCW'94), Chapel Hill, NC, EUA. ACM Press, Pág. 175 – 186. Disponível em:

<<http://www.acm.org/pubs/citations/proceedings/cscw/192844/p175-resnick/>> Consultado em: 24/02/2005

- [44] RESNICK P.; VARIAN, H.R. **Recommender systems**. Communications of the ACM, Vol. 40, No. 3, pp.56-58, 1997.
- [45] RESNICK, P.; ZECKHAUSER, R.; FRIEDMAN, E.; KUWABARA, K. **Reputation Systems: Facilitating Trust in Internet Interactions**. Communications of the ACM, 43(12), 2000. Disponível em: <<http://www.si.umich.edu/~presnick/papers/cacm00/>> Consultado em: 24/02/2005
- [46] SARWAR, B.; KARYPIS, G.; KONSTAN, J.; e RIEDL, J. **Item-based Collaborative Filtering Recommendation Algorithms**. In Proc. of the 10th International World Wide Web Conference (WWW10), Hong Kong, May 2001. Disponível em: <http://www.grouplens.org/papers/pdf/www10_sarwar.pdf> Consultado em: 10/9/2005
- [47] SAUNDERS, C.; WU, Y.A.; LI, Y.; WEISFELD, S. **Interorganizational Trust in B2B Relationships**. Proceedings of the 6th international conference on Electronic commerce, Março de 2004.
- [48] SCHAFER, J.B.. **MetaLens: A Framework for Multisource Recommendations**. Tese de Doutorado. University of Minnesota, Minnesota, 2001. Disponível em: <<http://www.cs.uni.edu/~schafer/research.htm>> Consultado em: 10/09/2005
- [49] SCHAFER, J. B., KONSTAN, J., RIEDL, J. **Recommender systems in ECommerce**. In Proceedings of the ACM Conference on Electronic Commerce (EC'99), pp.158-166, Nova York., EUA, 1999
- [50] SHARDANAND, U. **Social Information Filtering for Music Recommendation**. Massachusetts Institute of Technology, 1994.
- [51] SHARDANAND, U.; MAES, P. **Social information filtering: Algorithms for automating "word of mouth."** In Conference on Human Factors in Computing Systems - CHI'95. Denver, EUA, 1995.

- [52] SINHA, R.; SWEARINGEN, K.; **The Role of Transparency in Recommender Systems**. In Conference on Human Factors in Computing Systems, 2002, Minneapolis, Minnesota, EUA. Disponível em: <http://www.rashmisinha.com/articles/MusicCHI_RSFinal.pdf> Consultado em: 2/8/2005
- [53] SWEARINGEN, K.; SINHA, R. **Beyond algorithms: An HCI perspective on recommender systems**. in ACM SIGIR 2001 Workshop on Recommender Systems, New Orleans, Louisiana, EUA, 2001.
- [54] TORRES, R. D. **Personalização na Internet** – Como Descobrir Hábitos de Consumo de seus Clientes, fidelizá-los e Aumentar o Lucro de seu Negócio. São Paulo: Novatec Editora, 2004.
- [55] TV Juiz de Fora Ltda. (TV Panorama). Disponível em: <<http://www.ipanorama.com>> Consultado em: 2/8/2005
- [56] WIKIPEDIA. **The Free Encyclopedia**. Agosto de 2005. Disponível em: <http://en.wikipedia.org/wiki/Recommendation_systems> Consultado em: 10/10/2005
- [57] YU, K.; XU, X.; ESTER, M.; KRIEGL, H. **Selecting relevant instances for efficient and accurate collaborative filtering**. Proceedings of the 10th International Conference on Information and knowledge Management (CIKM'01), Atlanta, Georgia, EUA. ACM Press, pp. 239 – 246. Disponível em: <<http://portal.acm.org/citation.cfm?id=502626>> Consultado em: 25/02/2005
- [58] PEREIRA A. C. et al. **MedStatWeb - Manual de Estatística Médica**. Faculdade de Medicina da Universidade do Porto. Portugal. Disponível em: <http://stat2.med.up.pt/cursop/glossario/correlacao_Pearson.html> Consultado em: 18/11/2005
- [59] PAPAGELIS, M.; PLEXOUSAKIS, D. e KUTSURAS T. **Alleviating the Sparsity Problem of Collaborative Filtering Using Trust Inferences**. In Proceedings of I-Trust. Paris, França, 2005. Disponível em: <http://www.ics.forth.gr/isl/publications_index.jsp> Consultado em: 18/11/2005

- [60] SARWAR B.; KARYPIS G.; KONSTAN J. e RIEDL J. **Application of Dimensionality Reduction in Recommender System - A Case Study**. In ACM WebKDD Workshop, 2000. Disponível em: <<http://citeseer.ist.psu.edu/sarwar00application.html>> Consultado em: 18/11/2005
- [61] TORRES, R. D. **Combining Collaborative and Content-based filtering to recommend Research Papers**. Dissertação de Mestrado (Mestrado em Ciência da Computação). Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2004.
- [62] BURKE, R. **Hybrid Recommender Systems: survey and experiments**. In User Modeling and Users-adapted Interaction, UMUAI02, pp. 331-370, 2002.

Anexo A

Lista dos filmes cadastrados no Sistema de Recomendação

1. 007 - Um Novo Dia para Morrer
2. 13 Fantasma
3. 2010 - O Ano Em Que Faremos Contato
4. 21 Gramas
5. 8 Mile - Rua das Ilusões
6. 8 mulheres
7. A Bruxa de Blair
8. A cartada final
9. A Casa de Vidro
10. A Corrente do Bem
11. A Dona da História
12. A Era do Gelo
13. À Espera de Um Milagre
14. A Família da Noiva
15. A Fuga das Galinhas
16. A Gaiola das Loucas
17. A Identidade Bourne
18. A Ilha do Dr. Moreau
19. A Lenda do Tesouro Perdido
20. A Liga Extraordinária
21. A Lista de Schindler
22. A Máfia Volta ao Divã
23. A Mexicana
24. A Paixão de Cristo
25. A Senha: Swordfish
26. A Sétima Vítima
27. A Soma de Todos os Medos
28. A Testemunha
29. A Última Ameaça
30. A Última Ceia
31. A Última Noite
32. A Última Profecia
33. A Última Tentação de Cristo
34. A Viagem de Chihiro
35. A Vida é Bela
36. A Vila
37. Adeus, Lênin!
38. Albergue Espanhol
39. Alexandre
40. Alguém Tem que Ceder
41. Alta Frequência
42. American Pie - A Primeira Vez é Inesquecível
43. Amnésia
44. Amor à Segunda Vista
45. Amor Além da Vida
46. Amores Possíveis
47. Anjos da Noite - Underworld
48. Apertem os Cintos... O Piloto Sumiu
49. Arquivo X - O Filme
50. As Bicicletas de Belleville
51. As Branqueiras
52. As Confissões de Schmidt
53. As Pontes de Madison
54. Assassinato em Gosford Park
55. Asterix e Obelix: Missão Cleópatra
56. Ata-me!
57. Atrás das Linhas Inimigas
58. Austin Powers em O Homem do Membro de Ouro
59. Batman - O Retorno
60. Beijando Jessica Stein
61. Beleza Americana
62. Benjamim
63. Billy Elliot
64. Blade 2
65. Blade Runner - O Caçador de Andróides
66. Blade Trinity
67. Bob Esponja - O Filme
68. Brigada 49
69. Brilho Eterno de uma Mente Sem Lembranças
70. Buena Vista Social Club
71. Carandiru
72. Casablanca
73. Casseta & Planeta - A Taça do Mundo é Nossa
74. Cazuza - O Tempo não Pára
75. Celular - Um Grito de Socorro
76. Central do Brasil
77. Chicago
78. Cidade de Deus
79. Cine Majestic
80. Cinema Paradiso
81. Círculo de fogo
82. Closer - Perto Demais
83. Clube da Luta
84. Códigos de Guerra

85. Colateral
86. Confissões de uma Mente Perigosa
87. Constantine
88. Contos Proibidos do Marquês de Sade
89. Contra Todos
90. Cruzada
91. Cruzeiro das Loucas
92. Dança com Lobos
93. Dança Comigo?
94. Dançando no Escuro
95. De Olhos bem Fechados
96. De Volta Para o Futuro
97. Demolidor - O Homem sem Medo
98. Deus é Brasileiro
99. Dia de Treinamento
100. Diários de Motocicleta
101. Doce Lar
102. Doce Novembro
103. Dogma
104. Dogville
105. Dom
106. Donnie Darko
107. Dormindo Com o Inimigo
108. Doze Homens e Outro Segredo
109. Dr. Dolittle
110. E.T. - O Extraterrestre
111. Eclipse Mortal
112. Edifício Master
113. EdTV
114. Edukators
115. Efeito Borboleta
116. Elefante
117. Elektra
118. Encantadora de Baleias
119. Encontro Marcado
120. Encontros e Desencontros
121. Encurralada
122. Esfera
123. Espírito Selvagem
124. Eterno Amor
125. Eu, Robô
126. Experimentando a Vida
127. Extermínio
128. Fahrenheit 11/9
129. Falcão Negro em Perigo
130. Fale com Ela
131. Femme Fatale
132. Fenômeno
133. FormiguinhaZ
134. Frida
135. Gangues de Nova York
136. Garfield
137. Garota, Interrompida
138. Gattaca - Experiência Genética
139. Gente Como a Gente
140. Gigolô por Acidente
141. Gladiador
142. Hair
143. Halloween: Ressurreição
144. Harry Potter e a Pedra Filosofal
145. Hedwig - Rock, Amor e Traição
146. Hellboy
147. Homem-Aranha 2
148. Hulk
149. Impacto Profundo
150. Indiana Jones e Os Caçadores da Arca Perdida
151. Inimigo Íntimo
152. Instinto Selvagem
153. Inteligência Artificial
154. Irmão Sol, Irmã Lua
155. Irmão Urso
156. Jason X
157. Jogos Mortais
158. Jurassic Park - O Mundo Perdido
159. K-19: The Widowmaker
160. K-Pax - O Caminho da Luz
161. Kate & Leopold
162. Kill Bill: Volume 1
163. Laranja Mecânica
164. Lavoura Arcaica
165. Legalmente Loira
166. Lilo e Stitch
167. Lisbela e o Prisioneiro
168. Lucia e o Sexo
169. Lutero
170. Madame Satã
171. Madrugada dos Mortos
172. Máquina Mortífera 2
173. Mar Aberto
174. Mar Adentro
175. Maria - Mãe do Filho de Deus
176. Maria Cheia de Graça
177. Matrix
178. Matrix Revolutions
179. Maverick
180. Menina de Ouro
181. Menina dos Olhos
182. Mens@gem Para Você
183. Minority Report - A Nova Lei


184. Mississipi em Chamas
185. Moulin Rouge - Amor em Vermelho
186. Náufrago
187. Navio Fantasma
188. Nosferatu
189. O Alfaiate do Panamá
190. O Apanhador de Sonhos
191. O Aviador
192. O Chamado
193. O Clã das Adagas Voadoras
194. O Closet
195. O Colecionador de Ossos
196. O Crime do Padre Amaro
197. O Dia Depois de Amanhã
198. O Dia do Chacal
199. O Dossiê Pelicano
200. O Exorcista
201. O Expresso Polar
202. O Exterminador do Futuro
203. O Exterminador do Futuro 3: A Rebelião das Máquinas
204. O Fabuloso Destino de Amélie Poulain
205. O Fantasma da Ópera
206. O Grito
207. O Homem Bicentenário
208. O Homem que Copiava
209. O Massacre da Serra Elétrica
210. O Óleo de Lorenzo
211. O Paciente Inglês
212. O Piano
213. O Poderoso Chefão
214. O Professor Alopardo
215. O Quarto do Pânico
216. O Quatrilho
217. O Resgate do Soldado Ryan
218. O Retorno da Múmia
219. O Senhor dos Anéis: A Sociedade do Anel
220. O Sexto Sentido
221. O Terminal
222. O Terno de 2 Bilhões de Dólares
223. O Troco
224. O Último Imperador
225. O Último Samurai
226. O Xangô de Baker Street
227. Olga
228. Ônibus 174
229. Onze Homens e um Segredo
230. Os 101 Dálmatas
231. Os Imperdoáveis
232. Os Incríveis
233. Os Normais - O Filme
234. Os outros
235. Os Queridinhos da América
236. Papai Noel às Avessas
237. Patch Adams - O Amor É Contagioso
238. Patton - Rebelde ou Herói?
239. Pearl Harbor
240. Pelé Eterno
241. Perfume de Mulher
242. Pi
243. Planeta dos Macacos
244. Pollock
245. Por um Fio
246. Prenda-me se For Capaz
247. Procurando Nemo
248. Psicose
249. Pulp Fiction - Tempo de Violência
250. Quase Dois Irmãos
251. Quero Ser John Malkovich
252. Rain Man
253. Rastros de Ódio
254. Rei Arthur
255. Réquiem para um Sonho
256. Resident Evil 2: Apocalypse
257. Revelação
258. Rios Vermelhos
259. Rock Star
260. Será Que Ele É?
261. Seven - Os Sete Crimes Capitais
262. Sexo, Amor & Traição
263. Shakespeare Apaixonado
264. Shrek 2
265. Sideways - Entre Umas e Outras
266. Simplesmente Amor
267. Sinais
268. Sobre Meninos e Lobos
269. Sociedade dos Poetas Mortos
270. Spider - Desafie sua Mente
271. Star Wars: Episódio II - Ataque dos Clones
272. Super Size Me - A Dieta do Palhaço
273. Táxi
274. Timor Lorosae - O Massacre que o Mundo Não Viu
275. Tiros em Columbine
276. Todo Poderoso
277. Tombstone - A Justiça está Chegando
278. Toy Story - Um Mundo de Aventuras
279. Traffic

- | | |
|--|---|
| 280. Tróia | 291. Veludo Azul |
| 281. U-571 - A Batalha do Atlântico | 292. Viagem ao Centro da Terra |
| 282. U.S. Marshals - Os Federais | 293. Vida Bandida |
| 283. Último Tango em Paris | 294. Vida de Inseto |
| 284. Um Dia de Fúria | 295. Violação de Conduta |
| 285. Uma Linda Mulher | 296. Vovó...Zona |
| 286. Uma Mente Brilhante | 297. Wyatt Earp |
| 287. Van Helsing - O Caçador de Monstros | 298. X-Men 2 |
| 288. Vanilla Sky | 299. Xuxa e os Duendes 2 - No Caminho das Fadas |
| 289. Velocidade Máxima | 300. Zoolander |
| 290. Velozes e Furiosos | |

Anexo B

Modelagem do Sistema de Recomendação

Diagrama de Caso de Uso



Descrição dos Casos de Uso

Caso de Uso	Resumo
Navegar pelas páginas do site	Representa as outras ações que o visitante pode realizar no site que não envolvem o Sistema de Recomendação de Filmes.
Realizar cadastro no SR	O visitante deve efetuar seu cadastro no SR antes de utilizá-lo. Para efetuar o cadastro o visitante deve informar, obrigatoriamente, seu nome, sexo, cidade e estado onde reside, endereço de e-mail e lista de gêneros preferidos. O visitante também deve definir uma senha de acesso para a sua página pessoal no SR.
Acessar página pessoal no SR	O sistema cria para cada visitante cadastrado uma página pessoal. Para acessá-la o visitante deve informar seu endereço de e-mail e a senha definida no ato do cadastro.
Avaliar filmes	Representa a lista de filmes disponíveis para avaliação. Os filmes podem variar de acordo com os gêneros preferidos de cada visitante
Solicitar recomendação	Através de sua página pessoal o visitante pode solicitar recomendações de filmes ao sistema
Avaliar recomendação	O visitante pode avaliar a recomendação inferida pelo sistema. Essa informação foi utilizada para verificar a qualidade das recomendações geradas
Registrar informações	Descreve o armazenamento das informações submetidas no Banco de Dados do SR

Diagrama de Seqüência






Diagrama de Entidade-Relacionamento



Anexo C

Interfaces do Sistema de Recomendação

Apresentamos a seguir a interface dos seguintes componentes do sistema:



index.php (tela capturada em 25/01/2005)

[JORNALISMO](#)[ESPORTES](#)[ENTRETENIMENTO](#)[APLICATIVOS](#)[TODOS OS SITES](#)[GLOBO MEDIA CENTER](#)[CENTRAL DO ASSINANTE](#)[ASSINE JÁ](#)



[Início](#)[Programação](#)[Palpites](#)[Coluna](#)[Especiais](#)[Blog](#)[Cadastro](#)[Recomendação](#)[Promoção](#)[Créditos](#)

NOS CINEMAS

CLOSER - PERTO DEMAIS



Todos os quatro personagens demonstram aspectos que são parte da natureza humana, mesmo que ninguém se orgulhe desse fato.

DOZE HOMENS E OUTRO SEGREDO



Apesar das falhas, o filme segue o que propõe. A direção de Soderbergh acopla intertextualidade a um medido senso de humor.

EDUKATORS



Tudo feito de e contrapontos contraditórios, este é, finalmente, o filme de uma geração.

CINEFILIA RECOMENDA

*email:

*senha:

[Esqueci minha senha](#)

[Ainda não sou cadastrado](#)

PROGRAMAÇÃO

Veja quais filmes estão em exibição e convide um amigo para ir ao cinema!

ESTRÉIAS DA SEMANA

- Elektra
- Desventuras em Série
- Perto Demais

[Veja a programação completa](#)

COLUNA DO PALPITEIRO

Confira o que rolou nos primeiros dias da 8ª Mostra de Cinema de Tiradentes.

[Leia a coluna](#)



ESPECIAIS

Melhores e piores de 2004



Escolha um Especial

PROMOÇÃO FOX FILM

Concorra a pares de convites do filme **Elektra**.



[Quero concorrer!](#)

[Leia o Regulamento](#)

[Resultado da promoção do novo filme da Eliana](#)

TOP 5 DVDs

Confira a lista dos DVDs mais alugados na locadora **Cinéfilos Anônimos**.



- 1 O Enviado
- 2 Shrek 2
- 3 Brilho eterno de uma mente sem lembrança
- 4 Lugares Comuns
- 5 A Confissão

OPINIÃO DOS LEITORES

Existem novas opiniões sobre os filmes:

- [Resident Evil 2: Apocalypse](#)
- [Edukators](#)
- [Edukators](#)
- [Edukators](#)

ESCOLHA SEU FILME

Busca por gênero

Busca por palpiteiro

Busca pelo título do filme ou por partes do título

DUAS CARAS

FAHRENHEIT 11/9



Um mesmo filme com opiniões diferentes!

 [Palpite 1](#)

 [Palpite 2](#)

ÚLTIMAS ATUALIZAÇÕES

- 26/01 - [Closer - Perto Demais](#)
- 21/01 - [Doze Homens e Outro Segredo](#)
- 14/01 - [Edukators](#)
- 09/01 - [O Grito](#)
- 05/01 - [A Lenda do Tesouro Perdido](#)

[Últimos 15 filmes publicados](#)

BLOG DOS PALPITEIROS

A 8ª Mostra de Cinema de Tiradentes e o troféu **Quepe do Comodoro** são alguns dos assuntos discutidos em nosso Blog.

[Entrar no Blog](#)

 Indique o 

cadastro.php

FORMULÁRIO DE CADASTRO[Política de privacidade](#)

Seus dados pessoais

*Nome completo:

*Sexo: ☐ Masculino ☐ Feminino

Nascimento: / /

*Cidade onde mora: *UF:

Dados para acessar o Sistema de Recomendação de Filmes

*Seu e-mail:

*Escolha uma senha: *Confirme a senha:

Queremos conhecer suas preferências

*Dos gêneros listados abaixo, indique os que você mais gosta:

☐ Ação	☐ Documentário	☐ Infantil	☐ Suspense	☐ Musical
☐ Aventura	☐ Drama	☐ Policial	☐ Terror	☐ Western
☐ Comédia	☐ Ficção científica	☐ Romance	☐ Guerra	☐ Filmes nacionais

Dos gêneros listados abaixo, indique aquele que você **não gosta de jeito nenhum!**

☐ Ação	☐ Documentário	☐ Infantil	☐ Suspense	☐ Musical
☐ Aventura	☐ Drama	☐ Policial	☐ Terror	☐ Western
☐ Comédia	☐ Ficção científica	☐ Romance	☐ Guerra	☐ Filmes nacionais

☐ Gostaria de receber o boletim periódico com informações sobre o site.

☒ Li e estou de acordo com a Política de Privacidade adotada pelo Cinefilia.

Continuar

entrar.php

PÁGINA DA VIVIAN

[Sair](#)

Filmes disponíveis para avaliação (clique sobre o título do filme para saber mais)

Seven - Os Sete Crimes Capitais	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
Dia de Treinamento	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
O Chamado	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
Vida Bandida	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
Vanilla Sky	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
Cinema Paradiso	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
O Fabuloso Destino de Amélie Poulain	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
Cine Majestic	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
Sideways - Entre Umas e Outras	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	
O Massacre da Serra Elétrica	☐ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☒ ☐ 0 10 Não vi	

Desmarcar
Avaliar filmes

Recomendação de Filmes

[Quero receber uma recomendação](#)

Lista dos filmes que você já avaliou (total de 75 filmes)

- [Os outros](#)
- [Gladiador](#)
- (...)
- [O Exterminador do Futuro 3: A Rebelião das Máquinas](#)
- [Planeta dos Macacos](#)

receber_recomendacao.php

http://www.canalcinefilia.com.br - Recomendação Gerada - Microso...

TRÓIA

(Troy - EUA, 2004)



Direção: Wolfgang Petersen
Elenco: Brad Pitt, Eric Bana, Orlando Bloom, Diane Kruger, Sean Bean, Brian Cox, Peter O'Toole, Brendan Gleeson
Duração: 164 min.
Site oficial: troymovie.warnerbros.com

 **DRAMA**  **AÇÃO**  **ROMANCE**

Sinopse:
Em 1193 A.C., Paris (Orlando Bloom) é um príncipe que provoca uma guerra da Messência contra Tróia, ao afastar Helena (Diane Kruger) de seu marido, Menelaus (Brendan Gleeson). Tem início então uma sangrenta batalha, que dura por mais de uma década. A esperança do Priam (Peter O'Toole), rei de Tróia, em vencer a guerra está nas mãos de Aquiles (Brad Pitt), o maior herói da Grécia, e seu filho Hector (Eric Bana).

O que achou desta recomendação?
Baseado nas informações acima, que nota você acha que daria para este filme?



Avaliar esta indicação

Fechar

Concluído Internet

